UNIVERSITE D'ORLEANS

ÉCOLE DOCTORALE SCIENCES DE L'HOMME ET DE LA SOCIÉTÉ
Laboratoire d'Économie d'Orléans/ Laboratoire d'Économie et de Développement de Sfax

THÈSE EN COTUTELLE INTERNATIONALE

Présentée par :
RABIE LOUKIL
soutenue le : 17/06/2026

pour obtenir le grade de : **Docteur de l'Université d'Orléans et de l'Université de Sfax**
Discipline : **Sciences Économiques**

From Connectedness to Prediction: Machine-Learning Perspectives on the Crypto-Energy-Environment Nexus

THÈSE dirigée par :

M. Amine LAHIANI	Maître de Conférences HDR, Université d'Orléans
M. Foued Badr GABSI	Professeur, FSEGS, Université de Sfax

RAPPORTEURS :

M. Dimitrios ASTERIOU	Professeur, Oxford Brookes Business School
M. Mohamed Safouane BEN AISSA	Professeur, FSEGT, Tunis El Manar University

---

JURY :

M. Christophe RAULT	Professeur, Université d'Orléans (Président du Jury)
M. Dimitrios ASTERIOU	Professeur, Oxford Brookes Business School (Rapporteur)
M. Mohamed Safouane BEN AISSA	Professeur, FSEGT, Université de Tunis El Manar (Rapporteur)
M. Mihai MUTASCU	Professeur, West University of Timisoara, Romania (Examinateur)
Mme Kristen RALF	Professeure, ESCE International Business School (Examinatrice)
Mme Nada MSELMI	Maître de Conférences, Université Paris Saclay (Examinatrice)
M. Amine LAHIANI	Maître de Conférences HDR, Université d'Orléans (Directeur de thèse)
M. Foued Badr GABSI	Professeur, FSEGS, Université de Sfax (Directeur de thèse)

RABIE LOUKIL

De la connectivité à la prévision : une approche par apprentissage automatique du nexus crypto-énergie-environnement

Résumé

Cette thèse analyse le nexus crypto-énergie-macrofinance-environnement comme un système intégré reliant actifs numériques, marchés de l'énergie, conditions macrofinancières et contraintes environnementales. Elle montre d'abord, à partir d'un cadre ondelettes-TVP-VAR appliqué à des données américaines de janvier 2014 à juin 2025, que la connectivité entre cryptomonnaies, énergie, variables macrofinancières et actifs environnementaux est durablement élevée : l'indice de connectivité total se situe généralement entre 70 % et 90 % et atteint environ 93 % aux horizons longs. Les résultats mettent aussi en évidence plusieurs régimes successifs de contagion : une domination énergie-crypto avant 2020, une synchronisation financière pendant la crise du COVID-19, puis une configuration macro-énergie-environnement évoluant progressivement vers un régime de durabilité numérique à l'horizon 2025. À court terme, la contagion est surtout spéculative et entrainée par l'énergie ; à long terme, elle est davantage ancrée dans l'inflation, la production industrielle et les prix de l'électricité. La thèse affine ensuite la mesure des transmissions des chocs grâce au cadre de connectivité en réseau par classes, qui distingue les comouvements intra-classes de la contagion inter-classes. Sur des données journalières allant de janvier 2022 à octobre 2024, elle montre que les mesures standards de connectivité surestiment les transmissions de chocs totales d'environ 8 à 12 %, que la classe énergie constitue un transmetteur net persistant avec un pic proche de +0,96, et qu'environ 60 % de la variance des rendements environnementaux s'explique par des chocs énergétiques. Les simulations de Monte Carlo confirment qu'il s'agit d'un biais d'identification structurel. Enfin, la thèse transforme ces mesures de connectivité signal prédictif : les matrices de transmissions des chocs par classes sont intégrées dans une architecture d'apprentissage sur graphe pour prévoir les rendements du Bitcoin. Les gains prédictifs augmentent avec l'horizon de prévision : faibles à court terme, modérés à moyen terme et substantiels à long terme. La dépendance intra-classes domine à moyen terme, tandis que les transmissions des chocs inter-classes dominent long terme. Sur le plan économique, ces améliorations génèrent des gains significatifs dans des stratégies de trading avec ciblage de volatilité.

Mots clés : Cryptomonnaies ; Marchés de l'énergie ; Finance environnementale ; Connectivité dynamique ; Transmissions des chocs multi-échelles ; Décomposition en ondelettes ; TVP-VAR ; Connectivité en réseau par classes ; Réseaux de neurones sur graphes ; Prévision des rendements du Bitcoin.

From Connectedness to Prediction: Machine-Learning Perspectives on the Crypto-Energy-Environment Nexus

Abstract

This thesis examines the cryp to-energy-macrofinance-environment nexus as an integrated system linking digital assets, energy markets, macrofinancial conditions, an d environmental constraints. It starts from the premise that cryptocurrencies cannot be treated as isolated speculative assets, since their valuation, volatility, and systemic role are increasingly shaped by energy co sts, financial uncertainty, and sustainability-related forces. The thesis is structured progressively: from conceptual synthesis to empirical mapping, and from structural identification to forecasting. The empirical analysis first documents strong and persistent multiscale connecte dness among cryptocurrencies, energy variables, macrofinanc ial indicators, and environmental assets. Using a wavelet TVP-VAR framew rk on U.S. data from January 2014 to June 2025, it shows that the Total Connectedness Index generally ranges between 70% and 90%, pealing at 93% over long horizons. It also identifies successive contagion regimes: energy-crypto dominance before 2020, financial synchroniz tion during COVID-19, and a macro-energy-environment configuration that gradually evolves into a digital-sustainability regime by 2025. Short-run contagion is mainly speculative and energy-driver, whereas long-run connectedness becomes increasingly anchored in infla on, industrial production, and electricity prices. The thesis then refines spillover measurement through the Clustered Network Connectedne ss framework, which separates within-cluster comovement fr om between-cluster contagion. Using daily data from January 2022 to Octobe r 2024, it shows that standard generalized connectedness measures overestimate total spillovers by about 8-12%. The energy cluster appear as a persistent net transmitter, with net connectedness peaking at around +0.96, while cryptocurrencies shift from net receivers to net transm itters after the FTX episode. Strong energy-to-environmen t transmission is also documented, with about 60% of environmental return variance explained by energy shocks. Monte Carlo results confirm that this gap reflects a structural identification bias rather than a finite-san ple artifact. Finally, the thesis turns connectedness into a pr edictive signal. Clustered Forecasting Error Variance Decomposition spillov er matrices are interpreted as dynamic directed graphs and e mbedded in a temporal graph-learning architecture combining graph attention and gated recurrent dynamics to forecast Bitcoin returns. Th e results show that predictive gains are horizon-dependent: limited at the shor est horizon, more pronounced at intermediate horizons, and most pronounced at long horizons. Within-cluster dependence matters mos at medium horizons, whereas cross-cluster spillovers domin ate at long horizons. These gains further translate into economically signific ant gains in volatility-targeted trading strategies. Overall, the thesis shows that the crypto-energy-macro-environment nexus is a structure d transmission system whose architecture matters for interpr etation, systemic-risk measurement, and forecasting.

Keywords: Cryptocurrencies ; Energy markets; Environmental finance; Dynamic connectedness; M ultiscale spillovers; Wavelet decomposition; TVP-VAR; Cl ustered Network Connectedness; Graph neural networks; Bitcoin return foreca sting.

L'Université d'Orléans n'entend donner aucune approbation ou improbation aux opinions exprimées dans cette thèse. Ces opinions doivent être considérées comme propres à l'auteur.

Acknowledgements

First and foremost, I would like to express my deepest gratitude to God for granting me the strength, perseverance, and health to complete this thesis. I am profoundly thankful for His guidance, mercy, and blessings throughout this journey.

I would like to express my sincere gratitude to the members of the jury for agreeing to evaluate this thesis and for the time and attention they have devoted to its reading. Their insightful comments and suggestions are highly appreciated.

I am especially indebted to Professor Amine LAHIANI for his invaluable guidance, constant support, and unwavering involvement throughout this PhD. His day-to-day supervision, intellectual rigor, and commitment to pushing me toward higher academic standards have been instrumental in shaping both this thesis and my development as a researcher.

I am also deeply grateful to Professor Foued Badr GABSI for giving me the opportunity to pursue my academic path and continue my studies in France, which has been instrumental in strengthening my international academic trajectory. His valuable advice, trust, and guidance have played a decisive role in my path and have helped me develop a deeper and more structured way of thinking as an economist.

My heartfelt thanks go to my parents, whose unconditional love, sacrifices, and unwavering belief in me have been the foundation of all my achievements. I am equally grateful to my two sisters for their kindness, patience, and moral support throughout every stage of this work. I also wish to extend my sincere gratitude to all the members of my family, whose encouragement, prayers, and affection have sustained me in countless ways. Their presence has been a constant source of strength and comfort.

Finally, I would like to express my special thanks to my Girlfriend for standing by me throughout this journey, for her unwavering support, and for the time and understanding she generously gave me.

Without all of them, this thesis would not have been possible.

Abstract

This thesis examines the crypto-energy-macrofinance-environment nexus as an integrated system linking digital assets, energy markets, macrofinancial conditions, and environmental constraints. It starts from the premise that cryptocurrencies cannot be treated as isolated speculative assets, since their valuation, volatility, and systemic role are increasingly shaped by energy costs, financial uncertainty, and sustainability-related forces. The thesis is structured progressively: from conceptual synthesis to empirical mapping, and from structural identification to forecasting. The empirical analysis first documents strong and persistent multiscale connectedness among cryptocurrencies, energy variables, macrofinancial indicators, and environmental assets. Using a wavelet TVP-VAR framework on U.S. data from January 2014 to June 2025, it shows that the Total Connectedness Index generally ranges between 70% and 90%, peaking at 93% over long horizons. It also identifies successive contagion regimes: energy-crypto dominance before 2020, financial synchronization during COVID-19, and a macro-energy-environment configuration that gradually evolves into a digital-sustainability regime by 2025. Short-run contagion is mainly speculative and energy-driven, whereas long-run connectedness becomes increasingly anchored in inflation, industrial production, and electricity prices. The thesis then refines spillover measurement through the Clustered Network Connectedness framework, which separates within-cluster comovement from between-cluster contagion. Using daily data from January 2022 to October 2024, it shows that standard generalized connectedness measures overestimate total spillovers by about 8-12%. The energy cluster appears as a persistent net transmitter, with net connectedness peaking at around +0.96, while cryptocurrencies shift from net receivers to net transmitters after the FTX episode. Strong energy-to-environment transmission is also documented, with about 60% of environmental return variance explained by energy shocks. Monte Carlo results confirm that this gap reflects a structural identification bias rather than a finite-sample artifact. Finally, the thesis turns connectedness into a predictive signal. Clustered Forecasting Error Variance Decomposition spillover matrices are interpreted as dynamic directed graphs and embedded in a temporal graph-learning architecture combining graph attention and gated recurrent dynamics to forecast Bitcoin returns. The results show that predictive gains are horizon-dependent: limited at the shortest horizon, more pronounced at intermediate horizons, and most pronounced at long horizons. Within-cluster dependence matters most at medium horizons, whereas cross-cluster spillovers dominate at long horizons. These gains further translate into economically significant gains in volatility-targeted trading strategies. Overall, the thesis shows that the crypto-energy-macro-environment nexus is a structured transmission system whose architecture matters for interpretation, systemic-risk measurement, and forecasting.

Keywords: Cryptocurrencies; Energy markets; Environmental finance; Dynamic connectedness; Multiscale spillovers; Wavelet decomposition; TVP-VAR; Clustered Network Connectedness; Graph neural networks; Bitcoin return forecasting.

Résumé

Cette thèse analyse le nexus crypto-énergie-macrofinance-environnement comme un système intégré reliant actifs numériques, marchés de l'énergie, conditions macrofinancières et contraintes environnementales. Elle montre d'abord, à partir d'un cadre ondelettes-TVP-VAR appliqué à des données américaines de janvier 2014 à juin 2025, que la connectivité entre cryptomonnaies, énergie, variables macrofinancières et actifs environnementaux est durablement élevée : l'indice de connectivité total se situe généralement entre 70 % et 90 % et atteint environ 93 % aux horizons longs. Les résultats mettent aussi en évidence plusieurs régimes successifs de contagion : une domination énergie-crypto avant 2020, une synchronisation financière pendant la crise du COVID-19, puis une configuration macro-énergie-environnement évoluant progressivement vers un régime de durabilité numérique à l'horizon 2025. À court terme, la contagion est surtout spéculative et entrainée par l'énergie ; à long terme, elle est davantage ancrée dans l'inflation, la production industrielle et les prix de l'électricité. La thèse affine ensuite la mesure des transmissions des chocs grâce au cadre de connectivité en réseau par classes, qui distingue les comouvements intra-classes de la contagion inter-classes. Sur des données journalières allant de janvier 2022 à octobre 2024, elle montre que les mesures standards de connectivité surestiment les transmissions de chocs totales d'environ 8 à 12 %, que la classe énergie constitue un transmetteur net persistant avec un pic proche de +0,96, et qu'environ 60 % de la variance des rendements environnementaux s'explique par des chocs énergétiques. Les simulations de Monte Carlo confirment qu'il s'agit d'un biais d'identification structurel. Enfin, la thèse transforme ces mesures de connectivité signal prédictif : les matrices de transmissions des chocs par classes sont intégrées dans une architecture d'apprentissage sur graphe pour prévoir les rendements du Bitcoin. Les gains prédictifs augmentent avec l'horizon de prévision : faibles à court terme, modérés à moyen terme et substantiels à long terme. La dépendance intra-classes domine à moyen terme, tandis que les transmissions des chocs inter-classes dominent long terme. Sur le plan économique, ces améliorations génèrent des gains significatifs dans des stratégies de trading avec ciblage de volatilité.

Mots clés : Cryptomonnaies ; Marchés de l'énergie ; Finance environnementale ; Connectivité dynamique ; Transmissions des chocs multi-échelles ; Décomposition en ondelettes ; TVP-VAR ; Connectivité en réseau par classes ; Réseaux de neurones sur graphes ; Prévision des rendements du Bitcoin.

RÉSUMÉ EN FRANÇAIS

de la thèse de doctorat

From Connectedness to Prediction: Machine-Learning Perspectives on the Crypto-Energy-Environment Nexus

Rabie LOUKIL

Université d'Orléans - Université de Sfax

Laboratoire d'Économie d'Orléans

Discipline : Sciences économiques

Soutenance : 17 juin 2026

1. Introduction générale

Au cours de la dernière décennie, le système financier mondial a connu des transformations dont l'interprétation dépasse de plus en plus les cadres traditionnels qui distinguent la finance numérique, les marchés des matières premières et l'économie de l'environnement. La numérisation de la monnaie et des systèmes de paiement s'est accélérée, les marchés de l'énergie sont devenus plus instables et davantage exposés aux tensions géopolitiques, tandis que les enjeux liés au climat et à la durabilité occupent désormais une place centrale dans la réglementation financière, les stratégies d'investissement et la surveillance macroéconomique. Ces évolutions ne constituent pas de simples tendances parallèles. Elles interagissent de manière croissante, donnant naissance à de nouveaux canaux d'interdépendance entre les actifs, les secteurs et les institutions. Dans ce contexte, l'essor des cryptomonnaies ne s'est pas produit de manière isolée. Il s'est inscrit dans une période marquée par l'intensification des préoccupations relatives à la sécurité énergétique, à l'intensité carbone, à la volatilité des prix des matières premières et à l'architecture de l'intermédiation financière moderne, autant de dimensions devenues étroitement imbriquées (BIS, 2024 ; IMF, 2024 ; IEA, 2024 ; World Bank, 2024). Les cryptomonnaies ont progressivement évolué d'une innovation technologique marginale vers une composante désormais visible des marchés financiers mondiaux. Elles sont aujourd'hui négociées en continu, intégrées aux stratégies spéculatives et de couverture, et de plus en plus analysées à travers les mêmes prismes que les actifs financiers traditionnels, notamment sous l'angle de la volatilité, de la diversification, des effets de contagion (spillovers) et du risque systémique. Elles conservent néanmoins une caractéristique économique singulière : contrairement à de nombreux actifs financiers conventionnels, leur valorisation et leur fonctionnement reposent en partie sur des infrastructures physiques, en particulier dans les systèmes fondés sur le mécanisme de preuve de travail (Proof-of-Work). Dans ces systèmes, la validation des transactions nécessite une activité de minage intensivement consommatrice de puissance de calcul, impliquant une consommation importante d'électricité et établissant ainsi un lien direct entre les marchés des actifs numériques, les prix de l'énergie, les systèmes électriques et l'intensité carbone de la production d'électricité. Cette double nature, à la fois financière et infrastructurelle, fait des

cryptomonnaies un objet d'étude particulièrement pertinent pour analyser les interactions entre l'innovation numérique, les dynamiques macrofinancières, les marchés de l'énergie et les enjeux environnementaux (Corbet et al., 2019 ; de Vries, 2018 ; Krause et Tolaymat, 2018 ; Stoll et al., 2019). Cette thèse repose sur l'idée que les cryptomonnaies ne peuvent plus être considérées comme de simples instruments numériques isolés, dont le comportement pourrait être pleinement expliqué à travers une analyse limitée aux seuls marchés des cryptoactifs. Leur valorisation, leur volatilité ainsi que leur importance croissante au sein du système financier sont désormais influencées par des facteurs extérieurs à l'écosystème des cryptomonnaies lui-même : le coût et la disponibilité de l'énergie, l'instabilité des marchés pétroliers et électriques, la transmission des chocs inflationnistes et monétaires, ainsi que l'importance grandissante des contraintes liées à la durabilité et des flux d'investissement responsables. De ces interactions émerge un nexus plus large associant cryptomonnaies, énergie, macrofinance et environnement, au sein duquel les chocs peuvent se propager par des canaux multiples et évolutifs. L'hypothèse centrale de cette thèse est que ce nexus ne constitue ni une relation fortuite ni un phénomène transitoire. Il représente au contraire un système structuré d'interdépendances qui mérite d'être conceptualisé, mesuré, interprété et, à terme, exploité à des fins prédictives. La littérature académique fournit un socle solide pour examiner cette problématique, mais elle demeure fragmentée d'une manière qui limite une compréhension globale du phénomène. Un premier courant de recherche analyse les cryptomonnaies en tant qu'actifs financiers et s'intéresse à leurs propriétés de rendement, à leur intérêt dans la construction de portefeuilles ainsi qu'à leurs interactions avec les marchés financiers traditionnels. Un deuxième courant met l'accent sur l'empreinte environnementale du minage des cryptomonnaies et sur l'intensité énergétique des mécanismes fondés sur la preuve de travail (Proof-of-Work). Un troisième courant étudie les effets de transmission, de contagion et de connectivité entre les marchés financiers et les marchés des matières premières au moyen des décompositions de la variance de l'erreur de prévision (Forecast Error Variance Decomposition, FEVD) et d'approches apparentées fondées sur l'analyse des réseaux. Chacun de ces courants a apporté des contributions importantes. Toutefois, ils ne convergent pas vers un cadre unifié permettant d'expliquer de manière cohérente la

coévolution des cryptomonnaies, des variables énergétiques, des indicateurs macrofinanciers et des actifs environnementaux au sein d'un même système. En conséquence, la littérature apporte souvent des réponses partielles à des questions qui sont, dans la réalité, profondément interdépendantes (Corbet et al., 2019 ; de Vries, 2018 ; Krause et Tolaymat, 2018 ; Diebold et Yilmaz, 2012, 2014). Une première limite réside dans le champ empirique de nombreux travaux existants. Une part importante de la littérature se concentre sur des relations bilatérales, telles que le lien entre le Bitcoin et le pétrole, entre les cryptomonnaies et les énergies renouvelables, ou encore entre les actifs numériques et les mesures d'incertitude. Bien que ces études apportent des enseignements utiles, elles ne sont pas conçues pour appréhender l'architecture globale des mécanismes de transmission au sein d'un système fortement interconnecté. Lorsque l'analyse empirique se limite à des relations par paires ou à un ensemble très restreint de variables, il devient difficile d'évaluer la manière dont les chocs se propagent simultanément entre les différentes composantes du nexus, ainsi que l'évolution du rôle de chaque marché lorsque l'ensemble du système est pris en considération. Une deuxième limite concerne l'interprétation des mesures de connectivité (connectedness). La littérature sur la connectivité a démontré de manière convaincante que les décompositions de la variance de l'erreur de prévision issues des modèles VAR constitue un cadre à la fois souple et pertinent pour quantifier les effets de transmission directionnels entre les marchés. Toutefois, les mesures classiques de connectivité tendent à amalgamer des formes de dépendance qui sont conceptuellement distinctes. Plus précisément, elles ne permettent pas toujours de distinguer les co-mouvements observés entre des variables appartenant à un même groupe économique des véritables transmissions entre groupes économiquement distincts. Cette distinction est pourtant essentielle, tant du point de vue économique qu'économétrique. Les co-mouvements intra-groupes traduisent principalement des phénomènes d'interdépendance, d'exposition commune ou de fondamentaux partagés, tandis que les transmissions inter-groupes reflètent davantage des mécanismes de contagion, de propagation systémique et de diffusion des chocs entre différentes composantes d'un système qui ne peuvent être considérées comme homogènes. L'approche des fonctions de réponse impulsionnelle généralisées introduite par Koop, Pesaran et Potter

(1996), puis développée par Pesaran et Shin (1998), fournit un cadre invariant à l'ordre des variables pour l'analyse des chocs. Néanmoins, les travaux récents consacrés à la Clustered Network Connectedness montrent que même cette approche peut conduire à une surestimation de la transmission systémique lorsque la structure en groupes (clusters) est ignorée (Koop et al., 1996 ; Pesaran et Shin, 1998 ; Buchwalter et al., 2026).

Une troisième limite concerne le rôle même de la connectivité. Une grande partie de la littérature considère la connectivité comme une finalité descriptive, c'est-à-dire comme un outil permettant d'identifier les variables qui transmettent les chocs, celles qui les reçoivent et l'intensité des relations qui les unissent à un instant donné. Cette fonction descriptive est essentielle, mais elle n'épuise pas nécessairement toute l'information contenue dans le réseau. Si la connectivité résume l'architecture des mécanismes de transmission au sein d'un système dynamique, elle peut également renfermer une information prospective susceptible d'améliorer les performances des modèles de prévision. Cette perspective est d'autant plus pertinente que les méthodes d'apprentissage fondées sur les graphes ont précisément été développées pour exploiter des informations relationnelles structurées. Autrement dit, si les matrices de spillovers traduisent des relations économiquement significatives entre les variables, elles peuvent également servir de matrices d'adjacence dynamiques pour alimenter des modèles prédictifs dépassant les approches conventionnelles des séries temporelles (Veličković et al., 2018 ; Chung et al., 2014). L'objectif de cette thèse est de répondre à ces différentes lacunes au moyen d'une démarche de recherche cumulative qui progresse de la clarification conceptuelle à la caractérisation empirique, de la caractérisation empirique à l'identification structurelle, puis de l'identification structurelle à la prévision. L'ambition n'est pas uniquement de montrer que les cryptomonnaies entretiennent des liens avec les variables énergétiques et environnementales, ni simplement de mettre en évidence l'existence de mécanismes de transmission. Il s'agit avant tout de démontrer que l'architecture du nexus cryptomonnaies–énergie–macrofinance– environnement peut être analysée comme un objet économique cohérent, dont la structure revêt une importance déterminante pour l'interprétation économique, la mesure du risque systémique et les performances prédictives. Plus précisément, cette thèse s'articule autour de quatre questions de recherche

interdépendantes. La première est d’ordre conceptuel : comment définir le nexus cryptomonnaies–énergie–macrofinance–environnement, et par quels mécanismes les actifs numériques, les prix de l’énergie, les conditions macrofinancières et les contraintes environnementales interagissent-ils ? La deuxième porte sur la structure empirique de ce système : quelle est l’intensité des interdépendances qui le caractérisent, comment celles-ci évoluent-elles au cours du temps et dans quelle mesure diffèrent-elles selon les horizons temporels ? La troisième concerne l’identification : est-il possible de décomposer la connectivité observée de manière à distinguer les co-mouvements intra-groupes des véritables mécanismes de transmission entre groupes ? Enfin, la quatrième question porte sur la prévision : une fois la connectivité mesurée et affinée sur le plan structurel, contient-elle une informationprédictive susceptible d'améliorer les prévisions des rendements du Bitcoin et de produire des signaux économiquement pertinents ? Ces quatre questions ne sont pas abordées comme des problématiques indépendantes, mais comme les différentes composantes d’un même programme de recherche. La phase de conceptualisation est indispensable, dans la mesure où l’existence même du nexus ne peut être postulée a priori ; elle doit être justifiée sur des fondements théoriques et économiques. La caractérisation empirique est ensuite nécessaire, car la cohérence conceptuelle ne suffit pas à établir l’importance quantitative des interdépendances. Dès lors que la connectivité apparaît comme un phénomène majeur, une étape d’identification structurelle devient indispensable, puisque l’interprétation économique des spillovers dépend directement de la manière dont ils sont mesurés. Enfin, la prévision constitue l’aboutissement logique de cette démarche : une mesure de connectivité dotée d’une interprétation économique solide est également susceptible de présenter une réelle utilité prédictive. La contribution de cette thèse ne réside donc pas dans un résultat empirique isolé, mais dans l’articulation progressive et cohérente de ces différentes étapes de recherche. Le chapitre 1 constitue le socle conceptuel de la thèse. Il propose une revue de littérature approfondie consacrée au nexus cryptomonnaies–énergie–macrofinance–environnement et montre pourquoi ces différents domaines doivent être étudiés conjointement plutôt que séparément. Le chapitre retrace l’évolution des systèmes traditionnels de paiement numérique vers les registres distribués et les cryptomonnaies, en mettant en évidence les innovations institutionnelles et technologiques

introduites par les systèmes fondés sur la blockchain. Il s'intéresse ensuite au mécanisme de minage fondé sur la preuve de travail (Proof-of-Work) et montre que la validation des transactions en cryptomonnaies ne constitue pas un processus purement virtuel, mais qu'elle repose sur des infrastructures physiques, la demande en électricité, l'efficacité des équipements informatiques et les caractéristiques locales des systèmes énergétiques. Le chapitre examine également les relations entre le pétrole brut et l'électricité, entre l'électricité et les cryptomonnaies, ainsi qu'entre le Bitcoin et le pétrole, à partir d'une approche méta-analytique, avant d'élargir la réflexion au rôle des énergies renouvelables et à la relation ambiguë entre les actifs numériques et la transition énergétique. À ce titre, ce premier chapitre remplit une fonction qui dépasse largement celle d'une simple revue de littérature. Il établit l'unité conceptuelle de la thèse en démontrant que les cryptomonnaies s'inscrivent dans un système économique et environnemental plus vaste, dont les interactions internes présentent une véritable cohérence structurelle. Son rôle est ainsi fondamental plutôt que simplement introductif.

Le chapitre 2 propose une première cartographie empirique à grande échelle du nexus. En s'appuyant sur des données mensuelles relatives aux États-Unis ainsi que sur un cadre méthodologique combinant la décomposition en ondelettes (wavelet decomposition) et un modèle VAR à paramètres variables dans le temps (Time-Varying Parameter VAR), il analyse les mécanismes de connectivité entre les cryptomonnaies, les marchés de l'énergie, les variables macrofinancières et les indicateurs environnementaux. Les résultats mettent en évidence un niveau élevé et persistant d'intégration systémique. Plus encore, ils montrent que cette connectivité présente une forte dimension multi-échelle. Les spillovers de court terme sont principalement associés aux marchés de l'énergie et aux facteurs financiers, tandis que les mécanismes de transmission de long terme sont davantage liés aux variables macroéconomiques et structurelles, telles que l'inflation, la production industrielle et les prix de l'électricité. Le chapitre met également en évidence une évolution chronologique du leadership systémique. Avant 2020, le système est principalement dominé par les interactions entre les marchés de l'énergie et les cryptomonnaies. Durant la crise de la COVID-19, la synchronisation financière devient prédominante, avant de laisser place, à partir de 2021, à une configuration davantage structurée autour des interactions entre

macrofinance, énergie et environnement, évoluant progressivement vers un régime plus orienté vers les enjeux de durabilité à l'horizon 2025. Ce chapitre établit ainsi l'un des principaux faits stylisés de cette thèse : le nexus se caractérise non seulement par un niveau élevé d'interconnexion, mais également par une connectivité dynamique, dépendante des horizons temporels et sensible aux changements de régime. Le chapitre 3 approfondit l'analyse en s'intéressant au problème d'identification laissé en suspens par les mesures traditionnelles de connectivité. Les indicateurs classiques fondés sur la décomposition de la variance de l'erreur de prévision (Forecast Error Variance Decomposition, FEVD) permettent de mesurer les mécanismes de transmission, mais ils ne distinguent pas clairement si l'interdépendance observée résulte de co-mouvements au sein d'un même groupe de variables ou de véritables phénomènes de contagion entre groupes économiquement distincts. Afin de répondre à cette limite, cette thèse mobilise le cadre de la Clustered Network Connectedness développé par Buchwalter, Diebold et Yilmaz (2026), appliqué à un système composé de quatre groupes de variables : les cryptomonnaies, les marchés de l'énergie, les indicateurs macrofinanciers et les actifs environnementaux. Les résultats montrent que les mesures généralisées de connectivité tendent à surestimer les spillovers globaux en agrégeant les dépendances intra-groupes aux mécanismes de transmission à l'échelle du système. Une fois la structure en clusters prise en compte, l'architecture du réseau devient sensiblement plus interprétable. Le groupe des marchés de l'énergie apparaît comme un transmetteur net persistant lors des périodes de tension ; les cryptomonnaies évoluent progressivement d'une position de récepteurs nets vers celle de transmetteurs nets au cours des périodes les plus récentes ; enfin, le groupe des actifs environnementaux demeure fortement exposé aux chocs provenant des marchés de l'énergie. Les simulations de Monte Carlo confirment par ailleurs que l'écart observé entre les mesures de connectivité généralisée et celles fondées sur les clusters résulte d'un véritable biais d'identification structurelle et non d'un simple artefact lié aux propriétés des échantillons finis. Ce chapitre constitue ainsi le cœur méthodologique de la thèse en démontrant qu'une mesure pertinente de la connectivité nécessite une représentation économiquement fondée de la structure du réseau. Le chapitre 4 prolonge cette démarche en passant de l'interprétation à la prévision. En s'appuyant sur le cadre des matrices FEVD

clusterisées développé dans le chapitre précédent, il examine si des réseaux de spillovers identifiés sur des fondements économiques permettent d'améliorer les performances des prévisions hors échantillon des rendements du Bitcoin. À cette fin, les matrices FEVD clusterisées sont transformées en graphes orientés pondérés variant dans le temps, puis intégrées dans une architecture d'apprentissage sur graphes temporels combinant des mécanismes d'attention sur graphes (Graph Attention Networks, GAT) et des unités récurrentes à portes (Gated Recurrent Units, GRU). Les résultats montrent que le contenu prédictif de la connectivité dépend fortement de l'horizon de prévision considéré. Aux horizons les plus courts, les gains prédictifs demeurent limités en raison de la prédominance du bruit de haute fréquence dans la dynamique des rendements. Aux horizons intermédiaires, les améliorations deviennent plus marquées et les dépendances intra-groupes apparaissent particulièrement informatives. En revanche, aux horizons les plus longs, ce sont les spillovers inter-groupes qui dominent, le graphe inter-clusters offrant les meilleures performances, tant sur le plan statistique qu'économique. Dans l'exercice de stratégie de trading présenté, la spécification inter-clusters à horizon annuel obtient le ratio de Sharpe le plus élevé parmi l'ensemble des modèles comparés, tandis que les résultats observés aux horizons plus courts demeurent plus limités et relativement contrastés. Ce dernier chapitre empirique revêt une importance particulière puisqu'il démontre que la connectivité ne constitue pas uniquement un outil descriptif. Lorsqu'elle est correctement identifiée sur le plan économique, elle peut être transformée en un signal prédictif et intégrée dans une architecture d'apprentissage automatique capable d'améliorer de manière économiquement significative les performances de stratégies d'investissement fondées sur un ciblage de la volatilité (volatility-targeted trading strategies). Pris dans leur ensemble, les différents chapitres de cette thèse apportent une contribution cumulative et intégrée à la littérature. Premièrement, ils proposent un cadre conceptuel unifié pour l'analyse du nexus cryptomonnaies–énergie–macrofinance–environnement. Deuxièmement, ils fournissent de nouveaux résultats empiriques mettant en évidence la nature dynamique et multi-échelle des mécanismes de connectivité au sein de ce système. Troisièmement, ils améliorent la mesure de la connectivité en introduisant une logique d'identification fondée sur une structure en clusters, permettant de distinguer les co- mouvements intra-groupes des

véritables phénomènes de contagion inter-groupes. Enfin, ils montrent que la connectivité, lorsqu'elle est interprétée sur des fondements structurels, peut améliorer les prévisions des rendements du Bitcoin lorsqu'elle est intégrée dans un cadre d'apprentissage sur graphes. La contribution de cette thèse réside ainsi autant dans l'enchaînement cohérent de ces différentes étapes que dans les résultats propres à chacun des chapitres. Ces résultats s'adressent à plusieurs catégories d'acteurs. Pour les chercheurs, ils suggèrent que l'analyse des mécanismes de transmission devrait dépasser les approches fondées sur des relations bilatérales et accorder une attention plus importante à l'architecture économique qui sous-tend les canaux de propagation des chocs. Pour les décideurs publics et les autorités de régulation, ils indiquent que les cryptomonnaies ne doivent plus être appréhendées uniquement comme des actifs spéculatifs, mais également comme des composantes d'un système plus large, étroitement lié à la sécurité énergétique, aux actifs associés aux risques climatiques et aux vulnérabilités macrofinancières. Le rôle central des marchés de l'énergie en tant que principaux transmetteurs de chocs, ainsi que la forte exposition des actifs environnementaux aux perturbations énergétiques, présentent notamment des implications importantes pour la surveillance de la stabilité financière et l'évaluation des risques climatiques. Pour les investisseurs, cette thèse montre que les mesures de connectivité peuvent être converties en signaux opérationnels utilisables dans les processus de décision. Elle met également en évidence que la distinction entre les mécanismes de transmission intra-groupes et inter-groupes ne constitue pas seulement un raffinement méthodologique, mais représente également une source potentiellement précieuse d'information prédictive pour la gestion des risques et la construction de portefeuilles. Le reste de cette dissertation est organisé de la manière suivante. Le chapitre 1 établit les fondements conceptuels et présente la revue de littérature consacrée au nexus cryptomonnaies– énergie– macrofinance–environnement. Le chapitre 2 propose une cartographie dynamique et multi-échelle des mécanismes de transmission entre les cryptomonnaies, les marchés de l'énergie, les variables macrofinancières et les indicateurs environnementaux. Le chapitre 3 introduit le cadre de la Clustered Network Connectedness afin d'affiner l'interprétation structurelle des mécanismes de transmission. Le chapitre 4 exploite cette structure de réseau identifiée pour construire des signaux de prévision au moyen d'une architecture d'apprentissage sur

graphes temporels, puis en évalue les performances tant sur le plan statistique qu'économique. Enfin, la conclusion générale synthétise les principaux résultats de la thèse, discute leurs implications théoriques et pratiques, et propose plusieurs pistes de recherche pour les travaux futurs.

2. Chapitre 1 - Le nexus crypto-énergie-macrofinance-environnement : fondements conceptuels

2.1. Objet du chapitre et logique économique du nexus

Le premier chapitre construit le cadre conceptuel qui soutient l'ensemble de la thèse. Son point de départ est que les cryptomonnaies ne peuvent plus être étudiées comme des actifs purement numériques, indépendants du reste de l'économie. Leur fonctionnement dépend d'une infrastructure informatique et, pour les systèmes reposant sur la preuve de travail, d'une consommation électrique directement liée à l'activité de minage. En parallèle, leur financiarisation croissante les expose aux mêmes déterminants que d'autres actifs risqués : conditions de liquidité, appétit pour le risque, volatilité boursière, incertitude économique et chocs macroéconomiques. Le chapitre rassemble ainsi trois champs qui sont souvent traités séparément - finance numérique, économie de l'énergie et économie de l'environnement - afin de montrer qu'ils forment un système d'interdépendances. Cette construction conceptuelle justifie ensuite l'architecture empirique des chapitres suivants : si les mécanismes sont multiples et évolutifs, leur analyse exige un cadre capable de suivre simultanément les relations entre cryptoactifs, énergie, variables macrofinancières et indicateurs environnementaux. La définition retenue dans le manuscrit considère donc le nexus crypto-énergie-macrofinance-environnement comme un système dynamique de marchés interdépendants dans lequel les chocs se propagent par des canaux de transmission variables dans le temps.

Le manuscrit insiste en particulier sur le fait que ces interdépendances opèrent par plusieurs couches complémentaires. La couche technologique relie le mécanisme de consensus aux besoins de calcul et d'électricité ; la couche énergétique transmet les variations de coûts du pétrole, du gaz et de l'électricité ; la couche financière fait intervenir la liquidité, l'incertitude et le comportement des investisseurs ; enfin, la couche

environnementale traduit ces dynamiques en émissions, contraintes climatiques et valorisation d'actifs durables. L'intérêt du nexus est précisément de considérer simultanément ces mécanismes plutôt que de les isoler.

2.2. De la monnaie numérique aux registres distribués

Le chapitre rappelle d'abord que les paiements numériques traditionnels reposent sur une architecture centralisée dans laquelle les banques, processeurs de paiement et infrastructures de compensation tiennent des registres distincts et coordonnent le règlement final. Les registres distribués proposent une autre organisation : une base de données est répliquée entre plusieurs nœuds et les mises à jour sont validées collectivement au moyen d'un protocole de consensus. La blockchain constitue une forme particulière de registre distribué où les transactions sont regroupées en blocs liés cryptographiquement. Cette architecture permet l'existence d'actifs numériques dont l'émission et la validation sont gouvernées par des règles de protocole plutôt que par une autorité centrale. Dans le cas du Bitcoin, l'innovation résulte de la combinaison d'une règle d'offre, d'un réseau pair-à-pair et d'un mécanisme de consensus décentralisé. Le point essentiel pour la thèse est que cette décentralisation n'élimine pas les contraintes économiques : elle les déplace. La sécurité du réseau dépend d'incitations, de coûts d'équipement, de prix de l'électricité et de conditions de marché. La technologie doit donc être analysée avec les outils de l'économie des coûts, de l'énergie et de la finance, et non uniquement comme une innovation informatique.

Cette comparaison permet aussi de clarifier la nature économique de l'innovation blockchain. Le registre distribué réduit le rôle d'un opérateur central unique, mais il ne supprime ni les coûts de validation ni les problèmes d'incitation. La confiance institutionnelle est en partie remplacée par un protocole, une architecture de réseau et des mécanismes de consensus. Pour le Bitcoin, la sécurité dépend ainsi de ressources réelles, de capital informatique et d'énergie. La thèse mobilise cette observation pour relier directement l'économie monétaire numérique à l'économie industrielle du minage et, au-delà, aux marchés énergétiques.

2.3. Preuve de travail, minage et demande d’électricité

La preuve de travail constitue le premier canal matériel reliant directement les cryptoactifs au système énergétique. Les mineurs mobilisent de la puissance de calcul pour résoudre des problèmes cryptographiques ; le premier à valider un bloc reçoit la récompense prévue par le protocole ainsi que les frais associés. Ce mécanisme assure la sécurité du réseau, régule la création monétaire et répartit les revenus de validation, mais il implique une dépense énergétique importante. Le chapitre retrace l’évolution des équipements - processeurs généralistes, cartes graphiques, FPGA puis circuits ASIC - et souligne un résultat classique de l’économie du minage : l’amélioration de l’efficacité énergétique des machines ne garantit pas une baisse de la consommation agrégée. Lorsque la rentabilité et la difficulté de minage augmentent, les gains d’efficacité peuvent être absorbés par une augmentation de la puissance totale engagée sur le réseau. L’électricité devient alors un coût d’exploitation central et un déterminant de localisation. Les mineurs recherchent des zones où le prix de l’énergie, la disponibilité du réseau, la réglementation et les conditions climatiques réduisent les coûts. Cela crée une transmission potentielle des chocs énergétiques vers l’activité de minage et, indirectement, vers l’écosystème crypto.

Le chapitre rappelle que la preuve de travail remplit simultanément trois fonctions : elle sécurise le registre contre la double dépense, règle le rythme de création des nouvelles unités et répartit les revenus de validation entre les mineurs selon leur puissance de calcul. Cette architecture explique pourquoi une amélioration de l’efficacité des machines ne conduit pas nécessairement à une baisse de la consommation totale : l’augmentation de la rentabilité, du taux de hachage et de la difficulté peut inciter le secteur à déployer davantage de capacités, de sorte que l’effet d’échelle compense une partie des gains techniques.

2.4. Microéconomie du minage et canal des coûts

L’analyse microéconomique présentée dans le chapitre insiste sur l’arbitrage entre revenus anticipés et coûts variables. Les revenus dépendent du prix de l’actif, de la récompense de bloc, des frais de transaction et de la part de puissance détenue par le mineur ; les coûts dépendent principalement de l’électricité, de l’efficacité du matériel, du

refroidissement, de l'immobilier et du coût du capital. Cette structure implique qu'un choc sur le prix de l'électricité modifie le seuil de rentabilité des installations, provoque des entrées ou sorties de capacités et peut influencer la concentration géographique du minage. Les interactions énergie-crypto ne sont donc pas nécessairement contemporaines : elles peuvent passer par des ajustements de capacité et des décisions d'investissement. Le chapitre souligne également que la localisation du minage rend l'intensité carbone difficile à mesurer. Deux installations consommant la même quantité d'électricité peuvent avoir des empreintes environnementales très différentes selon le mix électrique local. L'effet environnemental dépend donc du volume d'électricité mais aussi de sa source, de la saison, du réseau utilisé et de la disponibilité de capacités renouvelables supplémentaires. Cette distinction prépare l'analyse ultérieure des relations entre énergie, émissions et actifs liés à la durabilité.

Le manuscrit distingue également trois composantes énergétiques : l'énergie incorporée dans la fabrication des équipements, l'électricité consommée en continu par les machines et l'énergie nécessaire au refroidissement. Cette décomposition enrichit l'analyse du coût marginal du minage, car une même hausse du prix de l'électricité peut avoir des effets différents selon l'efficacité du parc installé, le climat local et les besoins de refroidissement. Elle explique aussi la forte mobilité géographique des mineurs, attirés par des prix bas et stables, une infrastructure fiable, un climat favorable et un environnement réglementaire suffisamment prévisible.

2.5. Articulation pétrole-gaz-électricité

Le chapitre montre ensuite que le prix de l'électricité n'est pas isolé des autres marchés de l'énergie. Les interactions avec le pétrole brut et surtout le gaz naturel dépendent du mix de production, des mécanismes de tarification et de la structure du marché électrique. Le pétrole peut affecter directement certains coûts de production et, plus largement, les anticipations d'inflation et les conditions macroéconomiques. Le gaz naturel constitue un canal particulièrement important dans les systèmes où les centrales à gaz participent à la fixation du prix marginal de l'électricité. Les chocs géopolitiques, les contraintes d'offre, la demande saisonnière et la disponibilité des infrastructures peuvent ainsi se transmettre du pétrole et du gaz vers les prix électriques. Pour la thèse, cette articulation est essentielle : si

le coût électrique influence le minage, alors les chocs énergétiques plus larges peuvent se diffuser vers les marchés crypto par une chaîne de coûts indirecte. Cette logique explique pourquoi les analyses empiriques ne doivent pas se limiter à une relation bivariée Bitcoin-électricité. Le système doit inclure plusieurs variables énergétiques et macrofinancières afin d'identifier la source et la direction des transmissions.

La thèse souligne que le canal pétrole-électricité est fortement hétérogène. Il peut être direct dans les systèmes où les produits pétroliers restent utilisés pour produire de l'électricité, mais il est souvent indirect dans les économies avancées. Le mécanisme passe alors par le gaz naturel, notamment lorsque des contrats gaziers restent indexés sur le pétrole et que les centrales à gaz déterminent le prix marginal de l'électricité. L'intensité de la transmission dépend donc du mix de production, du poids du gaz, de l'indexation contractuelle, du degré de concurrence et des règles de tarification de détail.

2.6. Relation électricité-cryptomonnaies et ambiguïté causale

La relation entre électricité et cryptomonnaies présente une causalité potentiellement bidirectionnelle. D'un côté, une hausse du prix de l'électricité réduit la marge des mineurs et peut modifier la puissance de calcul déployée, les choix de localisation et la composition technologique du secteur. De l'autre, une concentration suffisamment importante d'activités de minage peut accroître localement la demande électrique et influencer les tensions sur le réseau. Le chapitre met toutefois en garde contre une interprétation mécanique : l'importance de ce second canal dépend de la taille du minage relativement au système électrique local, des contrats d'approvisionnement, de la capacité de réponse de la demande et des caractéristiques de la production. L'intensité et le signe de la relation peuvent donc varier selon les pays, les périodes et les régimes de marché. Cette hétérogénéité justifie l'utilisation ultérieure de méthodes dynamiques et multi-échelles. Plutôt que de rechercher un coefficient moyen unique, la thèse s'intéresse à l'évolution temporelle des interdépendances et à leur décomposition selon les horizons.

Cette relation ne doit donc pas être interprétée comme un lien causal unique allant de l'énergie vers le Bitcoin. Une hausse des coûts électriques peut réduire la rentabilité du minage et modifier le taux de hachage, tandis qu'une concentration importante de fermes de minage peut, localement, accroître la demande d'électricité. Le second effet dépend

toutefois de la taille du secteur relativement au réseau, des contrats d'approvisionnement, des possibilités d'effacement et de la capacité de production disponible. Cette ambiguïté motive l'approche dynamique de la thèse : le signe, l'intensité et la direction de la relation peuvent changer selon les régimes.

2.7. Méta-analyse du lien Bitcoin-pétrole

Une partie du chapitre examine de manière plus systématique la littérature consacrée au lien entre Bitcoin et pétrole brut. La méta-analyse agrège les estimations disponibles afin d'évaluer si un effet moyen stable peut être identifié. Le résultat central du manuscrit est prudent : sur les études retenues, l'association moyenne apparaît très faible et l'hétérogénéité entre résultats est extrêmement élevée. L'intervalle de confiance agrégé inclut zéro, ce qui ne permet pas de conclure à une relation structurelle uniforme. Les tests de symétrie du funnel plot ne mettent pas en évidence de biais clair de publication, mais leur puissance est limitée par le faible nombre d'études. Les variables modératrices testées - notamment l'année de publication, la qualité de l'article et l'inclusion de la période COVID - n'expliquent pas de façon convaincante l'hétérogénéité. La conclusion est donc que le lien Bitcoin-pétrole est probablement dépendant du contexte, des régimes de marché et des choix empiriques. Il peut refléter des canaux indirects via les coûts énergétiques et la macrofinance plutôt qu'une relation directe et stable.

La méta-analyse repose sur onze études et retient un modèle à effets aléatoires compte tenu de l'hétérogénéité observée. Le manuscrit rapporte un effet agrégé très faible, égal à 0,0377, avec un intervalle de confiance à 95 % allant de -0,0880 à 0,1643. L'hétérogénéité est en revanche extrêmement élevée, avec un I^2 de 96,55 %. Les tests de symétrie du funnel plot ne rejettent pas l'absence de biais de publication, et les analyses de modération par année, qualité de revue et présence de la période COVID n'expliquent pas la dispersion des résultats. Référence interne : tableau 1.2 et tableau 1.3.

2.8. Cryptomonnaies, énergies renouvelables et durabilité

Le dernier axe du chapitre traite de la tension entre innovation numérique et durabilité. Le manuscrit souligne qu'une part du débat public confond parfois consommation d'électricité et émissions de carbone. Or l'empreinte climatique du minage dépend du mix

énergétique effectivement mobilisé. Une utilisation accrue de sources renouvelables peut réduire l'intensité carbone, mais elle ne suffit pas à qualifier automatiquement le minage de durable. Il faut notamment distinguer l'utilisation d'une production renouvelable réellement additionnelle de la concurrence avec d'autres usages pour une électricité bas carbone rare. Le chapitre présente aussi l'autre versant du rapport blockchain-énergie : au-delà du minage, les registres distribués peuvent être utilisés dans des applications de commerce pair-à-pair de l'électricité, de traçabilité, de certificats ou de coordination de marchés locaux. Ces usages sont conceptuellement distincts de la consommation du Bitcoin mais illustrent la double nature de la technologie : elle peut être source de demande énergétique tout en servant d'infrastructure pour certains dispositifs décentralisés. La conclusion reste donc conditionnelle : l'effet environnemental dépend du mécanisme de consensus, du mix électrique, de la structure des marchés locaux, de l'additionnalité des renouvelables et du cadre réglementaire.

La discussion est volontairement nuancée sur le caractère « vert » du minage. Une électricité renouvelable réduit l'intensité carbone, mais la soutenabilité dépend aussi de son additionnalité : utiliser une production bas carbone déjà rare peut déplacer d'autres usages plutôt que réduire les émissions totales. Le manuscrit rappelle en outre que les estimations sont sensibles aux hypothèses sur la localisation, l'efficacité des ASIC, le refroidissement et la production hors réseau. Il distingue enfin le minage de Bitcoin des applications énergétiques de la blockchain, telles que l'échange pair-à-pair d'électricité, la traçabilité ou certains dispositifs de certificats.

2.9. Apport du chapitre 1 à la thèse

Le chapitre 1 identifie trois limites de la littérature qui structurent directement la suite de la thèse. Premièrement, les études restent souvent fragmentées et bivariées, alors que les mécanismes économiques suggèrent un réseau multivarié. Deuxièmement, les mesures standards de dépendance ou de connectivité ne séparent pas toujours les co-mouvements dus à des facteurs communs des transmissions véritablement intersectorielles. Troisièmement, la connectivité est le plus souvent utilisée comme outil descriptif et rarement comme information prédictive. Ces trois limites correspondent aux trois étapes empiriques suivantes. Le chapitre 2 cartographie le système avec une approche TVP-VAR

et ondelettes ; le chapitre 3 raffine l'identification en séparant comouvement intra-cluster et contagion inter-clusters ; le chapitre 4 teste si cette structure de réseau peut améliorer la prévision des rendements du Bitcoin. La contribution conceptuelle du premier chapitre est ainsi de donner une unité économique à des relations qui pourraient sinon apparaître comme une simple juxtaposition d'exercices.

Le chapitre fournit ainsi plus qu'une revue de littérature : il définit les mécanismes que les chapitres empiriques cherchent ensuite à mesurer. L'hétérogénéité du lien Bitcoin-pétrole justifie l'analyse multi-échelle ; la pluralité des canaux énergie-crypto justifie une approche multivariée ; la difficulté à distinguer facteurs communs et véritables transmissions prépare la méthode CNC ; enfin, l'idée que la connectivité résume une architecture économique ouvre la voie à son utilisation comme signal prédictif. La cohérence de la thèse repose donc sur cette traduction progressive des mécanismes conceptuels en objets économétriques observables.

3. Chapitre 2 - Connectivité dynamique et multi-échelle

3.1. Objectif empirique et choix de l'échelle temporelle

Le chapitre 2 fournit la première cartographie empirique globale du nexus. L'objectif est de mesurer simultanément l'intensité des interdépendances, leur évolution dans le temps et leur variation selon les horizons. Le choix méthodologique combine analyse ondelette et modèle VAR à paramètres variables dans le temps afin de traiter deux dimensions que les approches statiques captent mal : les changements de régime et l'hétérogénéité fréquentielle. Une même relation peut être forte à court terme et faible à long terme, ou inversement ; elle peut également changer de direction pendant une crise. La décomposition multi-échelle permet donc de distinguer la contagion rapide, pertinente pour les investisseurs de court terme, des mécanismes plus persistants liés aux fondamentaux macroéconomiques, à l'énergie et aux politiques publiques.

L'enjeu est d'éviter qu'une mesure moyenne masque deux phénomènes différents : une contagion brève liée aux épisodes de stress et une interdépendance plus lente associée aux fondamentaux. Les ondelettes permettent de décomposer cette dimension fréquentielle, tandis que le TVP-VAR suit l'évolution temporelle des coefficients et des covariances. Le

croisement des deux méthodes répond donc à une double question : à quel horizon les variables sont-elles liées, et comment cette liaison évolue-t-elle au cours de l'échantillon ? Cette architecture est particulièrement adaptée à un système marqué par plusieurs ruptures successives depuis 2014.

3.2. Données, groupes de variables et transformations

L'échantillon est mensuel et couvre les États-Unis de janvier 2014 à juin 2025. Les variables sont organisées en quatre piliers. Le bloc environnemental comprend les émissions de CO2 liées à l'énergie, la consommation d'énergies renouvelables, le Climate Concern Index et l'indice d'incertitude de durabilité ESGUI. Le bloc énergie comprend la consommation primaire d'énergie, le prix du pétrole WTI, le gaz naturel Henry Hub et le prix moyen de l'électricité. Le bloc macrofinance et incertitude regroupe notamment le S&P 500, le NASDAQ, l'inflation, la production industrielle, l'EPU et le risque géopolitique. Enfin, le bloc Bitcoin retient le prix, le volume de transactions et la capitalisation de marché. Les séries sont transformées en rendements logarithmiques ou taux de croissance afin d'harmoniser les unités et de travailler sur des séries stationnaires ; les tests ADF du tableau 2.2 confirment la stationnarité des séries transformées. Après transformation, le tableau 2.2 reporte 137 observations valides.

Le choix de la fréquence mensuelle est explicitement justifié par la disponibilité des variables macroéconomiques, environnementales et ESG, dont certaines ne sont pas observables de manière fiable à haute fréquence. Cette fréquence permet de maintenir une cohérence entre les quatre piliers sans introduire un bruit de mesure excessif. Les trois variables Bitcoin - prix, volume et capitalisation - sont conservées malgré leur proximité car elles décrivent des dimensions différentes : valorisation, intensité d'activité et profondeur de marché. Les log-différences harmonisent ensuite les unités et rendent comparables des séries exprimées à l'origine dans des métriques très différentes.

3.3. Décomposition par ondelettes

La première étape méthodologique utilise les ondelettes pour séparer les dynamiques selon les fréquences. Le chapitre combine la cohérence en ondelettes continues, fondée sur l'ondelette de Morlet, et une décomposition MODWT avec filtre de Haar. La cohérence

permet de localiser dans le temps et selon l'échelle les épisodes de synchronisation entre deux séries. La MODWT produit ensuite des composantes détaillées D1 à D6 et une composante lissée S6 sans sous-échantillonnage, ce qui préserve l'alignement temporel des observations. Cette propriété est particulièrement utile pour l'économétrie des séries financières car elle évite la perte de données et facilite l'application d'un modèle de connectivité sur chaque bande. L'idée économique est simple : les composantes de haute fréquence reflètent davantage les chocs rapides, le sentiment et la spéculation, tandis que les composantes de basse fréquence sont susceptibles de traduire des mécanismes macroéconomiques et structurels plus persistants.

Deux outils complémentaires sont mobilisés. La cohérence en ondelettes continues, fondée sur l'ondelette de Morlet, localise les zones de dépendance dans le plan temps-fréquence et, grâce aux différences de phase, renseigne sur les relations de leadership ou de retard. La MODWT, appliquée avec le filtre de Haar, produit ensuite des composantes fréquentielles directement utilisables dans l'analyse de connectivité. Son intérêt tient notamment à l'absence de sous-échantillonnage : les coefficients restent alignés dans le temps, ce qui facilite la comparaison entre variables et l'estimation économétrique sur chacune des bandes de fréquence.

3.4. TVP-VAR et mesure dynamique des transmissions

Sur chaque composante de fréquence, le chapitre estime un VAR à paramètres variables dans le temps. Le TVP-VAR permet aux coefficients et à la matrice de variance-covariance d'évoluer au fil de l'échantillon. Contrairement à un VAR à fenêtre glissante, il n'impose pas un choix fixe de fenêtre pour produire la dynamique principale. L'estimation mobilise un filtre de Kalman et retient des facteurs de décroissance kappa1 = 0,99 et kappa2 = 0,96, conformément à la spécification indiquée dans le manuscrit. À partir de la décomposition généralisée de la variance de l'erreur de prévision, plusieurs indicateurs sont calculés : l'indice total de connectivité (TCI), les transmissions directionnelles reçues et émises, la connectivité nette, les transmissions pair-à-pair et le rôle topologique des variables. Ces mesures permettent d'identifier non seulement l'intensité globale du système mais aussi qui transmet et qui reçoit les chocs à chaque date et à chaque horizon.

Dans le manuscrit, l’estimation dynamique repose sur un filtre de Kalman et des facteurs de décroissance fixés à 0,99 et 0,96. Pour l’exercice de connectivité sur les composantes décomposées, le VAR retient trois retards selon les critères d’information et un horizon de prévision de douze périodes. Les décompositions généralisées de variance permettent alors de construire le TCI, les mesures directionnelles TO et FROM, la position nette ainsi que les transmissions pair-à-pair. L’avantage du TVP-VAR est de faire évoluer ces relations sans imposer une fenêtre glissante unique comme source principale de dynamique.

3.5. Faits stylisés et épisodes de volatilité

Les statistiques descriptives montrent une hétérogénéité importante entre familles de variables. Les indicateurs liés au Bitcoin et certaines séries énergétiques présentent les dispersions les plus fortes, tandis que les variables macroéconomiques et environnementales sont plus stables. Le manuscrit identifie plusieurs épisodes qui structurent l’échantillon. La phase 2017-2018 correspond au premier cycle spéculatif important des cryptoactifs, avec des variations du prix et de la capitalisation du Bitcoin proches de plus ou moins 50 % dans les rendements mensuels. Au début de 2020, la pandémie provoque un choc systémique : le S&P 500 et le NASDAQ reculent de plus de 13 % sur l’épisode identifié, tandis que le pétrole et le gaz enregistrent des chutes historiques dépassant 70 % selon les séries étudiées. La période 2022-2023 correspond ensuite à un régime énergie-inflation lié notamment à la guerre en Ukraine, avant une phase plus récente dans laquelle les variables numériques, politiques et environnementales deviennent plus visibles dans la structure des transmissions.

La lecture des rendements fait apparaître plusieurs régimes qui servent ensuite de repères économiques pour interpréter les réseaux. Le cycle crypto de 2017-2018 se distingue par de fortes variations du prix et de la capitalisation du Bitcoin alors que les actifs traditionnels restent relativement plus stables. En 2020, le choc devient systémique : actions, énergie et indices d’incertitude réagissent simultanément. En 2022-2023, la dynamique se transforme en régime énergie-inflation sous l’effet du conflit russo-ukrainien et du resserrement macrofinancier. Ces changements expliquent pourquoi une structure de transmission constante serait peu crédible.

3.6. Co-mouvements environnement-énergie

La cohérence en ondelettes met en évidence des relations variables entre indicateurs environnementaux et variables énergétiques. Les épisodes de forte dépendance ne sont ni permanents ni identiques selon l'horizon, ce qui confirme l'intérêt de la décomposition temps-fréquence. Les émissions, la consommation d'énergie, le pétrole, le gaz, l'électricité et les indicateurs de durabilité peuvent partager des composantes communes pendant les périodes de stress énergétique, mais ces relations se déplacent lorsque le régime macroéconomique change. Le résultat important n'est donc pas l'existence d'une corrélation moyenne unique : il s'agit de la capacité des chocs énergétiques à devenir, dans certaines fenêtres, un moteur dominant de la dynamique environnementale. Cette intuition sera confirmée plus tard par le chapitre 3, où la transmission énergie-environnement est identifiée dans un cadre en clusters.

Les cartes de cohérence montrent notamment que CO2 et consommation primaire d'énergie présentent une synchronisation large et persistante sur une grande partie de l'échantillon. Les couples CO2-électricité et renouvelables-énergie primaire affichent également des bandes cohérentes à moyen et long terme, avec des configurations de phase suggérant que les variables énergétiques précèdent souvent leurs contreparties environnementales. À l'inverse, le lien renouvelables-pétrole est plus ponctuel et concentré autour de certains épisodes. Cette asymétrie confirme que le canal énergétique pertinent ne se réduit pas au pétrole brut et qu'il passe aussi par l'électricité et la consommation agrégée.

3.7. Co-mouvements environnement-macrofinance et environnement-Bitcoin

Les relations entre environnement et macrofinance se renforcent lorsque l'incertitude, l'inflation, les marchés boursiers ou les conditions énergétiques deviennent des facteurs dominants de valorisation. Le chapitre montre également que le lien entre variables environnementales et Bitcoin n'est pas constant. À haute fréquence, les mouvements des cryptoactifs restent largement dominés par des facteurs spéculatifs et de marché. À des horizons plus longs, les interactions avec l'énergie, l'inflation et les dimensions de durabilité deviennent plus visibles. Cette observation contribue à l'un des messages

généraux de la thèse : l'intégration du Bitcoin au reste du système financier et énergétique est progressive et dépend de l'horizon étudié.

Le lien CO2-production industrielle ressort comme l'un des plus persistants, ce qui est cohérent avec un mécanisme d'activité réelle : la production et les émissions partagent des cycles communs. La relation renouvelables-inflation devient particulièrement visible à basse fréquence autour de la période 2018-2022, tandis que les relations avec les indices boursiers restent plus épisodiques. Pour le Bitcoin, plusieurs îlots de cohérence apparaissent entre 2019 et 2021 avec les variables environnementales et de sentiment. La conclusion n'est donc pas celle d'un couplage permanent, mais d'une intégration renforcée lors de certains régimes financiers et énergétiques.

3.8. Co-mouvements énergie-macrofinance, énergie-Bitcoin et macrofinance-Bitcoin

Le bloc énergie entretient des relations particulièrement importantes avec les variables macrofinancières, car les prix du pétrole, du gaz et de l'électricité affectent simultanément les coûts, l'inflation et les anticipations de politique économique. Les relations énergie-Bitcoin sont plus instables : elles peuvent être fortes pendant des épisodes de stress ou de réallocation de risque, puis diminuer. Les relations macrofinance-Bitcoin se renforcent nettement à mesure que les cryptoactifs sont intégrés aux portefeuilles et réagissent aux conditions globales de marché. Le chapitre ne réduit donc pas le Bitcoin à un simple actif énergétique. Il montre qu'il se situe au croisement de plusieurs canaux : coût de minage, liquidité, sentiment, incertitude et réallocation entre actifs.

La relation entre énergie et économie réelle est plus stable que la relation énergie-Bitcoin. La consommation primaire et la production industrielle évoluent fréquemment de manière synchronisée, tout comme l'électricité et l'activité. Les relations avec le Bitcoin sont davantage concentrées autour des périodes de stress ou de changement de régime. Le bloc macrofinancier joue alors un rôle d'interface : le Bitcoin réagit aux conditions de marché, aux variations d'incertitude et aux réallocations de portefeuille, tandis que les chocs énergétiques influencent simultanément les coûts et les anticipations macroéconomiques. Cette multiplicité de canaux justifie l'analyse en réseau.

3.9. Niveau global de connectivité selon les fréquences

Le résultat central du chapitre est la persistance d'un niveau élevé de connectivité. Dans la conclusion du chapitre, l'indice total de connectivité se situe globalement entre environ 70 % et 90 % selon les horizons. Les composantes de court terme D1-D2 atteignent approximativement 85-89 %, les composantes intermédiaires D3-D4 se situent autour de 85-88 %, tandis que les composantes de long terme D5-D6 atteignent environ 89-93 %. La composante lissée S6 s'approche également de 93 %. Ces ordres de grandeur indiquent que l'interdépendance n'est pas seulement le produit de chocs temporaires : elle persiste à basse fréquence, où les facteurs macroéconomiques, énergétiques et institutionnels sont plus importants. Tous ces chiffres proviennent de la synthèse du chapitre et des figures de connectivité ; ils ne doivent pas être interprétés comme des paramètres universels mais comme les résultats de l'échantillon et de la spécification retenus.

La lecture des composantes fréquentielles montre aussi une transformation de la nature des transmetteurs. Aux fréquences élevées, le pétrole, les indices boursiers et le prix du Bitcoin dominent les transmissions rapides. Aux horizons intermédiaires, l'inflation, l'électricité, la production industrielle et l'incertitude deviennent plus importantes. Aux horizons les plus longs, les variables environnementales et de durabilité acquièrent un poids structurel plus marqué. Le niveau élevé du TCI à basse fréquence est donc essentiel : il montre que l'interdépendance n'est pas seulement une réaction de crise, mais qu'elle s'inscrit aussi dans des facteurs plus persistants.

3.10. Rotation des transmetteurs et changements de régime

Les mesures directionnelles révèlent une rotation chronologique du leadership systémique. Avant 2020, le réseau est principalement dominé par l'énergie et les cryptoactifs, avec le pétrole, le gaz et le prix du Bitcoin parmi les principaux transmetteurs. Pendant la pandémie, la contagion se comprime dans un régime plus synchronisé où les indices boursiers, notamment le S&P 500 et le NASDAQ, prennent une place centrale. La période 2021-2023 se caractérise ensuite par une propagation macro-énergétique dominée par l'inflation, la consommation ou les prix de l'énergie, le pétrole et l'électricité dans un contexte marqué par le choc inflationniste et géopolitique. En 2024-2025, le chapitre

identifie un régime plus numérique, politique et environnemental où les variables Bitcoin, ESG et incertitude économique deviennent davantage transmettrices.

Les trajectoires NPT permettent de résumer cette rotation en plusieurs phases. La première est dominée par l'énergie et le Bitcoin ; la seconde, autour de la pandémie, par une synchronisation macrofinancière plus compacte ; la troisième par le couple inflation-énergie et la montée de l'incertitude géopolitique ; enfin, la période récente voit réapparaître les variables Bitcoin et ESG aux côtés de l'électricité et du CO2. L'intérêt de cette lecture n'est pas de fixer définitivement un actif comme transmetteur, mais au contraire de montrer que la centralité change avec le régime économique et la fréquence considérée.

3.11. Interprétation économique du court et du long terme

La décomposition multi-échelle permet d'interpréter la nature de la contagion. À court terme, les transmissions sont principalement liées aux réactions rapides des marchés, à la spéculation et aux chocs énergétiques ou financiers. Le prix du Bitcoin peut alors apparaître comme un transmetteur important. À mesure que l'horizon s'allonge, les variables de volume et de capitalisation deviennent davantage réceptrices, tandis que les fondamentaux macroéconomiques et énergétiques gagnent en importance. L'inflation, la production industrielle et les prix de l'électricité jouent un rôle structurel plus marqué dans les composantes lentes. Le message n'est donc pas que les cryptoactifs perdent toute influence à long terme, mais que leur risque devient plus endogène au système macrofinancier et énergétique. Cette distinction entre contagion de haute fréquence et intégration structurelle est un résultat majeur du chapitre.

Cette opposition entre horizons donne une interprétation économique au résultat économétrique. À haute fréquence, les marchés réagissent à l'information, au sentiment et aux contraintes de liquidité ; les liens peuvent donc être rapides mais transitoires. À basse fréquence, les séries lissées reflètent davantage des ajustements de coûts, d'investissement, de production et de politique économique. Le fait que l'inflation, la production industrielle, l'électricité et certains indicateurs de durabilité prennent progressivement davantage d'importance suggère que l'intégration du Bitcoin au système ne se limite plus à la spéculation : elle passe aussi par des déterminants plus fondamentaux.

3.12. Implications pour la gestion des risques et la politique économique

Pour la gestion de portefeuille, le manuscrit interprète les niveaux élevés de connectivité à court terme comme le signe d'une faible indépendance des expositions pendant les épisodes de tension. La diversification entre énergie, actions et cryptoactifs peut alors devenir moins efficace précisément lorsque le risque augmente. À plus long terme, le rôle persistant de l'inflation, de la production industrielle et de l'électricité suggère que la gestion des risques liés aux cryptoactifs doit intégrer des variables macro-énergétiques. Pour les autorités publiques, le chapitre insiste sur la stabilisation du canal macro-énergie et sur le suivi conjoint des marchés numériques et des indicateurs de durabilité. Il propose également une meilleure transparence sur l'énergie utilisée par le minage. Ces implications restent des interprétations des résultats empiriques du chapitre et non des prescriptions universelles.

Une conséquence importante est que la diversification doit être pensée de manière conditionnelle. Lorsque la connectivité augmente fortement, des classes d'actifs qui paraissaient distinctes peuvent transmettre les mêmes chocs, réduisant les bénéfices attendus d'une allocation statique. Pour les autorités, le résultat plaide pour une lecture conjointe des risques numériques, énergétiques et environnementaux plutôt que pour des dispositifs séparés. Le manuscrit insiste également sur la transparence énergétique du minage, car la compréhension des canaux de transmission dépend de la capacité à mesurer l'origine de l'électricité et l'exposition du secteur aux changements de prix.

3.13. Robustesse et transition vers le chapitre 3

Le manuscrit vérifie la robustesse des principaux régimes en remplaçant le TVP-VAR par un VAR à fenêtre glissante de 100 observations. L'exercice reproduit les principales phases cycliques présentées dans les annexes, ce qui suggère que la dynamique observée n'est pas uniquement le produit du choix du TVP-VAR. Néanmoins, un problème d'interprétation subsiste : une mesure élevée de connectivité peut mélanger co-mouvement au sein d'un même groupe économique et transmission entre groupes distincts. Une partie du TCI peut ainsi refléter des variables qui réagissent au même choc plutôt qu'une

contagion d’un secteur vers un autre. Cette limite constitue le point de départ du chapitre 3 et explique le recours à la Clustered Network Connectedness.

L’exercice alternatif en VAR à fenêtre glissante de cent observations reproduit les grandes phases identifiées dans l’analyse principale, ce qui renforce l’idée que les changements de régime ne sont pas un artefact du TVP-VAR. Mais cette robustesse ne résout pas une difficulté conceptuelle : une FEVD généralisée peut attribuer à la transmission ce qui relève en réalité d’une corrélation contemporaine ou d’un facteur commun. Autrement dit, une connectivité élevée ne dit pas automatiquement si un secteur en contamine un autre. Le chapitre suivant traite précisément cette question d’identification en introduisant une structure explicite de clusters.

4. Chapitre 3 - Identification par Clustered Network Connectedness

4.1. Problème d’identification

Le chapitre 3 part d’une critique précise des mesures généralisées de connectivité. Dans un système comportant plusieurs variables proches économiquement, une forte covariance contemporaine peut être interprétée comme une transmission systémique, même lorsqu’elle reflète surtout l’exposition à des facteurs communs. Cette confusion est importante pour la finance : une autorité qui assimile synchronisation et contagion peut surestimer le risque intersectoriel ; un investisseur peut également sous-estimer la diversification disponible entre groupes. L’objectif est donc de distinguer deux objets. Le comouvement intra-cluster décrit la dépendance entre variables d’un même bloc économique. La contagion inter-clusters désigne la transmission entre blocs économiquement distincts. Le cadre Clustered Network Connectedness (CNC), mobilisé dans le manuscrit à partir de Buchwalter, Diebold et Yilmaz, impose une orthogonalité entre clusters tout en autorisant la dépendance interne.

Le point de départ est donc une distinction économique entre synchronisation et propagation. Deux actifs d’un même secteur peuvent bouger ensemble parce qu’ils sont exposés aux mêmes fondamentaux, sans que le choc de l’un cause la variation de l’autre. Une mesure de risque systémique qui assimile ces deux phénomènes peut gonfler artificiellement les transmissions intersectorielles. CNC est conçu pour conserver la dépendance économiquement plausible à l’intérieur d’un groupe tout en orthogonalisant les

innovations entre groupes. Le problème traité est ainsi moins celui de la quantité de connectivité que celui de son interprétation structurelle.

4.2. Échantillon journalier et architecture en quatre clusters

L'analyse utilise des rendements logarithmiques journaliers de 14 variables entre le 3 janvier 2022 et le 30 octobre 2024, en excluant week-ends et jours fériés américains. Le cluster crypto regroupe Bitcoin, Ethereum, XRP et Solana. Le cluster énergie comprend le WTI, le gaz naturel et la demande électrique américaine. Le cluster environnement réunit les émissions quotidiennes de CO2, un indice de transition énergétique propre et l'ETF ESGU. Le cluster macrofinancier comprend l'EPU, le NASDAQ, le VIX et l'or. La période couvre la sortie de pandémie, le choc énergétique associé à l'invasion de l'Ukraine, le resserrement monétaire américain, l'effondrement de FTX et les tensions bancaires de 2023. Cette concentration d'événements fournit un terrain pertinent pour étudier les changements de hiérarchie des transmetteurs.

La construction des quatre clusters est cohérente avec les mécanismes développés au chapitre 1. Les cryptoactifs partagent des déterminants de marché et de liquidité propres au secteur ; l'énergie regroupe les prix et la demande qui affectent les coûts ; le bloc environnemental rassemble émissions et actifs liés à la transition ; enfin, le cluster macrofinancier capte conditions financières, volatilité, incertitude et actif refuge. La période retenue concentre plusieurs chocs de nature différente, ce qui permet d'observer si la hiérarchie des transmetteurs varie lorsque le système passe d'un stress énergétique à un stress crypto puis à un stress bancaire.

4.3. VAR régularisé par Adaptive Elastic Net

La première composante de la méthode est un VAR estimé avec régularisation Adaptive Elastic Net. Le choix répond à la dimension du système et au risque de surparamétrisation dans une fenêtre glissante relativement courte. La pénalisation combine les propriétés de sélection du Lasso et la stabilisation du Ridge tout en utilisant des poids adaptatifs. Elle vise à conserver les relations dynamiques les plus informatives et à réduire l'instabilité des coefficients lorsque les prédicteurs sont corrélés. Le nombre de retards est sélectionné selon les critères présentés dans le tableau 3.2 ; la spécification retenue est

ensuite intégrée au pipeline de connectivité. Le but n'est pas de transformer l'exercice en modèle de prévision, mais d'obtenir une représentation dynamique suffisamment stable pour construire les décompositions de variance et suivre les transmissions dans le temps.

Les critères AIC, BIC et HQIC sélectionnent un VAR(1), résultat cohérent avec la rapidité d'intégration de l'information dans les données journalières. La régularisation Adaptive Elastic Net est ensuite utilisée pour limiter le risque de surparamétrisation dans un système relativement dimensionnel estimé sur des fenêtres mobiles. La pénalité combine Lasso et Ridge avec un poids de 0,5, tandis que le paramètre de régularisation est choisi par validation croisée en dix plis. Les poids adaptatifs pénalisent davantage les coefficients initialement faibles et préservent mieux les relations dynamiques les plus informatives.

4.4. Orthogonalisation par clusters et FEVD

La contribution d'identification intervient après l'estimation du VAR. La méthode CNC construit une orthogonalisation qui préserve la corrélation à l'intérieur de chaque cluster mais impose la séparation des innovations entre clusters. Les décompositions de variance de l'erreur de prévision sont ensuite calculées dans ce système transformé. On peut alors attribuer la variance d'un actif à trois composantes : ses propres innovations, les chocs provenant d'actifs du même cluster et les chocs provenant d'autres clusters. La somme de ces parts est normalisée afin de faciliter l'interprétation. Les indicateurs directionnels TO, FROM et NET sont calculés à partir des matrices FEVD. Cette construction donne une lecture plus structurelle que la connectivité généralisée, car un co-mouvement de deux actifs du même bloc n'est pas automatiquement requalifié en contagion entre secteurs.

La transformation CNC occupe une position intermédiaire entre deux cas classiques. Avec un seul cluster, elle rejoint la logique des chocs généralisés ; avec autant de clusters que de variables, elle se rapproche d'une identification récursive de type Cholesky. Dans l'application, quatre clusters sont utilisés. Comme l'ordre des blocs pourrait influencer une orthogonalisation séquentielle, le manuscrit calcule les FEVD pour les 24 permutations possibles des quatre clusters et moyenne les résultats. Cette étape réduit la dépendance à un ordre arbitraire tout en conservant l'objectif central : corrélation autorisée au sein des groupes, orthogonalité entre groupes.

4.5. Estimation glissante et suivi temporel

Le pipeline complet - VAR régularisé, orthogonalisation par clusters et FEVD - est réestimé dans des fenêtres de 126 jours de bourse qui avancent d'une journée. Le choix d'environ six mois recherche un compromis entre stabilité statistique et capacité à réagir aux changements de structure. Pour chaque fenêtre, les matrices de transmission et les indicateurs de connectivité sont recalculés. On obtient ainsi une série temporelle de rôles nets permettant d'observer lorsqu'un cluster passe de récepteur à transmetteur. La dynamique est cruciale dans l'échantillon étudié, car le même groupe peut changer de position entre le choc énergétique de 2022, l'épisode FTX et les tensions bancaires de 2023.

La fenêtre de 126 jours de bourse correspond approximativement à six mois et offre un compromis entre deux exigences contradictoires : disposer d'assez d'observations pour stabiliser l'estimation du VAR régularisé et rester suffisamment réactif aux ruptures de structure. À chaque déplacement d'une journée, l'ensemble du pipeline est recalculé : coefficients, résidus, orthogonalisation, FEVD et indicateurs de connectedness. Le résultat est une séquence de réseaux comparables dans le temps, qui permet de repérer les inversions de statut entre transmetteurs et récepteurs plutôt que de résumer toute la période par une seule matrice moyenne.

4.6. Expérience de Monte Carlo : logique

Le manuscrit complète l'application empirique par une expérience de Monte Carlo destinée à déterminer si l'écart entre Generalized Connectedness (GC) et CNC est simplement un artefact d'échantillon fini ou un problème d'identification. Trois processus générateurs sont construits. DGP0 comporte des dynamiques internes aux clusters mais aucune dépendance entre clusters ; GC et CNC doivent alors coïncider. DGP1 ajoute une corrélation contemporaine entre clusters sans transmission dynamique : si GC attribue cette corrélation à de la contagion, il doit produire un excès de connectivité inter-clusters. DGP2 combine corrélation et véritable transmission dynamique entre groupes. Les simulations utilisent 1 000 réplications, plusieurs tailles d'échantillon - 200, 500 et 1 000 observations - et des innovations gaussiennes ou de Student selon les exercices.

Les trois processus générateurs de données ont été construits pour isoler précisément les sources possibles de divergence entre GC et CNC. DGP0 contient des interactions internes mais aucune dépendance entre clusters ; DGP1 introduit une corrélation contemporaine entre groupes sans véritable transmission dynamique ; DGP2 ajoute ensuite une transmission inter-clusters effective. La logique du test est décisive : si GC mesure de la contagion dans DGP1 alors que la structure vraie n'en contient pas, l'écart ne peut pas être attribué à une simple imprécision d'échantillon. Les exercices avec innovations à queues épaisses vérifient en outre la robustesse dans un environnement plus proche des rendements financiers.

4.7. Population connectée et biais d'identification

Les résultats de population sont particulièrement informatifs. Dans DGP0, les mesures GC et CNC coïncident exactement, ce qui montre que la méthode clusterisée ne réduit pas mécaniquement la connectivité. Dans DGP1, où il existe une corrélation entre clusters mais aucune transmission dynamique, la connectivité croisée de GC est positive alors que celle de CNC est nulle ; le tableau 3.4 reporte un écart de 36,31 points pour la composante cross dans cette calibration. Dans DGP2, où une véritable transmission existe, les deux méthodes détectent des effets inter-clusters mais GC reste plus élevé ; l'écart cross de population est de 16,25 points dans le tableau 3.4. Ces résultats montrent que le problème provient de l'identification : la covariance contemporaine peut gonfler la mesure de transmission lorsque la structure des groupes n'est pas explicitement traitée.

Les résultats de population rendent cette logique particulièrement claire. Dans DGP0, où aucune dépendance croisée n'existe, GC et CNC coïncident. Dans DGP1, la seule présence d'une corrélation contemporaine conduit GC à produire une connectivité inter-clusters positive alors que CNC la maintient nulle ; l'écart cross atteint 36,31 points dans la calibration reportée. Dans DGP2, les deux approches détectent la transmission réelle mais GC reste plus élevé, avec un écart de 16,25 points. Ces résultats montrent que CNC ne réduit pas mécaniquement les spillovers : il corrige spécifiquement la partie imputable à l'identification.

4.8. Résultats de Monte Carlo en échantillon fini

Les simulations en échantillon fini confirment la logique de population. À mesure que la taille de l'échantillon augmente, la différence moyenne GC-CNC converge vers l'écart de population correspondant, ce qui est cohérent avec les hypothèses testées dans le chapitre. La robustesse à des innovations à queues épaisses vise à reproduire une caractéristique fréquente des rendements financiers et à vérifier que l'écart ne disparaît pas lorsque les distributions s'éloignent de la normalité. Les résultats des tableaux 3.5 et 3.6 et de la figure 3.1 soutiennent l'interprétation selon laquelle l'écart GC-CNC est structurel plutôt que lié uniquement au bruit d'estimation. Cette démonstration est importante car elle transforme la comparaison entre deux indicateurs en argument d'identification économétrique.

Lorsque la taille de l'échantillon augmente, les différences estimées convergent vers les écarts de population définis par les DGP, ce qui renforce l'interprétation structurelle. L'exercice est répété pour plusieurs tailles d'échantillon et sous des distributions d'innovations différentes. La persistance du résultat sous non-normalité est importante, car les rendements crypto et certaines séries financières présentent précisément des queues épaisses et des observations extrêmes. Les simulations montrent ainsi que l'écart GC-CNC n'est pas un phénomène fragile lié à une petite fenêtre ou à une hypothèse gaussienne stricte.

4.9. Distribution de la connectivité et réseau clusterisé

Dans l'application aux données, les densités des mesures directionnelles et nettes montrent une forte hétérogénéité entre variables et entre groupes. Le réseau clusterisé permet de visualiser les flux sans confondre la densité interne d'un groupe avec la transmission vers les autres groupes. Cette lecture fait apparaître l'énergie comme un bloc particulièrement important dans la propagation des chocs. Les actifs environnementaux restent sensibles aux innovations énergétiques, tandis que le cluster macrofinancier présente une part d'auto-explication et de comouvement interne plus élevée. Le cluster crypto est, au contraire, largement influencé par des facteurs externes dans l'échantillon.

La représentation en réseau révèle aussi quels actifs servent de ponts entre univers économiques. Le manuscrit identifie notamment le NASDAQ, le Bitcoin et l'indice d'énergie renouvelable comme nœuds importants, l'or jouant un rôle secondaire de transmission et de stabilisation. Dans le cluster énergie, les liens WTI-gaz-électricité traduisent les mécanismes de rééquilibrage de l'offre et de la demande ; la relation électricité-CO2 matérialise le canal énergétique vers l'environnement. Cette lecture est plus informative qu'un simple classement individuel, car elle montre comment certains nœuds relient des groupes et deviennent des vecteurs de propagation systémique.

4.10. Transmission nette et rôle des clusters

Les indicateurs dynamiques montrent que l'énergie se comporte comme transmetteur net persistant, en particulier pendant les épisodes de tension d'offre ou de forte volatilité géopolitique. Dans la discussion du chapitre, le rôle net moyen du cluster énergie est reporté autour de +0,64, tandis que les cryptoactifs et les actifs environnementaux se comportent plus fréquemment comme récepteurs. Les cryptomonnaies changent toutefois de statut après 2023 et deviennent davantage transmettrices après l'épisode FTX. Le groupe macrofinancier joue plus souvent un rôle d'absorption, notamment lors des tensions bancaires de mars 2023. Ces rôles doivent être lus comme des caractéristiques de l'échantillon, non comme des propriétés permanentes des classes d'actifs.

La dynamique des clusters met en évidence des rôles nettement asymétriques. L'énergie reste en moyenne transmettrice, avec une position nette moyenne proche de +0,64 et un pic autour de +0,96 lors des fortes tensions énergétiques. Le cluster macrofinancier est au contraire absorbant, avec une moyenne proche de -1,1 et un creux marqué pendant les tensions bancaires américaines de mars 2023. Le cluster crypto passe d'un statut de récepteur après FTX à un rôle plus transmetteur en 2023, tandis que l'environnement suit l'énergie avec un ajustement plus lent. Cette temporalité est centrale pour l'interprétation économique du réseau.

4.11. Décomposition own-comovement-contagion

La décomposition de la variance permet d'identifier l'origine de la fragilité. Dans la discussion empirique, le cluster crypto ne présente qu'une faible part de variance propre et

une forte exposition aux transmissions externes ; le manuscrit indique environ 9 % de variance propre et 76 % de dynamique expliquée par les spillovers externes pour ce groupe. Le cluster macrofinancier est plus autonome, avec une part interne plus élevée. Les blocs énergie et environnement se situent entre les deux, mais la transmission énergie-environnement ressort fortement. Le chapitre indique qu'environ 60 % de la variance des rendements environnementaux est liée aux innovations provenant du bloc énergie dans la décomposition considérée. Ce résultat soutient l'idée qu'un stress test climatique ne peut ignorer les chocs des marchés fossiles et électriques.

La décomposition permet de distinguer la fragilité interne d'un groupe de son exposition au reste du système. Dans le cluster crypto, le manuscrit ne trouve qu'environ 9 % de variance propre, tandis qu'une très grande part de la dynamique provient des transmissions externes. À l'opposé, le bloc macrofinancier conserve une composante propre et un comouvement interne plus importants. Les clusters énergie et environnement se situent entre ces deux configurations, avec une forte part de contagion croisée. Le résultat énergie-environnement est particulièrement important : il traduit quantitativement la dépendance des actifs durables aux perturbations des marchés énergétiques.

4.12. Comparaison GC-CNC dans les données

Dans l'échantillon empirique, la mesure GC reste systématiquement supérieure à CNC. La série de différence présentée à la figure 3.6 possède une moyenne positive proche de 0,09 et l'écart dépasse 0,35 autour de l'épisode post-FTX de fin 2022. Le chapitre interprète ce pic comme une période où la forte volatilité commune à plusieurs actifs conduit la mesure généralisée à attribuer une partie des mouvements intra-groupes à une transmission systémique. À partir de 2023-2024, l'écart se resserre avec le retour d'une structure plus segmentée. Dans la synthèse générale du chapitre, l'ordre de grandeur de la surestimation de la connectivité totale par les mesures généralisées est présenté autour de 8-12 %.

La comparaison empirique rejoint les simulations. La différence GC-CNC reste positive en moyenne, autour de 0,09, et dépasse 0,35 autour de l'épisode post-FTX. Le manuscrit interprète ce pic comme une période où la volatilité commune est suffisamment forte pour que la mesure généralisée confonde une partie des mouvements au sein des

groupes avec une transmission à l'échelle du système. Lorsque les marchés retrouvent davantage de segmentation en 2023-2024, l'écart se réduit. La surestimation globale, résumée dans le chapitre autour de 8 à 12 %, doit donc être comprise comme dépendante du régime.

4.13. Implications macroprudentielles et de portefeuille

La distinction entre synchronisation et contagion a plusieurs implications. Pour la surveillance macroprudentielle, une mesure qui gonfle les spillovers intersectoriels peut conduire à une évaluation trop pessimiste de la vulnérabilité systémique et à des calibrages de coussins ou de marges moins informatifs. CNC permet de suivre plus précisément les changements de hiérarchie des transmetteurs. Pour la finance climatique, la transmission énergie-environnement justifie l'intégration explicite des prix énergétiques dans les scénarios de stress. Pour les investisseurs, l'exposition élevée du cluster crypto aux chocs externes limite son rôle de diversification en période de crise et encourage une allocation dynamique qui tienne compte du statut de transmetteur ou de récepteur. Le chapitre reste prudent : ces implications découlent de l'échantillon et du cadre retenus et doivent être validées dans d'autres univers d'actifs.

Pour la surveillance financière, l'intérêt de CNC est d'éviter qu'une synchronisation interne soit automatiquement interprétée comme une contagion systémique nécessitant la même réponse prudentielle. Le manuscrit souligne qu'une surestimation persistante pourrait conduire à des coussins de capital, des marges ou des scénarios de stress excessivement conservateurs. Inversement, l'identification de véritables transmissions énergie-environnement permet de mieux cibler les scénarios climatiques. Pour la gestion de portefeuille, le statut dynamique de transmetteur ou de récepteur peut servir à adapter les expositions plutôt qu'à supposer une propriété de diversification constante des cryptoactifs ou des actifs ESG.

4.14. Transition vers la prévision

Le chapitre 3 établit finalement que l'architecture du réseau est économiquement informative. Si les matrices FEVD clusterisées isolent mieux les transmissions intersectorielles, elles peuvent être utilisées autrement que comme simples indicateurs ex

post. Cette idée conduit au chapitre 4 : les matrices de connectedness deviennent des graphes dynamiques orientés et pondérés destinés à alimenter un modèle d'apprentissage automatique. L'étape suivante consiste donc à tester si une meilleure identification du réseau produit également une information utile pour la prévision hors échantillon du Bitcoin.

Cette conclusion modifie la fonction attribuée à la connectivité dans la thèse. Jusqu'ici, le réseau sert principalement à mesurer et interpréter les mécanismes de transmission. Une fois les liens mieux identifiés, la question suivante est de savoir s'ils renferment une information prospective. Les FEVD clusterisées fournissent précisément un objet exploitable : à chaque date, elles décrivent un graphe orienté et pondéré indiquant quels nœuds contribuent à l'incertitude des autres. Le chapitre 4 transforme cette matrice économétrique en structure d'entrée pour un modèle d'apprentissage sur graphes, sans abandonner l'interprétation économique acquise au chapitre 3.

5. Chapitre 4 - De la connectivité à la prévision

5.1. De la mesure du réseau à la prévision

Le chapitre 4 transforme la connectivité en variable prédictive. L'idée est que les matrices FEVD ne résument pas seulement ce qui s'est passé dans le système : elles décrivent une architecture de propagation des chocs qui peut contenir une information prospective. Le défi consiste à exploiter cette structure sans perdre son interprétation économique. Pour cela, les matrices de spillovers issues du cadre clusterisé sont traitées comme des graphes orientés et pondérés qui varient dans le temps. Les nœuds correspondent aux variables ; les arêtes représentent l'intensité et la direction des transmissions. Cette construction se distingue d'un graphe fondé sur de simples corrélations car les liens ont une signification économétrique liée à la décomposition de variance.

Le chapitre formule ainsi une question de prévision clairement conditionnée par l'identification économique : la connectedness améliore-t-elle réellement les prévisions hors échantillon du rendement du Bitcoin lorsque le réseau distingue dépendance interne et transmission externe ? Le dispositif combine un premier étage économétrique, qui construit les graphes à partir des VAR et des FEVD, puis un étage d'apprentissage qui exploite leur

structure. Cette séparation est importante : le modèle ne cherche pas librement une topologie dans les données brutes ; il reçoit un réseau déjà interprété comme mécanisme de propagation des chocs.

5.2. Échantillon, cible et groupes économiques

L'analyse de prévision utilise des données quotidiennes allant du 1er janvier 2022 au 1er octobre 2025. Le Bitcoin est la variable cible. Le système comprend quatre cryptoactifs - Bitcoin, Ethereum, XRP et Solana -, trois variables d'énergie - WTI, gaz naturel et électricité -, des variables macrofinancières - NASDAQ, VIX et EPU - et deux proxys environnementaux ou de durabilité - un indice d'énergie renouvelable et le prix du carbone. Les séries sont transformées en rendements logarithmiques ou variations logarithmiques, exprimées en pourcentage. Le tableau 4.2 confirme la stationnarité des séries transformées et documente une forte non-normalité, particulièrement pour les cryptoactifs et l'incertitude économique.

La fréquence quotidienne est retenue parce que l'objet du chapitre est la prédictibilité conditionnelle et non une relation d'équilibre de long terme. Les variables sont transformées en rendements ou variations logarithmiques exprimés en pourcentage afin de rendre comparables les séries de prix, d'incertitude et de durabilité. Le choix du Bitcoin comme cible centrale s'explique par son poids dans l'écosystème crypto et par son rôle de nœud susceptible de recevoir des informations provenant des autres groupes. Les variables explicatives couvrent ainsi les dynamiques internes aux cryptomonnaies, les coûts énergétiques, les conditions financières et les dimensions ESG.

5.3. Organisation fixe en clusters

La partition en quatre clusters est imposée ex ante et reste fixe sur l'échantillon. Ce choix poursuit un objectif d'interprétabilité : les variables crypto partagent des déterminants de marché spécifiques ; les variables énergétiques capturent les canaux de coûts et de matières premières ; le bloc macrofinancier représente l'appétit pour le risque et l'incertitude ; le bloc environnemental reflète la valorisation de la durabilité et le prix du carbone. Cette structure permet de construire plusieurs graphes : un graphe complet, un graphe privilégiant les relations intra-clusters et un graphe représentant les transmissions

inter-clusters. La comparaison de ces spécifications devient ensuite un test économique des mécanismes de prévision.

La partition fixe constitue un choix méthodologique assumé. Elle permet de donner un sens stable aux comparaisons INTRA et INTER au cours de l'échantillon : si la composition des groupes changeait à chaque date, une amélioration de performance pourrait provenir du reclassement des variables plutôt que du contenu des transmissions. En contrepartie, cette stabilité réduit la capacité du modèle à capturer une éventuelle recomposition endogène des marchés. Le manuscrit présente donc la structure fixe comme un compromis entre interprétabilité et flexibilité, compromis qui constitue aussi l'une des limites discutées dans la conclusion.

5.4. Backbone économétrique et construction des graphes

Le chapitre conserve un socle économétrique avant l'apprentissage automatique. Un VAR glissant est estimé sur les séries transformées, puis converti en représentation moyenne mobile. Les FEVD produisent les matrices de connectedness qui deviennent les matrices d'adjacence des graphes. L'identification clusterisée est utilisée pour distinguer la dépendance à l'intérieur des groupes de la transmission entre groupes. Cette étape est essentielle : sans elle, le réseau transmis au modèle de machine learning mélangerait synchronisation et contagion. Le graphe est donc économiquement discipliné avant même l'apprentissage.

Le VAR est réestimé dans des fenêtres glissantes de 252 jours de bourse, soit approximativement une année, et le nombre de retards est choisi par le BIC sous contrainte de stabilité du système. Après passage en représentation moyenne mobile, les FEVD mesurent la contribution de chaque choc à l'erreur de prévision des autres variables. Les matrices obtenues deviennent ensuite des matrices d'adjacence orientées et pondérées. Le point méthodologique essentiel est que ces arêtes ne sont ni des corrélations brutes ni des distances arbitraires : elles sont issues d'un mécanisme de propagation identifié économétriquement.

5.5. GAT et GRU : dimensions transversales et temporelle

L'architecture combine un Graph Attention Network et des Gated Recurrent Units. Le mécanisme d'attention sur graphe apprend, à chaque date, quels voisins apportent l'information la plus pertinente pour la cible. Il exploite donc la dimension transversale du réseau et peut donner davantage de poids aux nœuds associés à des transmissions importantes. Les unités GRU traitent ensuite la persistance temporelle et les dépendances séquentielles. La combinaison GAT-GRU est cohérente avec la structure du problème : les FEVD définissent qui transmet à qui, l'attention sélectionne les relations les plus informatives et la composante récurrente suit leur évolution. L'apprentissage automatique complète ainsi l'identification économétrique au lieu de la remplacer.

Le mécanisme d'attention apprend une importance spécifique pour chaque voisin au lieu de traiter uniformément toutes les connexions. Dans la spécification retenue, cette attention est en outre modulée par le poids FEVD de l'arête : le modèle combine donc la pertinence apprise et l'intensité économétrique de la transmission. Les représentations ainsi obtenues passent ensuite dans les GRU, dont les portes contrôlent la quantité d'information nouvelle à intégrer et la part du passé à conserver. Cette architecture permet de distinguer un pic de spillover transitoire d'un régime de transmission plus persistant.

5.6. Prévision multi-horizon et évaluation hors échantillon

Les modèles sont évalués à plusieurs horizons afin de déterminer si la valeur prédictive du réseau dépend du temps nécessaire aux chocs pour se diffuser. Les critères statistiques principaux sont l'erreur absolue moyenne et la racine de l'erreur quadratique moyenne. Le protocole hors échantillon compare les spécifications de graphes à des benchmarks sans structure de réseau ou avec information plus limitée. Le raisonnement économique est qu'un effet intersectoriel peut être peu visible le lendemain mais devenir informatif à des horizons hebdomadaires, mensuels ou plus longs. Le chapitre s'intéresse donc autant au classement des modèles qu'à la façon dont ce classement évolue avec l'horizon.

Le protocole multi-horizon est directement lié à l'hypothèse économique du chapitre : certains chocs n'ont pas le temps de se diffuser en une journée mais peuvent devenir informatifs à l'échelle hebdomadaire, mensuelle ou annuelle. Les variables sont

standardisées à partir des moments de l'échantillon d'apprentissage seulement, les hyperparamètres sont sélectionnés sur les données disponibles à la date considérée et l'évaluation porte sur des observations non utilisées pour l'entraînement. Cette discipline évite une fuite d'information et aligne le test économétrique sur la manière dont un investisseur aurait réellement pu exploiter le signal au cours du temps.

5.7. Résultats au court horizon

Au plus court horizon, les gains prédictifs sont limités et les écarts entre modèles restent relativement modestes. Le manuscrit relie ce résultat au poids du bruit de haute fréquence et des innovations transitoires dans les rendements du Bitcoin. Même lorsqu'un canal de transmission est économiquement pertinent, il peut ne pas disposer de suffisamment de temps pour produire un effet mesurable dans la variable cible. Cette faiblesse du court terme est importante car elle évite une lecture excessive des résultats : le modèle de graphe n'améliore pas uniformément la prévision à toutes les fréquences.

À un jour, la spécification INTER obtient le meilleur résultat économique parmi les modèles présentés, avec un ratio de Sharpe annualisé de 0,65 contre 0,52 pour INTRA et 0,22 pour le buy-and-hold, mais les différences de MAE et RMSE restent moins tranchées. Le chapitre interprète ce contraste comme une limite naturelle de la prévisibilité à haute fréquence : une part importante des rendements du Bitcoin est dominée par le bruit, les effets transitoires et les innovations idiosyncratiques. La structure de réseau reste compétitive, mais l'horizon est trop court pour que les transmissions dynamiques se déploient pleinement.

5.8. Horizons intermédiaires et rôle de la dépendance intra-cluster

À des horizons intermédiaires, les performances des modèles de graphe s'améliorent. Le manuscrit observe que la dépendance intra-cluster devient particulièrement informative. Cela signifie que les dynamiques internes au marché crypto et les co-mouvements au sein de groupes économiquement homogènes contiennent une partie de l'information utile lorsque l'horizon laisse le temps aux mécanismes de dépendance de se manifester. L'attention sur graphe peut alors exploiter les nœuds qui jouent le rôle de transmetteurs

pertinents au sein des groupes. Cette lecture donne une interprétation économique à la performance du modèle plutôt que de la considérer comme un simple gain algorithmique.

Aux horizons hebdomadaire et mensuel, l'information relationnelle devient plus exploitable et la spécification INTRA se compare favorablement aux benchmarks. Le manuscrit reporte des ratios de Sharpe annualisés d'environ 0,48 à cinq jours et 0,59 à vingt jours, contre environ 0,25 et 0,28 pour le buy-and-hold. L'interprétation est que les dépendances internes aux groupes - en particulier les interactions au sein du marché crypto et les facteurs communs propres à chaque bloc - disposent désormais d'assez de temps pour se transmettre et améliorer le signal. La contribution des graphes est donc déjà visible avant que les canaux intersectoriels ne deviennent dominants.

5.9. Long horizon et domination des transmissions inter-clusters

Au plus long horizon étudié, la différence entre modèles devient plus nette et les transmissions inter-clusters prennent le dessus. Le chapitre indique qu'à l'horizon annuel la réduction de RMSE par rapport au meilleur benchmark sans graphe atteint environ 31 % dans la comparaison rapportée. La spécification INTER présente également le profil économique le plus favorable : la figure 4.2 reporte un ratio de Sharpe annualisé de 0,78 pour INTER, contre 0,35 pour INTRA et 0,20 pour la stratégie buy-and-hold. Ces chiffres doivent être lus dans le contexte exact du protocole de portefeuille retenu, mais ils soutiennent l'idée que les interactions avec l'énergie et la macrofinance deviennent plus importantes lorsque l'horizon s'allonge.

Le résultat annuel constitue le cas le plus favorable à l'hypothèse structurelle de la thèse. L'avantage d'INTER indique que les déterminants pertinents du Bitcoin à cet horizon ne sont plus seulement des comouvements internes au marché crypto. Les canaux énergétiques, macrofinanciers et systémiques deviennent progressivement plus importants, ce qui est cohérent avec une diffusion lente des coûts, des conditions de financement et des régimes de risque. La réduction d'environ 31 % du RMSE par rapport au meilleur benchmark non graphique et le ratio de Sharpe de 0,78 donnent ainsi une traduction statistique et économique au même mécanisme.

5.10. Robustesse MAE-RMSE

Le classement des modèles est globalement cohérent entre MAE et RMSE. Cette convergence est utile parce que les deux critères pénalisent différemment les erreurs extrêmes : RMSE donne davantage de poids aux grandes erreurs, tandis que MAE mesure plus directement l'erreur typique. Le fait que les améliorations apparaissent sur les deux dimensions suggère qu'elles ne résultent pas uniquement de quelques observations extrêmes. À long terme, certains benchmarks voient l'écart entre MAE et RMSE s'élargir, ce qui indique une sensibilité accrue aux grandes erreurs ; les modèles de graphe présentent un profil plus stable.

La cohérence entre MAE et RMSE est importante parce que ces deux critères ne réagissent pas de la même façon aux erreurs extrêmes. Une amélioration uniquement visible dans le RMSE pourrait être due à quelques grandes erreurs corrigées, tandis qu'une amélioration uniquement visible dans le MAE pourrait masquer des épisodes de forte dégradation. Le classement relativement stable des modèles suggère que le gain des graphes est plus général. Le manuscrit note également qu'à long terme certains benchmarks présentent un écart plus important entre les deux métriques, signe d'une sensibilité accrue aux erreurs de grande amplitude que les modèles de graphe semblent mieux contenir.

5.11. Passage de la précision statistique à la valeur économique

Une amélioration de prévision n'a d'intérêt financier que si elle se traduit en meilleure performance après prise en compte du risque. Le chapitre construit donc des stratégies de trading avec ciblage de volatilité. Quatre diagnostics sont utilisés : trajectoires de rendement net cumulé, ratios de Sharpe annualisés, ratios de Sharpe glissants et inférence bootstrap sur les différences de Sharpe. La figure 4.2 montre que la valeur économique devient plus nette avec l'horizon : le cas hebdomadaire reste faible et non significatif au seuil conventionnel ($p > 0,10$), le cas mensuel est plus fort avec $p = 0,02$, et le cas annuel est le plus marqué avec $p < 0,01$. L'utilisation du bootstrap par blocs vise à tenir compte de la dépendance temporelle des rendements.

La stratégie de portefeuille utilise les prévisions pour construire des positions dont l'exposition est ajustée par la volatilité récente. Cette normalisation vise à empêcher qu'un

modèle soit récompensé simplement parce qu'il prend davantage de risque. Les trajectoires de richesse cumulée et les Sharpe glissants complètent le ratio moyen en montrant si la performance est régulière ou concentrée dans quelques épisodes. Enfin, le bootstrap par blocs préserve la dépendance temporelle des rendements lors de l'inférence sur les différences de Sharpe. Cette couche économique est essentielle pour établir que la connectedness produit une information exploitable et pas uniquement une réduction abstraite de l'erreur de prévision.

5.12. Interprétation des mécanismes INTRA et INTER

La comparaison INTRA-INTER constitue le principal mécanisme d'interprétation du chapitre. Si INTRA domine, le gain de prévision est attribué surtout aux relations entre variables appartenant au même univers économique. Si INTER domine, l'information supplémentaire provient de flux entre univers distincts. Les résultats suggèrent une structure dépendante de l'horizon : l'intra-cluster est plus utile à moyen terme, alors que l'inter-clusters domine à long terme. Cela conduit à une interprétation du Bitcoin comme actif de plus en plus intégré à un système macrofinancier plus large lorsque l'horizon s'allonge. Les coûts énergétiques, l'incertitude et les conditions financières ne sont alors pas de simples variables corrélées mais des composantes d'un réseau dont la structure améliore la prévision.

La comparaison des deux graphes fournit une lecture économique du changement de performance avec l'horizon. INTRA capture surtout l'exposition à des facteurs communs ou des interactions entre variables appartenant au même univers ; INTER isole les transmissions entre blocs distincts. La domination d'INTRA à moyen terme puis d'INTER à long terme suggère une séquence de propagation : les ajustements apparaissent d'abord à l'intérieur des marchés, puis se diffusent vers les autres segments. Le chapitre transforme ainsi un résultat de machine learning en mécanisme testable sur la manière dont l'information traverse progressivement le système.

5.13. Complémentarité entre économétrie et machine learning

La contribution méthodologique du chapitre tient à la complémentarité entre deux familles d'outils. Le VAR et les FEVD imposent une discipline économique et identifient

une architecture de transmission. Le modèle GAT-GRU apporte la flexibilité nécessaire pour exploiter des interactions non linéaires et variables dans le temps. Cette articulation répond à une critique fréquente des modèles purement data-driven : un réseau construit sur des corrélations arbitraires peut être performant sans que l'origine du signal soit interprétable. Ici, les arêtes sont issues d'une mesure économétrique et la distinction en clusters donne un contenu économique au graphe. La machine learning layer apprend donc sur une structure préalablement définie par l'économétrie.

Cette articulation réduit le caractère de « boîte noire » souvent associé aux modèles prédictifs. L'économétrie définit d'abord ce qu'est une relation pertinente : un poids de FEVD interprétable dans un système VAR et corrigé pour la structure en clusters. Le GAT choisit ensuite, parmi ces relations, celles qui sont les plus utiles pour la cible, tandis que la GRU apprend leur persistance. L'apprentissage ne remplace donc pas l'identification ; il exploite une représentation économique déjà structurée. Cette complémentarité constitue l'une des principales contributions du chapitre et explique pourquoi les gains prédictifs peuvent être discutés en termes de mécanismes de transmission.

5.14. Limites de l'exercice de prévision

Le chapitre et la conclusion générale soulignent plusieurs limites. La structure en clusters est fixée ex ante et ne s'adapte pas endogènement aux changements d'organisation des marchés. La cible de prévision est le Bitcoin, de sorte que la généralisation à d'autres cryptoactifs ou classes d'actifs reste ouverte. L'analyse de valeur économique demeure volontairement simple et pourrait intégrer des contraintes de portefeuille, des coûts de transaction et des règles de gestion du risque plus sophistiqués. Les résultats doivent donc être interprétés comme une démonstration de la valeur informationnelle de la connectivité identifiée, et non comme une stratégie universelle immédiatement transposable.

Le manuscrit souligne en outre que les résultats doivent être interprétés relativement au protocole retenu. La partition des clusters n'est pas estimée endogènement ; la cible est uniquement le Bitcoin ; la stratégie de valeur économique ne reproduit pas toutes les contraintes d'un portefeuille institutionnel ; enfin, les performances peuvent dépendre des coûts de transaction, des bornes d'exposition et de la fréquence de rééquilibrage. Ces limites ne remettent pas en cause le résultat principal, mais elles définissent son domaine de

validité : il s’agit d’une preuve de contenu informationnel des réseaux identifiés, non d’une règle universelle de trading.

6. Synthèse transversale, limites et perspectives

6.1. Cohérence des quatre chapitres

La thèse suit une progression cumulative. Le premier chapitre établit pourquoi les cryptomonnaies, l’énergie, la macrofinance et l’environnement peuvent être étudiés comme un système cohérent. Le deuxième montre empiriquement que ce système est fortement connecté et que sa structure change selon les périodes et les horizons. Le troisième démontre ensuite que la manière d’identifier la connectivité modifie l’interprétation du risque : une partie de ce que les mesures standards attribuent à la contagion correspond à des comouvements internes. Enfin, le quatrième transforme la structure identifiée en information prédictive et montre que les gains dépendent de l’horizon et de la nature intra- ou inter-cluster des relations. Cette continuité évite que les quatre essais apparaissent comme indépendants. Chaque chapitre résout une limite laissée ouverte par le précédent. Références internes : manuscrit, introduction générale ; conclusions des chap. 1-4 ; conclusion générale.

Cette progression peut aussi être lue comme une chaîne logique de validation. Le chapitre 1 formule les canaux ; le chapitre 2 montre qu’ils produisent effectivement une connectivité variable selon les horizons ; le chapitre 3 vérifie que cette connectivité doit être correctement identifiée pour ne pas confondre comouvement et contagion ; le chapitre 4 teste enfin si la structure ainsi identifiée possède une valeur prospective. Le passage d’un chapitre à l’autre réduit progressivement l’ambiguïté de l’objet étudié, depuis une intuition économique large jusqu’à un signal quantifié et évalué hors échantillon.

6.2. Message économique transversal

Le message économique transversal est que le Bitcoin n’est ni entièrement autonome ni réductible à une simple composante des marchés traditionnels. Son rôle dépend du régime et de l’horizon. À court terme, les dynamiques spéculatives et les chocs rapides peuvent dominer. À moyen terme, les dépendances internes au marché crypto deviennent

informatives. À long terme, les interactions avec l'énergie, l'inflation, les conditions financières et les variables de durabilité prennent davantage d'importance. Cette stratification explique pourquoi des études bivariées peuvent produire des résultats contradictoires : elles observent des fragments d'un système dont la structure change.

L'intégration du Bitcoin au reste du système est donc graduelle plutôt que totale. À certaines dates, les mouvements propres au marché crypto restent dominants ; dans d'autres régimes, les conditions énergétiques ou macrofinancières deviennent déterminantes. Cette variabilité explique pourquoi le Bitcoin peut apparaître tour à tour comme récepteur ou transmetteur et pourquoi sa capacité de diversification n'est pas stable. La thèse conduit ainsi à rejeter deux représentations simples : celle d'un actif entièrement autonome et celle d'un actif qui ne ferait que répliquer les marchés traditionnels. Son comportement dépend de l'architecture des transmissions et de l'horizon considéré.

6.3. Apport économétrique

L'apport économétrique réside dans l'enchaînement de trois niveaux. Premièrement, la décomposition en ondelettes et le TVP-VAR traitent l'hétérogénéité temporelle et fréquentielle. Deuxièmement, la CNC ajoute une dimension d'identification économique en séparant co-mouvement et contagion. Troisièmement, les matrices FEVD deviennent des graphes dynamiques pour l'apprentissage prédictif. La thèse ne présente donc pas une méthode unique mais une architecture méthodologique dans laquelle chaque outil répond à une question différente : quand les marchés sont-ils connectés, par quels canaux le sont-ils, et cette structure contient-elle une information prospective ?

L'intérêt de l'architecture méthodologique réside aussi dans la spécialisation des outils. Les ondelettes répondent à la question de l'horizon ; le TVP-VAR répond à celle du changement temporel ; CNC répond à celle de l'identification ; le graphe GAT-GRU répond à celle de l'exploitation prédictive. Aucun de ces outils n'est présenté comme suffisant isolément. Leur combinaison forme une séquence dans laquelle la sortie d'une étape devient l'entrée de la suivante. Cette cohérence limite le risque d'empiler des méthodes sans justification économique et donne à chaque choix économétrique une fonction précise dans la démonstration.

6.4. Implications pour la stabilité financière et la finance climatique

Les résultats suggèrent que la surveillance des actifs numériques gagne à intégrer les marchés de l'énergie et les conditions macrofinancières. L'énergie apparaît comme un transmetteur important dans plusieurs exercices, tandis que les actifs environnementaux restent exposés aux perturbations énergétiques. Cela implique qu'une lecture cloisonnée des risques climatiques, énergétiques et numériques peut manquer des canaux de propagation communs. La distinction entre comouvement et contagion est particulièrement importante pour les stress tests : deux marchés peuvent baisser ensemble parce qu'ils réagissent au même facteur, sans qu'un choc de l'un se transmette mécaniquement à l'autre.

La thèse met particulièrement en évidence le rôle de l'énergie comme canal de transmission vers les actifs environnementaux. Pour les stress tests climatiques, cela signifie qu'un scénario centré uniquement sur les émissions ou le prix du carbone risque d'omettre une source importante de volatilité provenant du pétrole, du gaz ou de l'électricité. De même, l'intégration croissante des cryptoactifs aux conditions financières implique que la surveillance du risque numérique doit tenir compte des chocs macrofinanciers. L'apport de CNC est alors de distinguer une baisse simultanée provoquée par un facteur commun d'une véritable propagation entre secteurs.

6.5. Implications pour les investisseurs

Pour les investisseurs, la thèse montre que la diversification dépend du régime et de l'horizon. Les périodes de forte connectivité réduisent les bénéfices d'une diversification naïve entre classes d'actifs. Le cluster crypto, dans l'échantillon du chapitre 3, est largement exposé à des innovations externes ; il ne constitue donc pas un refuge stable en période de stress. En revanche, les mesures de réseau peuvent être utilisées comme signaux lorsqu'elles sont correctement identifiées. L'exercice du chapitre 4 illustre cette possibilité : la valeur économique de la connectivité augmente aux horizons où les transmissions ont le temps de se propager. Références internes : manuscrit, chap. 3, §3.6 ; chap. 4, §4.5.

Une allocation fondée uniquement sur les corrélations moyennes peut donc devenir trompeuse au moment où le régime change. Les résultats encouragent plutôt une lecture dynamique des expositions : identifier les blocs qui transmettent les chocs, ceux qui les

absorbent et les horizons auxquels les relations deviennent pertinentes. Le chapitre de prévision montre en outre que cette information peut être transformée en signal, mais que sa valeur dépend de la maturité du mécanisme de transmission. La gestion des risques gagne ainsi à intégrer non seulement l'intensité des liens, mais leur direction, leur origine sectorielle et leur persistance.

6.6. Limites générales

Plusieurs limites encadrent les résultats. Les échantillons changent entre chapitres afin de répondre à des objectifs distincts, ce qui limite les comparaisons mécaniques de niveaux de connectivité. Les clusters sont définis selon une logique économique mais restent fixes dans les chapitres 3 et 4. Les mesures de carbone et de durabilité sont des proxys imparfaits de dimensions complexes. Les exercices de prévision sont centrés sur le Bitcoin et le dispositif de portefeuille reste volontairement simple. Enfin, comme dans toute analyse de connectivité, l'interprétation dépend du choix des variables, de l'horizon de FEVD et de la spécification du VAR. Ces limites sont explicitement discutées dans le manuscrit et motivent les pistes de recherche futures.

6.7. Perspectives de recherche

Les extensions proposées portent sur l'élargissement des actifs liés à la durabilité - crédits carbone, obligations vertes et indices d'incertitude de politique climatique -, sur des structures de clusters dynamiques, sur des identifications variant avec la fréquence ou des modèles bayésiens à paramètres variables, et sur l'extension de la prévision à d'autres actifs. Une autre piste consiste à enrichir l'évaluation économique par des coûts de transaction plus réalistes et des contraintes de portefeuille. Ces prolongements conservent le principe général de la thèse : combiner une représentation économiquement interprétable du réseau avec des méthodes capables de suivre sa dynamique et d'en exploiter le contenu informationnel.

7. Conclusion générale

Conclusion générale

Cette thèse a étudié le nexus émergent entre les cryptomonnaies, l'énergie, la macrofinance et l'environnement en le considérant comme un système économique cohérent, façonné par les interactions entre la finance numérique, les dynamiques des marchés de l'énergie, les conditions macrofinancières et les contraintes environnementales. Son point de départ repose sur le constat que les cryptomonnaies ne peuvent plus être analysées comme de simples actifs spéculatifs isolés. Leur essor s'est accompagné de l'importance croissante des enjeux liés à la sécurité énergétique, à la transition climatique et au développement d'une finance orientée vers la durabilité, faisant ainsi émerger un nouveau champ d'interdépendances au sein duquel les chocs se propagent entre des marchés qui étaient jusqu'alors étudiés de manière distincte. L'objectif général de cette thèse était donc de dépasser les résultats fragmentés de la littérature afin de développer un cadre d'analyse cumulatif permettant de conceptualiser ce nexus, de mesurer l'évolution de ses interdépendances, d'identifier la structure de ses mécanismes de transmission et d'évaluer si cette structure renferme une information prédictive présentant une réelle valeur économique. La première contribution de cette thèse consiste à avoir établi les fondements conceptuels et analytiques de ce nexus. Le chapitre consacré à l'état de l'art a montré que l'essor des cryptomonnaies est indissociable des infrastructures physiques qui les sous-tendent, en particulier dans les systèmes fondés sur le mécanisme de preuve de travail (Proof-of-Work), où l'activité de minage dépend directement de la demande en électricité, de l'efficacité des équipements informatiques et de l'intensité carbone du mix énergétique. Il a également montré que les relations entre les cryptomonnaies, le pétrole brut, l'électricité et les énergies renouvelables ne relèvent pas de simples coïncidences, mais traduisent des mécanismes économiques plus profonds impliquant les structures de coûts, les réponses réglementaires, le sentiment des investisseurs et les externalités environnementales. Cette étape conceptuelle était essentielle, car elle justifie l'architecture générale de la thèse : les cryptomonnaies ne sont plus considérées comme des actifs numériques autonomes, mais comme des actifs intégrés à un système plus large reliant l'innovation numérique, les marchés de l'énergie et la durabilité environnementale. Dans le prolongement de cette base conceptuelle, le deuxième chapitre propose la première cartographie empirique globale de ce nexus. En mobilisant un cadre méthodologique

combinant la décomposition en ondelettes (wavelet decomposition) et les mesures de connectivité issues d'un modèle TVP-VAR, il montre que le système américain réunissant les cryptomonnaies, l'énergie, l'environnement et les variables macroéconomiques présente un degré d'intégration élevé et persistant, l'indice global de connectivité (Total Connectedness Index) se situant généralement entre 70 % et 90 %, avec un maximum proche de 93 % aux horizons de long terme. Les résultats mettent également en évidence que cette connectivité n'est pas homogène selon les échelles temporelles. Les mécanismes de contagion de court terme sont principalement alimentés par les dynamiques spéculatives et les marchés de l'énergie, tandis que les interdépendances de long terme reposent davantage sur des variables macroéconomiques fondamentales telles que l'inflation, la production industrielle et les prix de l'électricité. Le chapitre identifie par ailleurs une évolution chronologique du leadership systémique : une domination des interactions énergie–cryptomonnaies avant 2020, suivie d'une forte synchronisation financière durant la crise de la COVID-19, puis d'un régime dominé par les interactions entre énergie et macrofinance après 2021, avant une évolution progressive vers une configuration davantage orientée vers les enjeux de durabilité à l'horizon 2025. Ce chapitre établit ainsi un premier résultat majeur : le nexus se caractérise non seulement par un niveau élevé d'interconnexion, mais également par une connectivité dynamique, multi-échelle et dépendante des régimes économiques. Le troisième chapitre approfondit cette analyse en s'attaquant à une limite méthodologique majeure des mesures traditionnelles de connectivité. Si les indicateurs classiques fondés sur la décomposition de la variance de l'erreur de prévision (Forecast Error Variance Decomposition, FEVD) permettent de mesurer les mécanismes de transmission entre variables, ils ne distinguent pas les co-mouvements observés au sein d'un même groupe des véritables phénomènes de contagion entre groupes économiquement distincts. L'application du cadre de la Clustered Network Connectedness montre que cette distinction revêt une importance empirique essentielle. Les résultats indiquent que les mesures généralisées de connectivité surestiment les spillovers globaux d'environ 8 à 12 %, dans la mesure où elles assimilent les co-mouvements internes aux clusters à des mécanismes de transmission à l'échelle de l'ensemble du système. Une fois ce problème d'identification corrigé, l'architecture du réseau apparaît avec davantage

de clarté. Le groupe des marchés de l'énergie se révèle être un transmetteur net persistant de chocs, atteignant des valeurs proches de +0,96 lors des périodes de fortes tensions. Les cryptomonnaies évoluent progressivement d'une position de récepteurs nets vers celle de transmetteurs nets après l'épisode FTX. Quant au groupe des actifs environnementaux, il réagit plus lentement aux perturbations mais demeure fortement exposé aux chocs énergétiques, près de 60 % de la variance de leurs rendements étant expliquée par les innovations provenant des marchés de l'énergie. Les simulations de Monte Carlo confirment que l'écart observé entre la connectivité généralisée et la connectivité fondée sur les clusters traduit un véritable biais d'identification structurelle et ne résulte pas d'un simple effet lié aux propriétés des échantillons finis. Ce chapitre montre ainsi qu'une mesure pertinente de la connectivité suppose une identification économiquement fondée de la structure du réseau. Le quatrième chapitre prolonge cette démarche en passant de la mesure à la prévision. Plutôt que de considérer la connectivité comme un simple indicateur descriptif, il transforme les matrices de spillovers FEVD clusterisées en graphes dynamiques orientés, qui sont ensuite intégrés dans une architecture d'apprentissage sur graphes temporels combinant les Graph Attention Networks (GAT) et les Gated Recurrent Units (GRU). Les résultats montrent que le contenu prédictif de la connectivité dépend fortement de l'horizon de prévision. Aux horizons les plus courts, les gains de prévision demeurent limités, car les fluctuations du Bitcoin sont principalement dominées par le bruit de haute fréquence et des chocs transitoires. Aux horizons intermédiaires, les améliorations deviennent nettement plus importantes et sont essentiellement portées par les dépendances intra-clusters. À l'inverse, aux horizons les plus longs, les spillovers inter-clusters deviennent prépondérants, indiquant que les rendements du Bitcoin sont de plus en plus influencés par des mécanismes de transmission macrofinanciers et intersectoriels. L'analyse de la valeur économique confirme ces résultats en montrant que l'intégration de la connectivité dans une architecture d'apprentissage sur graphes améliore sensiblement les performances ajustées du risque lorsque l'horizon de prévision s'allonge. Ce chapitre démontre ainsi que la connectivité ne constitue pas uniquement un outil de diagnostic ex post de la structure des marchés ; elle représente également un objet informationnel prospectif pouvant être exploité pour la prévision financière et la construction de

portefeuilles. Pris dans leur ensemble, ces différents chapitres conduisent à une conclusion générale unique : le nexus cryptomonnaies–énergie–macrofinance–environnement doit être appréhendé comme un système stratifié et évolutif, au sein duquel les mécanismes de transmission diffèrent selon les horizons temporels, les régimes économiques et la structure des variables qui le composent. Cette thèse montre que la progression allant de la synthèse conceptuelle à la caractérisation empirique, puis de cette dernière à l'identification structurelle et enfin à la prévision, ne constitue pas une simple succession d'étapes, mais une démarche cumulative et cohérente. Le premier chapitre explique pourquoi ce nexus existe ; le deuxième montre qu'il présente une connectivité forte, dynamique et dépendante du temps ; le troisième démontre que sa structure interne est déterminante pour son interprétation ; enfin, le quatrième établit que cette structure renferme une information exploitable pour améliorer la prévision des rendements du Bitcoin. Plusieurs implications découlent de ces résultats. Pour la littérature académique, cette thèse suggère que les recherches futures consacrées aux systèmes financiers interconnectés devraient accorder une place plus importante à la structure économique sous-jacente des mécanismes de transmission, plutôt que de s'appuyer exclusivement sur des mesures agrégées ou bilatérales de dépendance. Plus spécifiquement, pour la littérature sur la connectivité, elle montre que la distinction entre co-mouvements et contagion ne présente pas seulement un intérêt conceptuel, mais revêt également une importance quantitative significative. Enfin, à l'interface entre l'économétrie et l'apprentissage automatique, cette thèse met en évidence que les architectures d'apprentissage sur graphes gagnent simultanément en performance et en capacité d'interprétation lorsque les réseaux qu'elles exploitent sont construits à partir de mécanismes de transmission identifiés sur des fondements économiques, plutôt qu'à partir de simples corrélations ou de mesures de dépendance non différenciées. Cette thèse présente également plusieurs implications pour les politiques publiques et la pratique financière. Le rôle persistant des marchés de l'énergie en tant que principaux transmetteurs de chocs suggèrent que la surveillance macroprudentielle ne peut ignorer le canal énergétique dans l'évaluation de la fragilité des marchés d'actifs numériques. La forte transmission des chocs énergétiques vers les actifs environnementaux indique en outre que les exercices de tests de résistance climatique (climate stress testing) devraient intégrer

explicitement la volatilité des prix des combustibles fossiles et de l'électricité, les instruments financiers liés à la durabilité n'étant pas isolés des perturbations affectant les marchés de l'énergie. Plus largement, les résultats montrent que les cryptomonnaies se comportent moins comme des actifs alternatifs indépendants que comme des composantes à fort bêta d'un système macrofinancier plus vaste, en particulier durant les périodes de tensions systémiques. Ce constat remet en question leur rôle potentiel en tant qu'instruments efficaces de diversification dans les périodes de turbulences et souligne la nécessité d'une surveillance intégrée des risques liés aux actifs numériques, à l'énergie et à la finance climatique. Comme tout travail empirique, cette thèse présente néanmoins certaines limites. Tout d'abord, la structure en clusters est définie a priori et non estimée de manière endogène. Si ce choix renforce l'interprétabilité économique des résultats, il ne permet pas de prendre pleinement en compte les évolutions temporelles de l'organisation des marchés. Ensuite, l'analyse prédictive est centrée sur le Bitcoin. Ce choix se justifie par son importance systémique au sein de l'écosystème des cryptomonnaies, mais il laisse ouverte la question de la généralisation de ces résultats à d'autres actifs numériques ou à des classes d'actifs plus larges. Par ailleurs, bien que l'architecture d'apprentissage sur graphes démontre que la connectivité peut être transformée en signaux prédictifs, l'analyse de la valeur économique demeure volontairement simple. Elle pourrait être enrichie en intégrant des contraintes de portefeuille plus réalistes, des structures de coûts de transaction plus sophistiquées ainsi que des règles alternatives de gestion du risque. Les résultats prédictifs doivent ainsi être interprétés comme une démonstration de l'intérêt de la connectivité identifiée sur des bases économiques dans le cadre spécifique de cette étude, plutôt que comme une règle universellement applicable à l'ensemble des classes d'actifs. Ces limites ouvrent naturellement plusieurs perspectives de recherche. Une première consisterait à étendre le cadre d'analyse à un ensemble plus large d'actifs liés à la durabilité, notamment les marchés des crédits carbones, les obligations vertes (green bonds) et les indices d'incertitude relatifs aux politiques climatiques. Une deuxième piste viserait à autoriser une évolution dynamique de la structure en clusters elle-même, en combinant l'identification économique avec des méthodes de partitionnement fondées sur les données. Une troisième extension consisterait à intégrer des schémas d'identification variant dans le

domaine fréquentiel ou fondés sur des approches bayésiennes à paramètres variables dans le temps, afin de mieux capturer les interactions entre transitions structurelles, régimes de marché et chocs de politique économique. Enfin, le cadre de prévision pourrait être généralisé au-delà du seul Bitcoin afin d'évaluer si des structures de graphes identifiées sur des fondements économiques permettent également d'améliorer la prévision des rendements sur d'autres marchés fortement interconnectés. Dans son ensemble, cette thèse montre que le nexus cryptomonnaies–énergie–macrofinance– environnement ne peut être réduit à une juxtaposition de relations bilatérales isolées, mais qu'il constitue un système structuré et évolutif de transmission des chocs. Son principal message est que la compréhension de ce nexus exige davantage que la simple mise en évidence de co-mouvements entre variables. Elle nécessite d'identifier l'architecture économique des mécanismes de transmission, de reconnaître leur dépendance aux horizons temporels et d'exploiter le contenu informationnel qu'ils renferment. En ce sens, cette thèse s'inscrit dans un programme de recherche plus large en économie et en finance, visant à réconcilier la mesure du risque systémique, l'interprétation structurelle des mécanismes économiques et la prévision, dans un contexte marqué par l'accélération de la numérisation, de la transition énergétique et des incertitudes environnementales.

Contents

Abstract
Résumé
Acknowledgements
List of Abbreviations
List of Figures
List of Tables

Chapter 0. General Introduction 1

Chapter 1. The Crypto-Energy-Macrofinance-Environment Nexus: State of the Art 8
1.1. Introduction 8
1.2. From digital payments to distributed ledgers and cryptocurrencies 9
1.3. Proof-of-Work mining and the energy footprint of cryptocurrencies 10
1.3.1. Consensus and mining 10
1.3.2. Hardware evolution and energy demand 10
1.3.3. Micro-level energy channels 11
1.4. Crude oil-electricity nexus 12
1.4.1. Direct impact of crude oil on electricity 12
1.4.2. Indirect impact via natural gas and price indexation 12
1.5. Electricity-cryptocurrency nexus 13
1.5.1. Mining, electricity consumption 13
1.5.2. Carbon footprint and comparison with traditional payment systems 13
1.6. Crude oil-cryptocurrency nexus 14
1.6.1. Introduction 14
1.6.2. Data and Methodology 17
1.6.3. Empirical results and discussion 20
1.7. Cryptocurrency-Renewable Energy Nexus 26
1.8. Conclusion 29

Chapter 2. Interconnected multiscale waves: Tracking shock transmission across cryptocurrency, energy, economy and the environment 31
2.1. Introduction 32
2.2. Literature review 34
2.3. Methodology 37
2.3.1. Wavelet Transform 37
2.3.2. TVP-VAR connectedness 39
2.3.3. Dynamic connectedness measures 40
2.4. Data 42
2.5. Empirical analysis 46
2.5.1. Analysis of time-frequency comovements 46
2.5.2. Comovement between environmental factors and energy measures 47
2.5.3. Comovement between environmental factors and Macrofinancial and Uncertainty Indicators 48
2.5.4. Comovement between environmental factors and Bitcoin Indicators 50
2.5.5. Comovement between energy measures and Macrofinancial and Uncertainty Indicators 52
2.5.6. Comovement between energy measures and Bitcoin Indicators 54

2.5.7. Comovement between Macrofinancial & Uncertainty Indicators variables and Bitcoin Indicators 55
2.5.8. TVP-VAR connectedness analysis 58
2.6. Conclusion 76

Chapter 3. Shocks, Transmissions, and Sustainability: Mapping the Crypto-Energy-Environment Nexus 87
3.1. Introduction 88
3.2. Literature Review 91
3.3. Data 93
3.4. Methodology 95
3.4.1. Model overview 95
3.4.2. VAR Estimation via Adaptive Elastic Net 96
3.4.3. Cluster orthogonalization 97
3.4.4. Forecast Error Variance Decompositions 98
3.4.5. Rolling estimation procedure 98
3.4.6. Connectedness measurements 99
3.4.7. Monte Carlo evidence on identification and measurement differences. 100
3.4.7.1. Monte Carlo design 100
3.4.7.2. Population connectedness 102
3.4.7.3. Finite-sample Monte Carlo results 103
3.5. Results 106
3.5.1. Summary statistics 106
3.5.2. Overview of connectedness distributions 107
3.5.2.1. Directional and net connectedness densities 107
3.5.2.2. Clustered network connectedness 108
3.5.2.3. Dynamic net transmissions 110
3.5.3. Within-cluster vs. cross-cluster spillovers 111
3.5.4. Connectedness assessment: CNC vs GC 113
3.6. Discussion and policy implications 114
3.7. Conclusion 115

Chapter 4. From Network Spillovers to Trading Signals: Clustered Graph Neural Networks for Bitcoin Return Prediction 117
4.1. Introduction 118
4.2. Literature Review 120
4.2.1. Connectedness measurement and spillover identification 120
4.2.2. Bitcoin, macrofinancial linkages, and spillovers 120
4.2.3. Graph-based learning and financial forecasting 121
4.2.4. Motivation and main contributions 121
4.3. Methodology 122
4.3.1. Econometric backbone: the rolling VAR system 122
4.3.2. Moving-average representation and dynamic propagation 123
4.3.3. Forecast error variance decomposition as a measure of connectedness 123
4.3.4. Why clustered identification is needed 124
4.3.5. From FEVD matrices to dynamic directed graphs 125
4.3.6. Graph attention as a cross-sectional learning device 125
4.3.7. GRU dynamics as the temporal learning layer 126
4.3.8. Multi-horizon forecasting design 127

4.3.9. Portfolio returns, cumulative performance, and normalization 128
4.3.10. Risk-adjusted performance and rolling diagnostics 129
4.3.11. Inference on Sharpe differences under dependence 129
4.4. Data and cluster structure 130
4.4.1. Sample construction and data transformation 130
4.4.2. Cluster-based organization of variables 132
4.4.3. Bitcoin as the central forecasting target 134
4.4.4. Economic rationale for the cluster structure 135
4.5. Empirical Results 136
4.5.1. Short-horizon forecasts: limits of predictability under high-frequency noise 137
4.5.2. Intermediate horizons: emergence of economically meaningful predictive content 138
4.5.3. Long-horizon forecasts: dominance of structural spillovers 139
4.5.4. Consistency between MAE and RMSE: robustness of predictive gains 140
4.5.5. Economic value: from statistical predictability to investment relevance 140
4.5.6. Mechanism-based interpretation: intra- vs inter-cluster transmission… 142
4.6. Discussion and Conclusion 143

General Conclusion 146

References 151

List of Abbreviations

ADF - Augmented Dickey-Fuller test

AIC - Akaike Information Criterion

ASIC - Application-Specific Integrated Circuit

BIC - Bayesian Information Criterion

BIS - Bank for International Settlements

BTC - Bitcoin

CBECI - Cambridge Bitcoin Electricity Consumption Index

CCI - Climate Concern Index

CMA - Comprehensive Meta-Analysis

CNC - Clustered Network Connectedness

CO2 - Carbon dioxide

CPMI - Committee on Payments and Market Infrastructures

DGP - Data-generating process

DLT - Distributed Ledger Technology

ELEC - Electricity price

EMNLP - Conference on Empirical Methods in Natural Language Processing

EPU - Economic Policy Uncertainty

ESG - Environmental, Social and Governance

ETH - Ethereum

FEVD - Forecast Error Variance Decomposition

FPGA - Field-Programmable Gate Array

FROM - Directional spillovers received from others

GAS - Natural gas price

GAT - Graph Attention Network

GC - Generalized Connectedness

GPU - Graphics Processing Unit

GRU - Gated Recurrent Unit

HO - Hedges-Olkin method

IEA - International Energy Agency

IMF - International Monetary Fund

IND - Industrial production

INTER - Inter-cluster spillover graph/specification

INTRA - Intra-cluster spillover graph/specification

IRENA - International Renewable Energy Agency

MAE - Mean Absolute Error

MCBTC - Bitcoin market capitalization

MODWT - Maximal Overlap Discrete Wavelet Transform

NASDAQ - NASDAQ Composite Index

NET - Net Total Directional Connectedness

NPDC - Net Pairwise Directional Connectedness

NPT - Net Pairwise Transmission

PBTC - Bitcoin price

PoS - Proof of Stake

PoW - Proof of Work

PRISMA - Preferred Reporting Items for Systematic Reviews and Meta-Analyses

Q - Cochran’s Q statistic

RE - Random-effects model

REML - Restricted Maximum Likelihood

RENERG - Renewable energy index

RMSE - Root Mean Squared Error

SHA-256 - Secure Hash Algorithm 256-bit

SJR - SCImago Journal Rank

SOL - Solana

SP500 - S&P 500 index

TCI - Total Connectedness Index

TO - Directional spillovers transmitted to others

TVP-VAR - Time-Varying Parameter Vector Autoregression

US - United States

VAR - Vector Autoregression

VBTC - Bitcoin trading volume

VIX - CBOE Volatility Index

WTC - Wavelet Transform Coherence

XRP - Ripple

List of Figures

Figure 1.1 Bitcoin price in US dollar 14
Figure 1.2 Crude oil price in US dollar per barrel 15
Figure 1.3 The PRISMA process 18
Figure 1.4 The Baujat Plot 22
Figure 1.5 Standardized residual plot 23
Figure 1.6 The Forest Plot 24
Figure 1.7 The funnel Plot 25

Figure 2.1 Return of dataset variables 46
Figure 2.2 Comovement between environmental factors and energy 47
Figure 2.3 Comovement between environmental factors and macro 49
Figure 2.4 Comovement between environmental factors and Bitcoin 51
Figure 2.5 Comovement between energy and macro indicators 53
Figure 2.6 Comovement between energy and Bitcoin 55
Figure 2.7 Comovement between macro indicators and Bitcoin 56
Figure 2.8 Wavelet decomposition of variables 59
Figure 2.9 Total connectedness index (TCI) 62
Figure 2.10 Overall net pairwise transmission (NPT) 63
Figure 2.11 Net total directional connectedness 64
Figure 2.12 Network connectedness (decomposed series) 67
Figure A2 Total connectedness index (TCI) 78
Figure A3 Overall net pairwise transmission (NPT) 79
Figure A4 Net total directional connectedness 79
Figure A6 Network connectedness (raw series) 80
Figure A7 Environmental-energy comovement 80
Figure A8 Environmental-macro comovement 81
Figure A9 Environmental-Bitcoin comovement 83
Figure A10 Energy-macro comovement 83
Figure A11 Energy-Bitcoin comovement 85
Figure A12 Macro-Bitcoin comovement 86

Figure 3.1 Convergence of GC-CNC difference 104
Figure 3.2 Kernel density of connectedness 108
Figure 3.3 Clustered network graph 109
Figure 3.4 Dynamic net directional connectedness 111
Figure 3.5 Variance decomposition across clusters 112
Figure 3.6 GC minus CNC differences 113

Figure 4.1 Forecasting accuracy (MAE and RMSE) 138
Figure 4.2 Economic value diagnostics 141

List of Tables

Table 1.1 Selected studies on Bitcoin-Oil nexus 20
Table 1.2 Synthesis of collected estimates 21
Table 1.3 Funnel plot asymmetry test 25

Table 2.1 Variables and data sources 44
Table 2.2 Summary statistics and stochastic properties 45
Table 2.3 Wavelet frequency scale correspondence 58
Table 2.4 Return spillovers between variables 68
Table A1 ADF stationarity test 78

Table 3.1 Variables and data sources 94
Table 3.2 Optimal VAR Lag Selection 96
Table 3.3 Data-generating processes (DGP) 100
Table 3.4 Population connectedness (×100) 102
Table 3.5 Monte Carlo results - DGP1 104
Table 3.6 Monte Carlo results - DGP2 105
Table 3.7 Summary statistics 107

Table 4.1 Variables, sources and cluster assignment 131
Table 4.2 Descriptive statistics 132

1 Chapitre 0 : Introduction générale

Au cours de la dernière décennie, le système financier mondial a connu des transformations dont l'interprétation dépasse de plus en plus les cadres traditionnels qui distinguent la finance numérique, les marchés des matières premières et l'économie de l'environnement. La numérisation de la monnaie et des systèmes de paiement s'est accélérée, les marchés de l'énergie sont devenus plus instables et davantage exposés aux tensions géopolitiques, tandis que les enjeux liés au climat et à la durabilité occupent désormais une place centrale dans la réglementation financière, les stratégies d'investissement et la surveillance macroéconomique. Ces évolutions ne constituent pas de simples tendances parallèles. Elles interagissent de manière croissante, donnant naissance à de nouveaux canaux d'interdépendance entre les actifs, les secteurs et les institutions. Dans ce contexte, l'essor des cryptomonnaies ne s'est pas produit de manière isolée. Il s'est inscrit dans une période marquée par l'intensification des préoccupations relatives à la sécurité énergétique, à l'intensité carbone, à la volatilité des prix des matières premières et à l'architecture de l'intermédiation financière moderne, autant de dimensions devenues étroitement imbriquées (BIS, 2024 ; IMF, 2024 ; IEA, 2024 ; World Bank, 2024).

Les cryptomonnaies ont progressivement évolué d'une innovation technologique marginale vers une composante désormais visible des marchés financiers mondiaux. Elles sont aujourd'hui négociées en continu, intégrées aux stratégies spéculatives et de couverture, et de plus en plus analysées à travers les mêmes prismes que les actifs financiers traditionnels, notamment sous l'angle de la volatilité, de la diversification, des effets de contagion (spillovers) et du risque systémique. Elles conservent néanmoins une caractéristique économique singulière : contrairement à de nombreux actifs financiers conventionnels, leur valorisation et leur fonctionnement reposent en partie sur des infrastructures physiques, en particulier dans les

systèmes fondés sur le mécanisme de preuve de travail (*Proof-of-Work*). Dans ces systèmes, la validation des transactions nécessite une activité de minage intensivement consommatrice de puissance de calcul, impliquant une consommation importante d'électricité et établissant ainsi un lien direct entre les marchés des actifs numériques, les prix de l'énergie, les systèmes électriques et l'intensité carbone de la production d'électricité. Cette double nature, à la fois financière et infrastructurelle, fait des cryptomonnaies un objet d'étude particulièrement pertinent pour analyser les interactions entre l'innovation numérique, les dynamiques macrofinancières, les marchés de l'énergie et les enjeux environnementaux (Corbet *et al.*, 2019 ; de Vries, 2018 ; Krause et Tolaymat, 2018 ; Stoll *et al.*, 2019).

Cette thèse repose sur l'idée que les cryptomonnaies ne peuvent plus être considérées comme de simples instruments numériques isolés, dont le comportement pourrait être pleinement expliqué à travers une analyse limitée aux seuls marchés des cryptoactifs. Leur valorisation, leur volatilité ainsi que leur importance croissante au sein du système financier sont désormais influencées par des facteurs extérieurs à l'écosystème des cryptomonnaies lui-même : le coût et la disponibilité de l'énergie, l'instabilité des marchés pétroliers et électriques, la transmission des chocs inflationnistes et monétaires, ainsi que l'importance grandissante des contraintes liées à la durabilité et des flux d'investissement responsables. De ces interactions émerge un nexus plus large associant cryptomonnaies, énergie, macrofinance et environnement, au sein duquel les chocs peuvent se propager par des canaux multiples et évolutifs. L'hypothèse centrale de cette thèse est que ce nexus ne constitue ni une relation fortuite ni un phénomène transitoire. Il représente au contraire un système structuré d'interdépendances qui mérite d'être conceptualisé, mesuré, interprété et, à terme, exploité à des fins prédictives.

La littérature académique fournit un socle solide pour examiner cette problématique, mais elle demeure fragmentée d'une manière qui limite une compréhension globale du phénomène. Un premier courant de recherche analyse les cryptomonnaies en tant qu'actifs financiers et s'intéresse à leurs propriétés de rendement, à leur intérêt dans la construction de portefeuilles ainsi qu'à leurs interactions avec les marchés financiers traditionnels. Un deuxième courant met l'accent sur l'empreinte environnementale du minage des cryptomonnaies et sur l'intensité énergétique des mécanismes fondés sur la preuve de travail (*Proof-of-Work*). Un troisième courant étudie les effets de transmission, de contagion et de connectivité entre les marchés financiers et les marchés des matières premières au moyen des décompositions de la variance de l'erreur de prévision (*Forecast Error Variance Decomposition*, FEVD) et d'approches apparentées fondées sur l'analyse des réseaux. Chacun de ces courants a apporté des contributions importantes. Toutefois, ils ne convergent pas vers un cadre unifié permettant

d'expliquer de manière cohérente la coévolution des cryptomonnaies, des variables énergétiques, des indicateurs macrofinanciers et des actifs environnementaux au sein d'un même système. En conséquence, la littérature apporte souvent des réponses partielles à des questions qui sont, dans la réalité, profondément interdépendantes (Corbet *et al.*, 2019 ; de Vries, 2018 ; Krause et Tolaymat, 2018 ; Diebold et Yilmaz, 2012, 2014).

Une première limite réside dans le champ empirique de nombreux travaux existants. Une part importante de la littérature se concentre sur des relations bilatérales, telles que le lien entre le Bitcoin et le pétrole, entre les cryptomonnaies et les énergies renouvelables, ou encore entre les actifs numériques et les mesures d'incertitude. Bien que ces études apportent des enseignements utiles, elles ne sont pas conçues pour appréhender l'architecture globale des mécanismes de transmission au sein d'un système fortement interconnecté. Lorsque l'analyse empirique se limite à des relations par paires ou à un ensemble très restreint de variables, il devient difficile d'évaluer la manière dont les chocs se propagent simultanément entre les différentes composantes du nexus, ainsi que l'évolution du rôle de chaque marché lorsque l'ensemble du système est pris en considération.

Une deuxième limite concerne l'interprétation des mesures de connectivité (*connectedness*). La littérature sur la connectivité a démontré de manière convaincante que les décompositions de la variance de l'erreur de prévision issues des modèles VAR constituent un cadre à la fois souple et pertinent pour quantifier les effets de transmission directionnels entre les marchés. Toutefois, les mesures classiques de connectivité tendent à amalgamer des formes de dépendance qui sont conceptuellement distinctes. Plus précisément, elles ne permettent pas toujours de distinguer les co-mouvements observés entre des variables appartenant à un même groupe économique des véritables transmissions entre groupes économiquement distincts. Cette distinction est pourtant essentielle, tant du point de vue économique qu'économétrique. Les co-mouvements intra-groupes traduisent principalement des phénomènes d'interdépendance, d'exposition commune ou de fondamentaux partagés, tandis que les transmissions inter-groupes reflètent davantage des mécanismes de contagion, de propagation systémique et de diffusion des chocs entre différentes composantes d'un système qui ne peuvent être considérées comme homogènes. L'approche des fonctions de réponse impulsionnelle généralisées introduite par Koop, Pesaran et Potter (1996), puis développée par Pesaran et Shin (1998), fournit un cadre invariant à l'ordre des variables pour l'analyse des chocs. Néanmoins, les travaux récents consacrés à la *Clustered Network Connectedness* montrent que même cette approche peut conduire à une surestimation de la transmission systémique lorsque la structure en groupes (clusters) est ignorée (Koop *et al.*, 1996 ; Pesaran et Shin, 1998 ; Buchwalter *et al.*, 2026).

Une troisième limite concerne le rôle même de la connectivité. Une grande partie de la littérature considère la connectivité comme une finalité descriptive, c'est-à-dire comme un outil permettant d'identifier les variables qui transmettent les chocs, celles qui les reçoivent et l'intensité des relations qui les unissent à un instant donné. Cette fonction descriptive est essentielle, mais elle n'épuise pas nécessairement toute l'information contenue dans le réseau. Si la connectivité résume l'architecture des mécanismes de transmission au sein d'un système dynamique, elle peut également renfermer une information prospective susceptible d'améliorer les performances des modèles de prévision. Cette perspective est d'autant plus pertinente que les méthodes d'apprentissage fondées sur les graphes ont précisément été développées pour exploiter des informations relationnelles structurées. Autrement dit, si les matrices de spillovers traduisent des relations économiquement significatives entre les variables, elles peuvent également servir de matrices d'adjacence dynamiques pour alimenter des modèles prédictifs dépassant les approches conventionnelles des séries temporelles (Veličković *et al.*, 2018 ; Chung *et al.*, 2014). L'objectif de cette thèse est de répondre à ces différentes lacunes au moyen d'une démarche de recherche cumulative qui progresse de la clarification conceptuelle à la caractérisation empirique, de la caractérisation empirique à l'identification structurelle, puis de l'identification structurelle à la prévision. L'ambition n'est pas uniquement de montrer que les cryptomonnaies entretiennent des liens avec les variables énergétiques et environnementales, ni simplement de mettre en évidence l'existence de mécanismes de transmission. Il s'agit avant tout de démontrer que l'architecture du nexus cryptomonnaies–énergie–macrofinance–environnement peut être analysée comme un objet économique cohérent, dont la structure revêt une importance déterminante pour l'interprétation économique, la mesure du risque systémique et les performances prédictives.

Plus précisément, cette thèse s'articule autour de quatre questions de recherche interdépendantes. La première est d'ordre conceptuel : comment définir le nexus cryptomonnaies–énergie–macrofinance–environnement, et par quels mécanismes les actifs numériques, les prix de l'énergie, les conditions macrofinancières et les contraintes environnementales interagissent-ils ? La deuxième porte sur la structure empirique de ce système : quelle est l'intensité des interdépendances qui le caractérisent, comment celles-ci évoluent-elles au cours du temps et dans quelle mesure diffèrent-elles selon les horizons temporels ? La troisième concerne l'identification : est-il possible de décomposer la connectivité observée de manière à distinguer les co-mouvements intra-groupes des véritables mécanismes de transmission entre groupes ? Enfin, la quatrième question porte sur la prévision : une fois la connectivité mesurée et affinée sur le plan structurel, contient-elle une information

prédictive susceptible d'améliorer les prévisions des rendements du Bitcoin et de produire des signaux économiquement pertinents ?

Ces quatre questions ne sont pas abordées comme des problématiques indépendantes, mais comme les différentes composantes d'un même programme de recherche. La phase de conceptualisation est indispensable, dans la mesure où l'existence même du nexus ne peut être postulée a priori ; elle doit être justifiée sur des fondements théoriques et économiques. La caractérisation empirique est ensuite nécessaire, car la cohérence conceptuelle ne suffit pas à établir l'importance quantitative des interdépendances. Dès lors que la connectivité apparaît comme un phénomène majeur, une étape d'identification structurelle devient indispensable, puisque l'interprétation économique des spillovers dépend directement de la manière dont ils sont mesurés. Enfin, la prévision constitue l'aboutissement logique de cette démarche : une mesure de connectivité dotée d'une interprétation économique solide est également susceptible de présenter une réelle utilité prédictive. La contribution de cette thèse ne réside donc pas dans un résultat empirique isolé, mais dans l'articulation progressive et cohérente de ces différentes étapes de recherche.

Le chapitre 1 constitue le socle conceptuel de la thèse. Il propose une revue de littérature approfondie consacrée au nexus cryptomonnaies–énergie–macrofinance–environnement et montre pourquoi ces différents domaines doivent être étudiés conjointement plutôt que séparément. Le chapitre retrace l'évolution des systèmes traditionnels de paiement numérique vers les registres distribués et les cryptomonnaies, en mettant en évidence les innovations institutionnelles et technologiques introduites par les systèmes fondés sur la blockchain. Il s'intéresse ensuite au mécanisme de minage fondé sur la preuve de travail (*Proof-of-Work*) et montre que la validation des transactions en cryptomonnaies ne constitue pas un processus purement virtuel, mais qu'elle repose sur des infrastructures physiques, la demande en électricité, l'efficacité des équipements informatiques et les caractéristiques locales des systèmes énergétiques. Le chapitre examine également les relations entre le pétrole brut et l'électricité, entre l'électricité et les cryptomonnaies, ainsi qu'entre le Bitcoin et le pétrole, à partir d'une approche méta-analytique, avant d'élargir la réflexion au rôle des énergies renouvelables et à la relation ambiguë entre les actifs numériques et la transition énergétique. À ce titre, ce premier chapitre remplit une fonction qui dépasse largement celle d'une simple revue de littérature. Il établit l'unité conceptuelle de la thèse en démontrant que les cryptomonnaies s'inscrivent dans un système économique et environnemental plus vaste, dont les interactions internes présentent une véritable cohérence structurelle. Son rôle est ainsi fondamental plutôt que simplement introductif.

Le chapitre 2 propose une première cartographie empirique à grande échelle du nexus. En s'appuyant sur des données mensuelles relatives aux États-Unis ainsi que sur un cadre méthodologique combinant la décomposition en ondelettes (*wavelet decomposition*) et un modèle VAR à paramètres variables dans le temps (*Time-Varying Parameter VAR*), il analyse les mécanismes de connectivité entre les cryptomonnaies, les marchés de l'énergie, les variables macrofinancières et les indicateurs environnementaux. Les résultats mettent en évidence un niveau élevé et persistant d'intégration systémique. Plus encore, ils montrent que cette connectivité présente une forte dimension multi-échelle. Les spillovers de court terme sont principalement associés aux marchés de l'énergie et aux facteurs financiers, tandis que les mécanismes de transmission de long terme sont davantage liés aux variables macroéconomiques et structurelles, telles que l'inflation, la production industrielle et les prix de l'électricité. Le chapitre met également en évidence une évolution chronologique du leadership systémique. Avant 2020, le système est principalement dominé par les interactions entre les marchés de l'énergie et les cryptomonnaies. Durant la crise de la COVID-19, la synchronisation financière devient prédominante, avant de laisser place, à partir de 2021, à une configuration davantage structurée autour des interactions entre macrofinance, énergie et environnement, évoluant progressivement vers un régime plus orienté vers les enjeux de durabilité à l'horizon 2025. Ce chapitre établit ainsi l'un des principaux faits stylisés de cette thèse : le nexus se caractérise non seulement par un niveau élevé d'interconnexion, mais également par une connectivité dynamique, dépendante des horizons temporels et sensible aux changements de régime.

Le chapitre 3 approfondit l'analyse en s'intéressant au problème d'identification laissé en suspens par les mesures traditionnelles de connectivité. Les indicateurs classiques fondés sur la décomposition de la variance de l'erreur de prévision (*Forecast Error Variance Decomposition*, FEVD) permettent de mesurer les mécanismes de transmission, mais ils ne distinguent pas clairement si l'interdépendance observée résulte de co-mouvements au sein d'un même groupe de variables ou de véritables phénomènes de contagion entre groupes économiquement distincts. Afin de répondre à cette limite, cette thèse mobilise le cadre de la *Clustered Network Connectedness* développé par Buchwalter, Diebold et Yilmaz (2026), appliqué à un système composé de quatre groupes de variables : les cryptomonnaies, les marchés de l'énergie, les indicateurs macrofinanciers et les actifs environnementaux. Les résultats montrent que les mesures généralisées de connectivité tendent à surestimer les spillovers globaux en agrégeant les dépendances intra-groupes aux mécanismes de transmission à l'échelle du système. Une fois la structure en clusters prise en compte, l'architecture du réseau devient sensiblement plus

interprétable. Le groupe des marchés de l'énergie apparaît comme un transmetteur net persistant lors des périodes de tension ; les cryptomonnaies évoluent progressivement d'une position de récepteurs nets vers celle de transmetteurs nets au cours des périodes les plus récentes ; enfin, le groupe des actifs environnementaux demeure fortement exposé aux chocs provenant des marchés de l'énergie. Les simulations de Monte Carlo confirment par ailleurs que l'écart observé entre les mesures de connectivité généralisée et celles fondées sur les clusters résulte d'un véritable biais d'identification structurelle et non d'un simple artefact lié aux propriétés des échantillons finis. Ce chapitre constitue ainsi le cœur méthodologique de la thèse en démontrant qu'une mesure pertinente de la connectivité nécessite une représentation économiquement fondée de la structure du réseau.

Le chapitre 4 prolonge cette démarche en passant de l'interprétation à la prévision. En s'appuyant sur le cadre des matrices FEVD clusterisées développé dans le chapitre précédent, il examine si des réseaux de spillovers identifiés sur des fondements économiques permettent d'améliorer les performances des prévisions hors échantillon des rendements du Bitcoin. À cette fin, les matrices FEVD clusterisées sont transformées en graphes orientés pondérés variant dans le temps, puis intégrées dans une architecture d'apprentissage sur graphes temporels combinant des mécanismes d'attention sur graphes (*Graph Attention Networks*, GAT) et des unités récurrentes à portes (*Gated Recurrent Units*, GRU). Les résultats montrent que le contenu prédictif de la connectivité dépend fortement de l'horizon de prévision considéré. Aux horizons les plus courts, les gains prédictifs demeurent limités en raison de la prédominance du bruit de haute fréquence dans la dynamique des rendements. Aux horizons intermédiaires, les améliorations deviennent plus marquées et les dépendances intra-groupes apparaissent particulièrement informatives. En revanche, aux horizons les plus longs, ce sont les spillovers inter-groupes qui dominent, le graphe inter-clusters offrant les meilleures performances, tant sur le plan statistique qu'économique. Dans l'exercice de stratégie de trading présenté, la spécification inter-clusters à horizon annuel obtient le ratio de Sharpe le plus élevé parmi l'ensemble des modèles comparés, tandis que les résultats observés aux horizons plus courts demeurent plus limités et relativement contrastés. Ce dernier chapitre empirique revêt une importance particulière puisqu'il démontre que la connectivité ne constitue pas uniquement un outil descriptif. Lorsqu'elle est correctement identifiée sur le plan économique, elle peut être transformée en un signal prédictif et intégrée dans une architecture d'apprentissage automatique capable d'améliorer de manière économiquement significative les performances de stratégies d'investissement fondées sur un ciblage de la volatilité (*volatility-targeted trading strategies*).

Pris dans leur ensemble, les différents chapitres de cette thèse apportent une contribution

cumulative et intégrée à la littérature. Premièrement, ils proposent un cadre conceptuel unifié pour l'analyse du nexus cryptomonnaies–énergie–macrofinance–environnement. Deuxièmement, ils fournissent de nouveaux résultats empiriques mettant en évidence la nature dynamique et multi-échelle des mécanismes de connectivité au sein de ce système. Troisièmement, ils améliorent la mesure de la connectivité en introduisant une logique d'identification fondée sur une structure en clusters, permettant de distinguer les co-mouvements intra-groupes des véritables phénomènes de contagion inter-groupes. Enfin, ils montrent que la connectivité, lorsqu'elle est interprétée sur des fondements structurels, peut améliorer les prévisions des rendements du Bitcoin lorsqu'elle est intégrée dans un cadre d'apprentissage sur graphes. La contribution de cette thèse réside ainsi autant dans l'enchaînement cohérent de ces différentes étapes que dans les résultats propres à chacun des chapitres.

Ces résultats s'adressent à plusieurs catégories d'acteurs. Pour les chercheurs, ils suggèrent que l'analyse des mécanismes de transmission devrait dépasser les approches fondées sur des relations bilatérales et accorder une attention plus importante à l'architecture économique qui sous-tend les canaux de propagation des chocs. Pour les décideurs publics et les autorités de régulation, ils indiquent que les cryptomonnaies ne doivent plus être appréhendées uniquement comme des actifs spéculatifs, mais également comme des composantes d'un système plus large, étroitement lié à la sécurité énergétique, aux actifs associés aux risques climatiques et aux vulnérabilités macrofinancières. Le rôle central des marchés de l'énergie en tant que principaux transmetteurs de chocs, ainsi que la forte exposition des actifs environnementaux aux perturbations énergétiques, présentent notamment des implications importantes pour la surveillance de la stabilité financière et l'évaluation des risques climatiques.

Pour les investisseurs, cette thèse montre que les mesures de connectivité peuvent être converties en signaux opérationnels utilisables dans les processus de décision. Elle met également en évidence que la distinction entre les mécanismes de transmission intra-groupes et inter-groupes ne constitue pas seulement un raffinement méthodologique, mais représente également une source potentiellement précieuse d'information prédictive pour la gestion des risques et la construction de portefeuilles.

Le reste de cette dissertation est organisé de la manière suivante. Le chapitre 1 établit les fondements conceptuels et présente la revue de littérature consacrée au nexus cryptomonnaies–énergie–macrofinance–environnement. Le chapitre 2 propose une cartographie dynamique et multi-échelle des mécanismes de transmission entre les cryptomonnaies, les marchés de

l'énergie, les variables macrofinancières et les indicateurs environnementaux. Le chapitre 3 introduit le cadre de la *Clustered Network Connectedness* afin d'affiner l'interprétation structurelle des mécanismes de transmission. Le chapitre 4 exploite cette structure de réseau identifiée pour construire des signaux de prévision au moyen d'une architecture d'apprentissage sur graphes temporels, puis en évalue les performances tant sur le plan statistique qu'économique. Enfin, la conclusion générale synthétise les principaux résultats de la thèse, discute leurs implications théoriques et pratiques, et propose plusieurs pistes de recherche pour les travaux futurs.

2 Chapter 1. The Crypto-Energy-Macrofinance-Environment Nexus: State of the Art

- Publication notes: A section of this chapter is based on joint work with Amine Lahiani and Foued Badr Gabsi. This work was published as a book chapter:

Loukil, R., Lahiani, A., & Gabsi, F. B. (2023). *The Cryptocurrency-Oil Nexus: A Meta-Analytic Perspective*. In *Resilience and Sustainable Development* (p. 116). Bloomsbury India.

1.1. Introduction

The accelerating digitalization of finance is unfolding at the same time as two major structural transitions: the reconfiguration of global energy systems and the growing urgency of climate mitigation. Cryptocurrencies, once a marginal technological curiosity, have become significant financial assets traded on global markets, while their underlying infrastructures consume amounts of electricity comparable to those of medium-sized countries (de Vries, 2018; Krause and Tolaymat, 2018). In parallel, energy markets have been reshaped by fossil fuel supply, the expansion of renewables, and recurrent geopolitical shocks, all of which have reinforced the central role of crude oil, natural gas and electricity prices in macrofinancial dynamics (IEA, 2023). These developments raise a simple but far-reaching question: how digital assets, energy markets and environmental constraints interact within a unified system of dynamic spillovers, and to what extent these interactions can be structurally identified and economically exploited. Answering this question requires treating cryptocurrencies not as an isolated "virtual" phenomenon, but as part of a broader crypto-energy-macrofinance environment nexus. On the one hand, proof-of-work[2] cryptocurrencies derive their security from energy-intensive computation, tying their cost structure and carbon footprint to fossil-fuel and electricity markets

[2] Proof-of-work is a consensus mechanism in which network participants validate transactions by solving computationally intensive cryptographic problems, requiring substantial energy consumption.

(Stoll et al., 2019; de Vries, 2021). On the other hand, crypto assets are now embedded in global portfolios and co-move with traditional risk factors, including oil prices, equity indices, interest rates and measures of economic uncertainty (Bouri et al., 2017; Okorie and Lin, 2020). This chapter sets the conceptual stage for the thesis by organizing the stylized facts and main mechanisms at work in this nexus, from payment technologies and distributed ledgers Technology (DLT)[3] to the crude oil-electricity system, the electricity-cryptocurrency link, and the emerging interactions with renewable energy.

In this thesis, the crypto-energy-macrofinance-environment nexus is defined as a dynamic system of interdependent markets in which shocks propagate across cryptocurrencies, energy prices, macrofinancial variables, and environmental indicators through time-varying transmission channels.

1.2. From digital payments to distributed ledgers and cryptocurrencies

Over recent decades, the rapid diffusion of digital technologies has transformed how economic agents pay, save, and transact. Traditional digital payments rely on a centralized architecture: each party and each intermediary (banks, payment processors, clearing houses) maintains its own ledger, and final settlement is achieved through clearing systems operated or overseen by central banks (Mills et al., 2016; CPMI, 2017). This multi-ledger architecture is robust but involves significant reconciliation costs and delays, especially in cross-border transactions.

Distributed Ledger Technology has been proposed as an alternative. A distributed ledger is a shared database replicated across a network of nodes, where each participant holds a copy of the ledger and updates are validated collectively through a consensus protocol. Once validated, a block of transactions is appended to the ledger in a way that is extremely costly to alter ex post, which enhances integrity and tamper-resistance (Narayanan et al., 2016).

Blockchain is a particular form of DLT in which transactions are recorded in "blocks" linked cryptographically in chronological order. Each block contains a hash of the previous block, a time stamp, and a batch of validated transactions. This structure enables a public, append-only, time-stamped ledger that does not require a single central operator.

On top of this infrastructure, cryptocurrencies emerged as digital assets designed to operate as a medium of exchange, store of value, or unit of account in a decentralised network. The first and most prominent cryptocurrency, Bitcoin, was proposed by the pseudonymous Satoshi

[3] Distributed ledgers are decentralized databases in which transactions are recorded and synchronized across multiple nodes without a central authority, ensuring transparency and immutability.

Nakamoto (2008). It combines: (i) a capped supply rule encoded in the protocol, (ii) a peer-to-peer transaction network, and (iii) a decentralised consensus mechanism that replaces the traditional role of central banks and clearinghouses.

Cryptocurrencies share several common features (Vejacka, 2014; Narayanan et al., 2016):

- They have no intrinsic physical form and exist only as entries on a distributed ledger.
- Supply and transaction validation are governed by protocol rules rather than a central authority.
- All transactions are recorded in a public ledger, ensuring transparency, while users remain pseudonymous via public-private key pairs.
- The system is designed to be resistant to unilateral manipulation of the money supply or transaction history.

While these features attracted substantial investor and media attention, they also created a new set of economic and environmental challenges, particularly linked to the energy-intensive nature of the consensus mechanism used by most early cryptocurrencies.

1.3. Proof-of-Work mining and the energy footprint of cryptocurrencies

1.3.1. Consensus and mining

Most first-generation cryptocurrencies, including Bitcoin and (until recently) Ethereum, rely on a Proof-of-Work (PoW) consensus mechanism. In PoW systems, "miners" compete to solve cryptographic puzzles based on hashing functions[4] (e.g. SHA-256 in Bitcoin). The first miner to find a valid solution earns the right to append a new block of transactions to the blockchain and receives a block reward plus transaction fees (Nakamoto, 2008; Narayanan et al., 2016).

This mechanism fulfils three roles simultaneously:

- It secures the network against double-spending and certain attacks (e.g. 51% attacks[5]).
- It determines the pace of new coin issuance via an algorithmically programmed reward schedule and difficulty adjustment.
- It allocates seigniorage[6] revenue to miners in proportion to their share of network computational power.

Because PoW puzzles are deliberately computationally intensive, security is obtained by

[4] Hashing functions are cryptographic algorithms that transform input data into fixed-length outputs, ensuring data integrity and enabling secure verification within blockchain systems

[5] A 51% attack refers to a situation in which a single entity or coordinated group controls a majority of the network's computational power, enabling it to manipulate transaction validation and potentially reverse recent transactions

[6] Seigniorage refers to the revenue generated from the creation of new currency. In proof-of-work systems, it takes the form of block rewards allocated to miners who validate transactions

making attacks economically prohibitive. However, it also implies that validating the network demands large amounts of electricity.

1.3.2. Hardware evolution and energy demand

The history of mining hardware illustrates the dynamic nature of this energy demand. Early Bitcoin mining was performed on standard CPU[7]s, quickly supplanted by GPU[8]s, which offered greater parallelism. Later, miners moved to Field-Programmable Gate Arrays (FPGAs[9]) and ultimately to Application-Specific Integrated Circuits (ASICs[10]) designed solely for hashing. Each step raised computational efficiency (more hashes per joule) but also increased fixed investment and favored large industrial players (Narayanan et al., 2016; Vranken, 2017).

At any point in time, the minimum electricity use of the network can be approximated as the product of the aggregate hash rate and the energy efficiency of the most efficient ASICs. In practice, aggregate consumption is higher, because many miners employ less efficient devices and additional power is required for cooling and infrastructure (Krause and Tolaymat, 2018; Stoll et al., 2019).

Despite efficiency gains at the device level, aggregate electricity demand has grown rapidly as network participation and mining difficulty increased. Estimates from the Cambridge Bitcoin Electricity Consumption Index (CBECI) and other studies (de Vries, 2018, 2021; Krause and Tolaymat, 2018) suggest that:

- Annual Bitcoin electricity consumption is comparable to that of mid-sized countries.
- The associated CO2 emissions are similar to those of some medium economies, depending on the underlying electricity mix.
- Ethereum, before its migration to Proof-of-Stake (PoS), also exhibited substantial electricity use, though below Bitcoin's level.

Cryptocurrency mining is thus not simply a digital process: it is heavily anchored in the physical energy system, with implications for fuel demand, electricity markets and climate policy.

1.3.3. Micro-level energy channels

From a micro perspective, energy enters the mining process through three main channels:

1. Embodied (physical) energy: energy required to manufacture mining equipment (ASICs, racks, cooling systems), including extraction and processing of raw materials.

[7] The Central Processing Unit (CPU) executes sequential instructions and underpins iterative econometric computations

[8] The Graphics Processing Unit (GPU) enables massively parallel computation, making it particularly efficient for large-scale matrix operations and machine learning models

[9] FPGAs reconfigurable chips used to perform specific computations more efficiently than general-purpose hardware.

[10] ASICs are specialized chips designed for a single task, offering maximum efficiency in cryptocurrency mining.

2. Operational electricity: continuous power drawn by ASICs and supporting infrastructure while solving PoW puzzles. As difficulty rises, more computations are required per unit of reward, raising electricity demand.
3. Cooling: heat generated by high-density hardware must be dissipated to avoid malfunction, which often requires energy-intensive cooling systems (fans, air conditioning, liquid cooling).

These channels imply that the location choice of mining centers is crucial. Miners tend to seek:

- Low and stable electricity prices,
- Cool climates to reduce cooling costs,
- Reliable network infrastructure
- Regulatory and political stability

1.4. Crude oil-electricity nexus

The energy used in mining is produced within a broader fossil-fuel-electricity system. Understanding how crude oil, natural gas and electricity interact is therefore essential for analysing the cost structure and environmental footprint of cryptocurrencies.

1.4.1. Direct impact of crude oil on electricity

In some countries-especially oil exporters and isolated power systems-crude oil and oil products (diesel, heavy fuel oil) are still important fuels for electricity generation. In such systems, oil price shocks can have a direct and relatively rapid impact on generation costs and, through regulated or market-based pass-through mechanisms, on wholesale and retail electricity prices. However, in most advanced economies, the direct use of oil in power generation has become small, as gas, coal, nuclear and renewables dominate the generation mix. In these contexts, the direct correlation between oil prices and electricity prices tends to be limited and concentrated in specific segments (peaking units, backup generation, certain islands).

1.4.2. Indirect impact via natural gas and price indexation

The more important channel from oil to electricity in many regions is indirect, via natural gas. Historically, a large share of gas imports in Europe and Asia has been governed by long-term contracts with prices indexed to oil (e.g. Brent, fuel oil) through formulae that smooth shocks over several months (Melling, 2010; European Commission, 2014).

Because gas-fired plants often set the marginal price in wholesale electricity markets, especially in systems where renewables and nuclear cover baseload, shocks to oil prices propagate as follows:

- Oil price ↑ → gas import price ↑ (through indexation)
- Gas price ↑ → marginal cost of gas-fired power ↑
- Wholesale electricity price ↑ (through merit-order pricing)

The strength of this channel depends on:

- The share of gas indexed to oil vs. traded on hubs and spot markets,
- The weight of gas in the generation mix,
- The degree of competition and regulation in retail tariffs.

Empirical evidence shows strong oil-gas correlations where indexation predominates, weaker correlations where hub pricing dominates, and overall moderate and heterogeneous oil-electricity correlations across Europe and other regions (European Commission, 2014; IEA, 2017).

For electricity-intensive activities such as PoW mining, this implies that oil price shocks can affect mining costs mainly where:

- Electricity prices are gas-linked, and
- Gas prices remain significantly indexed to oil.

1.5. Electricity-cryptocurrency nexus

1.5.1. Mining, electricity consumption

Cryptocurrency mining translates electricity into computational work and heat. Because networks run 24/7 and difficulty adjusts to maintain block times (e.g. 10 minutes in Bitcoin), total power demand reflects both market incentives and protocol design.

Estimating global mining electricity use is challenging due to:

- The decentralised and anonymous nature of mining,
- The lack of comprehensive data on installed hardware and locations,
- The rapid evolution of technology and profitability.

Despite these uncertainties, studies by de Vries (2018, 2021), Krause and Tolaymat (2018), Stoll et al. (2019), and Blandin et al. (2020) converge on the conclusion that:

- Total electricity use for Bitcoin mining alone lies in the tens to low hundreds of TWh per year.
- The range of estimates is wide, but even lower-bound estimates represent substantial shares of national or sectoral demand.
- When both Bitcoin and Ethereum (pre-PoS) are considered, combined consumption is comparable to that of countries such as Sweden, Thailand, or Romania, depending on

the year and methodology.

These magnitudes imply that the crypto sector is no longer negligible from the viewpoint of global electricity demand, especially in certain regions where mining is geographically concentrated.

1.5.2. Carbon footprint and comparison with traditional payment systems

The carbon footprint of mining depends on the electricity mix of the regions where miners operate. When mining relies heavily on coal or other fossil fuels, per-transaction and per-dollar emissions can far exceed those of traditional payment rails.

Comparative analyses that contrast Bitcoin and Ethereum with centralized systems like Visa find that:

- In absolute terms, global payment networks such as Visa consume more energy because they process vastly more transactions and operate large corporate infrastructures.
- In per-transaction terms, however, PoW cryptocurrencies consume orders of magnitude more energy and emit much more CO2 than card networks, even when only computational costs are considered for Visa (de Vries, 2018; Stoll et al., 2019).

These comparisons highlight that early-generation PoW cryptocurrencies are structurally misaligned with climate-mitigation objectives if they scale without major technological changes or a full shift to low-carbon electricity.

These interdependencies suggest that the relationship between cryptocurrencies, energy markets and macrofinancial variables is best captured through a network-based perspective, where shocks propagate across interconnected nodes rather than through isolated bilateral channels.

1.6. Crude oil-cryptocurrency nexus

1.6.1 Introduction

Since Bitcoin’s introduction in 2009, cryptocurrencies have evolved from a niche technological innovation into a significant segment of global financial markets. Their growing integration into financial markets has renewed interest in their links with major commodities, especially crude oil, given the role of energy prices in macrofinancial conditions and in the cost structure of proof-of-work mining. This motivates a more systematic assessment of the Bitcoin-oil relationship.

Figure 1.1 Bitcoin price in US dollar

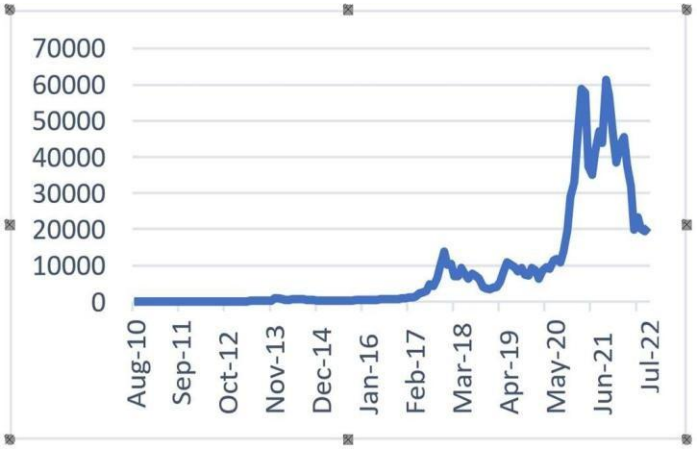

Source: Author's calculation

Consistent with this market expansion, the literature on cryptocurrencies has grown rapidly over the past decade, with increasing attention to their economic and financial characteristics as well as to their links with conventional assets and commodity markets.

In parallel, Bitcoin price fluctuations (Figure 1.1) and their links with other financial assets and commodities have attracted increasing attention from researchers (Dyhrberg, 2016; Baur et al., 2018; Klein et al., 2018; Selmi et al., 2018; Symitsi and Chalvatzis, 2019).

Crude oil is an indispensable commodity that plays a substantial role in the global economy, as evidenced by the findings of numerous studies by scholars (Kilian, 2008; Okorie and Lin, 2020). Its value lies in its widespread use as the basis for trading various financial instruments in international financial markets. Furthermore, the dependence on crude oil has increased in recent years, leading to a substantial impact on the global economy. As shown in Figure 1.2, in 2021, the global consumption of oil amounted to around 100 million barrels per day, with the United States being the leading consumer, followed by China and India, according to data from the International Energy Agency (IEA). This underlines the continuing global importance of crude oil and the breadth of its macroeconomic effects.

Moreover, oil price shocks have become a significant source of uncertainty for the world economy, especially since the mid-2000s when the oil market became financialized. This trend has been evident in recent years as the global economy experiences volatile oil prices that have led to significant economic and geopolitical consequences. According to a study by Yin et al. (2021), oil market shocks pose a considerable risk to the cryptocurrency market. The study argues that such shocks may result in a risk level that is comparable to macroeconomic changes,

particularly since the mid-2000s, when commodity markets became increasingly financialized.

Figure 1.2 Crude oil price in US dollar per barrel

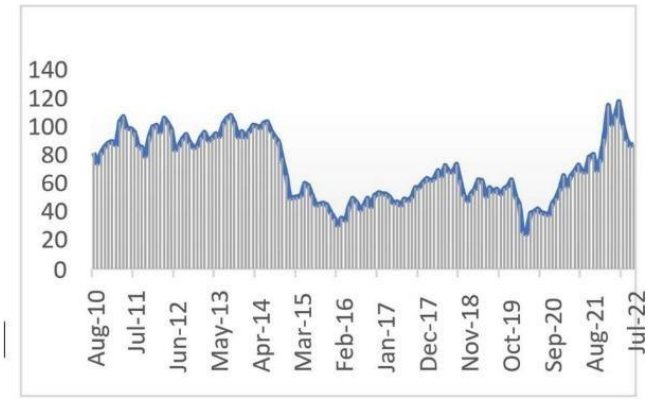

Source: Author's calculation

Previous research has shown that fluctuations in oil prices have a considerable effect on a variety of factors, including real output, inflation, monetary policy, and international interest rates. Changes in oil prices may therefore play a significant role in the uncertainty surrounding cryptocurrency prices. For investors, companies, and resource policymakers in particular, it may be crucial to look into how changes in oil prices affect other financial markets, such as the crypto market. Given that crude oil and bitcoin both have some similarities and since bitcoin is also referred to as a commodity, recent empirical studies have focused on the connections that have existed between these two commodities over the course of different market epochs in order to better inform academics, policymakers, and international investors about the potential advantages and risks of these asset markets (Dyhrberg, 2016; Bouri et al., 2018).

In fact, the purpose of our study is to examine the interdependence between bitcoin and crude oil from a meta-analytic standpoint. The selection of this interdependence for study is not arbitrary; rather, it is due to the fact the price of crude oil can indirectly affect the cost of cryptocurrency mining through its impact on electricity prices, particularly in systems where electricity generation relies on fossil fuels or gas indexed to oil prices (Melling, 2010; European Commission, 2014).

In this context, meta-analysis provides a useful quantitative framework for synthesizing the available evidence (Borenstein et al., 2009; Stanley & Doucouliagos, 2012). In this paper, we will integrate and contrast empirical data from earlier studies conducted on the cryptocurrency-oil nexus using cutting-edge methods and principles of meta-analysis proposed by Stanley and Doucouliagos (2012), Havránek et al. (2020). To our knowledge, evidence syntheses on this specific relationship remain scarce, and no prior study appears to have provided a formal meta-

analytic synthesis focused specifically on the Bitcoin-oil nexus.

In addition to synthesizing the relevant literature, meta-analysis allows the researcher to assess whether the available evidence may be affected by publication selection bias, while recognizing that such diagnostics are more informative in larger samples of studies. "Publication selection" is the act of choosing which research results to publish based on whether they are congruent with the dominant paradigm and/or statistically significant findings. As a result, the research record will over-represent more significant and more substantial impacts. The primary issue with publishing selection is not its absence, but rather the significant biases that, if left unchecked, may affect any compilation of empirical economic interpretation.

To combine the evidence reported in the selected studies, we rely on the Hunter and Schmidt meta-analytic framework, using the random-effects version discussed in Hunter and Schmidt (2004) and Schmidt and Hunter (2015). Unlike a narrative review, meta-analysis provides a quantitative framework for summarizing evidence across studies. To specifically analyze the effects of the nexus, we apply the random-effects form of the HS procedure. To examine the impact of publishing quality and gauge the COVID-19 period's influence, we incorporate moderation analyses into the main analysis.

1.6.2 Data and Methodology

Our three-step procedure for obtaining meta-estimates follows the meta-analytic framework of Hunter and Schmidt (2004). First, we conducted the literature search, extracted and coded the relevant information, and retained studies that were conceptually comparable and relied on sufficiently similar statistical evidence to permit quantitative synthesis.

As a result of its many benefits, we have decided to use the modified procedure developed by Schmidt and Hunter (2015). This method presents at least three advantages: First, it does not make any assumptions about the sample distribution. Second, its mean squared errors are smaller than those obtained by the HO, DL, and REML methods. Third, it allows for the use of moderator analyses even when the number of studies is small (Veroniki et al., 2016).

The terms "cryptocurrency", "crypto-asset", "digital asset", "Bitcoin", "crude oil", "oil", "Bitcoin-oil correlation", "cryptocurrency and oil", and "commodities and cryptocurrencies" were used to identify studies examining the relationship between cryptocurrencies and oil prices. The search was conducted using Web of Science, Publons, Google Scholar, and Scopus, and was complemented by manual searches in relevant finance, economics, and management journals as well as by screening the reference lists of recent studies. Given data-availability and

comparability constraints, the sample was restricted to peer-reviewed journal articles; this restriction should be interpreted as a practical selection criterion rather than as a way to eliminate publication bias.

To construct the final sample, we followed the PRISMA procedure (Preferred Reporting Items for Systematic Reviews and Meta-Analyses; Moher et al., 2009). As shown in Figure 1.3, the procedure involves four stages: identification, screening, eligibility, and inclusion. After combining the records and removing duplicates with Zotero, the initial search yielded 107 articles. In the screening stage, we retained only peer-reviewed journal articles and excluded books, conference papers, and proceedings. This step reduced the sample to 62 articles.

We then examined the remaining papers more carefully using the following eligibility criteria. (i) Cryptocurrency and oil should be the studies' primary subject. (ii) Studies with uncertain concept definitions or papers on mathematical modeling are not included. (iii) The investigation must be quantitative and either report Pearson's correlation directly or provide test statistics from which a correlation measure can be consistently derived. In fact, Pearson's correlations provide more reliable meta- analytic findings (Roth et al., 2018). At this stage, 51 studies were excluded because they did not meet all the eligibility criteria. The final sample therefore consists of 11 studies.

Figure 1.3 The PRISMA process

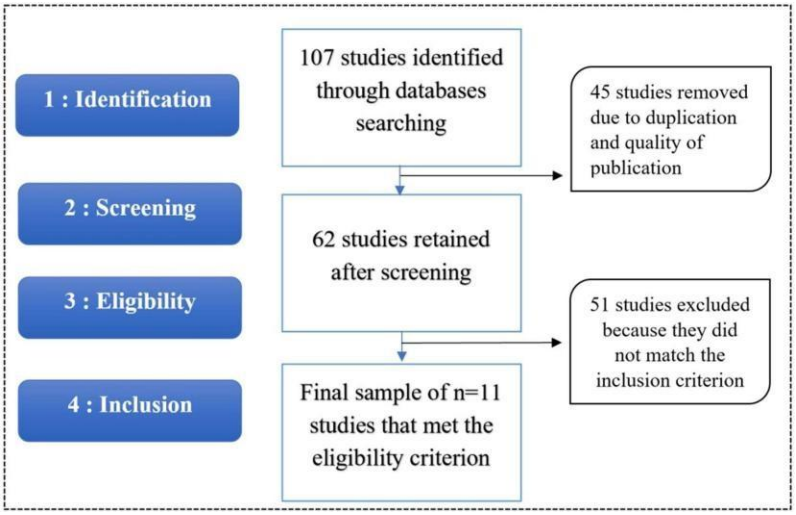

Source: Author's analysis

We have adopted Schmidt and Hunter's (2015) meta-analysis approach, which employs the random-effects model to statistically aggregate empirical findings from multiple studies. The meta-analysis in our study is performed as follows:

- Mean effect size:

The correlation measure, also known as the effect size, is calculated as the first step, and is used to reflect the results of sampling research. Specifically, we calculate Pearson association values between cryptocurrency and petroleum oil prices. As a result, we have to extract data on statistics like t-statistics or p-values and convert them to correlation coefficients because relatively few studies report the correlation coefficient directly. We calculate the effect size (θ_i) for the ith $(\mathrm{i} = 1,2, \ldots, \mathrm{n})$ research using the method supplied by Rosenthal (1991) from a given z- or p-value using the following formula:

$$\theta_i = \frac{t}{\sqrt{n}} \quad \textbf{(1.1)}$$

By averaging the effect values from each individual research and assigning each a weight, we can determine the overall mean influence when the writers use more than one metric.

- Standard error:

The second step involves determining the standard error by assuming that the study's variations are constant, followed by the z-test to evaluate the meta-general analysis's hypothesis.

- Q-test of Homogeneity:

Third, we use a chi-square measure with $\mathrm{n} - 1$ degrees of freedom, known as Cochrane's Q-statistic, to look for variation between studies. If the Q-statistic is high enough, we can reject the null hypothesis that the included papers have similar variances.

- Choice between fixed and random effects:

In the end, picking a fixed- or random-effects meta-analysis approach is what it takes to calculate the influence summary (Borenstein et al., 2010). Fixed-effects models assume that individual study effect sizes are unique and reflect set values, while random-effects models assume that effect sizes are representative of the community as a whole (Hedges, 1983; DerSimonian and Laird, 1986).

When variability is minimal or when the Q-test fails to reject the null hypothesis, the fixed-effects model is appropriate. On the other hand, when an unobserved chance factor is present and heterogeneity is substantial, the random-effects model is preferred.

With the homogeneity test (Q-test) being rejected, the random-effects version of the Hunter-Schmidt model is favored here (see Section 3 for more details). An explanation of the random-effects model used in this analysis is as follows. Let's consider the following model:

$$\theta_i = \eta_i + \theta_i + \varepsilon_i \quad \textbf{(1.2)}$$

where θ_i is the estimated effect size for the ith study that corresponds to the true unknown effect

size θ_i, η_i refers to a non-sampling error, and ε_i is a sampling error term.

η_i and ε_i are considered to be independent with $\eta_i \sim N(0, r^2)$ and $\varepsilon_i \sim N(0, \sigma^2)$.

The between-study variance parameter is estimated following the Hunter-Schmidt random-effects framework.

$$r^2 = Q - \frac{n}{\sum_{i=1}^{n} w_i} \quad \textbf{(1.3)}$$

Therefore, we use the more cautious random-effects model, which adjusts the weight for each study to allow for non-sampling variation.

Finally, a forest image is used to illustrate the impact summary based on the random-effects model, drawing attention to the variation in effect sizes across studies.

1.6.3 Empirical results and discussion

A meta-analysis may be carried out using a variety of tools, including Comprehensive Meta-Analysis (CMA) and SPSS syntax files. The R libraries "metafor" (Viechtbauer, 2010) and "robumeta"(Fisher and Tipton, 2015) have been utilized throughout this chapter. Thanks to its open-source nature and the ease with which the scripts it uses can be shared and duplicated; R makes an excellent software program for meta-analyses.

Table 1.1 presents the dataset of 11 studies, including publication year, Pearson correlations, sample sizes, and the three moderator variables. The first moderator is the SJR journal quartile, used to assess whether journal quality affects the reported relationship. The second moderator captures whether the underlying sample period includes the COVID-19 episode. The third moderator is publication year.

Table 1.1 Selected studies on Bitcoin-Oil nexus

Study ID	Authors	Year	Sample size	Pearson Correlation	Sample Period	SJR Q-Rank	Covid Period
1	Selmi et al.	2018	680	-0.2025	13/09/2011 - 29/07/2017	1	0
2	Ji et al.	2019	819	-0.1700	15/08/2015 - 27/09/2018	1	0
3	Giudici et al.	2019	405	0.3050	18/04/2016 - 30/04/2018	1	0
4	Owusu Junior et al.	2020	1500	-0.1530	30/04/2013 - 18/04/2019	3	0
5	Ozturk	2020	777	0.1300	03/01/2017 - 31/12/2019	3	0
6	Jareno et al.	2021	376	-0.1287	20/11/2018 - 30/06/2020	1	0

Study ID	Authors	Year	Sample size	Pearson Correlation	Sample Period	SJR Q-Rank	Covid Period
7	Mondal et al.	2021	311	0.1900	01/01/2015 - 01/11/2020	4	1
8	Zeeshan et al.	2022	484	0.3200	22/01/2020 - 20/12/2021	1	1
9	Będowska-Sójka et al.	2022	392	0.1200	10/02/2020 - 10/02/2022	1	1
10	Ghorbel et al.	2022	571	-0.2040	01/01/2019 - 23/02/2021	1	1
11	Kumah et al.	2022	877	0.2040	10/08/2015 - 18/02/2019	3	0

Within-study error and actual effect size heterogeneity are the two factors that affect the observed effects differently. We are interested in the actual effect size heterogeneity. Q-statistics, which measure the ratio of observed variation to within-study variance, can be used to estimate the proportion of observed variability that may be due to genuine between-studies variation. The Q-statistic tests the null hypothesis that all studies share the same underlying effect size. In this way, a statistically significant Q-statistic indicates that the studied papers do not all have the same impact magnitude.

In a similar vein, the I^2 indicates what proportion of the observed discrepancy can be attributed to variations between studies as opposed to changes within individual studies. I^2 thresholds of 25, 50, and 75% have been suggested (Higgins et al., 2003) to determine low, moderate, and large variance, respectively. I^2 has a key advantage over Q-statistic, in that it is not sensitive to the quantity of research included. In random-effects models, the Tau-squared statistic can also be used as a measure of the overall variability present in the research. A zero value of Tau-squared means that there is no heterogeneity.

As shown in Table 1.2, the overall I2 statistic was 96.55%, indicating extremely high between-study heterogeneity. Moreover, the significant Q-statistic together with the estimated tau-squared indicate substantial between-study heterogeneity, which is inconsistent with the assumption of a common underlying effect size. Even though these tests investigate heterogeneity, they do not reveal which research may be unduly impacting heterogeneity. Baujat et al. (2002) proposed a visualization to find studies that significantly affect variability and the general result. Research in the upper right portion of the graph might have an effect on the outcomes. Figure 1.4 suggests that studies 10, 3, and 8 contribute more than the others to

the observed heterogeneity.

Table 1.2. Synthesis of collected estimates

Model / Specification	k	Estimate ($\hat{\theta}$)	Std. Error	95% CI [L, U]	Tau² (τ^2)	I² (%)	H²	Q-statistic (Cochran Q)
Overall analysis								
Random-effects model (RE)	11	0.0377*	(0.0646)	[-0.0880, 0.1643]	0.0440	96.55	28.95	279.24***
Unrestricted WLS (unadjusted)	11	0.0376	(0.0616)	[-0.0880, 0.1643]	0.0399			279.25***
Unrestricted WLS (adjusted)	11	-0.0776	(0.0344)	[-0.1450, -0.0102]				279.24***
Moderator analysis								
Quality (intercept)	11	0.0065		[-0.1649, 0.1779]	0.0515			
COVID-19 (intercept)	11	-0.0019		[-0.1630, 0.1593]				
Year (intercept)	11	0.0489		[-0.0426, 0.1405]				

Notes: ***, **, and * denote statistical significance at the 1%, 5%, and 10% levels, respectively. The numbers in brackets denote standard deviation values of the statistics.
a: Null hypothesis: The synthesized effect size is zero. b: Null hypothesis: Effect sizes are homogeneous.
c: Ranged between 0 and 100%, with larger scores indicating heterogeneity

Figure 1.4 The Baujat Plot

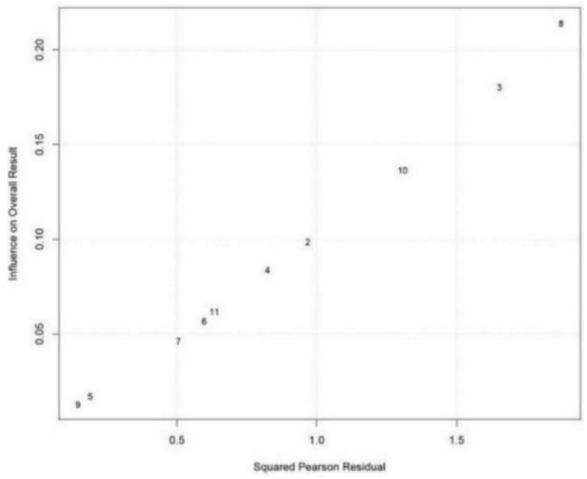

Figure 1.5 presents the standardized residual plot, which is useful for detecting potentially influential studies. Each dot represents one study. In our case, no observation appears to be

sufficiently extreme to suggest the presence of a strongly influential outlier.

Forest plots provide a visual summary of the estimated overall effect size together with the individual study effect sizes and their 95% confidence intervals. Figure 1.6 presents the forest plot based on our dataset. The lower diamond represents the pooled effect, and its width reflects the 95% confidence interval. The large I^2 statistic and the significant Q-statistic are consistent with the substantial heterogeneity visible across studies. In the random-effects model, the size of each square reflects the relative weight assigned to the corresponding study.

Figure 1.5 Standardized residual plot

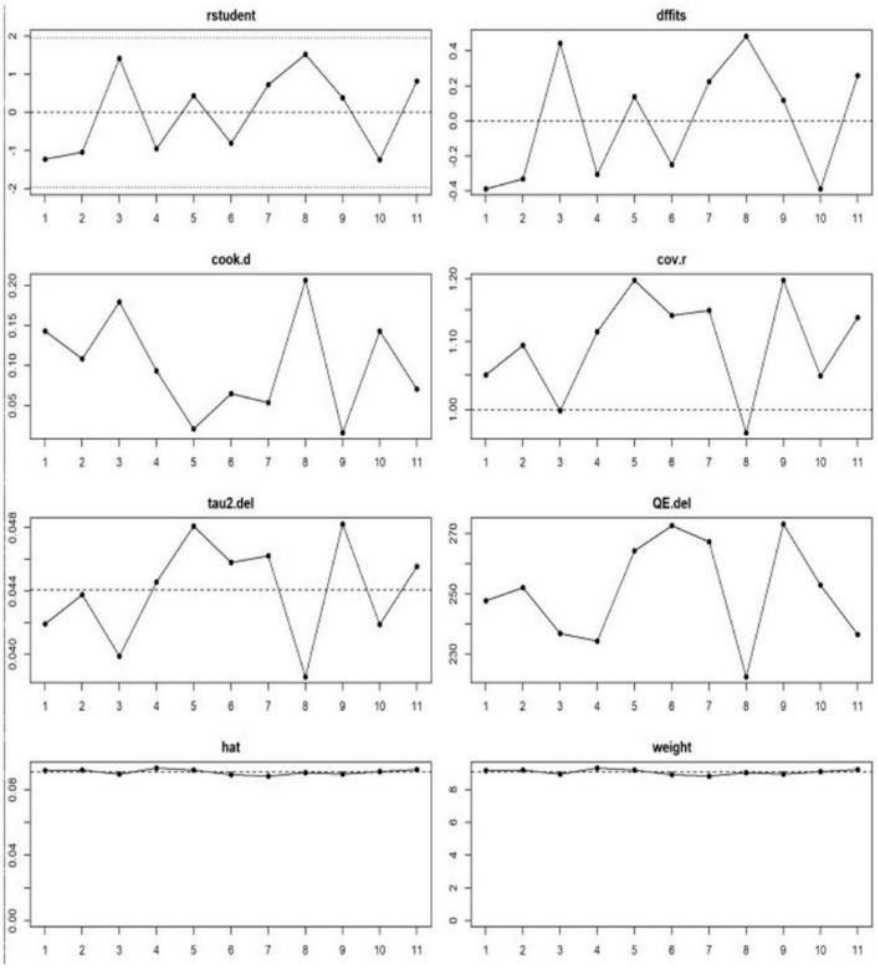

Studies with bigger impact sizes are more likely to be published and later included in a meta-analysis, which is known as publication bias. A funnel diagram is the most popular instrument for displaying possible publishing bias in meta-analyses. These graphs display the various impact values along the horizontal axis and the corresponding standard deviations along the vertical axis.

The studies with lower standard deviations are found at the apex of the funnel image. The funnel lines depict the expected range of dispersion for a given degree of standard error. They are focused on the vertical line that represents the overall impact magnitude. In reality, a substantial departure from the straight line in the impact magnitude of the study with a low standard error would be improbable. Given that the vertical line represents the total of all the studies, these scores should be spread evenly on both sides of the line. According to publishing bias, studies with unimportant findings are less likely to be released. Accordingly, if a substantial favorable influence were found, say for the total effect size, the vertical line would be situated to the right of zero. Any study that found no substantial difference would be false around zero, so if the funnel is irregular, with more studies that are strongly linked to the right side of the line, this is evidence in favor of publishing bias (Figure 1.7).

Figure 1.6 The Forest Plot

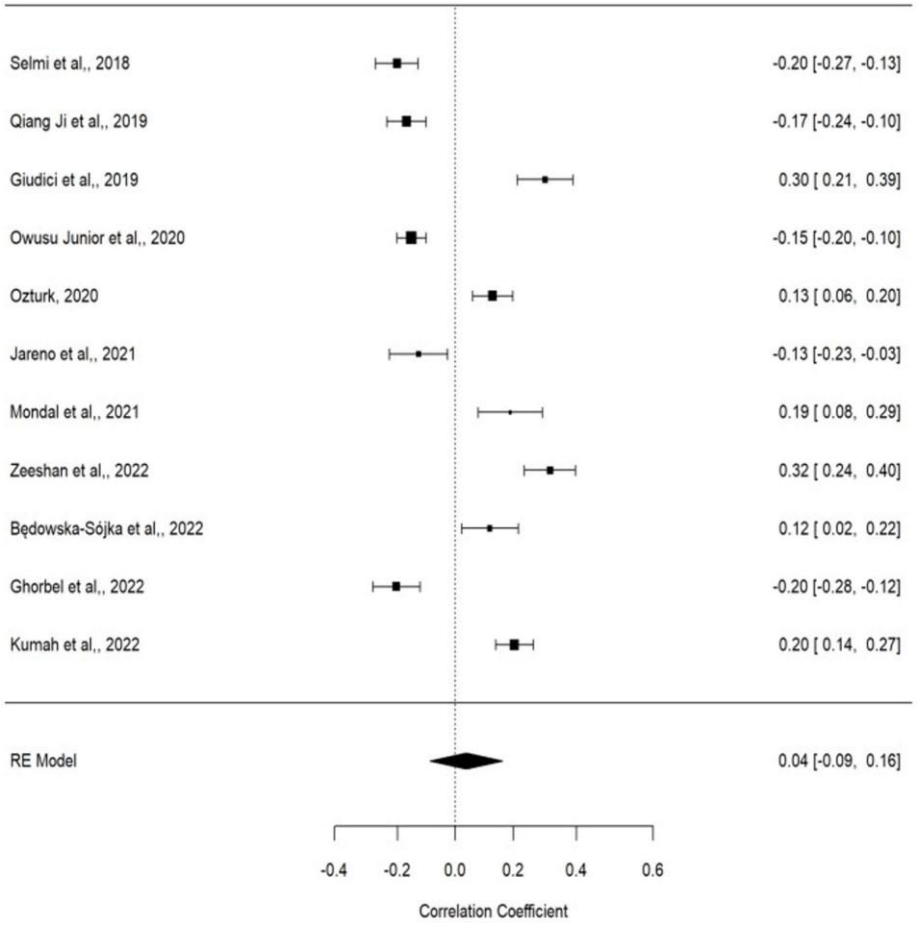

Figure 1.7 The funnel Plot

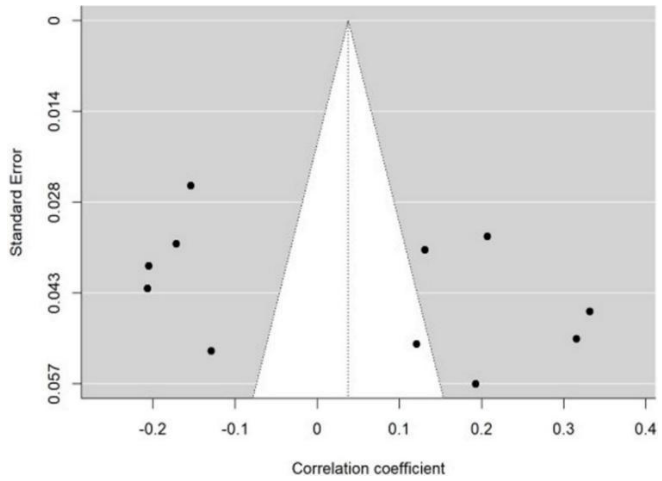

The fact that funnel plots only provide an arbitrary measurement of possible publication bias is another flaw in them. To determine an objective assessment of possible bias, two tests are frequently used. Using the rank correlation test, effect estimates and sample variances from each research are compared to see if they are linked. A non-symmetrical funnel plot is consistent with a significant test ($p < 0.05$). The strength of the rank correlation test may be low for moderate-sized meta-analyses (Sterne et al., 2000). For meta-analyses with fewer than 25 papers, an alternative measure, Egger's regression test, may be more suitable. (Egger et al., 1997).

Table 1.3 Regression test for funnel plot asymmetry

	Egger regression test	**p-value**	**Rank correlation test (Kendall's tau)**	**p-value**
Mixed-effects model Predictor: standard error	1.3146	0.1886	0.2000	0.4454

The results reported in Table 1.3 show that neither the rank correlation test nor Egger's regression test rejects the null hypothesis of funnel-plot symmetry. However, given the small number of included studies, these results should be interpreted cautiously because the statistical power of such tests is limited. Moderating variables can be used to explain a portion of the reported differences. In order to ascertain the source of heterogeneity and the extent to which it contributes to the observed variation in effect sizes between studies, a moderator analysis may be carried out. Findings from this analysis indicate that neither the publication year nor the

quality of the article had a moderating effect, as indicated in Table 1.2. The examination of our dataset also revealed that adding the COVID-19 era to the papers' utilized samples did not affect the correlation in any way. These findings could imply the existence of other, as yet undiscovered causes of research heterogeneity. The available evidence remains highly heterogeneous across studies. Based on 11 prior studies, the meta-analysis points to a very small average association between Bitcoin and crude oil prices. However, the extremely high heterogeneity and the fact that the pooled confidence interval includes zero suggest that this relationship is not stable across samples, market regimes, and empirical specifications. The evidence is therefore more consistent with a weak, unstable, and context-dependent link than with a robust and uniform structural association. One possible interpretation is that the Bitcoin-oil relationship partly reflects indirect energy-cost and macrofinancial channels rather than a stable direct linkage. However, given the strong heterogeneity of the evidence, this interpretation should remain cautious and deserves further investigation.

1.7. Cryptocurrency-Renewable Energy Nexus

The rapid expansion of cryptocurrencies has brought to the forefront a central tension between digital innovation and environmental sustainability. Proof-of-Work (PoW) blockchains rely on energy-intensive validation processes, which means that the growth of crypto-asset markets can generate substantial electricity demand and associated carbon emissions. This issue has become increasingly important as Bitcoin and other PoW-based cryptocurrencies have moved from niche technological experiments to visible components of the global financial system. A growing body of research shows that the environmental footprint of these systems depends not only on the volume of mining activity, but also on the electricity mix used to power it and on the geographical distribution of mining operations (de Vries, 2018; Krause and Tolaymat, 2018; Stoll et al., 2019; OECD, 2022).

At the same time, the environmental assessment of cryptocurrency mining remains more complex than a simple opposition between “dirty” and “clean” energy. Mining activity is highly mobile and tends to concentrate in locations where electricity is inexpensive, infrastructure is reliable, and regulation is relatively accommodating. Because the location of mining changes over time, and because miners may combine different sources of electricity across regions and seasons, the underlying energy mix is difficult to observe precisely. This is one reason why estimates of the renewable share of mining vary across studies and should be interpreted with caution. The Cambridge Centre for Alternative Finance reports that mining facilities often use a mixed energy portfolio and estimated an average renewable share of around 39% in the 3rd Global Cryptoasset Benchmarking Study, while later research emphasized that large

uncertainties remain regarding the actual carbon intensity of mining and the representativeness of available data (Blandin et al., 2020; de Vries et al., 2022).

From this perspective, renewable energy is often presented as the most plausible route for reducing the environmental burden of cryptocurrency mining. Renewable electricity-whether hydro, wind, solar, or geothermal-has a lower carbon intensity than fossil-fuel-based generation and can therefore substantially reduce the emissions associated with PoW validation. However, lower carbon intensity does not eliminate the core issue: mining still requires large quantities of electricity, and its sustainability depends on whether it uses genuinely additional low-carbon supply or instead competes with other users for scarce clean electricity. In other words, the relevant question is not only whether miners use renewable power, but also whether the expansion of mining supports or undermines broader decarbonization objectives (de Vries et al., 2022; OECD, 2022).

The broader energy context makes this question particularly important. The global energy system is undergoing a transition characterized by the rapid deployment of renewables, continuing pressure to reduce emissions, and a decline in the cost of several renewable technologies. Recent IEA and IRENA reports show that renewables are gaining a larger role in electricity systems and that the cost competitiveness of solar and wind has improved markedly in many jurisdictions (IEA, 2023; IRENA, 2024). This evolving landscape creates a potential intersection between cryptocurrency mining and renewable energy development: in principle, miners may be attracted to regions with relatively abundant low-cost renewable electricity, especially where surplus generation, curtailment, or weak local demand creates low off-take prices. Yet this possibility should not be romanticized. The existence of a commercial incentive to use low-cost renewables does not imply that mining is inherently green, nor does it guarantee that it contributes positively to the energy transition.

In parallel, blockchain technology itself has been increasingly discussed as an enabling infrastructure for decentralized energy applications. The literature shows that distributed ledger systems can, under certain conditions, facilitate peer-to-peer electricity trading, support local market coordination, improve transaction traceability, and reduce some transaction costs in decentralized energy systems. Systematic reviews of blockchain in the energy sector identify applications in energy trading, certificates, flexibility markets, and grid coordination, while IRENA's innovation briefs similarly highlight the possible role of blockchain in peer-to-peer electricity trading and in broader renewable integration strategies (Andoni et al., 2019; IRENA,

2019; IRENA, 2020). These applications are conceptually distinct from crypto-mining itself, but they matter for the present thesis because they show that blockchain can be both a source of electricity demand and, in other contexts, a tool for organizing more decentralized energy systems.

A further difficulty is methodological. Estimates of the electricity consumption and carbon footprint of cryptocurrencies are sensitive to assumptions about hardware efficiency, hash rate, cooling requirements, mining location, and the treatment of off-grid or behind-the-meter generation. Lei et al. (2021) explicitly show that the measurement of blockchain energy use depends critically on methodological choices, while de Vries (2018, 2021) and de Vries et al. (2022) demonstrate that aggregate consumption can change sharply with profitability and network conditions. This implies that the environmental assessment of cryptocurrencies should remain cautious and transparent about uncertainty. It also means that the transition from Bitcoin-specific estimates to broader claims about the entire crypto ecosystem must be handled carefully, especially because energy use beyond Bitcoin can be substantial. Gallersdörfer et al. (2020) document that cryptocurrencies beyond Bitcoin also generate meaningful energy demand, reinforcing the need to consider the broader mining landscape rather than Bitcoin alone.

From an economic standpoint, the key driver of miners' behavior is cost minimization rather than environmental stewardship. Mining is an extremely competitive activity, and profitability depends heavily on the price of electricity. As a result, miners have a strong incentive to seek the cheapest available power, whatever its source. In some cases, this may lead them toward hydro-rich or renewable-rich regions; in others, it may pull them toward fossil-fuel-based electricity systems where prices are low because of subsidies, weak regulation, stranded resources, or excess supply. The fact that renewable electricity can sometimes be cheap and abundant does create room for partial alignment between mining and decarbonization, but this alignment is contingent rather than automatic. The available evidence does not support the view that cryptocurrency mining is intrinsically compatible with climate goals simply because some miners use renewables (Blandin et al., 2020; de Vries et al., 2022; OECD, 2022).

Overall, the cryptocurrency-renewable energy nexus is characterized by a fundamental ambivalence. On the one hand, PoW-based cryptocurrencies remain associated with high electricity demand and potentially significant carbon emissions, particularly when mining relies on fossil-fuel-intensive grids. On the other hand, blockchain-related innovations may support

decentralized renewable-energy applications, and mining activity may, under specific conditions, exploit relatively low-carbon or otherwise underutilized electricity. The net environmental effect therefore depends on a combination of factors: the consensus mechanism used by the cryptocurrency, the actual electricity mix powering mining, the structure of local electricity markets, the pace of renewable deployment, and the regulatory framework that shapes miners' location choices and incentives. This ambiguity is precisely why the crypto-energy-macrofinance-environment nexus cannot be reduced to a simple technological narrative. It must be analyzed as an evolving system in which financial, energy, and environmental forces interact simultaneously.

1.8. Conclusion

This chapter has provided a structured overview of the emerging crypto-energy-macrofinance-environment nexus by integrating insights from digital finance, energy economics, and environmental studies. It has shown that cryptocurrencies cannot be analyzed as isolated financial innovations: their underlying technological architecture-particularly Proof-of-Work-anchors them directly in the physical energy system, while their growing financialization embeds them within global macrofinancial dynamics. As a result, interactions between crypto-assets, energy prices, and environmental constraints are not anecdotal but reflect a multi-layered system of interdependencies.

At the technological level, distributed ledgers and consensus mechanisms determine the energy intensity and cost structure of cryptocurrencies. At the market level, electricity prices-shaped by fossil fuels, natural gas linkages, and merit-order dynamics-constitute a key transmission channel between energy markets and mining activity. At the financial level, cryptocurrencies increasingly co-move with traditional assets and respond to macroeconomic uncertainty, positioning them as part of a broader risk allocation system. Finally, at the environmental level, the carbon footprint of mining and the interaction with renewable energy introduce a critical sustainability dimension, raising questions about the compatibility of digital finance with climate objectives.

The review of the literature highlights three main limitations. First, most empirical contributions remain fragmented and pairwise, focusing on isolated relationships (e.g. oil-crypto or electricity-crypto) rather than modelling the system as a joint, interconnected network. Second, existing measures of dependence often rely on reduced-form correlations or standard connectedness frameworks, which do not disentangle true structural spillovers from

contemporaneous co-movements driven by common shocks. Third, the literature has largely treated connectedness as a descriptive tool, without fully exploiting its potential as an informational variable for forecasting and decision-making.

These limitations motivate the empirical strategy adopted in the remainder of the thesis. The central hypothesis is that the crypto-energy-macrofinance-environment nexus is best understood as a dynamic, multi-scale network of spillovers, whose structure evolves over time and across horizons, and whose economic content depends critically on proper identification.

Accordingly, the thesis develops a progressive and coherent analytical framework. Chapter 2 provides a first empirical mapping of the nexus by estimating time-varying connectedness across cryptocurrencies, energy markets, macrofinancial variables, and environmental indicators. Using a multi-scale approach, it documents the existence of strong and persistent interdependencies, as well as their heterogeneity across investment horizons and economic regimes.

Building on this evidence, Chapter 3 addresses a key methodological limitation of standard connectedness measures by introducing a clustered identification strategy. This approach allows for a distinction between intra- and inter-cluster spillovers and corrects for the upward bias induced by contemporaneous correlations, thereby providing a more structurally interpretable measure of transmission mechanisms within the system.

Finally, Chapter 4 moves from description to application by investigating whether connectedness contains predictive information. By embedding network structures into a graph-based learning framework, it assesses the extent to which spillover dynamics can be transformed into economically meaningful forecasting signals, particularly for cryptocurrency returns.

Taken together, these chapters follow a clear logical progression-from conceptual synthesis to empirical mapping, then to structural identification, and ultimately to predictive exploitation of network dynamics. In doing so, the thesis contributes to bridging the gap between fragmented empirical evidence and a unified, structurally grounded understanding of the crypto-energy-macrofinance-environment nexus.

3 **Chapter 2.** Interconnected multiscale waves: Tracking shock transmission across cryptocurrency, energy, economy and the environment

- This chapter was published in *International Review of Economics & Finance* (Quartile: Q1 / ABS: 2)

Loukil, R., Boukef Jlassi, N., Gabsi, F., & Lahiani, A. (2026). Interconnected Multiscale Waves: Tracking Shock Transmission across Cryptocurrency, Energy, Economy and the Environment. *International Review of Economics & Finance*, 106, 104937. https://doi.org/10.1016/j.iref.2026.104937

ABSTRACT

This study examines the dynamic and multiscale connectedness among cryptocurrencies, energy markets, macrofinancial variables, and environmental indicators in the United States from January 2014 to June 2025. Using a hybrid framework that combines wavelet decomposition with a time-varying parameter vector autoregression (TVP-VAR), we assess spillovers across short-, medium-, and long-term horizons. The results reveal a persistently high level of systemic integration, with the Total Connectedness Index (TCI) ranging between 70% and 90% and reaching about 93% at long horizons. Three contagion regimes are identified: energy-crypto dominance before 2020, financial synchronization during the COVID-19 crisis, and a macro-energy-environmental phase after 2021 that evolves into a digital-sustainability regime by 2025. The multiscale decomposition uncovers hidden directional reversals, Bitcoin price shifts from a short-term volatility transmitter to a long-run structural influencer, while transaction and capitalization variables move from emitters to receivers as horizons lengthen. Robustness tests using a rolling-window VAR confirm the persistence of these dynamics. Overall, the evidence shows that short-term contagion is speculative and energy-driven,

whereas long-term connectedness is anchored in inflation, industrial production, and electricity prices. These findings offer actionable insights for investors and policymakers seeking to manage systemic risk and design sustainable strategies at the intersection of digital finance, energy markets, and environmental policy.

Keywords: Cryptocurrency, Energy, Environment, United States Economy, time-varying parameters vector autoregression (TVP-VAR), Network connectedness, Wavelet decomposition

2.1. Introduction

Given the escalating environmental challenges associated with climate change and ecological degradation, the transition toward sustainable energy solutions has become a global priority (Chen & Lin, 2021). The rise of Bitcoin and other cryptocurrencies has sparked debates regarding their environmental consequences (Bajra et al., 2024). Since its introduction in 2009, Bitcoin has revolutionized the financial system through decentralized payment technologies and digital asset innovation. Nevertheless, the energy-intensive nature of Bitcoin mining has significantly increased electricity consumption and carbon dioxide (CO2) emissions, raising concerns about its compatibility with global decarbonization goals (Kiliç and Altan, 2023).

The interplay between the cryptocurrency market, energy consumption, and environmental consequences poses both challenges and opportunities for economies, particularly in the United States (US); a pioneer in digital finance, energy production, and climate policy. Studying this multidimensional nexus can help clarify how shocks originating in one domain propagate to others, revealing new forms of systemic risk and potential leverage for green-transition strategies. Using monthly U.S. data from January 2014 to June 2025, this paper explores the time-frequency connectedness and dynamic spillover structure linking cryptocurrencies, energy markets, environmental indicators, and economic variables.

Previous research has examined several pairwise relationships across these domains, such as crypto-energy linkages (Corbet et al., 2021; Annamalaisamy and Jayaraman, 2024), crypto-environmental impacts (Zhang et al., 2023), and the macrofinancial implications of clean energy and carbon dynamics (Miśkiewicz et al., 2022). However, integrated frameworks that jointly assess how digital assets, energy markets, environmental outcomes, and macroeconomic

activity interact across multiple time horizons remain scarce. Recent works have begun using time-frequency methods to capture evolving comovements and spillovers of environmental attention in crypto markets (Qing and Alnafrah; 2025) and on the linkage between green bonds, renewables, and crypto-assets (Yadav et al., 2025) but these studies generally focus on bivariate relations or shorter samples, leaving open questions about multiscale dynamic interdependence. From a theoretical standpoint, the linkages among these variables can be understood through financial-energy-environment feedback mechanisms. Fluctuations in cryptocurrency valuations affect energy demand through mining incentives, while energy-price shocks influence mining profitability, investor sentiment, and capital flows into digital assets. In turn, these dynamics alter emissions patterns and environmental investment behavior, creating a bidirectional transmission channel that connects financial innovation, energy consumption, and environmental performance within the broader macroeconomic system.

Against this background, this study addresses three key questions: (i) Do comovements between cryptocurrency, energy, environmental, and economic variables vary across different time scales? (ii) Which variables act as net transmitters or receivers of shocks over time? (iii) How do these connectedness patterns evolve around major events such as the COVID-19 pandemic and the 2022 energy-price surge?

To answer these questions, we combine wavelet coherence analysis, which captures localized comovements and lead-lag dependencies in time-frequency space, with the maximum overlap discrete wavelet transform (MODWT) and the time-varying parameter vector autoregression (TVP-VAR) framework to quantify evolving connectedness and directional spillovers. This integration allows us to uncover both short- and long-horizon transmission mechanisms that static or single-scale models fail to detect.

This study contributes to the existing literature in several important ways. First, it provides a comprehensive multiscale perspective on the crypto-energy-environment-economy nexus by jointly analyzing their interdependencies in both time and frequency domains. Second, it advances the methodological frontier by combining wavelet decomposition and TVP-VAR connectedness analysis, thereby capturing the time-varying and frequency-dependent structure of shock transmission. Third, by focusing on the U.S. market, a global benchmark for both cryptocurrency activity and energy consumption, this study delivers insights that are directly relevant to policy design and sustainable finance strategies. Finally, the results offer practical implications for investors and policymakers seeking to balance digital innovation with environmental sustainability, highlighting how cryptocurrency dynamics can amplify or

mitigate energy-related and macroeconomic shocks.

The remainder of the paper is organized as follows. Section 2.2 reviews the related literature. Section 2.3 details the empirical methodology, including the wavelet coherence and TVP-VAR frameworks. Section 2.4 describes the data and descriptive statistics. Section 2.5 presents and discusses empirical results and robustness analyses. Section 2.6 concludes the paper and provides practical policy implications and directions for future research.

2.2. Literature review

The growing scale of cryptocurrency operations, particularly Bitcoin, has raised increasing academic and policy concern regarding its energy consumption and broader economic implications. Early studies focused mainly on the magnitude of energy demand and its environmental externalities. Krause and Tolaymat (2018) highlighted the accelerating rate of electricity use in Bitcoin mining, while Stoll et al. (2019) quantified its environmental impact, showing that Bitcoin production carries a high carbon footprint. Gandal et al. (2018) further identified significant links between Bitcoin price movements and energy-market dynamics, underscoring the dependence between cryptocurrency valuation, energy costs, and macroeconomic conditions. Collectively, these studies established the importance of assessing the macro-environmental consequences of crypto-mining activity. This stream of research underscores the urgent need to assess how digital-asset growth intersects with the broader goals of energy transition and climate mitigation (de Vries, 2018; Akhter, 2012; Androniceanu & Georgescu, 2023).

The interplay involving the cryptocurrency mining process, especially that of Bitcoin, and CO2 emissions has become a significant field of study (Zhang et al., 2023). This energy-intensive process, based on proof-of-work [11]validation, requires vast computing power and substantial electricity inputs, often sourced from fossil fuels (de Vries, 2018; Kohli et al., 2023), thereby magnifying CO2 emissions (Zhang et al., 2023). According to Mora et al. (2018), if current trends persist, Bitcoin alone could drive global warming beyond the two-degree Celsius threshold. This impact is especially severe in regions with coal-dependent electricity generation, which are among the highest contributors to pollution (Zhou et al., 2024). Consequently, growing public and scholarly attention has turned to the contribution of crypto-mining to climate change, alongside traditional sources of environmental degradation such as

[11] Proof-of-work (PoW) is a consensus mechanism used by certain blockchains, such as Bitcoin, that requires miners to solve complex mathematical puzzles to validate transactions and add new blocks to the chain.

deforestation and industrialization (Clark et al., 2023). These findings are consistent with broader evidence linking energy consumption, economic growth, and environmental degradation in both developed and emerging economies (Akhter, 2012; Rehman & Apergis, 2020; Raza et al., 2020).

Beyond its environmental footprint, Bitcoin's interaction with macrofinancial indicators has also been explored. Hong et al. (2019) analyzed pricing relationships between Bitcoin and leading economic indices, while Bouri et al. (2020) documented the market's sensitivity to energy shocks. Phillips and Gorse (2018) found that Bitcoin's linkages with traditional financial markets strengthen during episodes of market distress, while Dyhrberg (2016) demonstrated that Bitcoin behaves simultaneously as a commodity and a currency, hedging stock-market movements and inflation. These macrofinancial interactions echo the dual role of energy and renewables in growth-environment feedbacks (Jones et al., 2019; Jamel & Maktouf, 2017) and highlight how digital assets may amplify or mitigate such feedback mechanisms within sustainable finance. This multidimensional characterization has informed ongoing assessments of Bitcoin's macroeconomic relevance and potential role within diversified asset portfolios.

The concern with the environmental consequences of Bitcoin mining has raised the call for more sustainable and efficient power usage on the part of the cryptocurrency sector. Truby (2018) proposed a legal framework encouraging environmentally friendly crypto-mining methods, while Li et al. (2018) proposed improvements to reduce energy consumption in blockchain technology[12]. Along the same lines, Caporale et al. (2019) examined the role of economic-indicator announcements concerning Bitcoin prices and found evidence of increased integration with, and sensitivity to, traditional financial indicators.

Methodologically, a wide array of econometric tools has been employed to analyze spillovers between cryptocurrencies, energy, and financial markets. Diebold and Yilmaz (2014) introduced the generalized forecast-error variance decomposition (GFEVD) framework to measure total and directional connectedness. Kristoufek (2015) applied wavelet coherence to detect comovements between Bitcoin and macroeconomic variables at different time scales, demonstrating complex, time-varying dependencies. Balcilar et al. (2017) examined Bitcoin's volatility through a GARCH framework, confirming its linkages with energy and financial factors. Subsequent refinements of connectedness analysis (Diebold & Yilmaz, 2009, 2014; Baruník & Křehlík, 2018) extended spillover measures to dynamic and frequency-specific

[12] A blockchain is a decentralized and distributed digital ledger that records transactions in a secure, transparent, and tamper-resistant manner through a sequence of cryptographically linked blocks.

domains. Yet rolling-window VARs remain sensitive to window size, motivating the adoption of the time-varying parameter VAR (TVP-VAR) model (Antonakakis & Gabauer, 2020), which captures smoothly evolving interdependence. Yahya et al. (2019) and Urom et al. (2021) combined wavelet decomposition with connectedness metrics to evaluate spillovers across frequencies, confirming the benefits of integrating time- and frequency-domain perspectives.

More recent literature has expanded the scope and sophistication of this research frontier. Zhang et al. (2023) investigate the environmental implications of cryptocurrency energy usage for climate change, using quantile causality, cross-quantilograms, and dynamic connectedness. While methodologically advanced, their analysis remains mainly technical, with limited discussion of how such dependencies inform energy-transition or macro-policy channels. Annamalaisamy and Vepur Jayaraman (2024) used wavelet coherency to explore the integration between cryptocurrencies, equity, sustainability, and clean-energy indices, identifying heterogeneous linkages across horizons. Yadav et al. (2025) examined time-frequency connectedness among green bonds, renewable-energy assets, and crypto markets, finding that linkages intensify during financial turbulence. Qing and Alnafrah (2025) show that environmental attention in cryptocurrency markets stimulates clean-energy investment, linking financial sentiment with sustainability dynamics. Together, these studies affirm the importance of multiscale and time-varying frameworks for capturing evolving crypto-energy-environment interdependence, yet they stop short of integrating environmental fundamentals with macrofinancial variables into a single system. However, existing studies, including Zhang et al. (2023), primarily examined the environmental effects of cryptocurrency energy consumption using Granger causality across quantiles, cross-quantilograms, and dynamic connectedness. Their results show strong tail dependence between Bitcoin's energy intensity and CO2emissions, underscoring how extreme mining activity amplifies environmental damage. While methodologically rigorous, their study focuses on bilateral crypto-energy-emission linkages and gives limited attention to broader macrofinancial or policy dynamics. In contrast, our study adopts a system-level, multiscale framework that jointly analyzes the evolving connectedness among cryptocurrencies, energy prices, environmental indicators, and macroeconomic variables. This design captures how shocks propagate across domains and clarifies their implications for energy transition and sustainability policies.

Nevertheless, three key gaps persist. First, most studies remain bivariate or focus on limited asset pairs, restricting systemic insight into the joint behavior of cryptocurrency, energy, environmental, and macroeconomic variables (Corbet et al., 2021; Miśkiewicz et al., 2022).

Second, several works rely on static or short-sample models that cannot capture structural shifts such as the COVID-19 collapse or the 2022 energy-price shock (IMF, 2020; Arezki & Nguyen, 2022). Third, despite widespread use of wavelet coherence or TVP-VAR individually, few studies combine both within a unified multiscale framework that simultaneously quantifies temporal and spectral spillovers (Baruník & Křehlík, 2018; Antonakakis & Gabauer, 2020).

Our study addresses these gaps by developing a comprehensive multiscale dynamic-connectedness model that combines wavelet coherence, maximum-overlap discrete wavelet transforms, and TVP-VAR approaches to jointly assess temporal and spectral transmission mechanisms. This dual-domain design captures the evolving structure of spillovers across the cryptocurrency, energy, environment, and economic sectors, yielding insights beyond the scope of existing studies. Besides methodological novelty, the analysis also contributes substantively by revealing how crypto-asset dynamics intersect with energy transition and environmental sustainability objectives. In doing so, it complements prior work by providing system-level evidence on how shocks propagate jointly across digital, energy, environmental, and macrofinancial domains, clarifying not only the magnitude but also the mechanisms of interdependence beyond purely methodological innovation.

2.3. Methodology

As described above, this study employs a comprehensive econometric methodology that integrates wavelet transform and TVP-VAR models to examine the dynamic interconnections between the cryptocurrency market, energy consumption, economic indicators, and environmental impacts. This section presents an introduction to our econometric approach, describing these techniques and the rationale behind their use.

2.3.1. Wavelet Transform

The power of wavelet transform in time-frequency analysis with financial time series has been demonstrated in studies such as Urom et al. (2021), Ren et al. (2022), and Mensi et al. (2023). This technique implements multi-resolution analysis for which a time series is decomposed into various components at different time scales. This decomposition is advantageous for extracting detailed information from the series at various time locations and investment horizons to quantify multiscale correlations between different time series.

Using the wavelet transform method, any time function can be represented by two fundamental

functions, the father and mother wavelet (Ramsey, 2002), which are used to capture long-term smooth components and short-term fluctuations, respectively.

- **The father wavelet**

The father wavelet, also called scaling function, reveals the smooth and long-term components of the signals, revealing highlighting trends or slowly changing components in time series data. The father wavelet equation at scale j and position k is as follows:

$$\phi_{j,k}(t) = 2^{\frac{-j}{2}}\phi(2^{-j}t - k) \quad \textbf{(2.1)}$$

where $\phi(t)$ is the Haar scaling function, which is defined as follows:

$$\phi(t) = \begin{cases} 1, & if \ \ 0 \le t \le 1 \\ 0, & otherwise \end{cases} \quad \textbf{(2.2)}$$

- **The mother wavelet**

This function is sensitive to deviant and short-term components to allow the detection of sudden changes or anomalies in the data, identifying short-term fluctuations that reveal volatility or specific events relevant to the series.

The mother wavelet equation at scale j and position k is as follows:

$$\psi_{j,k}(t) = 2^{\frac{-j}{2}}\psi(2^{-j}t - k) \quad \textbf{(2.3)}$$

where $\psi(t)$ is the Haar function, which is defined as

$$\psi(t) = \begin{cases} 1, & if \ \ 0 \le t \le 1/2 \\ -1, & if \ \ 1/2 < t \le 1 \\ 0, & otherwise \end{cases} \quad \textbf{(2.4)}$$

An arbitrary series $y(t)$ can be expressed using the two wavelet functions as follows:

$$y(t) = \sum_k \alpha_{j,k}\boldsymbol{\phi}_{j,k}(t) + \sum_k \beta_{j,k}\psi_{j,k}(t) + \sum_k \beta_{j-1,k}\psi_{j-1,k}(t) + \cdots + \sum_k \beta_{1,k}\psi_{1,k}(t) \quad \textbf{(2.5)}$$

where $\alpha_{j,k} = \sum_t y(t)\boldsymbol{\phi}_{j,k}(t)$ denotes the smooth coefficient (low-frequency) representing the contribution of the basis function $\phi_{j,k}(t)$ to the smooth part of the overall signal $y(t)$, and $\beta_{j,k} = \sum_t y(t)\psi_{j,k}(t)$ indicates the contribution of the corresponding detail component $\psi_{j,k}(t)$ to the overall signal $y(t)$.

To investigate time-frequency comovements, we apply the continuous wavelet coherence (WTC) using the complex Morlet wavelet as the mother function (Torrence and Compo, 1998; Rua, 2010). The WTC between two series $x(t)$and $y(t)$is defined as:

$$R^2_{xy}(a,b) = \frac{|\langle W_x(a,b)\, W_y^*(a,b)\rangle|^2}{\langle |W_x(a,b)|^2\rangle \langle |W_y(a,b)|^2\rangle} \quad \textbf{(2.6)}$$

where $W_x(a, b)$ and $W_y(a, b)$ are the continuous wavelet transforms of $x(t)$and $y(t)$, respectively. $\langle\cdot\rangle$ represents a smoothing operator, $W_y^*(a, b)$ is the complex conjugate of the wavelet coefficient $W_y(a,b)$, a is the scale parameter to adjust the wavelet's width, and b is the translation parameter shifting the wavelet along the time axis.

This approach identifies localized synchronization patterns across both time and frequency.

Then, to obtain the frequency-specific components required for connectedness analysis, we employ the MODWT technique using the Haar (Daubechies 1) filter. MODWT is a variant of DWT that avoids down-sampling, producing non-decimated, translation-invariant coefficients suitable for time-series econometrics (Percival and Walden, 2000).

The wavelet and scaling coefficients at scale j and time t are computed as:

$$W_{x,j,t} = \sum_{k=0}^{L_j-1} \tilde{h}_{j,k}\, x_{(t-k)} \quad mod\ N; \qquad \tilde{h}_{j,k} = \frac{h_k}{\sqrt{2^j}} \quad \textbf{(2.7)}$$

$$W_{y,j,t} = \sum_{k=0}^{L_j-1} \tilde{g}_{j,k}\, y_{(t-k)} \quad mod\ N; \qquad \tilde{g}_{j,k} = \frac{g_k}{\sqrt{2^j}} \quad \textbf{(2.8)}$$

where h_k and g_k are the mother wavelet filter coefficients.

The final decomposition of a return series $r(t)$ using MODWT into J+1 sequences at different time scales is expressed as follows:

$$r(t) = S_J(t) + \sum_{j=1}^{J} D_j(t) \quad \textbf{(2.9)}$$

where $S_J(t)$ represents the smooth component (level J), and $D_j(t)$ denotes the detailed components at each level j.

2.3.2. TVP-VAR connectedness

We use the TVP-VAR model (Antonakakis et al., 2020) to determine how the time- and frequency-domain components change over time and how they affect each other. This model modifies the analytical tools proposed by Diebold and Yilmaz (2014) for investigating sequences decomposed through wavelet analysis. This issue is much less pronounced in the

~~TVP-VAR model compared to traditional VAR-based approaches for assessing connectedness,~~ which depends very sensitively on the choice of window size. The Markov Chain Monte Carlo algorithm primarily estimates the dynamic coefficients, variances, and covariances. Therefore,

it is possible to directly evaluate dynamic relationships between different variables without the need for a rolling window approach.

The TVP-VAR model applied to a wavelet decomposed series at scale *j* is as follows:

$$r_t^{(j)} = A_{1,t}^{(j)} r_{t-1}^{(j)} + A_{2,t}^{(j)} r_{t-2}^{(j)} + \cdots + A_{p,t}^{(j)} r_{t-p}^{(j)} + \varepsilon_t^{(j)} \quad \textbf{(2.10)}$$

where $r_t^{(j)}$ is a $k \times 1$ dimensional column vector representing the time series at scale j, p is the lag order, $A_{i,t}^{(j)}$ (for $i = 1,2, \ldots, p$) represents $k \times k$ dimension time-varying coefficient matrices, and $\varepsilon_t^{(j)}$ is a random disturbance term with $\varepsilon_t^{(j)} \sim \text{iid}\, N(0, \Sigma_t)$, where Σ_t is a time-varying covariance matrix.

We then estimate the time-varying coefficients and variance-covariance matrices using the Kalman filter[13] algorithm. Following Huang et al. (2023), we set the decay factors to $k_1 = 0.99$ and $k_2 = 0.96$. This approach eliminates the requirement for a rolling window, improving the model's capacity to directly capture dynamic interactions.

2.3.3. Dynamic connectedness measures

To more thoroughly analyze the connectedness between system variables, we compute various measures derived using generalized forecast error variance decomposition in the context of the TVP-VAR model applied to wavelet decomposed sequences. These measures quantify the dynamic interactions and spillover effects between different variables over time.

- **Total Connectedness Index (TCI)**

This index calculates the overall spillover effect between all variables, excluding diagonal elements (self-spillovers). A higher TCI indicates stronger connectedness and hence a high potential for spillovers between the variables.

$$TCI_t^{(j)}(H) = \left(\frac{\sum_{i,j=1, i \neq j}^{k} \tilde{\theta}_{iy,t}^{(y)}(H)}{\sum_{i,j=1}^{k} \tilde{\theta}_{iy,t}^{(y)}(H)} \right) \times 100 \quad \textbf{(2.11)}$$

where $\tilde{\theta}_{iy,t}^{(y)}(H)$ represents the decomposition of the forecast error variance of variable i attributed to shocks from variable j at time t over forecast horizon H.

[13] The Kalman filter is a recursive algorithm used to estimate unobserved state variables in dynamic systems. In the context

of the TVP-VAR model, it enables the real-time updating of time-varying parameters by efficiently processing new information from the data.

- **Transmitting (TO) and Receiving (FROM) Spillover Indices**

These indices measure how much a variable i influences (TO) or is influenced by (FROM) all other variables in the system. The TO index reveals the effects of shocks from variable i on other variables, while the FROM index shows the impact of shocks from all other variables on variable i. A high TO indicates that the variable significantly influences other variables in the system, acting as a shock transmitter. In contrast, a high FROM value indicates that a variable is strongly impacted by shocks from other variables, indicating a high vulnerability to external effects. These indices are obtained as follows:

$$TO_{i,t}^{(j)}(H) = \left(\frac{\sum_{j=1,j\neq i}^{k} \tilde{\theta}_{yi,t}^{(y)}(H)}{\sum_{j=1}^{k} \tilde{\theta}_{yi,t}^{(y)}(H)}\right) \times 100 \quad \textbf{(2.12)}$$

$$FROM_{i,t}^{(j)}(H) = \left(\frac{\sum_{j=1,j\neq i}^{k} \tilde{\theta}_{iy,t}^{(y)}(H)}{\sum_{j=1}^{k} \tilde{\theta}_{iy,t}^{(y)}(H)}\right) \times 100 \quad \textbf{(2.13)}$$

- **Net Total Directional Connectedness Index (NET)**

This index reflects whether variable i is a net transmitter or net receiver of shocks in the system, whether it is positive or negative, at time i and scale j. A positive (negative) NET index suggests that variable i is a net source (recipient) of spillovers, which is calculated as follows:

$$NET_{i,t}^{(j)}(H) = TO_{i,t}^{(j)}(H) - FROM_{i,t}^{(j)}(H) \quad \textbf{(2.14)}$$

- **Net Pairwise Directional Connectedness Index (NPDC)**

The NPDC measures the net effect of shocks between two particular variables identifying the degree and direction of the spillover effect. A positive (negative) NPDC value implies that variable i is a net transmitter (receiver) to (from) variable j, which is calculated as follows:

$$NPDC_{ij,t}^{(j)}(H) = [\theta_{ji,t}^{(j)}(H) - \theta_{ij,t}^{(j)}(H)] \times 100 \quad \textbf{(2.15)}$$

- **Net Pairwise Transmission (NPT)**

Net Pairwise Transmission (NPT) index provides a topological view of the system by counting, for each variable i, how many bilateral relations it dominates at a given time t. Formally, for a k-variable system and time t:

$$= \sum$$

$$NPT_{i,t} \quad \sum_{j=1,j\neq i}^{k} \begin{cases} 1, \text{if } NPDC_{i,j,t} > 0 \\ 0, otherwise \end{cases} \quad \textbf{(2.16)}$$

where $NPDC_{i,j,t}$ denotes the Net Pairwise Directional Connectedness from variable i to j (Diebold and Yilmaz, 2014; Antonakakis et al, 2020). A higher $NPT_{i,t}$indicates that variable i acts as a topological transmitter, exerting dominant influence over a larger number of markets, while a lower value suggests a receiver role.

2.4. Data

This study analyzes a US monthly dataset spanning the period from January 2014 to June 2025. A range of key variables are employed to investigate the connectedness between environmental metrics, energy measures, macrofinancial indicators, and the influence of Bitcoin activities in the United States. The choice of the U.S. as our primary focus is driven by its significant impact on environmental policies, energy consumption, and production patterns. Besides, it is the world's largest financial market and has a key role as a global benchmark for cryptocurrency adoption and mining activity. While wavelet coherence can benefit from high-frequency data, the monthly frequency is chosen here to ensure the inclusion of key macrofinancial and environmental variables that are unavailable at daily or weekly horizons. Following the approach of Baruník and Křehlík (2018) and Antonakakis and Gabauer (2020), who also employed monthly data in multivariate connectedness settings, this choice maintains cross-domain consistency and avoids the measurement noise typical of high-frequency environmental or ESG data.

As summarized in Table 2.1, the dataset variables are classified into four pillars. The first pillar, environmental factors, includes total energy-related CO2 emissions, total renewable energy consumption, and two climate-related indicators: the Climate Concern Index (CCI) and the Sustainability Uncertainty Index (ESGUI), which together provide insights into the country's environmental footprint and sustainability efforts.

The second pillar covers energy consumption and cost metrics, including total primary energy consumption, WTI crude oil prices, natural gas, and electricity prices, providing valuable information on the U.S. energy demand, input costs, and sectoral exposure to fossil fuel volatility.

The third group of variables contains key macroeconomic and financial indicators such as the SP500 index, NASDAQ composite performance, inflation rates, industrial production index, and policy-related uncertainty indices including energy policy uncertainty (EPU) and geopolitical risk index (GPR). The choice of NASDAQ over other benchmark indicators, such as the Dow 30, was intentional due to NASDAQ's strong focus on technology and innovation-driven companies, which closely aligns with the characteristics of the cryptocurrency market.

These indicators are crucial for understanding the economic landscape in the U.S. while also offering perspectives on global economic trends, given the country's significant influence on world markets.

The last pillar includes metrics for Bitcoin evaluation (price, transaction volume, and market capitalization), which are retrieved from CoinMarketCap and the Binance API. Although these three metrics are mechanically related, they capture distinct transmission channels: valuation, activity intensity, and market depth. Therefore, these metrics collectively estimate the systemic footprint of the Bitcoin ecosystem. Table 2.1 provides a summary of the variables, their definitions and sources.

Returns series are computed using log-differences of price series using the following formula:

$$R_t = 100 \times (\ln(P_t) - \ln(P_{t-1})) \quad \textbf{(2.17)}$$

where R_t denotes log returns for price-based variables and growth rates for quantitative indicators such as CO2 emissions, energy consumption, or environmental indexes. This transformation harmonizes measurement units across heterogeneous variables while preserving their economic interpretation. Augmented-Dickey-Fuller (ADF) tests indicate that all variables in levels are non-stationary, while their log-differenced series are stationary (see Table 2.2).

Figure 2.1 reveals three distinct volatility regimes throughout the sample. During 2017-2018, the crypto-asset bubble is observable in PBTC and MCBTC, with return swings approaching ±50%, while traditional asset classes remain comparatively stable, reflecting an initial decoupling of digital assets from broader markets (Corbet et al., 2021). In early 2020, a systemic shock triggered by the COVID-19 pandemic leads to sharp, synchronized declines in equities and energy prices; the SP500 and NASDAQ contract by over 13%. Between 2020 and 2021, Priceoil and GAS experience historic plunges exceeding 70%, and both policy and geopolitical uncertainty indices spike sharply, consistent with the global collapse in demand and liquidity (IMF, 2020; Baker et al., 2016). Notably, VBTC registers its most pronounced positive spike during this period, which is distinct from the earlier crypto boom. The 2022-2023 period marks a shift to an energy-inflation regime driven by the Russia-Ukraine conflict, as Priceoil and GAS exhibit substantial increases, inflation accelerates, and equity indices temporarily retreat, while renewable and ESG indicators respond positively but with a lag, indicative of gradual portfolio adjustment toward sustainable assets (Arezki and Nguyen, 2022). These evolving patterns point out the need for time-varying connectedness models, such as TVP-VAR or frequency-domain approaches, to accurately capture regime-dependent spillover dynamics (Antonakakis et al, 2020; Baruník and Křehlík, 2018).

Table 2.2 reports the summary statistics of all variables over the sample period, showing that mean returns are close to zero for most series and revealing marked differences in dispersion and distributional shape across variables. Bitcoin-related and energy series display the strongest volatility, whereas macroeconomic and environmental variables exhibit comparatively stable fluctuations. Several series, particularly industrial production, oil prices, and Bitcoin return, present high kurtosis values, indicating heavy-tailed behavior. The Jarque-Bera test shows that all log-differenced series strongly deviate from normality.

Table 2.1 Variables and data sources

Variable		Detail	Data sources
Environmental Factors	**CO2**	Total Energy CO2 Emissions (Million Metric Tons of Carbon Dioxide)	U.S. Energy Information Administration (EIA)
	RENERG	Total Renewable Energy Consumption (Trillion Btu)	
	CCI	Climate Concern Index	PolicyUncertainty Website
	ESGUI	Sustainability Uncertainty Indexes	
Energy measures	**Penergy**	Total Primary Energy Consumption (Quadrillion Btu)	U.S. Energy Information Administration (EIA)
	Priceoil	WTI Crude Oil Price (Dollars per Barrel)	
	GAS	Henry Hub Natural Gas Spot Price Dollars (Million BTU)	
	ELEC	Average Price of Electricity (Cents per Kilowatt-hour	
Macrofinancial & Uncertainty Indicators	**SP500**	The SP500 index	Federal Reserve Economic Data (FRED)
	NASDAQ	Composite indicator of the performance of the stock market	
	Infl	Consumer Price Index: inflation	
	IND	Industrial Production Index (Total)	
	EPU	Economic Policy Uncertainty Index	PolicyUncertainty Website
	GPR	Geopolitical Risk Index	
Bitcoin Indicators	**PBTC**	Average Bitcoin Price (Dollars)	CoinMarketCap -Binance API
	VBTC	Bitcoin Transaction Volume	
	MCBTC	Bitcoin Market Capitalization	

Table 2.2 Summary statistics and stochastic properties

	CCI	CO2	ELEC	EPU	ESGUI	GAS	GPR	IND	Infl	MCBTC	NASDAQ	PBTC	Penergy	Priceoil	RENERG	SP500	VBTC
Mean	0,0224	-0,2215	0,2549	1,01	1,30	-0,3	0,75	0,04	0,22	3,89	1,16	3,45	-0,13	-0,29	0,20	0,9	8,26
Std.Dev	18,80	8,26	1,52	25,80	17,64	17,44	21,67	2,24	0,27	20,12	5,11	20,20	7,48	12,63	5,54	4,26	50,74
Min	-51,55	-23,83	-3,66	-50,57	-61,19	-71,39	-60,01	-16,96	-0,78	-47,29	-14,22	-49,21	-20,12	-78,18	-11,80	-13,36	-101,75
Max	53,03	18,02	5,01	119,83	57,06	68,01	69,62	9,01	1,24	53,21	14,36	53,28	16,30	63,32	19,83	11,94	317,48
ADF	-6.65**	-7.14***	-5.15***	-5.41***	-5.63***	-4.98***	-6.83***	-5.92***	-3.31*	-3.95**	-4.38***	-3.92**	-7.25***	-7.12***	-7.64***	-5.31***	-4.95***
Skewness	-0,16	-0,51	0,32	1,02	0,04	-0,36	0,44	-2,64	0,22	-0,04	-0,42	-0,07	-0,56	-0,88	0,74	-0,54	1,75
Kurtosis	0,69	-0,21	1,32	2,55	1,76	3,73	0,86	23,48	2,70	-0,05	0,26	0,02	-0,33	13,15	0,87	0,67	8,77
JB	3.85**	6.45***	13.3***	64.1***	19.3***	86.9***	9.41***	3416***	45.6***	0.04***	4.85***	4.89***	7.92***	1042***	17.9***	10.0***	529***
N.Valid	137	137	137	137	137	137	137	137	137	137	137	137	137	137	137	137	137

Note: Std.Dev refers to standard deviation. Min (Max) denotes the variable's minimum (maximum) value. JB and ADF designate Jarque-Bera and Augmented Dickey-Fuller tests, respectively. ***, **, * indicate significance at the 1%, 5%, and 10% levels, respectively.

Figure 2.1 Return of dataset variables

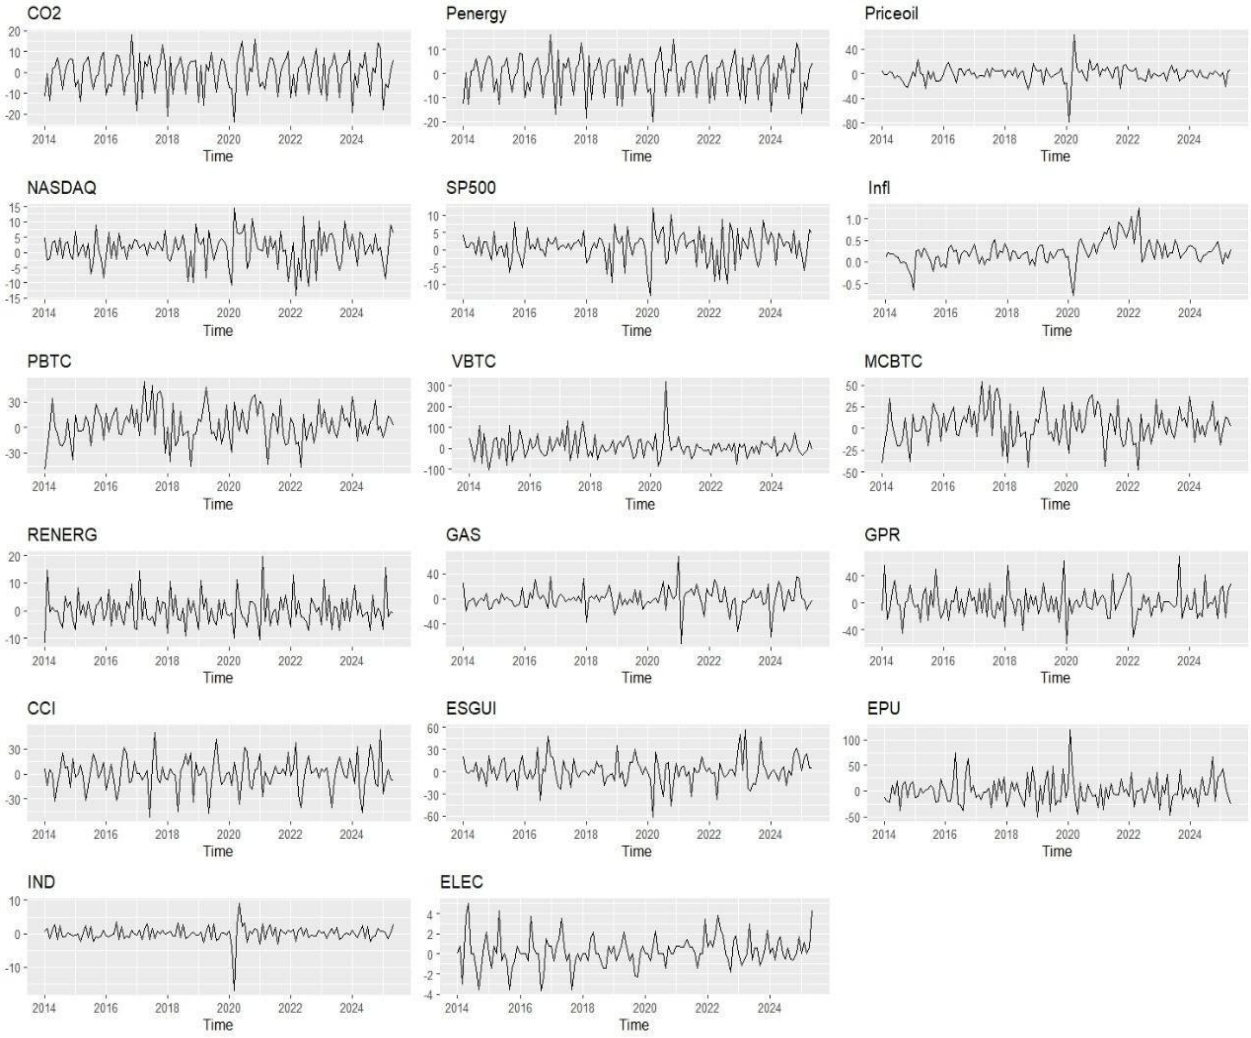

2.5. Empirical analysis

2.5.1. Analysis of time-frequency comovements

Our empirical approach employs wavelet coherence and phase difference to assess time-frequency comovement focusing on the dynamic dependence and lead-lag relationships between the variables. In the wavelet coherence plots (Figure 2.2-2.7), the vertical axis indicates the timescale and the horizontal axis represents time. In addition, the intensity of color denotes the wavelet coherence strength, where a hotter color indicates more stronger dependence. The arrows refer to the phase difference, which indicates the lead-lag relationships between two variables. Right arrows indicate synergy movement, while left arrows indicate reverse

movement. Then, right-up (left-down) arrows indicate that the first variable leads positively (negatively), and the right-down (left-up) arrows indicate that the first variable lags positively (negatively). Finally, the line represents the influence cone, which represents a 5% significance level.

2.5.2. Comovement between environmental factors and energy measures

The results in Figure 2.2 highlight clear and time-localized comovement structures across environmental, energy, and confidence indicators. The relationship between CO2 emissions and primary energy consumption exhibits a broad and persistent high-coherence pattern spanning nearly the entire sample period and across all frequency bands up to two years, characterized by rightward arrows that denote a strong and stable in-phase synchronization between the two variables. Similarly, the CO2-ELEC and RENERG-Penergy pairs display pronounced medium- to long-term coherence bands between 2017 and 2022, concentrated around 0.4-1.5-year periods, with arrows predominantly oriented right-upward, indicating that fluctuations in electricity and primary energy variables lead their environmental counterparts. The RENERG-ELEC relationship also reveals coherent medium-term cycles over 2016-2021 and a secondary long-term synchronization around 2019-2023, while coherence between RENERG and oil prices is much weaker and confined to a low-frequency burst during 2020-2021, with anti-phase dynamics and oil leading renewable energy. Finally, both CCI-Penergy and CCI-ELEC pairs show significant coherence over 2016-2021 in the 0.5-1.5-year bands, reflecting in-phase relationships where energy factors tend to precede variations in consumer confidence. Overall, these WTC patterns demonstrate that energy-related variables, particularly electricity and primary energy consumption, exhibit the most consistent and temporally extended comovements with environmental and sentiment indicators, while oil-related coherence remains episodic and low-frequency.

Figure 2.2 Comovement between environmental factors and energy measures

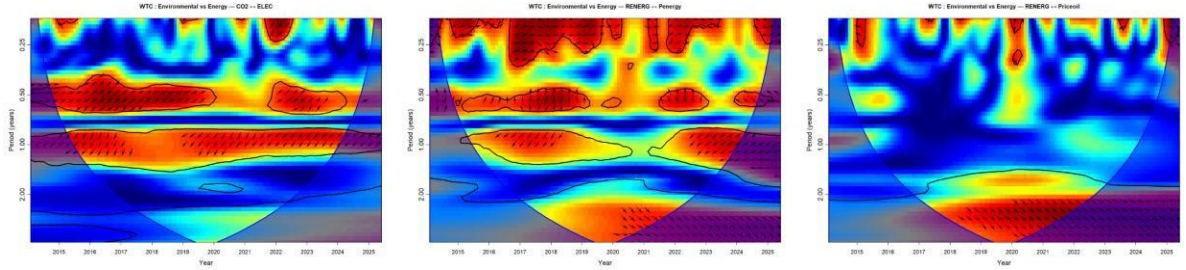

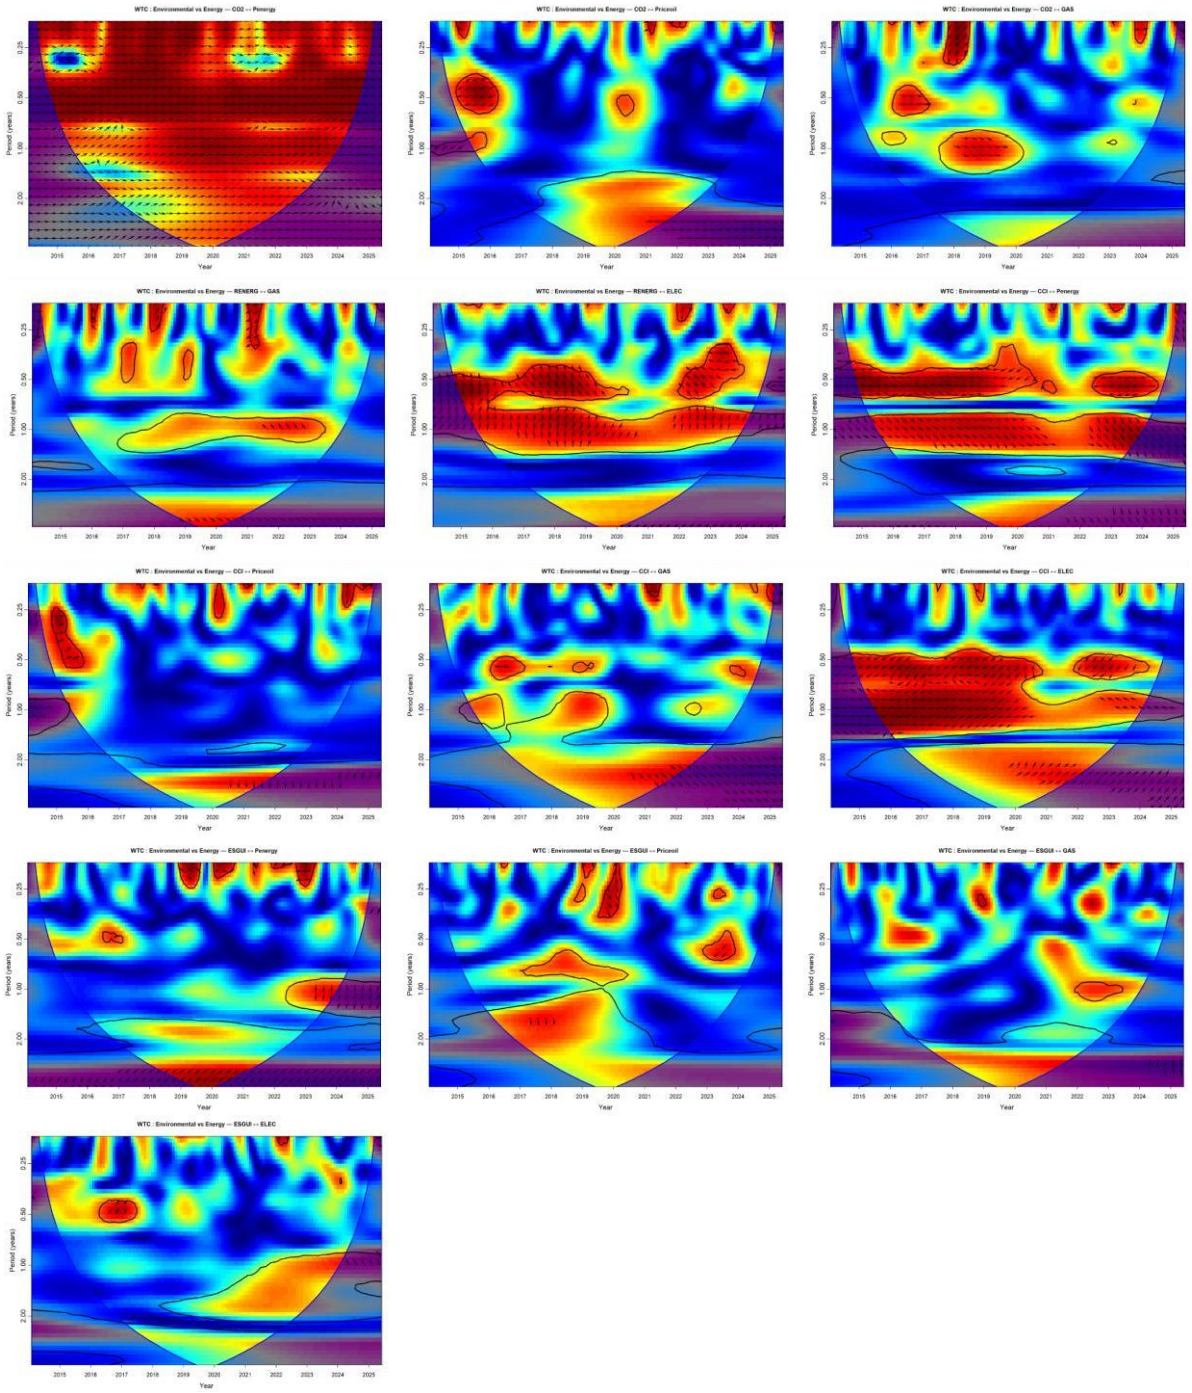

2.5.3. Comovement between environmental factors and Macrofinancial and Uncertainty Indicators

Figure 2.3 uncovers clear yet heterogeneous time-frequency interdependencies, mainly concentrated between 2018 and 2022. The linkage between CO2 emissions and industrial production (IND) stands out as the most persistent and structurally coherent, exhibiting strong

medium- to long-term synchronization (0.5-2 years) with consistently rightward arrows that denote in-phase dynamics and a common cyclical behavior, peaking sharply around 2020. In contrast, the relationship between CO2 and the SP500is weaker and episodic, with only isolated coherence islands around 2019-2021 and 2023, indicating sporadic synchronization between emissions and U.S. equity market cycles. The RENERG-Infl pair shows a stable long-term coherence band (1.5-2 years) spanning 2018-2022, characterized by a pronounced and persistent in-phase association, especially around 2020, suggesting that renewable energy activity and inflation evolved jointly at low frequencies. Finally, the CCI-IND interaction displays two distinct phases of medium-term coherence (0.5-1.5 years): an initial episode during 2016-2018 and a renewed synchronization after 2021, separated by a visible decoupling around 2020. Overall, the results reveal that the strongest and most enduring comovements occur between CO2 and industrial production, and between renewable energy and inflation, while financial market linkages remain intermittent.

Figure 2.3 Comovement between environmental factors and Macrofinancial & Uncertainty Indicators

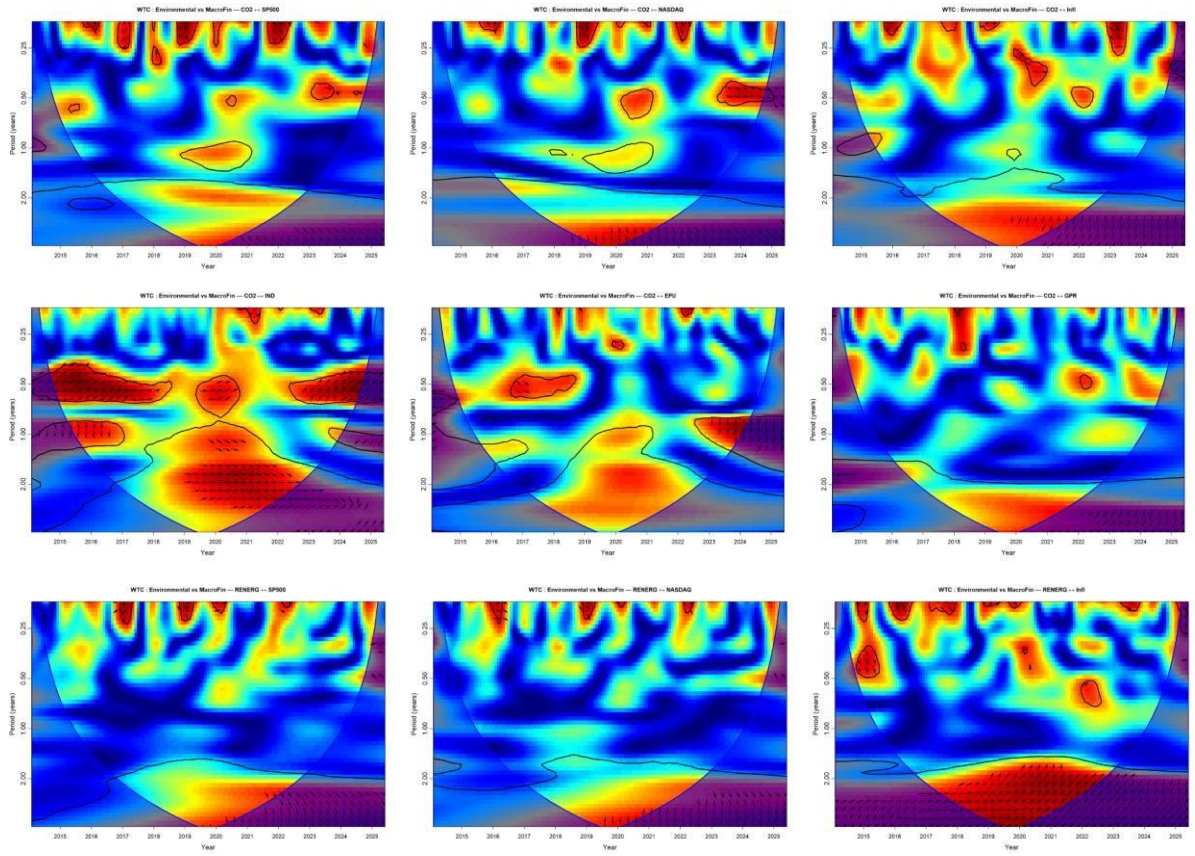

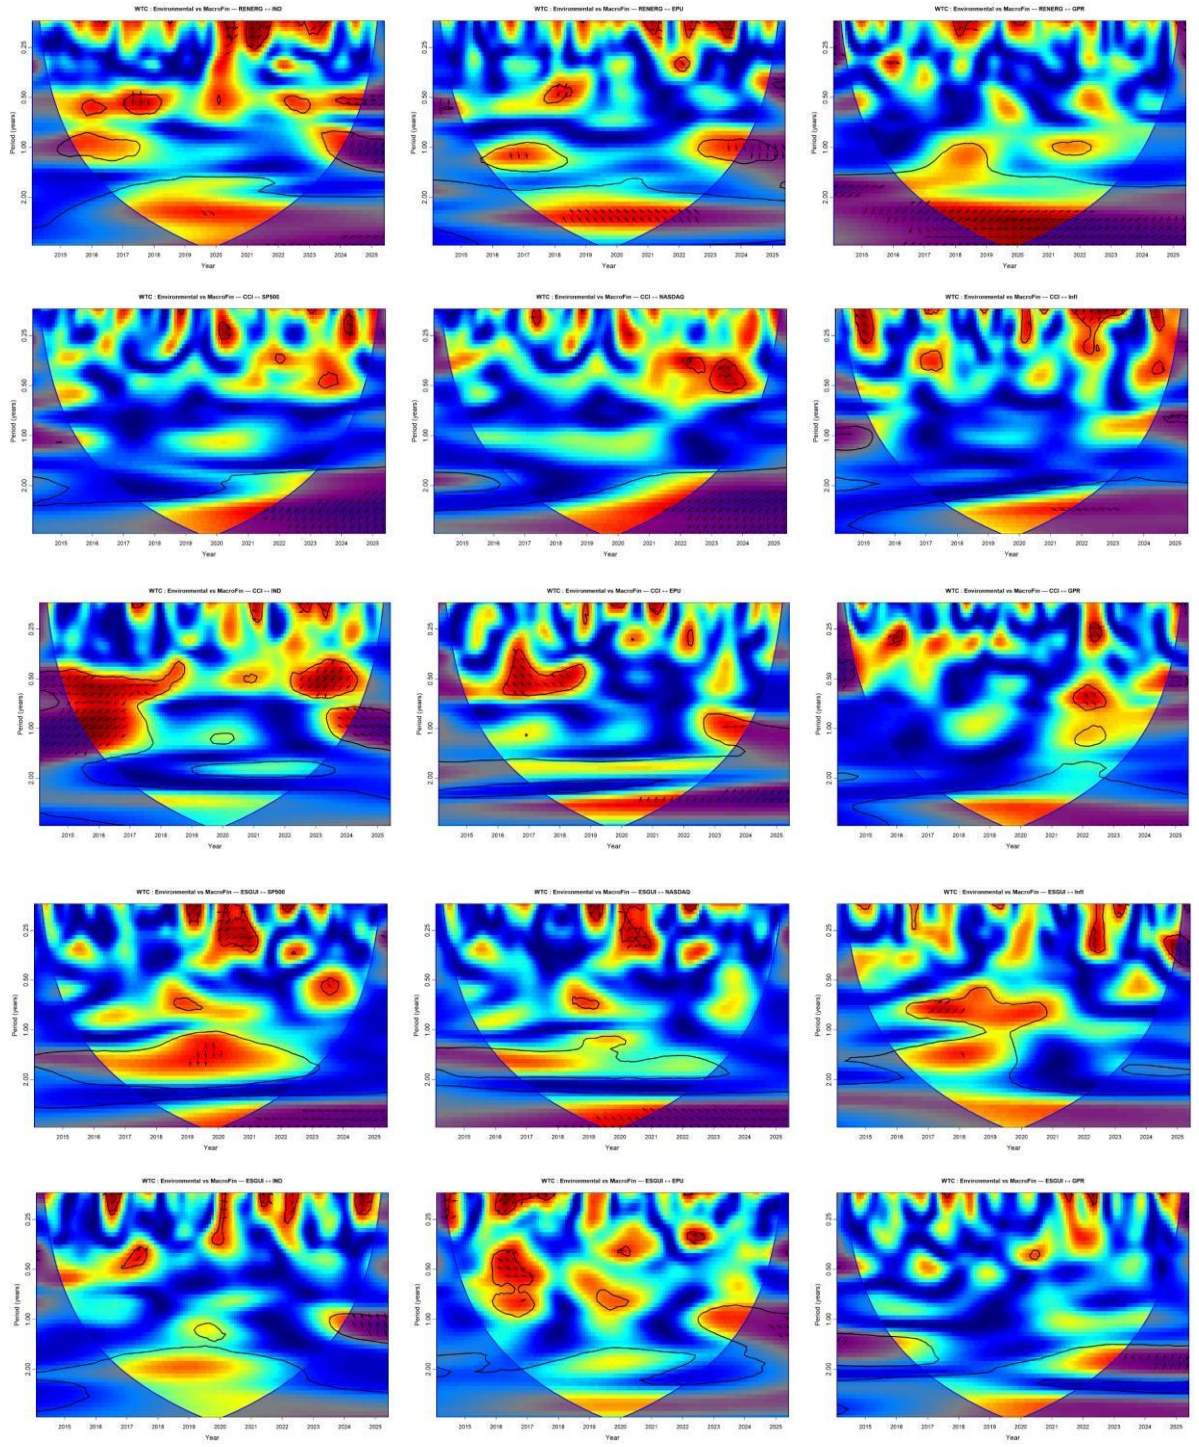

2.5.4. Comovement between environmental factors and Bitcoin Indicators

As shown in Figure 2.4**,** the connection between CO2 emissions and Bitcoin prices (PBTC) appears during two distinct phases, 2016-2018 and 2019-2021, over medium-term cycles of about 0.5-1.5 years, where both move in the same direction, suggesting that periods of strong

Bitcoin price activity coincide with higher emission fluctuations, but without a lasting long-run link. The link between renewable energy use and Bitcoin prices is weaker overall but becomes temporarily strong between 2020 and 2022, pointing to a long-term comovement as Bitcoin's energy demand and renewable capacity evolved together. Similarly, consumer confidence and Bitcoin returns show a clear alignment between 2019 and 2022, especially over cycles of 1-2 years, meaning that optimism in the economy tended to coincide with rising crypto-market activity. Finally, the relationship between ESG performance and Bitcoin indicators is the most stable over time, particularly from 2019 to 2021, when both the ESG index and Bitcoin market dynamics moved in sync at long frequencies. Overall, these results suggest that Bitcoin's behavior became more connected with environmental and economic sentiment factors during 2019-2021, a period marked by major shifts in global finance, energy, and investor attention to sustainability.

Figure 2.4 Comovement between environmental factors and Bitcoin Indicators

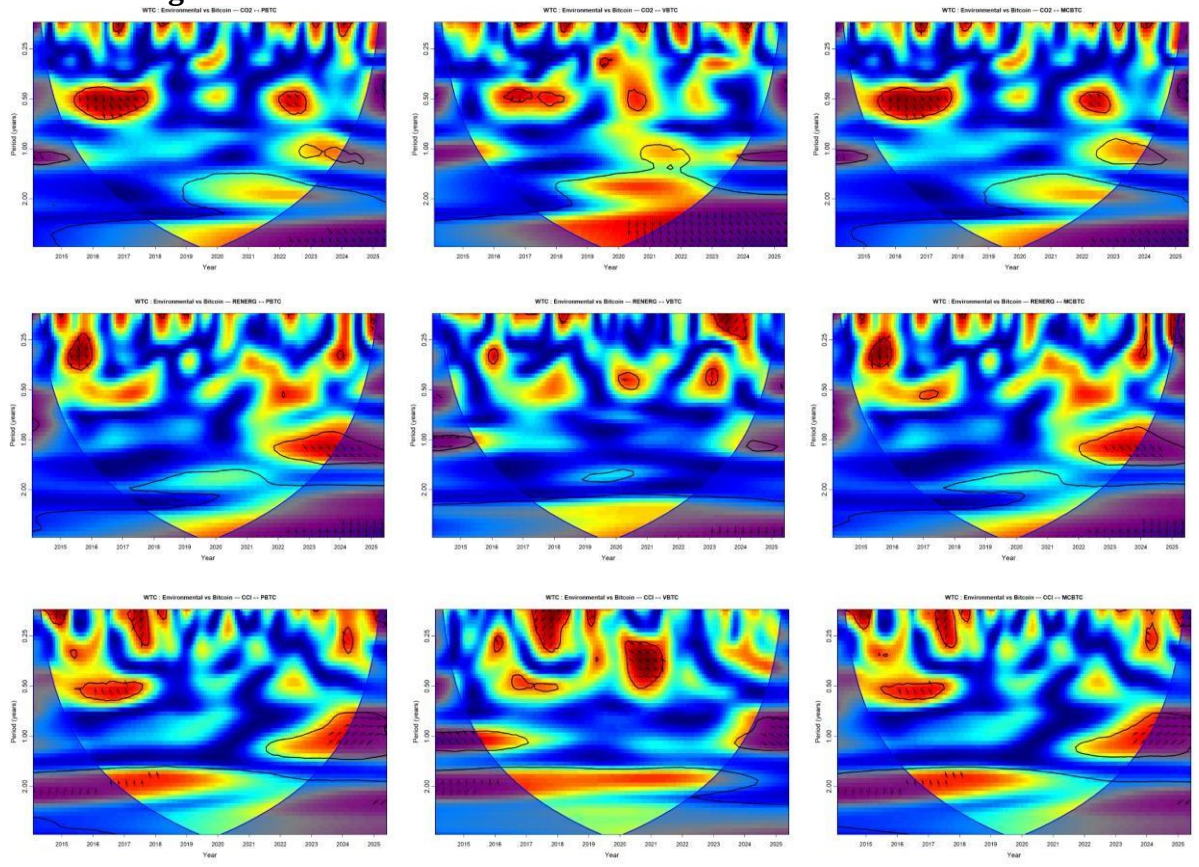

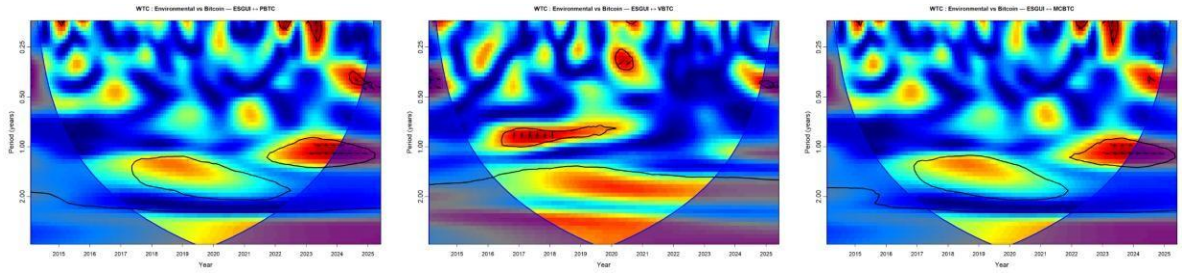

2.5.5. Comovement between energy measures and Macrofinancial and Uncertainty Indicators

Figure 2.5 reveals a clear pattern of cyclical and time-localized comovement between energy markets and macrofinancial activity, particularly between 2018 and 2022, a period marked by global shocks and subsequent recovery. The coherence between primary energy consumption and industrial production stands out as the most stable and long-lasting, with synchronized dynamics in both medium- and long-term frequency bands. In contrast, the connection between energy consumption and the SP500 remains episodic, peaking only around 2019-2021. Similarly, electricity prices and industrial output show recurrent in-phase movements, with industrial activity responding slightly after energy cost adjustments, confirming that production cycles are strongly energy-dependent. These patterns collectively indicate that the energy-real economy nexus intensified during periods of systemic stress, notably the COVID-19 crisis, when industrial and consumption cycles became closely aligned with energy dynamics.

Regarding the interaction between oil prices and macrofinancial indicators, coherence plots demonstrate broad and persistent synchronization across multiple channels. Oil prices exhibit strong in-phase comovement with inflation, reflecting the well-established transmission of energy shocks to consumer prices, especially between 2018 and 2021. Likewise, oil's relationship with equity markets (SP500 and NASDAQ) shows a powerful but transitory alignment around 2020, when both markets reacted simultaneously to oil price collapses and subsequent rebounds. The long-term coherence between oil prices and industrial production further highlights energy's central role in shaping real economic cycles, while the pronounced comovement with EPU underscores the sensitivity of both energy and financial conditions to geopolitical and macroeconomic instability. Overall, these findings confirm that energy markets act as a transmission channel for macrofinancial shocks, with their synchronization patterns strengthening during crises and gradually dissipating in calmer periods.

Figure 2.5 Comovement between energy measures and Macrofinancial & Uncertainty Indicators

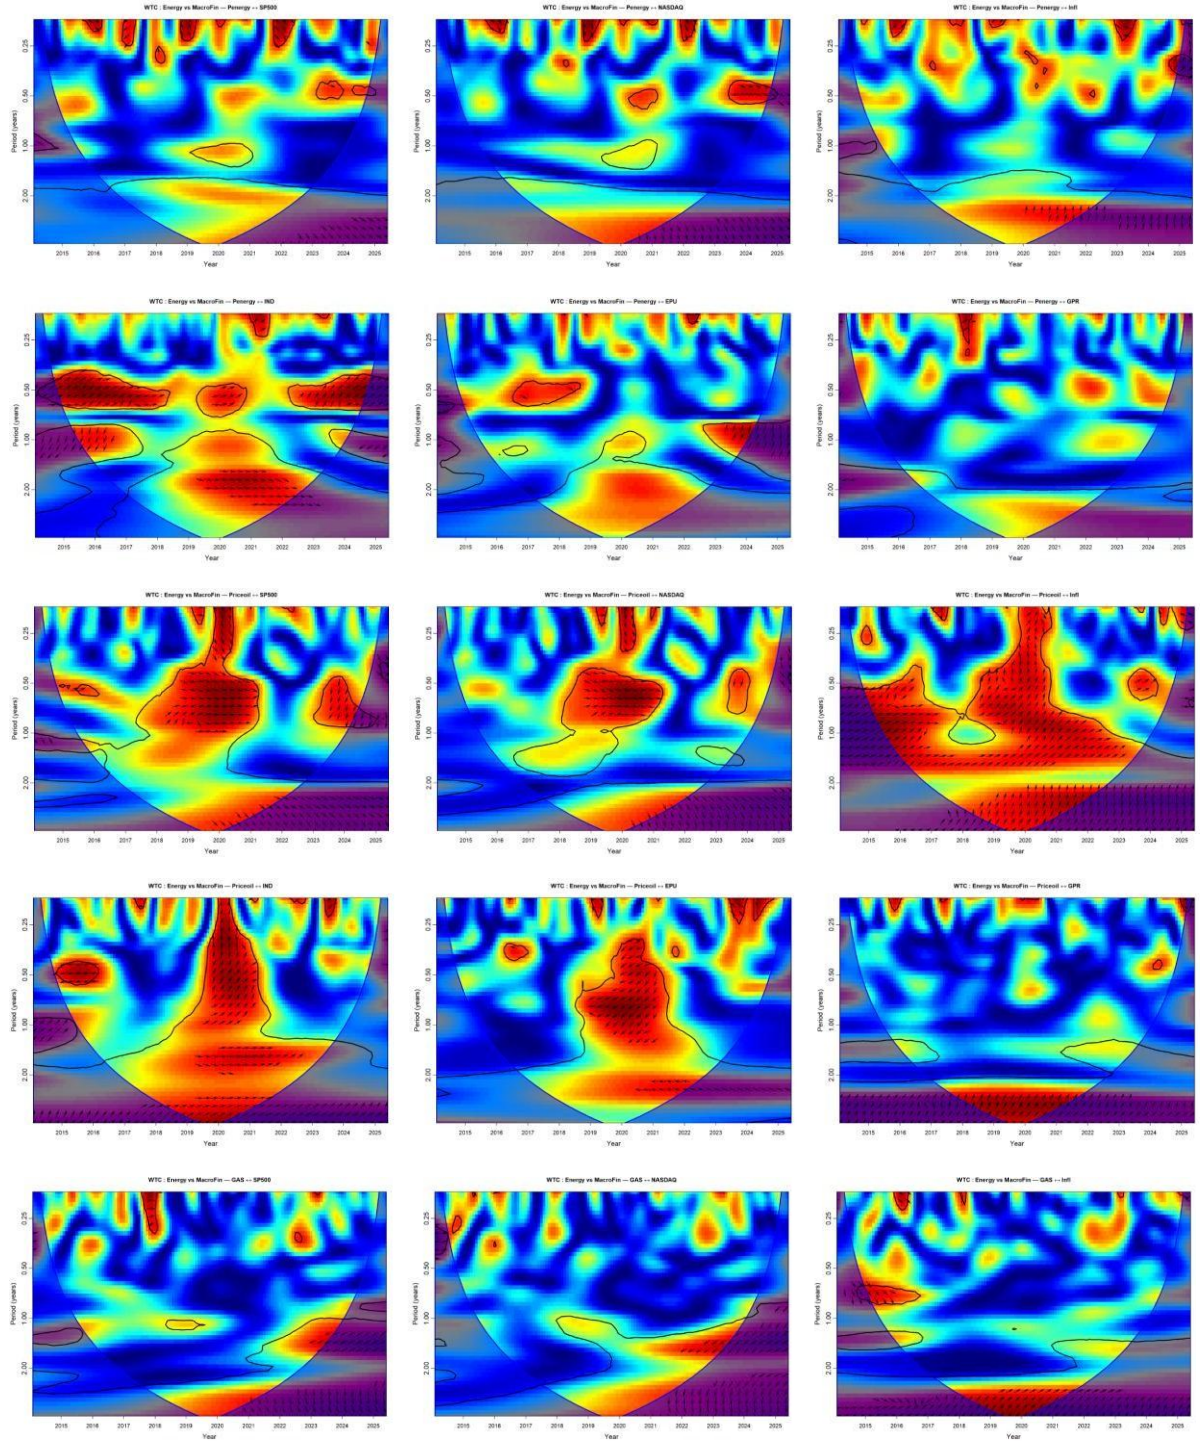

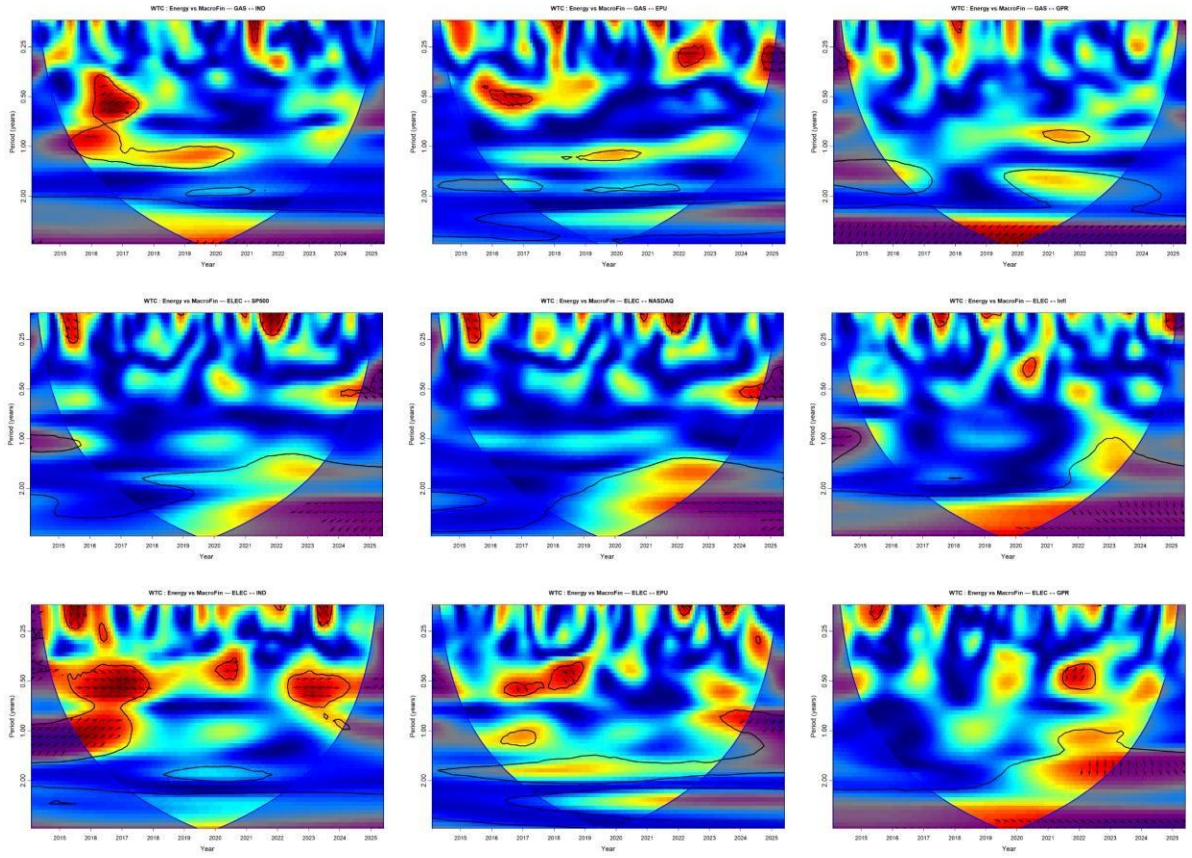

2.5.6. Comovement between energy measures and Bitcoin Indicators

As shown in Figure 2.6, the relationship between primary energy consumption (Penergy) and Bitcoin prices (PBTC) is notably intermittent, with two distinct synchronization episodes, first during 2016-2018 and then between 2020-2023, both characterized by in-phase movements suggesting that energy demand and Bitcoin market cycles evolved together during periods of heightened crypto activity and global energy volatility. Similarly, the coherence between oil prices (Priceoil) and Bitcoin volatility (VBTC) shows a pronounced and time-bound connection around 2018-2021, when oil market fluctuations and crypto-market instability became synchronized in response to systemic shocks such as the COVID-19 crisis.

In parallel, the link between electricity prices (ELEC) and Bitcoin prices (PBTC) displays two medium-term comovement episodes, centered around 2016-2017 and 2021-2023 periods, where both series move in phase. These results suggest that electricity costs and energy market dynamics intermittently influence Bitcoin valuation and volatility, primarily through the energy-intensive mining process and the sensitivity of crypto-market behavior to global energy shocks. Overall, the findings point to a temporary and cyclical energy-Bitcoin connection,

strongest during major crises and market adjustments, but not structural or persistent over time, underscoring the situational nature of crypto-energy interdependence.

Figure 2.6 Comovement between energy measures and Bitcoin Indicators

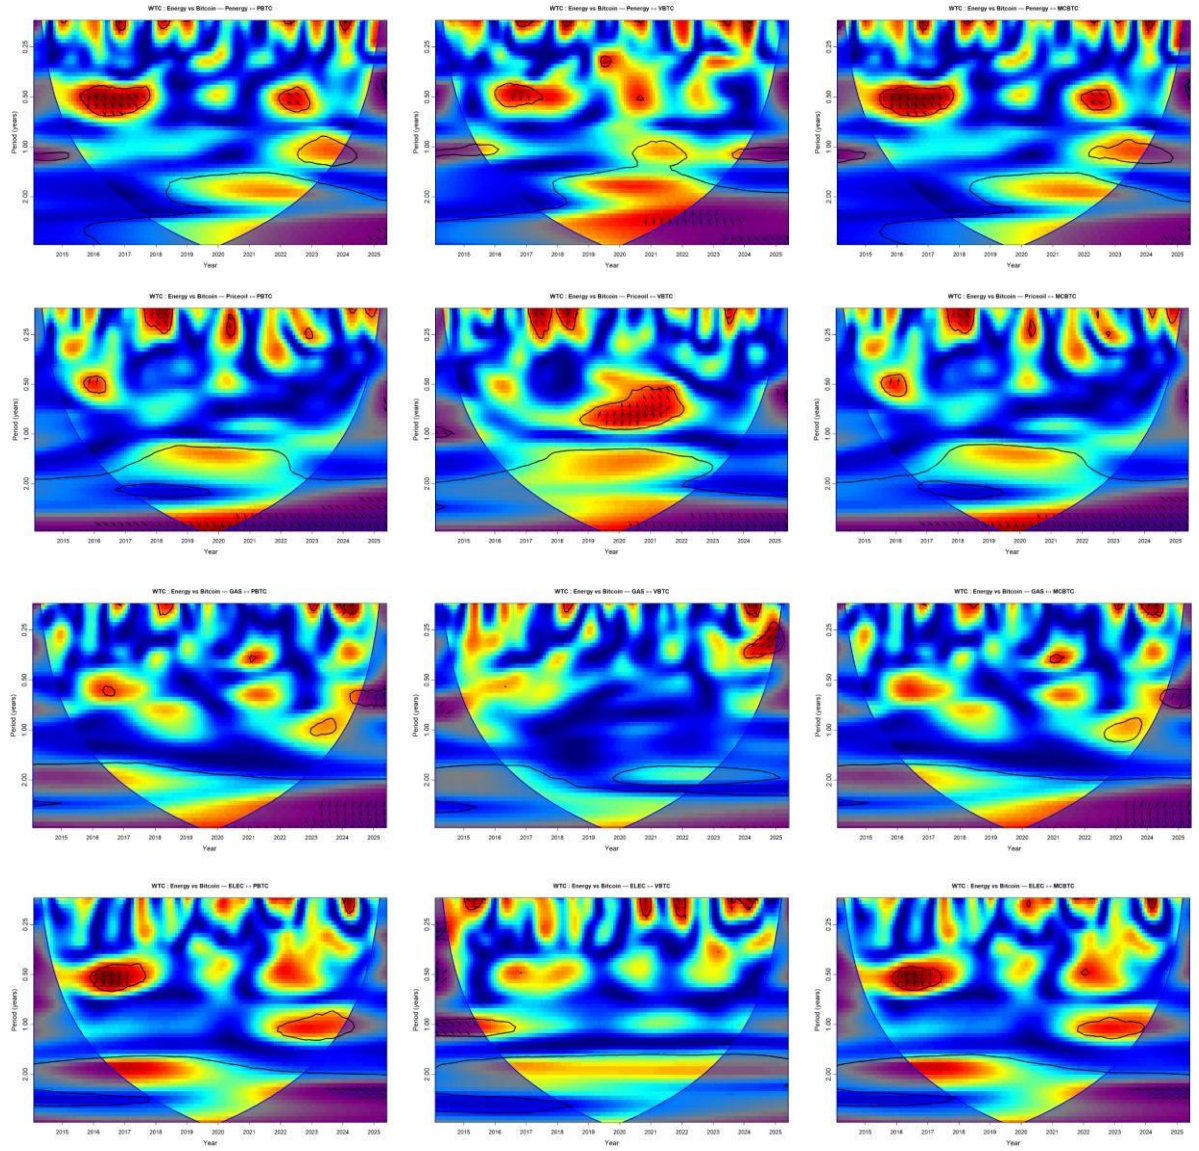

2.5.7. Comovement between Macrofinancial & Uncertainty Indicators variables and Bitcoin Indicators

The wavelet coherence results between macrofinancial indicators and Bitcoin variables (Figure 2.7) reveal episodic but economically significant linkages, mainly concentrated during major global disruptions between 2018 and 2023. The SP500-PBTC pair shows a moderate and time-limited comovement around 2019-2021, especially over long-term cycles (1.5-2 years), where Bitcoin and U.S. equities moved in phase, a reflection of shared risk-on behavior during the

COVID-19 crisis and liquidity-driven recovery. Similarly, the Infl-VBTC and EPU-VBTC plots display synchronized dynamics in medium-term horizons (0.8-1.5 years) over the 2018-2021 period, when rising inflation and surging policy uncertainty coincided with heightened Bitcoin volatility. These results highlight that Bitcoin's instability was closely tied to macroeconomic shocks and shifts in monetary expectations, reinforcing its sensitivity to global uncertainty cycles rather than its role as an inflation hedge or safe haven.

At the real-economy level, industrial production (IND) exhibits intermittent yet meaningful synchronization with Bitcoin prices and volatility, particularly between 2019 and 2023, confirming the growing interdependence between digital assets and the business cycle during the post-pandemic rebound. Meanwhile, geopolitical risk (GPR) shows only weak and short-lived coherence with Bitcoin prices, limited to 2018-2019 and 2022-2023, suggesting that Bitcoin reacts to geopolitical shocks as a speculative sentiment asset rather than a structural hedge. Altogether, the evidence indicates that Bitcoin's connection with macrofinancial and real variables is cyclical and event-driven, intensifying during crises marked by liquidity shocks, uncertainty spikes, and synchronized global financial stress, but dissipating once market conditions stabilize.

Figure 2.7 Comovement between Macrofinancial & Uncertainty Indicators variables and Bitcoin Indicators

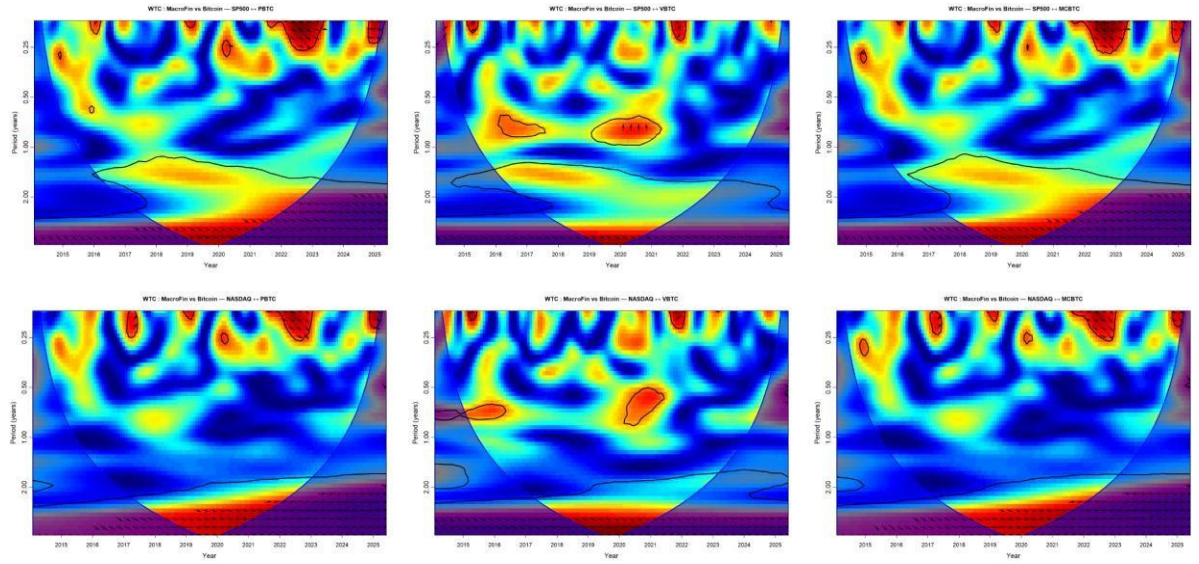

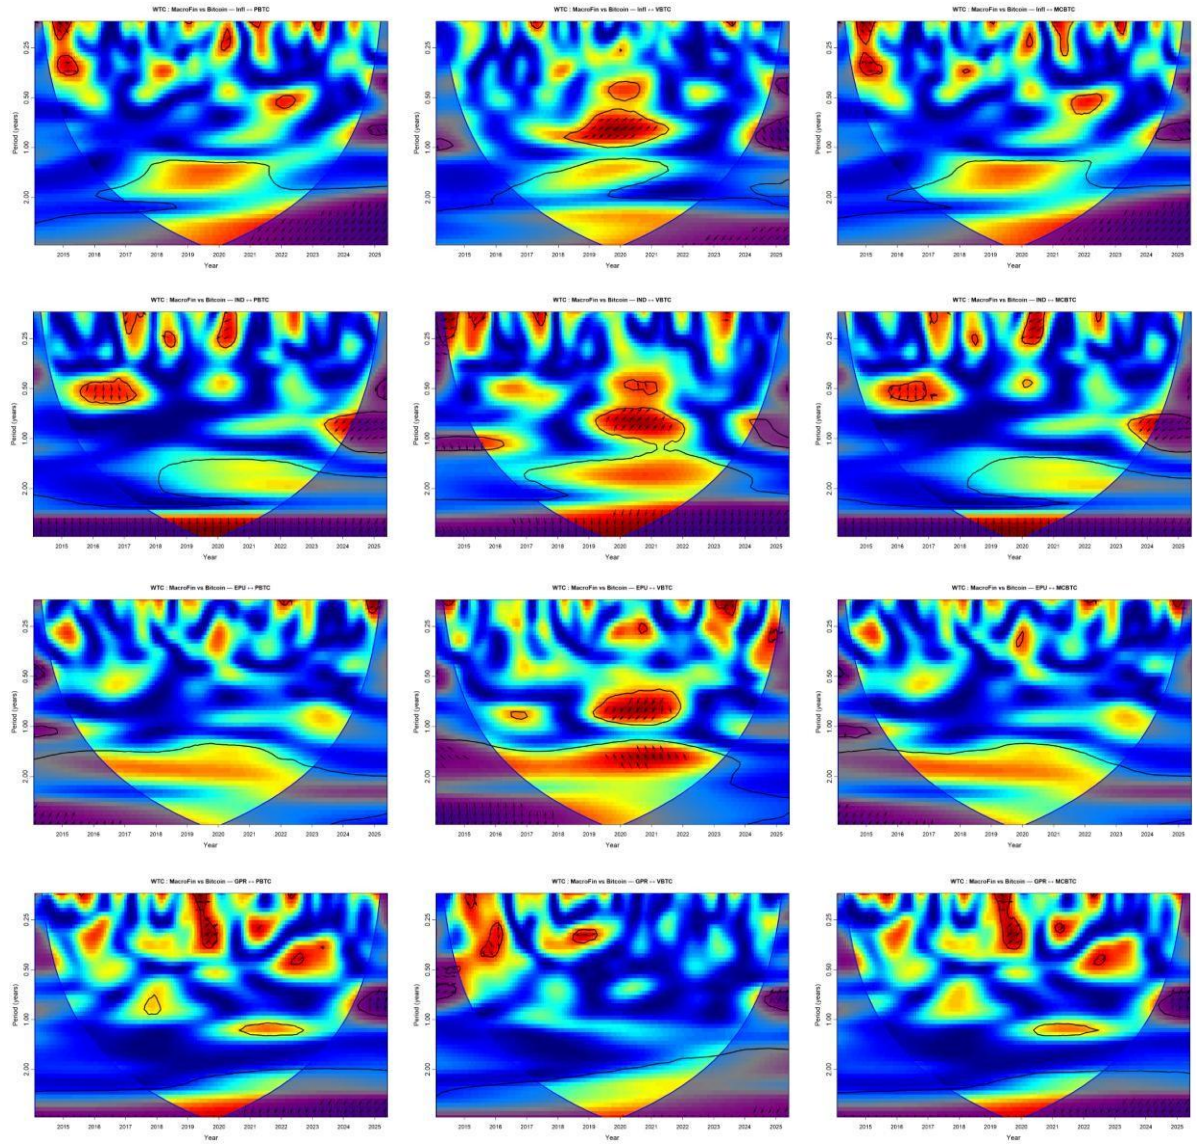

Across the four analytical pillars, the wavelet coherence results consistently reveal episodic yet economically significant time-frequency comovements, mainly concentrated during periods of global disruption between 2018 and 2022. The most persistent and structurally coherent relationships appear between CO2 emissions and industrial production, and between oil prices, inflation, and industrial activity, confirming the central role of energy markets as transmission channels of macrofinancial shocks. Environmental variables (CO2, RENERG, ESGUI) also display reinforced coherence with both energy prices and Bitcoin dynamics during 2019-2021, reflecting how the crypto-energy-environment nexus tightened amid the pandemic and post-crisis rebound. Similarly, Bitcoin's synchronization with equity indices,

inflation, and uncertainty indicators points to its cyclical responsiveness to liquidity conditions and global risk sentiment rather than any long-term safe-haven property.

To validate the robustness of these findings, all analyses were re-estimated using the Paul mother wavelet (parameter = 6) instead of the Morlet function. The main direction, timing, and phase structure of the coherence episodes remain consistent, though the overall magnitude of coherence slightly weakens, confirming that the observed relationships are methodologically robust and economically stable across wavelet specifications. The corresponding robustness plots are presented in the Appendix (Figures A7-A12).

2.5.8. TVP-VAR connectedness analysis

Based on the proposed approach by Wang et al. (2021), we modified the structure to suit our data covering a period of 138 months. We define the mean values for 1-24 months (D1-D2) as short term, 24-60 months (D3-D4) as medium term, and 60 months or more (D5-D6) as long term (see Table 2.3).

Table 2.3 Correspondence of the frequency scale of the wavelet decomposition

Frequency scale	Time scale	
D1	1-12	Short-term
D2	12-24	
D3	24-48	Medium-term
D4	48-60	
D5	60-84	Long-term
D6	>84	

We employ the MODWT technique to obtain a deeper comprehension of the connectedness between our variables, breaking down the return series into six distinct time frames, which allows us to extract information across various time periods and frequencies. As shown in Table A1 in the Appendix, the tests confirm that the decomposed series are stationary, which validates their use in the TVP-VAR approach. Figure 2.8 presents graphs of the return series that are deconstructed using wavelet analysis. The high-frequency scales (D1-D3) display dense and irregular oscillations, reflecting short-term volatility and noise, while the intermediate bands (D4-D5) begin to show more structured cyclical patterns with visible medium-term fluctuations. As we move toward the low-frequency levels (D6-D7), the series become progressively smoother, capturing persistent trends and long-run dynamics. The final smooth

component (S6) isolates the dominant low-frequency behavior, revealing underlying structural movements that persist across the sample period.

Figure 2.8 Wavelet decomposition of used variables

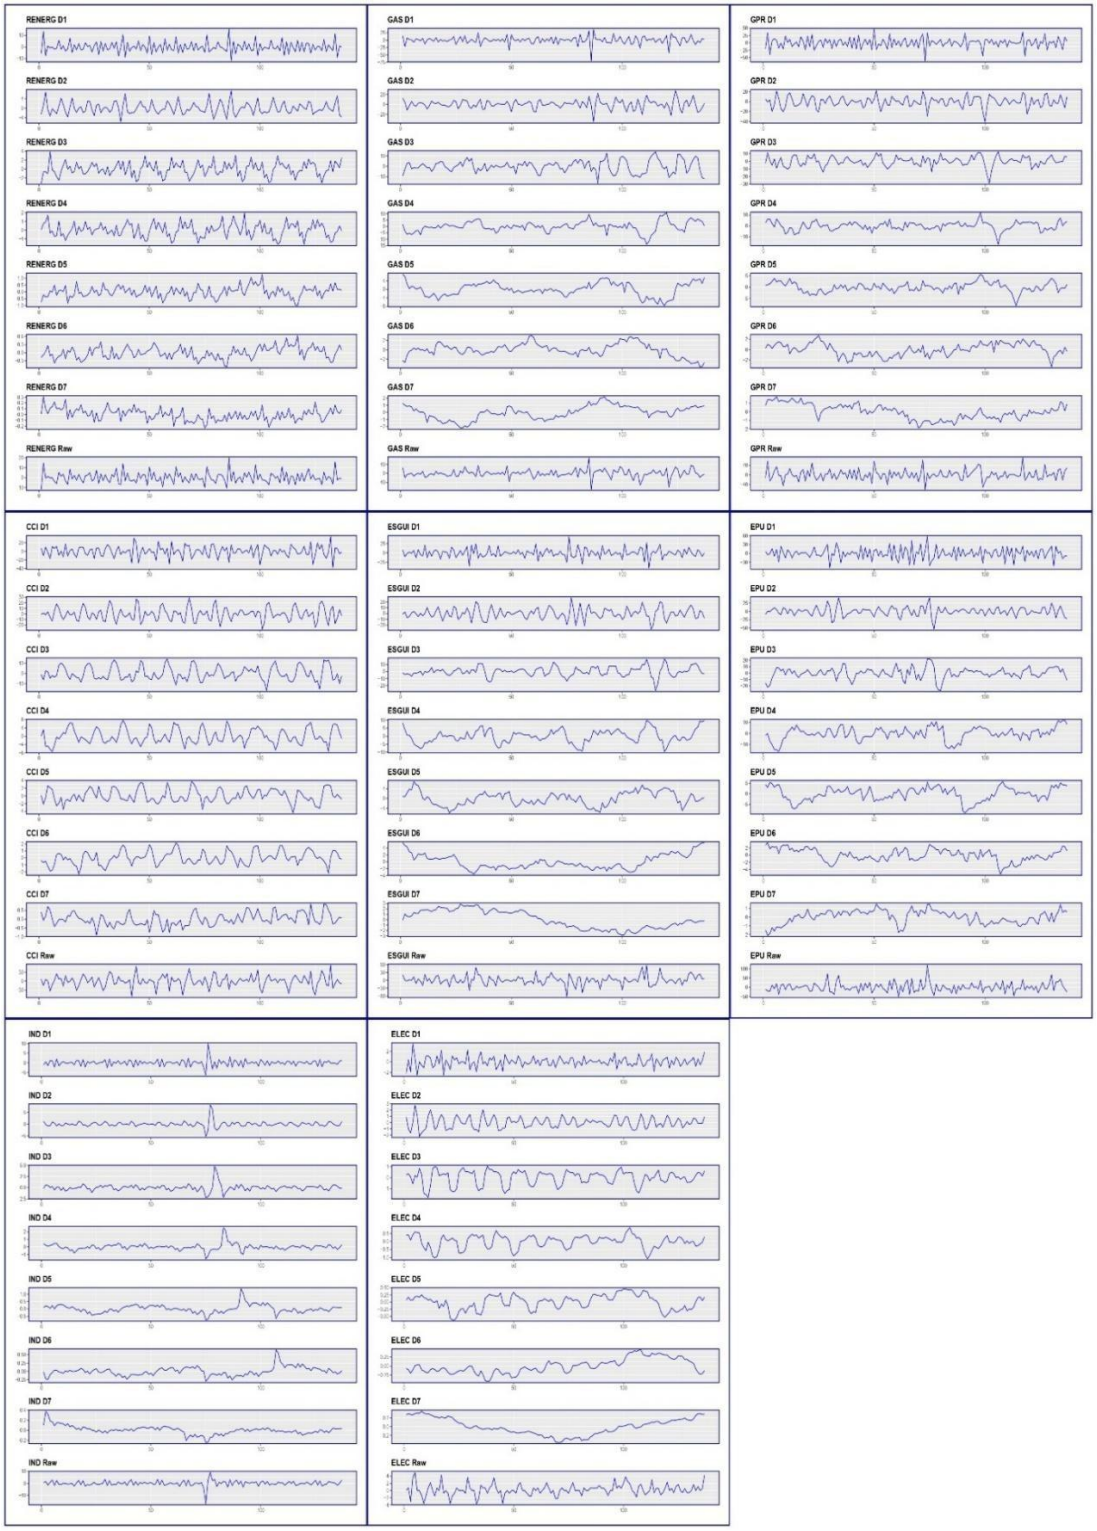

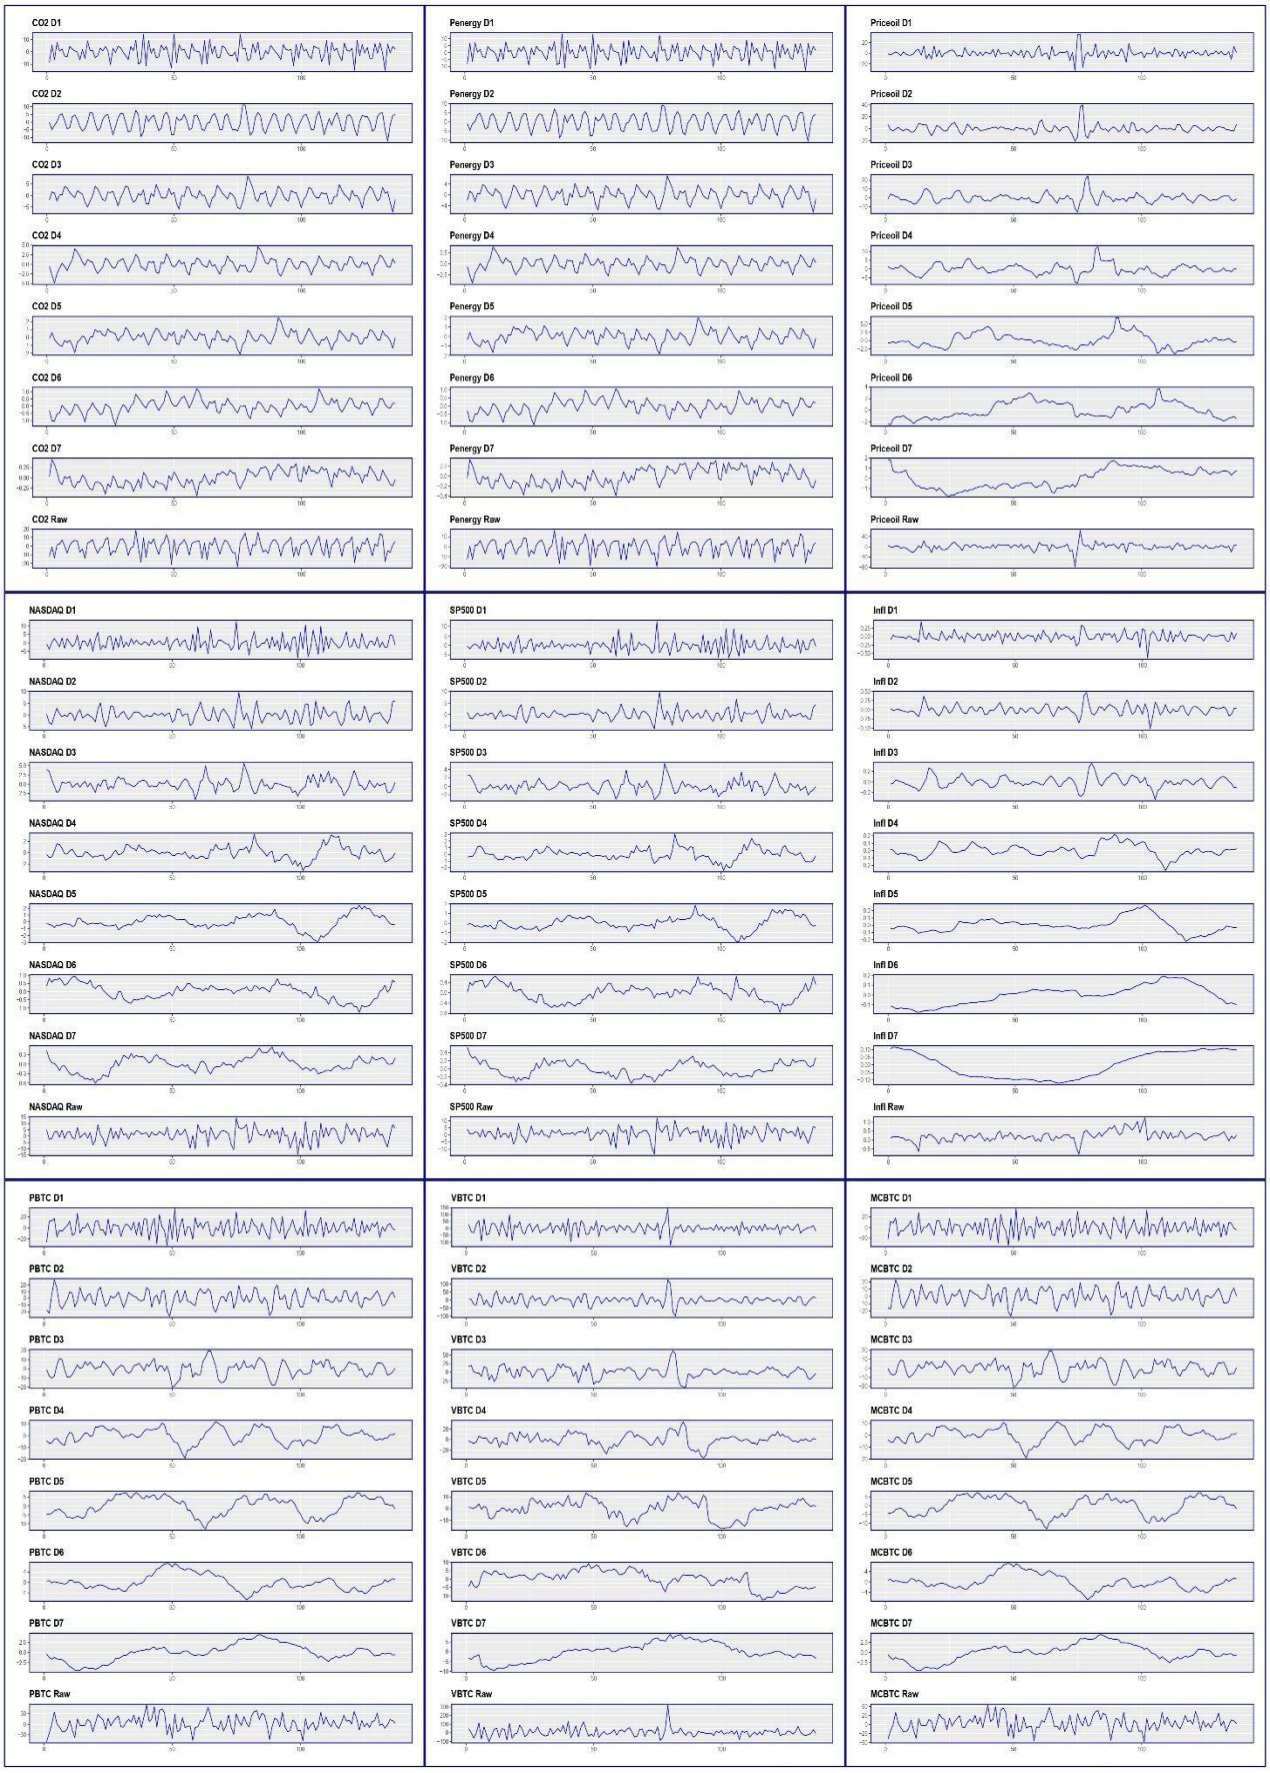
CO2 D1
CO2 D2
CO2 D3
CO2 D4
CO2 D5
CO2 D6
CO2 D7
CO2 Raw
Penergy D1
Penergy D2
Penergy D3
Penergy D4
Penergy D5
Penergy D6
Penergy D7
Penergy Raw
Priceoil D1
Priceoil D2
Priceoil D3
Priceoil D4
Priceoil D5
Priceoil D6
Priceoil D7
Priceoil Raw
NASDAQ D1
NASDAQ D2
NASDAQ D3
NASDAQ D4
NASDAQ D5
NASDAQ D6
NASDAQ D7
NASDAQ Raw
SP500 D1
SP500 D2
SP500 D3
SP500 D4
SP500 D5
SP500 D6
SP500 D7
SP500 Raw
Infl D1
Infl D2
Infl D3
Infl D4
Infl D5
Infl D6
Infl D7
Infl Raw
PBTC D1
PBTC D2
PBTC D3
PBTC D4
PBTC D5
PBTC D6
PBTC D7
PBTC Raw
VBTC D1
VBTC D2
VBTC D3
VBTC D4
VBTC D5
VBTC D6
VBTC D7
VBTC Raw
MCBTC D1
MCBTC D2
MCBTC D3
MCBTC D4
MCBTC D5
MCBTC D6
MCBTC D7
MCBTC Raw

We then combine the TVP-VAR model and Diebold and Yilmaz's spillover measure to estimate the transmission of returns across the variables . We determined the lag of the TVP-VAR model to be 3 based on the AIC and BIC criteria and considered the forecast horizon value to 12.

Figure 2.9 illustrates the Total Connectedness Index (TCI) across multiple frequency bands, capturing the evolution of overall systemic dependence over time. The TCI remains consistently high across all horizons, typically between 70 % and 90 %, revealing a persistently integrated system with strong spillovers among all variables. In the short-term scales (D1-D2), the index exhibits small but frequent oscillations, reflecting rapid transmission of short-lived shocks and episodes of market stress. At the medium-term levels (D3-D5), the connectedness stabilizes, suggesting the dominance of cyclical linkages and gradual cross-market adjustments. In the long-term horizons (D6-S6), the TCI curve becomes smoother and less volatile, indicating that systemic interdependence is primarily driven by structural rather than transient factors. Overall, these results demonstrate that cross-market linkages remain robust and persistent across time-frequency dimensions, confirming the presence of a stable yet adaptive dependence structure within the system.

As shown in Table 2.4, in the short term (D1-D2), spillover intensity is high and highly reactive to market disturbances, with the TCI rising from 76% in the raw series to 85-89% across the first two wavelet scales. The strongest short-horizon transmitters are Priceoil, SP500, NASDAQ, and PBTC, confirming that energy and financial shocks dominate rapid information transmission. These short-term interactions capture the system's immediate response to crises such as the COVID-19 collapse in March 2020 and subsequent energy-market volatility, consistent with the short-lived yet powerful contagion identified in Antonakakis and Gabauer (2020).

In the medium term (D3-D4), connectedness becomes more persistent but less erratic, with TCI values stabilizing around 85-88%, indicating a structural adjustment phase. During this horizon, transmission is mainly driven by Infl, Priceoil, ELEC, and IND, as inflation dynamics and industrial recovery amplify energy-financial linkages. The co-leadership of GAS and EPU at these scales highlights the integration of geopolitical and policy uncertainty into the energy-macro channel, reflecting the medium-run propagation of post-pandemic and Ukraine-war effects.

In the long term (D5-D6), overall connectedness remains strong yet more stable (89-93%), suggesting enduring but less crisis-sensitive interdependence. The long-horizon transmitters

shift toward CO2, ELEC, IND, and ESGUI, revealing that environmental and sustainability-related linkages have become structural drivers of systemic connectedness. The persistence of high TCI at the scaling level (S6 93%) points to deep, low-frequency comovements binding environmental, energy, macroeconomic, and crypto-financial dimensions. This long-run cohesion implies that the system's architecture is governed by fundamental, policy-driven, and sustainability-based interconnections rather than transient shocks, consistent with the structural transmission mechanisms highlighted in Diebold & Yilmaz (2014) and Buchwalter et al. (2026).

Figure 2.9 Total connectedness index (TCI)

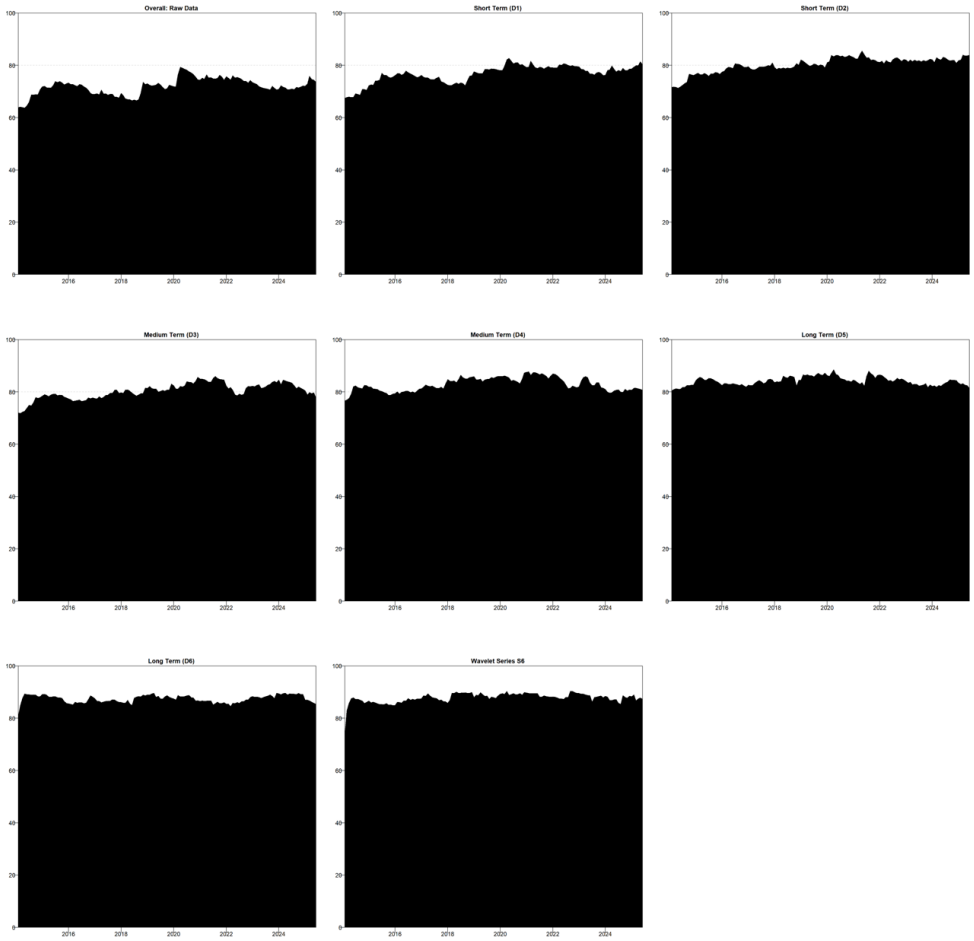

As shown in Figure 2.10, the NPT dynamics depict a clear sequential reordering of systemic leadership across sectors. In the early stage (2014-2018), PBTC, Priceoil, and Penergy dominate, reflecting the joint rise of speculative crypto activity and the post-oil-collapse energy rebound, while SP500 maintains consistent topological influence as the main global transmitter. Between 2018 and 2021, dominance transitions progressively from energy and industrial

drivers toward financial and macro variables. The 2018-2019 period is marked by sharp NPT spikes in GAS, Priceoil, and IND, consistent with volatile energy-demand adjustments and industrial amplification of shocks. During the COVID-19 phase (2020), contagion becomes highly synchronized, with SP500, IND, and Infl leading the system, indicating a compressed macrofinancial transmission structure. By 2021, the network shifts again toward Infl, Penergy, and ELEC, signaling the onset of the post-pandemic inflation-energy nexus that precedes the Ukraine-war disruptions.

The 2022-2023 window confirms this reorientation, as Priceoil, ELEC, and Penergy dominate alongside growing contributions from GPR and EPU, capturing the geopolitical and policy-uncertainty amplification of energy shocks. Finally, in 2024-2025, PBTC, VBTC, MCBTC, and ESGUI emerge as renewed systemic transmitters, while CO2 and ELEC remain structurally influential, evidencing a lasting energy-environmental coupling. Overall, the NPT trajectories reveal a three-stage evolution: from energy-crypto dominance (2014-2018), to macrofinancial synchronization (2018-2021), and finally to a digital-environmental leadership (2022-2025).

Figure 2.10 Overall net pairwise Transmission (NPT)

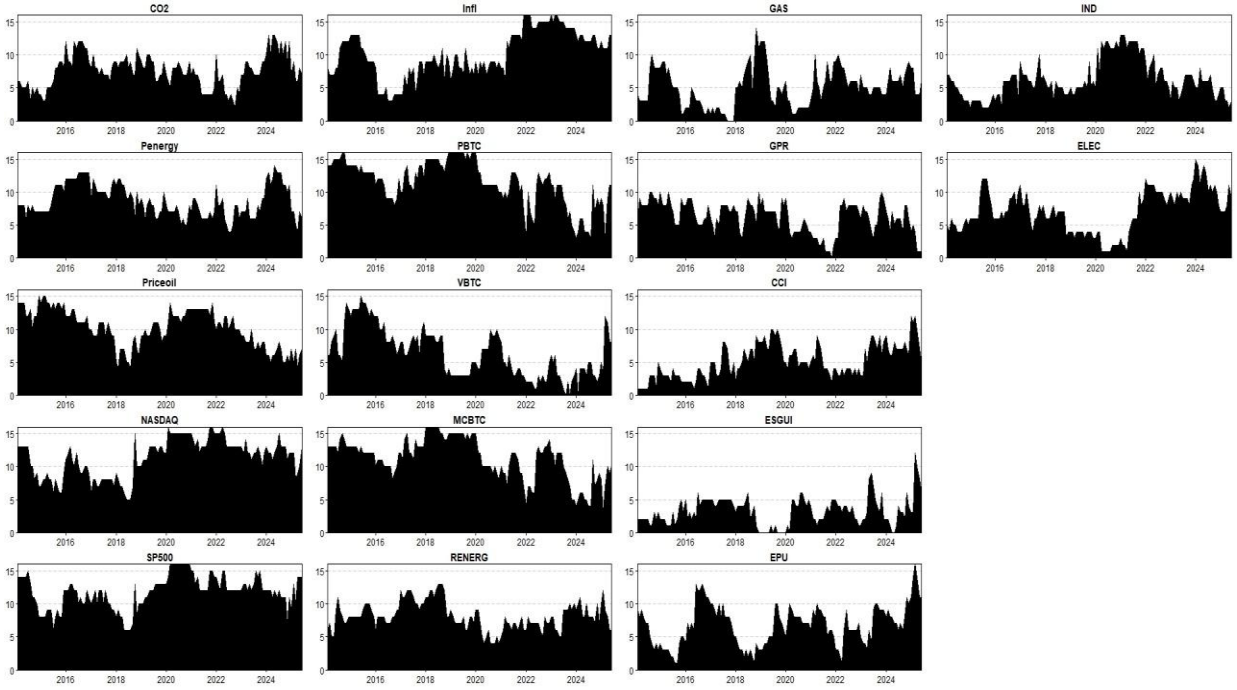

Furthermore, the net directional connectedness plots in Figure 2.11 offer a more detailed perspective by revealing which variables are primarily shock emitters or receivers. For example, during the pre-2020 period, transmission is mainly driven by energy and crypto markets: Priceoil, GAS, and PBTC act as persistent net transmitters, while environmental (CO2) and

macro variables remain largely neutral. The COVID-19 phase (2020) brings a short-lived alignment of positive NTDC for SP500 and NASDAQ, indicating strong but transient financial contagion. From 2021 to 2023, the connectedness structure becomes decisively macro-energy oriented: Infl, Penergy, Priceoil, and ELEC emerge as dominant transmitters, capturing the inflation-energy nexus and supply disruptions following the Ukraine conflict. In contrast, GPR and RENERG evolve into stable receivers, absorbing systemic shocks rather than amplifying them. In the most recent period (2024-2025), leadership shifts again toward PBTC, VBTC, MCBTC, ESGUI, and EPU, marking a new phase where digital-financial and sustainability-driven contagion replaces traditional energy dominance. Overall, the NTDC dynamics confirm a three-regime evolution of systemic influence, energy-crypto leadership (pre-2020), macrofinancial transmission (2020-2023), and digital-policy-environmental contagion (2024-2025)

Figure 2.11 Net Total Directional Connectedness Index

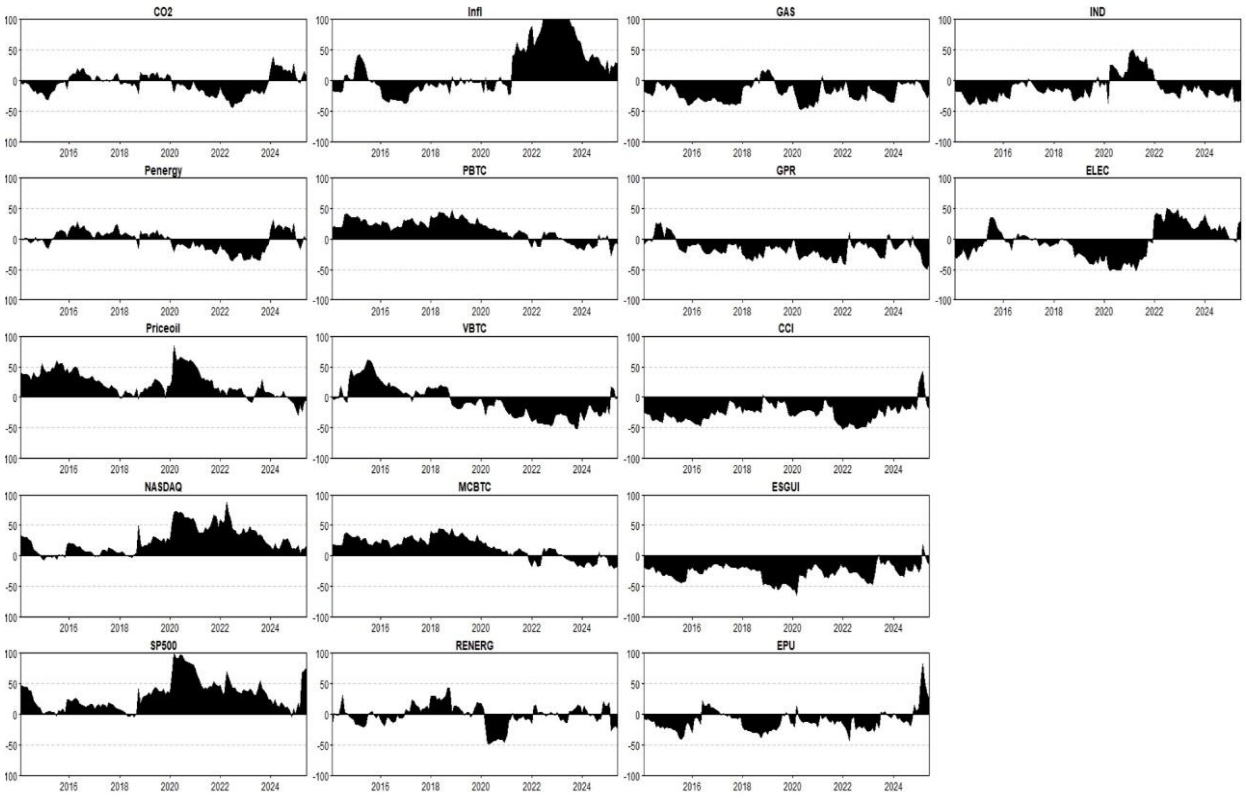

The connectedness matrix obtained enables the identification of sources and recipients of net shocks through a graphical network representation (Figure 2.12). Blue nodes represent net shock emitters, while yellow nodes denote net shock receivers. The arrows indicate the

direction of transmission, and their thickness reflects the intensity of connectedness.

Figure 2.12 displays the connectedness networks for the raw system and the MODWT-decomposed series (D1-D6 + S6). The overall graph (raw data) captures the global structure of dependencies, with Infl, SP500, NASDAQ, and Priceoil appearing as dominant net transmitters, while environmental and sentiment variables such as CO2, ELEC, GPR, and ESGUI act as net receivers. However, this aggregate topology conceals significant frequency-specific reconfigurations. The decomposition unveils that transmission roles evolve across horizons, exposing multiple regime switches and directional inversions, particularly within the Bitcoin cluster, that are impossible to observe in the raw matrix.

In the short-term layers (D1-D2), the network is dominated by financial and speculative propagation. PBTC and VBTC are strong emitters, forming dense outgoing links to SP500, NASDAQ, and CCI, which reflects the fast contagion of sentiment-driven crypto shocks to equity and consumer confidence. These short-horizon connections capture the speculative feedback typical of bull-bear phases in crypto markets (Corbet et al., 2021). MCBTC joins this cluster as a secondary transmitter, reinforcing that capitalization growth in Bitcoin amplifies liquidity spillovers toward financial markets. Energy and environmental variables, by contrast, remain passive, showing that short-run volatility originates mainly from digital-financial speculation rather than physical markets.

Moving to the medium-term scales (D3-D4), the structure becomes more balanced and intertwined. PBTC continues to exert influence on financial assets but its centrality declines, while VBTC progressively turns into a net receiver, absorbing shocks from Infl, Priceoil, and ELEC. This shift signals that, as speculative euphoria fades, Bitcoin activity becomes responsive to macrofinancial and energy-price adjustments, consistent with the transition from purely speculative contagion to macro-sensitive interdependence. MCBTC, positioned between PBTC and VBTC, acts as a bridge variable transmitting valuation shocks from crypto prices to industrial and policy uncertainty indices (EPU, GPR), suggesting that capitalization fluctuations translate into cross-asset uncertainty. These medium-term dynamics reveal that the crypto block no longer leads contagion but integrates into the broader macro-energy network, echoing the "financialization" pattern noted in Bouri et al., (2020).

At the longer horizons (D5-D6), the system reorganizes around macro-structural forces. Infl and IND dominate as persistent transmitters, but Bitcoin variables retain non-trivial roles. PBTC remains a mild but consistent structural emitter, maintaining arrows toward EPU and

CCI, indicating that long-run crypto cycles influence policy and sentiment through expectation channels. Meanwhile, VBTC fully switches to receiver status, absorbing long-term shocks from Infl, SP500, and ELEC, demonstrating that transaction activity becomes an endogenous reaction to macrofinancial cycles. MCBTC behaves similarly, reflecting the capitalization adjustment of the crypto market to global liquidity and industrial conditions. This phase confirms that Bitcoin's systemic influence persists, yet its directionality reverses, from driving contagion in high-frequency horizons to absorbing macrofinancial and energy dynamics over the long run.

Finally, at the residual equilibrium scale (S6), the topology crystallizes into the most persistent structure of global connectedness. The system is anchored by Infl, ELEC, and IND, which transmit enduring shocks to nearly all other variables. Within this equilibrium, PBTC remains a small but steady emitter, symbolizing Bitcoin's structural integration as a low-frequency volatility carrier; its influence on EPU and SP500 highlights that crypto valuations have become embedded in long-term financial expectations. Conversely, VBTC and MCBTC remain clear receivers, collecting cumulative effects from macro-price and industrial channels, implying that transactional and capitalization aspects of Bitcoin have matured into macro-responsive rather than speculative dynamics.

Overall, the multiscale decomposition fundamentally changes the interpretation of systemic connectedness. It reveals hidden causal rotations, for instance, PBTC evolves from a short-term volatility emitter to a long-term equilibrium transmitter, while VBTC and MCBTC progressively shift from transmitters to receivers as horizons lengthen. Such transitions, invisible in the aggregate graph, demonstrate that the crypto-energy-macro nexus is time-scale dependent. In the short run, contagion is speculative and sentiment-driven; in the long run, it is policy- and inflation-anchored. The MODWT-TVP-VAR approach therefore isolates how transient crypto shocks fade while structural macro-energy linkages prevail, confirming that inflation, industrial production, and electricity prices govern the enduring backbone of global connectedness, whereas Bitcoin acts as a cyclical amplifier whose influence depends critically on time scale and market regime.

The TVP-VAR results confirm a persistently high level of systemic integration, with the Total Connectedness Index ranging between 70 % and 90 % across all bands. The Net Directional Connectedness traces three distinct contagion regimes. Before 2020, spillovers stem mainly from energy and crypto transmitters (Priceoil, GAS, PBTC). During the COVID-19 phase,

shocks become synchronized under financial dominance (SP500, NASDAQ). From 2021-2023, connectedness turns macro-energy driven, led by Infl, Penergy, Priceoil, and ELEC, reflecting the inflation-energy nexus and post-Ukraine disruptions. Finally, 2024-2025 marks a digital-financial and sustainability regime, where PBTC, VBTC, MCBTC, ESGUI, and EPU transmit long-horizon shocks.

The Net Pairwise Transmission paths confirm this rotation, from early energy-crypto leadership (2014-2018) to macrofinancial synchronization (2018-2021), then to digital-environmental dominance (2022-2025). Decomposed networks reveal that short-term contagion is speculative and financial, while long-term propagation is macro-energy and policy-anchored.

All findings remain robust when the TVP-VAR is replaced by a rolling-window VAR (window = 100), consistent with Antonakakis et al., (2020), whose comparison shows this window perfectly replicates TVP dynamics. The rolling-window outputs (Figures A2-A5) reproduce the same cyclical phases, confirming the stability of the multiscale contagion structure and the sequential evolution of systemic leadership across energy, macro, and digital domains.

Figure 2.12 Network connectedness of the decomposed series

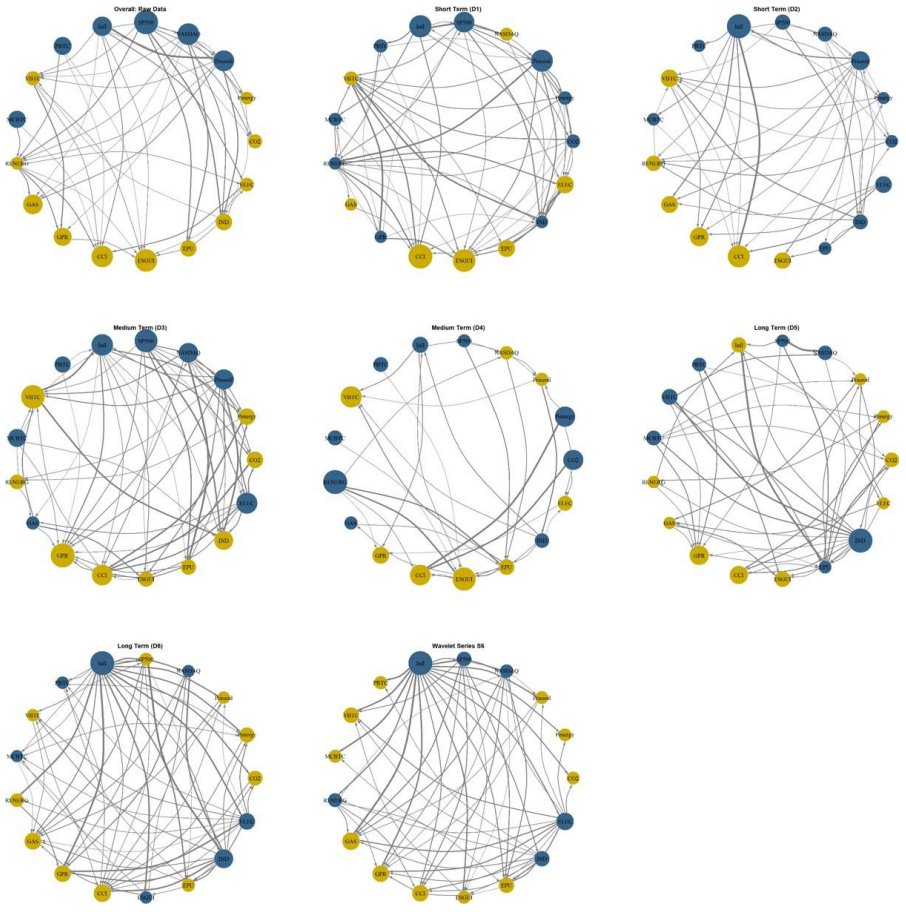

Table 2.4 Return spillovers between variables

	CO2	Penergy	Priceoil	NASDAQ	SP500	Infl	PBTC	VBTC	MCBTC	RENERG	GAS	GPR	CCI	ESGUI	EPU	IND	ELEC	FROM
Raw series																		
CO2	17.59	17.38	3.50	5.80	5.91	4.14	3.97	2.46	3.89	6.08	4.38	2.21	4.14	2.08	3.43	6.19	6.86	82.41
Penergy	16.69	17.40	3.52	5.58	5.82	4.08	4.37	2.56	4.27	7.26	3.56	2.32	4.34	1.93	3.48	5.82	7.00	82.60
Priceoil	2.92	3.59	35.21	7.81	10.07	5.88	3.41	2.16	3.24	2.61	2.11	3.93	3.15	2.87	4.99	3.62	2.41	64.79
NASDAQ	3.17	3.06	5.54	25.83	22.40	7.79	4.96	2.09	4.69	2.69	1.82	2.18	2.35	2.35	4.00	2.01	3.06	74.17
SP500	2.77	2.68	7.07	22.67	26.65	6.96	4.74	1.62	4.53	2.83	1.65	2.71	2.25	2.25	3.92	2.14	2.55	73.35
Infl	2.09	2.52	13.75	5.41	6.70	37.66	4.19	2.51	4.19	3.47	2.83	2.57	2.59	1.30	3.81	1.80	2.61	62.34
PBTC	3.04	3.39	3.18	4.14	4.20	5.61	26.06	6.50	25.88	2.55	2.80	2.40	1.59	1.51	1.65	3.60	1.88	73.94
VBTC	3.13	3.14	4.97	4.23	4.59	4.88	6.94	32.62	6.89	3.75	2.37	4.00	2.56	2.96	3.22	5.65	4.10	67.38
MCBTC	3.04	3.39	3.12	3.94	4.08	5.68	25.87	6.59	25.90	2.61	2.91	2.40	1.64	1.59	1.82	3.54	1.88	74.10
RENERG	6.84	9.01	5.31	5.23	6.71	3.82	6.17	3.05	5.88	21.66	3.67	4.23	3.99	1.84	4.24	4.99	3.38	78.34
GAS	5.16	4.18	5.55	3.99	3.32	4.99	4.30	2.44	4.12	7.49	31.50	3.46	3.98	4.46	3.80	2.99	4.27	68.50
GPR	2.60	2.56	5.52	4.16	3.87	4.25	3.58	9.04	3.67	8.18	3.39	33.73	3.65	2.46	2.60	2.36	4.39	66.27
CCI	5.37	5.27	3.28	3.49	2.83	5.77	3.65	5.31	3.65	8.48	4.62	3.98	24.78	2.64	2.88	5.93	8.08	75.22
ESGUI	3.88	3.43	4.83	3.66	3.53	3.80	3.74	5.34	3.45	3.97	4.58	4.81	2.54	34.46	4.76	4.74	4.48	65.54
EPU	2.55	2.46	6.48	8.81	8.69	3.85	2.52	2.84	2.52	3.68	3.20	2.91	3.43	4.17	33.57	4.09	4.22	66.43
IND	7.37	7.81	8.53	5.81	7.66	3.51	4.23	3.57	4.16	5.00	2.43	3.06	4.45	1.80	4.58	21.95	4.07	78.05
ELEC	6.63	6.91	3.38	4.39	4.00	6.41	2.81	3.74	2.76	6.30	2.70	3.59	3.75	2.44	2.58	6.61	30.98	69.02
TO	77.24	80.79	87.55	99.14	104.38	81.43	89.46	61.83	87.77	76.96	49.03	50.75	50.40	38.65	55.75	66.07	65.22	1222.43
Inc.Own	94.83	98.19	122.76	124.97	131.03	119.09	115.52	94.45	113.68	98.63	80.54	84.48	75.18	73.11	89.32	88.02	96.21	cTCI/TCI
NET	-5.17	-1.81	22.76	24.97	31.03	19.09	15.52	-5.55	13.68	-1.37	-19.46	-15.52	-24.82	-26.89	-10.68	-11.98	-3.79	76.40/71.91
NPT	7.00	9.00	11.00	13.00	12.00	15.00	14.00	4.00	15.00	7.00	2.00	5.00	1.00	1.00	7.00	5.00	8.00	

	CO2	Penergy	Priceoil	NASDAQ	SP500	Infl	PBTC	VBTC	MCBTC	RENERG	GAS	GPR	CCI	ESGUI	EPU	IND	ELEC	FROM
D1 Wavelet Series																		
CO2	16.72	16.67	6.47	5.41	6.60	3.94	3.51	2.47	3.48	6.63	3.88	3.04	3.71	1.90	4.34	7.47	3.75	83.28
Penergy	15.95	16.71	6.73	5.15	6.62	4.13	3.88	2.37	3.83	7.85	2.96	3.25	3.63	1.78	4.31	7.06	3.79	83.29
Priceoil	3.48	3.97	28.49	5.69	8.06	7.75	3.37	3.27	3.22	4.08	3.30	6.28	2.10	4.86	4.71	4.42	2.94	71.51
NASDAQ	4.39	3.91	4.43	19.75	17.78	8.88	3.69	2.92	3.40	4.64	3.79	4.23	2.89	3.62	6.22	2.45	2.99	80.25
SP500	3.95	3.56	6.14	16.65	21.16	8.19	3.51	2.49	3.23	4.60	4.40	5.30	2.48	3.61	5.88	2.13	2.71	78.84
Infl	3.98	3.78	9.16	4.00	6.29	28.44	2.83	4.94	2.60	5.00	6.23	3.81	3.26	4.42	4.02	3.52	3.75	71.56
PBTC	3.13	2.87	1.89	2.91	3.48	6.14	22.92	6.45	22.95	2.49	3.96	5.20	3.01	3.17	2.16	4.38	2.88	77.08
VBTC	5.25	4.89	5.50	3.57	5.13	4.41	5.65	25.47	5.88	4.12	3.97	5.24	1.97	1.79	3.70	9.04	4.44	74.53
MCBTC	3.12	2.82	1.93	2.84	3.55	5.79	22.94	6.40	23.31	2.48	4.07	5.27	2.92	3.17	2.15	4.39	2.86	76.69
RENERG	8.48	10.27	9.12	4.36	7.20	4.87	4.72	1.94	4.59	17.46	3.68	5.00	3.20	2.08	4.83	5.07	3.11	82.54
GAS	4.41	3.61	4.17	3.79	4.29	7.24	3.68	2.88	3.66	5.64	31.58	3.73	4.10	5.89	4.73	3.70	2.87	68.42
GPR	3.30	3.77	7.49	2.95	3.75	4.89	3.79	10.28	3.88	7.43	4.23	26.16	4.57	2.67	2.56	3.37	4.92	73.84
CCI	5.25	4.47	3.33	2.83	3.07	6.40	4.42	6.03	4.39	7.37	6.21	5.64	20.53	2.81	4.28	7.02	5.97	79.47
ESGUI	3.48	3.34	7.93	4.32	5.61	4.22	3.81	4.90	3.52	3.80	5.14	6.12	2.54	27.91	3.74	5.45	4.18	72.09
EPU	4.67	4.42	5.06	6.34	5.57	4.67	3.12	5.64	3.03	4.01	5.43	3.46	5.12	4.05	24.60	4.06	6.74	75.40
IND	8.31	8.50	7.61	4.23	5.66	4.50	3.93	4.05	3.96	6.84	3.04	4.82	5.04	2.56	4.99	18.00	3.97	82.00
ELEC	5.73	5.50	4.59	3.31	3.37	5.99	3.00	4.11	2.94	6.32	3.65	4.11	5.10	2.58	3.00	9.51	27.19	72.81
TO	86.87	86.35	91.56	78.33	96.02	92.01	79.85	71.14	78.55	83.31	67.95	74.50	55.64	50.97	65.62	83.03	61.87	1303.58
Inc.Own	103.59	103.06	120.05	98.09	117.18	120.45	102.77	96.61	101.86	100.77	99.53	100.67	76.17	78.88	90.22	101.03	89.06	cTCI/TCI
NET	3.59	3.06	20.05	-1.91	17.18	20.45	2.77	-3.39	1.86	0.77	-0.47	0.67	-23.83	-21.12	-9.78	1.03	-10.94	81.47/76.68
NPT	10.00	10.00	12.00	8.00	11.00	11.00	10.00	7.00	10.00	9.00	9.00	8.00	2.00	4.00	3.00	7.00	5.00	

	CO2	Penergy	Priceoil	NASDAQ	SP500	Infl	PBTC	VBTC	MCBTC	RENERG	GAS	GPR	CCI	ESGUI	EPU	IND	ELEC	FROM
D2 Wavelet Series																		
CO2	13.88	13.63	3.50	6.36	5.24	6.54	3.36	3.27	3.26	5.51	5.46	2.55	4.00	3.19	4.72	9.08	6.42	86.12
Penergy	13.73	13.99	3.82	6.04	5.01	6.60	3.16	3.55	3.10	6.31	4.85	2.54	3.99	3.18	4.50	8.97	6.66	86.01
Priceoil	5.76	5.63	23.98	7.33	9.71	6.15	2.87	1.71	3.00	3.46	2.62	2.65	3.77	3.14	6.14	5.20	6.91	76.02
NASDAQ	3.88	3.66	6.45	18.97	15.43	6.90	4.47	2.44	4.47	5.27	3.36	2.71	3.98	2.98	7.99	2.91	4.13	81.03
SP500	3.97	3.51	7.53	15.15	17.34	7.03	5.17	2.58	5.22	5.89	3.65	2.94	3.34	2.84	7.03	2.46	4.35	82.66
Infl	4.34	3.95	11.85	3.63	5.35	25.99	3.39	3.27	3.28	4.58	3.81	2.48	2.83	5.03	6.42	4.09	5.73	74.01
PBTC	3.87	3.76	3.79	4.63	5.01	6.80	19.60	5.06	19.35	2.80	3.64	3.61	2.64	4.78	3.04	4.03	3.59	80.40
VBTC	5.75	6.23	5.73	3.69	4.89	3.55	5.52	19.14	6.23	5.27	2.97	5.37	2.82	3.25	3.65	8.87	7.08	80.86
MCBTC	3.86	3.75	3.66	4.55	4.89	6.79	19.37	5.22	19.43	2.84	3.72	3.48	2.68	4.89	3.28	4.13	3.48	80.57
RENERG	9.01	9.64	6.19	4.11	5.13	7.42	3.44	2.79	3.71	16.38	3.86	2.51	4.01	3.94	4.54	8.63	4.67	83.62
GAS	4.66	3.90	6.07	4.34	4.99	9.00	4.81	3.99	4.65	4.02	22.33	3.09	4.26	5.52	4.27	5.17	4.91	77.67
GPR	2.88	2.75	5.31	2.45	2.55	6.83	4.19	9.16	4.52	3.37	4.35	26.51	3.86	4.67	5.17	4.05	7.38	73.49
CCI	5.78	5.54	6.04	5.38	3.12	11.54	4.89	5.08	4.98	6.14	4.44	3.16	11.85	3.92	3.70	4.82	9.59	88.15
ESGUI	3.87	3.55	6.87	3.84	3.31	6.52	5.10	4.25	4.95	5.11	5.52	3.93	3.43	22.30	5.51	6.78	5.15	77.70
EPU	3.52	3.20	6.34	10.48	8.42	8.34	4.08	2.43	4.20	3.05	4.44	3.54	2.32	6.11	22.78	3.68	3.05	77.22
IND	6.46	6.37	8.48	5.90	7.19	5.38	3.83	3.42	3.98	4.52	3.22	3.95	3.26	3.00	6.98	17.30	6.76	82.70
ELEC	6.83	7.11	5.89	2.71	3.02	6.32	2.86	5.57	3.00	5.17	2.22	3.82	5.02	3.42	3.03	8.90	25.13	74.87
TO	88.17	86.20	97.51	90.60	93.26	111.71	80.51	63.80	81.90	73.32	62.14	52.32	56.21	63.85	79.96	91.77	89.85	1363.08
Inc.Own	102.05	100.19	121.49	109.57	110.61	137.70	100.11	82.94	101.33	89.70	84.47	78.83	68.06	86.15	102.74	109.07	114.98	cTCI/TCI
NET	2.05	0.19	21.49	9.57	10.61	37.70	0.11	-17.06	1.33	-10.30	-15.53	-21.17	-31.94	-13.85	2.74	9.07	14.98	85.19/80.18
NPT	10.00	9.00	11.00	11.00	9.00	15.00	9.00	4.00	8.00	8.00	6.00	2.00	2.00	3.00	7.00	11.00	11.00	

	CO2	Penergy	Priceoil	NASDAQ	SP500	Infl	PBTC	VBTC	MCBTC	RENERG	GAS	GPR	CCI	ESGUI	EPU	IND	ELEC	FROM
D3 Wavelet Series																		
CO2	15.77	15.19	3.05	5.40	5.59	4.93	3.12	3.57	3.46	5.89	4.68	2.85	3.24	3.41	3.59	7.36	8.91	84.23
Penergy	14.83	14.86	3.03	5.00	5.22	5.32	3.23	3.42	3.52	6.84	4.20	3.06	3.57	3.41	3.63	7.54	9.33	85.14
Priceoil	2.45	2.53	24.79	6.99	10.15	7.93	4.59	2.82	5.12	3.51	5.06	3.54	3.94	2.85	4.33	2.74	6.67	75.21
NASDAQ	3.02	2.68	6.14	18.81	15.52	6.32	5.11	3.02	5.26	4.54	5.62	2.27	4.08	5.27	5.27	3.27	3.79	81.19
SP500	3.45	3.22	7.35	14.89	18.75	7.22	4.97	3.10	5.20	3.64	5.15	2.88	2.73	5.84	3.94	3.20	4.45	81.25
Infl	2.01	1.88	10.36	5.92	6.59	20.87	5.55	2.83	5.71	5.41	6.47	3.57	4.37	4.26	3.07	2.64	8.49	79.13
PBTC	1.99	2.04	5.08	4.40	4.44	4.12	22.58	6.35	22.66	3.47	3.95	2.79	3.51	2.42	3.46	3.36	3.39	77.42
VBTC	3.37	3.42	5.78	5.92	4.87	7.83	5.63	17.10	6.06	4.34	5.09	3.46	5.35	5.12	4.43	7.03	5.18	82.90
MCBTC	2.09	2.17	5.00	4.38	4.48	4.14	22.44	6.37	22.79	3.38	3.87	2.84	3.48	2.42	3.44	3.39	3.31	77.21
RENERG	7.10	8.50	5.15	4.55	4.38	5.83	4.45	2.29	4.52	17.03	4.43	4.23	6.61	3.71	4.04	7.56	5.61	82.97
GAS	4.35	3.43	5.38	5.15	6.20	8.02	3.74	2.20	4.00	6.15	21.85	3.83	6.08	5.88	3.50	3.66	6.60	78.15
GPR	2.32	2.29	6.43	4.49	5.49	7.22	4.25	3.63	4.54	4.45	5.45	22.76	6.67	5.67	4.47	3.80	6.07	77.24
CCI	7.90	8.51	5.07	4.95	5.03	6.39	3.38	3.34	3.32	5.79	5.43	4.04	12.32	4.15	6.60	4.78	9.01	87.68
ESGUI	3.37	3.01	5.91	3.70	4.47	6.61	3.10	5.22	3.10	3.84	9.11	3.72	2.67	27.65	5.23	3.27	6.02	72.35
EPU	4.16	3.99	6.56	10.78	8.13	4.62	3.46	3.94	3.78	4.14	3.31	2.19	3.76	4.51	22.70	4.15	5.82	77.30
IND	7.38	7.59	7.89	5.16	7.81	4.30	4.72	2.35	5.18	6.66	4.35	2.79	4.43	3.40	5.31	13.99	6.71	86.01
ELEC	5.41	5.65	4.05	5.56	5.87	8.45	4.35	4.49	4.47	5.42	4.35	4.04	4.86	3.59	6.14	3.85	19.44	80.56
TO	75.19	76.11	92.24	97.24	104.25	99.26	86.08	58.94	89.92	77.45	80.51	52.10	69.33	65.90	70.44	71.62	99.35	1365.93
Inc.Own	90.95	90.97	117.03	116.05	123.01	120.12	108.67	76.04	112.71	94.48	102.36	74.86	81.65	93.55	93.13	85.61	118.79	cTCI/TCI
NET	-9.05	-9.03	17.03	16.05	23.01	20.12	8.67	-23.96	12.71	-5.52	2.36	-25.14	-18.35	-6.45	-6.87	-14.39	18.79	85.37/80.35
NPT	4.00	6.00	12.00	10.00	12.00	12.00	11.00	5.00	14.00	5.00	8.00	2.00	6.00	7.00	7.00	4.00	11.00	

	CO2	Penergy	Priceoil	NASDAQ	SP500	Infl	PBTC	VBTC	MCBTC	RENERG	GAS	GPR	CCI	ESGUI	EPU	IND	ELEC	FROM
D4 Wavelet Series																		
CO2	17.06	16.36	2.97	3.83	3.13	4.40	4.37	2.83	4.26	6.74	3.95	4.16	3.78	3.95	4.55	6.39	7.28	82.94
Penergy	16.75	16.76	2.85	3.85	3.04	4.27	4.59	2.86	4.47	7.16	3.50	4.33	3.85	3.64	4.45	6.10	7.53	83.24
Priceoil	4.88	5.37	19.44	7.51	8.43	6.60	3.98	3.19	4.11	6.16	3.37	3.79	3.90	3.52	6.43	4.90	4.42	80.56
NASDAQ	4.21	4.25	4.91	15.40	12.85	8.22	4.56	4.63	4.69	8.45	4.86	4.54	4.36	2.67	3.80	3.55	4.05	84.60
SP500	4.85	4.68	6.22	12.38	15.32	7.71	5.12	3.81	5.25	6.57	4.94	3.22	4.68	3.39	3.67	4.96	3.22	84.68
Infl	3.71	3.97	8.15	5.73	5.80	22.18	3.87	1.73	4.26	4.21	3.24	3.92	5.30	6.54	5.54	7.74	4.12	77.82
PBTC	4.07	3.88	3.21	3.24	4.16	4.69	18.92	7.47	18.28	4.93	5.46	4.44	3.55	2.30	3.26	4.01	4.13	81.08
VBTC	3.31	3.38	5.27	4.14	4.78	5.18	7.75	16.57	8.08	5.90	4.41	5.34	4.99	3.52	7.79	6.40	3.18	83.43
MCBTC	4.04	3.92	3.42	3.29	4.26	4.73	18.41	7.40	18.05	5.09	5.61	4.40	3.57	2.28	3.38	3.95	4.19	81.95
RENERG	7.98	8.66	4.25	5.57	5.13	4.64	3.56	5.33	3.82	15.83	5.95	5.38	4.83	3.60	4.66	6.44	4.36	84.17
GAS	3.81	3.32	4.44	4.94	5.25	4.70	4.03	2.87	4.42	7.31	26.54	3.92	4.04	9.26	3.41	4.27	3.46	73.46
GPR	4.98	4.57	4.29	4.39	4.17	7.55	4.73	4.02	5.15	7.43	5.28	16.48	4.74	3.26	4.34	5.75	8.86	83.52
CCI	10.78	11.56	3.37	3.35	4.18	4.30	4.93	3.34	4.68	7.11	4.60	6.09	11.57	2.83	6.27	6.10	4.94	88.43
ESGUI	4.17	4.33	4.54	4.50	4.32	4.17	4.50	4.34	4.29	10.18	6.42	4.46	5.76	14.94	7.01	6.41	5.68	85.06
EPU	4.85	4.82	6.29	7.10	7.66	4.46	3.66	3.78	3.62	10.14	5.96	4.74	3.61	2.69	14.47	6.66	5.47	85.53
IND	7.76	7.76	9.58	5.30	6.35	4.60	4.11	3.95	4.06	7.28	3.47	3.99	4.41	3.72	4.06	16.24	3.38	83.76
ELEC	10.02	10.09	4.16	2.56	3.47	6.02	4.84	2.32	4.72	5.06	4.78	6.80	4.71	4.06	5.36	5.37	15.66	84.34
TO	100.19	100.92	77.93	81.69	86.98	86.24	87.01	63.87	88.18	109.70	75.81	73.51	70.07	61.25	77.98	89.00	78.25	1408.57
Inc.Own	117.25	117.68	97.37	97.09	102.30	108.42	105.93	80.44	106.22	125.53	102.35	89.99	81.65	76.19	92.45	105.24	93.91	cTCI/TCI
NET	17.25	17.68	-2.63	-2.91	2.30	8.42	5.93	-19.56	6.22	25.53	2.35	-10.01	-18.35	-23.81	-7.55	5.24	-6.09	88.04/82.86
NPT	12.00	11.00	6.00	5.00	9.00	11.00	13.00	2.00	12.00	13.00	9.00	5.00	6.00	2.00	5.00	8.00	7.00	

	CO2	Penergy	Priceoil	NASDAQ	SP500	Infl	PBTC	VBTC	MCBTC	RENERG	GAS	GPR	CCI	ESGUI	EPU	IND	ELEC	FROM
D5 Wavelet Series																		
CO2	12.51	12.51	4.85	4.31	4.29	3.47	4.76	5.48	5.25	6.24	3.40	3.89	4.50	3.93	6.77	8.73	5.13	87.49
Penergy	12.54	13.13	4.32	4.28	4.11	3.35	4.76	5.33	5.25	6.95	3.14	3.83	4.55	3.79	6.67	8.25	5.74	86.87
Priceoil	3.82	4.65	17.02	7.25	7.54	4.37	4.45	4.96	5.04	3.85	4.41	5.04	3.65	4.60	7.30	4.95	7.10	82.98
NASDAQ	3.44	2.86	5.28	15.10	9.54	5.15	5.65	7.66	5.74	4.72	8.36	2.76	3.50	5.59	3.61	5.71	5.34	84.90
SP500	3.48	3.29	7.50	16.40	15.24	4.12	5.51	5.20	5.69	4.49	5.60	2.52	3.25	5.12	2.66	5.36	4.57	84.76
Infl	2.04	2.70	4.73	5.84	6.88	16.22	2.68	2.90	2.71	7.71	5.80	4.41	4.33	8.73	12.17	6.88	3.27	83.78
PBTC	2.99	3.07	3.04	5.13	4.43	3.38	17.04	10.01	17.07	3.29	3.80	2.22	3.57	3.53	4.42	8.83	4.17	82.96
VBTC	5.19	4.78	3.58	4.11	3.63	4.30	8.77	19.06	8.67	4.58	3.87	3.13	4.07	3.96	3.81	9.45	5.05	80.94
MCBTC	3.15	3.25	2.97	4.86	4.31	3.40	17.02	10.21	17.28	3.22	3.60	2.26	3.66	3.52	4.43	8.64	4.23	82.72
RENERG	7.86	9.88	4.73	4.02	5.16	4.39	3.90	3.35	4.07	14.63	4.91	3.58	5.55	4.15	4.86	9.14	5.83	85.37
GAS	2.87	3.38	7.78	6.70	4.78	6.06	3.57	3.54	3.46	6.56	18.42	4.68	3.33	5.63	5.27	6.70	7.26	81.58
GPR	4.43	5.04	5.84	3.63	4.56	5.47	5.94	5.14	5.76	6.13	7.14	17.07	3.87	6.55	3.62	5.97	3.84	82.93
CCI	9.10	8.93	4.97	3.51	3.94	4.17	4.74	4.26	5.07	4.99	5.04	3.92	13.93	3.92	4.73	9.12	5.64	86.07
ESGUI	3.04	3.18	5.95	5.08	4.97	7.38	4.55	7.83	4.78	5.39	9.22	5.58	2.35	12.26	7.63	6.46	4.35	87.74
EPU	2.59	2.96	4.56	5.65	6.84	5.20	4.68	7.24	5.12	3.67	4.05	5.48	7.08	5.42	16.45	7.46	5.54	83.55
IND	6.63	7.11	8.15	4.76	5.51	3.69	4.33	3.60	4.32	7.01	4.31	3.30	5.25	3.34	4.18	18.16	6.34	81.84
ELEC	6.43	6.96	4.34	6.83	5.84	6.05	3.06	6.27	3.54	5.84	4.56	4.07	4.29	4.58	3.35	7.44	16.53	83.47
TO	79.61	84.54	82.58	92.36	86.32	73.94	88.37	92.98	91.55	84.66	81.21	60.68	66.80	76.36	85.49	119.11	83.39	1429.95
Inc.Own	92.12	97.67	99.60	107.46	101.56	90.16	105.41	112.05	108.82	99.29	99.63	77.75	80.73	88.62	101.94	137.27	99.92	cTCI/TCI
NET	-7.88	-2.33	-0.40	7.46	1.56	-9.84	5.41	12.05	8.82	-0.71	-0.37	-22.25	-19.27	-11.38	1.94	37.27	-0.08	89.37/84.11
NPT	5.00	6.00	8.00	9.00	10.00	8.00	10.00	12.00	11.00	7.00	9.00	3.00	3.00	8.00	7.00	14.00	6.00	

	CO2	Penergy	Priceoil	NASDAQ	SP500	Infl	PBTC	VBTC	MCBTC	RENERG	GAS	GPR	CCI	ESGUI	EPU	IND	ELEC	FROM
D6 Wavelet Series																		
CO2	10.23	10.09	5.92	4.41	3.92	8.55	4.88	5.17	4.92	5.02	4.67	4.60	3.84	4.45	4.46	7.52	7.36	89.77
Penergy	10.02	10.15	5.89	4.17	3.77	8.24	5.29	5.12	5.20	5.47	4.45	4.34	3.83	4.55	4.52	7.41	7.59	89.85
Priceoil	4.42	4.42	12.68	4.55	5.30	11.09	4.49	5.98	4.52	5.06	4.87	3.93	2.90	6.85	5.47	6.33	7.15	87.32
NASDAQ	3.99	3.59	4.73	10.64	9.60	9.50	6.22	4.39	6.03	3.36	3.17	3.03	2.84	5.94	5.24	11.03	6.71	89.36
SP500	3.62	3.20	4.26	10.44	11.16	8.11	7.14	4.26	6.93	3.28	2.89	3.06	3.06	5.89	4.60	11.85	6.23	88.84
Infl	3.37	3.30	5.87	4.37	2.82	26.01	4.06	5.32	3.95	2.84	5.01	2.67	5.52	6.44	6.23	6.16	6.05	73.99
PBTC	3.47	3.15	3.65	5.73	4.97	6.20	14.69	5.79	14.66	4.29	3.26	6.05	2.84	3.48	5.77	5.72	6.28	85.31
VBTC	3.76	3.61	5.27	4.79	3.90	8.47	5.56	12.16	5.11	6.76	3.33	3.69	3.82	8.00	5.19	8.17	8.41	87.84
MCBTC	3.40	3.14	3.65	5.66	4.83	6.30	14.65	6.06	14.92	4.29	3.20	5.69	2.82	3.60	5.93	5.63	6.23	85.08
RENERG	5.80	6.14	4.63	4.74	4.15	9.00	5.54	6.18	4.98	11.03	3.57	3.26	4.13	5.28	4.42	7.97	9.17	88.97
GAS	4.48	4.19	7.80	6.06	6.61	8.91	4.86	5.35	4.94	5.08	9.58	4.37	3.20	6.33	5.10	6.46	6.68	90.42
GPR	3.90	3.45	4.74	7.22	6.21	9.57	4.86	5.26	4.44	7.09	3.71	9.15	3.55	5.04	4.64	8.24	8.94	90.85
CCI	6.74	6.84	5.27	5.52	5.26	8.38	5.32	4.78	4.99	5.26	3.76	3.67	9.83	4.81	4.23	8.79	6.55	90.17
ESGUI	3.43	3.27	4.58	6.66	6.13	11.96	3.99	5.92	3.82	4.20	3.56	4.29	3.95	14.31	5.20	8.51	6.22	85.69
EPU	3.84	3.50	5.98	6.25	6.48	11.16	3.58	5.53	3.70	4.29	4.04	3.74	4.46	4.43	12.38	8.22	8.43	87.62
IND	4.69	4.47	6.33	5.63	5.02	9.12	4.16	5.28	4.35	6.61	3.42	3.50	3.24	6.48	4.12	15.37	8.21	84.63
ELEC	4.33	4.12	5.35	5.44	5.36	12.46	4.12	5.46	3.80	6.57	4.72	3.58	4.13	6.61	5.03	8.30	10.62	89.38
TO	73.25	70.47	83.93	91.64	84.33	147.01	88.74	85.86	86.33	79.48	61.64	63.46	58.13	88.17	80.15	126.31	116.21	1485.09
Inc.Own	83.48	80.61	96.61	102.28	95.50	173.02	103.42	98.02	101.25	90.51	71.22	72.61	67.96	102.48	92.53	141.67	126.83	cTCI/TCI
NET	-16.52	-19.39	-3.39	2.28	-4.50	73.02	3.42	-1.98	1.25	-9.49	-28.78	-27.39	-32.04	2.48	-7.47	41.67	26.83	92.82/87.36
NPT	2.00	3.00	7.00	10.00	9.00	16.00	9.00	10.00	10.00	5.00	3.00	6.00	1.00	9.00	8.00	15.00	13.00	

	CO2	Penergy	Priceoil	NASDAQ	SP500	Infl	PBTC	VBTC	MCBTC	RENERG	GAS	GPR	CCI	ESGUI	EPU	IND	ELEC	FROM
S6 Wavelet Series																		
CO2	11.18	10.90	2.94	6.01	6.46	9.58	5.03	2.99	5.17	7.97	2.57	2.60	3.14	4.69	3.81	7.33	7.63	88.82
Penergy	10.37	10.45	3.14	5.82	6.61	9.67	4.97	2.90	5.09	8.32	2.54	2.61	3.21	5.06	3.88	7.35	8.01	89.55
Priceoil	4.22	4.17	14.69	6.69	7.31	13.23	4.03	3.26	4.05	5.51	2.29	3.19	3.94	4.43	4.41	6.69	7.90	85.31
NASDAQ	5.28	4.92	4.64	9.98	8.94	12.82	5.03	3.14	5.14	7.73	2.04	3.23	2.60	3.43	3.35	8.86	8.91	90.02
SP500	5.31	5.45	4.65	10.30	11.72	11.12	5.45	2.82	5.53	7.75	1.55	2.52	2.52	3.59	3.81	7.79	8.13	88.28
Infl	3.52	3.22	6.55	4.88	5.95	25.21	4.05	3.42	4.17	4.64	2.55	2.86	4.11	4.59	3.73	6.80	9.74	74.79
PBTC	4.08	3.94	5.41	5.80	6.90	11.82	10.16	4.39	10.09	4.82	2.46	2.68	3.40	5.03	3.81	8.22	6.99	89.84
VBTC	4.34	4.43	4.44	5.22	6.71	10.94	4.85	11.63	4.91	5.31	2.94	2.81	4.22	7.39	5.26	5.95	8.65	88.37
MCBTC	4.08	3.92	5.37	5.77	6.95	11.94	10.04	4.51	10.08	4.78	2.44	2.73	3.43	4.92	3.87	8.22	6.93	89.92
RENERG	6.82	7.75	3.86	4.99	6.65	11.81	4.66	3.36	4.63	12.11	2.85	3.33	3.24	4.42	4.24	6.30	8.96	87.89
GAS	4.82	4.68	5.78	7.29	7.38	12.25	4.43	3.59	4.50	6.84	8.69	2.89	3.25	4.66	3.26	6.98	8.71	91.31
GPR	3.91	3.88	6.30	6.60	6.31	10.37	4.39	4.22	4.28	6.20	2.97	10.00	3.67	7.22	3.20	7.14	9.34	90.00
CCI	5.47	5.63	4.76	7.41	7.45	8.80	5.04	4.02	4.76	7.01	3.12	4.54	8.29	4.55	3.41	7.17	8.57	91.71
ESGUI	4.37	4.40	4.01	5.92	6.55	12.02	3.62	4.23	3.67	6.82	3.70	2.95	2.97	16.01	3.69	6.55	8.52	83.99
EPU	4.12	4.08	5.51	8.01	8.59	9.01	4.46	2.94	4.53	7.24	3.41	3.80	2.95	3.39	10.04	9.00	8.93	89.96
IND	6.47	6.77	4.97	6.47	7.27	11.72	5.07	2.67	4.96	8.32	2.57	2.66	2.72	3.86	3.22	12.74	7.54	87.26
ELEC	3.78	3.62	4.94	5.68	6.53	15.89	4.69	3.69	4.82	6.11	2.63	3.68	3.47	5.40	3.34	6.52	15.21	84.79
TO	80.96	81.75	77.26	102.86	112.56	183.00	79.79	56.16	80.30	105.38	42.62	49.07	52.84	76.64	60.29	116.86	133.45	1491.80
Inc.Own	92.14	92.19	91.95	112.84	124.28	208.22	89.96	67.80	90.38	117.49	51.31	59.07	61.13	92.66	70.33	129.61	148.65	cTCI/TCI
NET	-7.86	-7.81	-8.05	12.84	24.28	108.22	-10.04	-32.20	-9.62	17.49	-48.69	-40.93	-38.87	-7.34	-29.67	29.61	48.65	93.24/87.75
NPT	6.00	7.00	7.00	12.00	11.00	16.00	7.00	2.00	8.00	14.00	2.00	2.00	2.00	9.00	3.00	13.00	15.00	

2.6. Conclusion

This study investigates the dynamic and multiscale connectedness among environmental, energy, macrofinancial, and Bitcoin variables in the United States over the period from January 2014 to June 2025. The evidence points to a persistently and strongly integrated system, with the Total Connectedness Index (TCI) oscillating between roughly 70 % and 90 % across all horizons. Short-term spillovers intensify markedly, from 76 % in the raw series to 85-89 % at the D1-D2 scales, reflecting rapid contagion during episodes of market stress. Medium-term connectedness (D3-D4) stabilizes near 85-88 %, while the long-term levels (D5-D6) reach 89-93 %, and the residual S6 component approaches 93 %. These results indicate that systemic interdependence is both high and enduring, with transient volatility progressively giving way to structural, policy-driven linkages at lower frequencies.

The directional and pairwise connectedness measures (NET and NPT) reveal a clear chronological reordering of systemic leadership. Before 2020, the network is dominated by energy and crypto markets, particularly Priceoil, GAS, and PBTC, which act as principal transmitters. The COVID-19 period compresses contagion into a synchronized financial regime led by SP500 and NASDAQ, while the 2021-2023 window marks a shift toward macro-energy propagation, driven by Infl, Penergy, Priceoil, and ELEC, amid the inflation-energy nexus following the Russia-Ukraine conflict. By 2024-2025, a digital-policy-environmental regime emerges, with PBTC, VBTC, MCBTC, ESGUI, and EPU becoming the main transmitters, indicating that sustainability and digital-finance shocks now shape systemic connectedness.

The multiscale network analysis clarifies why these regime transitions occur. Wavelet decomposition exposes hidden directional rotations that the aggregate topology conceals. PBTC functions as a strong short-run transmitter but evolves into a moderate long-run source of structural volatility; VBTC and MCBTC shift from emitters to receivers as horizons lengthen, reflecting the progressive integration of crypto activity into macrofinancial dynamics. These transitions align with the time-localized volatility bursts visible in the descriptive analysis, ± 50 % swings in PBTC/MCBTC during 2017-2018, > 70 % collapses in Priceoil and GAS in 2020, and simultaneous 13 % drops in SP500 and NASDAQ in March 2020, demonstrating that speculative contagion dominates at high frequency, while macro-energy fundamentals govern at low frequency.

From an investment perspective, the results imply that short-term connectedness above 85 % (D1-D2) signals high cross-asset sensitivity, requiring tactical hedging across energy, equity, and crypto exposures. In contrast, the long-term TCI of 89-93 % and the S6 equilibrium near 93 % highlight the structural importance of Inflation, Industrial Production, and Electricity

Prices as enduring transmitters. Crypto variables, though influential at high frequency, become macro-responsive in the long run, their risk contribution is cyclical rather than structural.

From a policy perspective, the findings underline the need to stabilize the macro-energy channel that drives persistent connectedness. Anchoring inflation expectations and mitigating electricity-price volatility are essential to reduce systemic spillovers observed around 90 % at long horizons. Likewise, the increasing comovement between Bitcoin activity and environmental indicators supports the implementation of transparent energy-reporting standards for crypto-mining and the greater integration of renewable sources into digital-finance infrastructure. At the same time, sustained monitoring of high-frequency transmitters (Priceoil, SP500, NASDAQ, PBTC) would allow policymakers and regulators to identify and pre-empt rapid contagion phases, while medium-term interventions targeting the Infl-Priceoil-ELEC-IND nexus could help dampen the persistence of macro-energy shocks.

Finally, all empirical patterns, including the magnitude and timing of the regime shifts, remain robust when the TVP-VAR specification is replaced by a rolling-window VAR (window = 100). This alternative approach, consistent with Antonakakis et al. (2020), reproduces the same cyclical phases (Appendix A2-A5), confirming that the observed connectedness dynamics are not model-specific but intrinsic to the data. Overall, the evidence reveals a stable yet adaptive contagion architecture in which the balance of influence gradually rotates from energy and speculative drivers to macrofinancial and environmental anchors, emphasizing the structural interdependence of energy, climate, and digital finance in the U.S. economy.

Appendix

Table A1. Augmented Dickey-Fuller stationarity test for decomposed series

Band	D1	D2	D3	D4	D5	D6	S6
CO2	-18.549**	-7.621**	-7.207**	-6.323**	-6.21**	-5.551**	-6.891**
Penergy	-19.579**	-7.636**	-7.332**	-6.354**	-6.279**	-5.478**	-6.999**
Priceoil	-16.064**	-8.252**	-5.458**	-4.219**	-2.434	-1.941	-3.838**
NASDAQ	-19.851**	-9.033**	-6.754**	-4.034**	-2.076	-2.332	-3.161*
SP500	-20.184**	-9.556**	-7.031**	-4.39**	-2.657	-3.134	-3.445*
Infl	-13.864**	-7.752**	-4.285**	-2.279	-1.15	2.229	-2.453
PBTC	-18.435**	-8.69**	-5.08**	-2.766	-1.926	-1.448	-1.484
VBTC	-18.728**	-9.242**	-6.091**	-4.383**	-3.11	-3.466**	-1.274
MCBTC	-18.695**	-8.675**	-5.11**	-2.763	-1.948	-1.494	-1.381
RENERG	-26.853**	-9.589**	-9.187**	-8.472**	-8.553**	-7.389**	-9.164**
GAS	-20.195**	-9.841**	-5.756**	-4.06**	-2.984	-2.96	-3.19*
GPR	-22.7**	-9.643**	-6.903**	-5.789**	-4.777**	-4.159**	-3.737**
CCI	-15.55**	-8.812**	-5.761**	-5.319**	-5.723**	-5.194**	-6.699**
ESGUI	-19.034**	-8.576**	-5.272**	-3.727**	-3.255*	-2.252	-2.363
EPU	-20.909**	-9.041**	-5.996**	-4.496**	-3.747**	-3.93**	-3.859**
IND	-18.797**	-8.739**	-6.656**	-5.79**	-4.137**	-4.278**	-4.097**
ELEC	-15.753**	-7.564**	-4.92**	-4.006**	-3.008	-2.15	-0.466

Note: ***, **, * denote significance at 1%, 5%, and 10% levels, respectively

Figure A2. Total connectedness index (TCI)

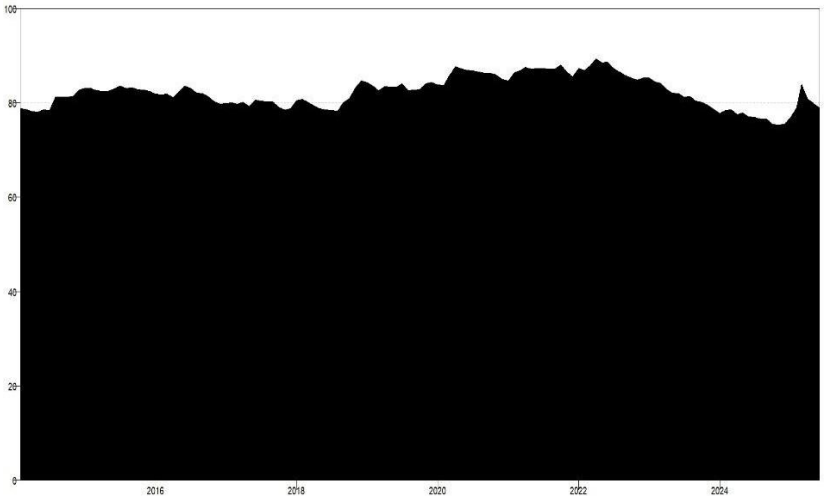

Figure A3. Overall net pairwise Transmission (NPT)

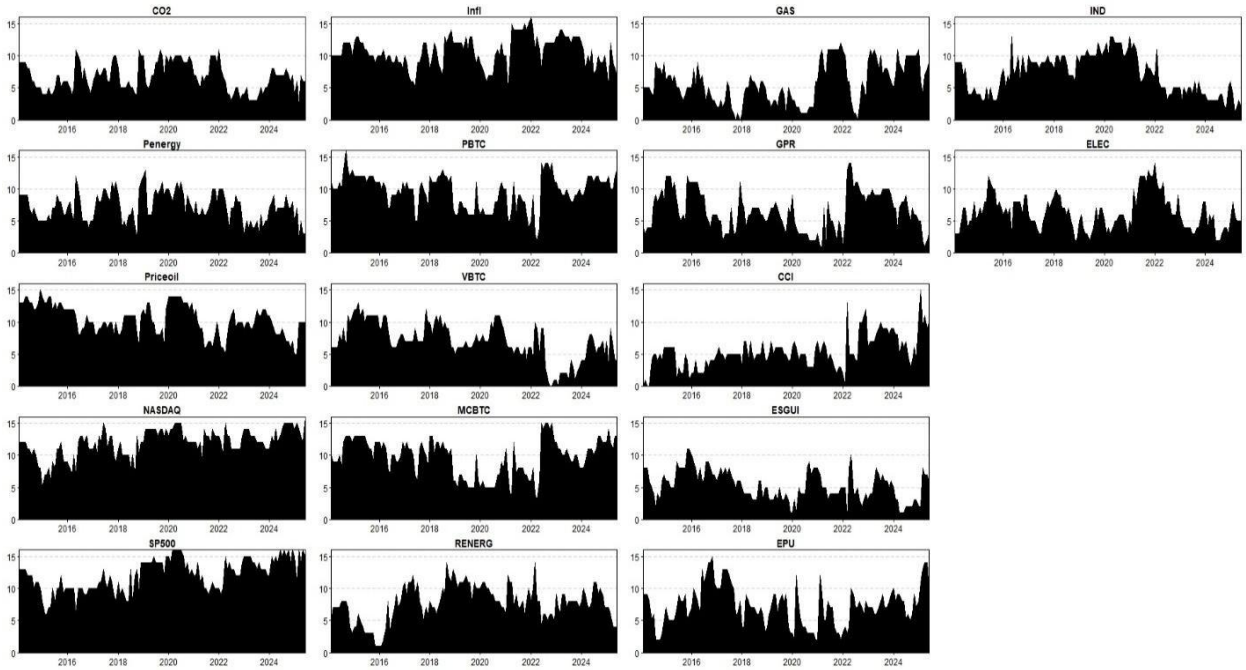

Figure A4. Net Total Directional Connectedness Index

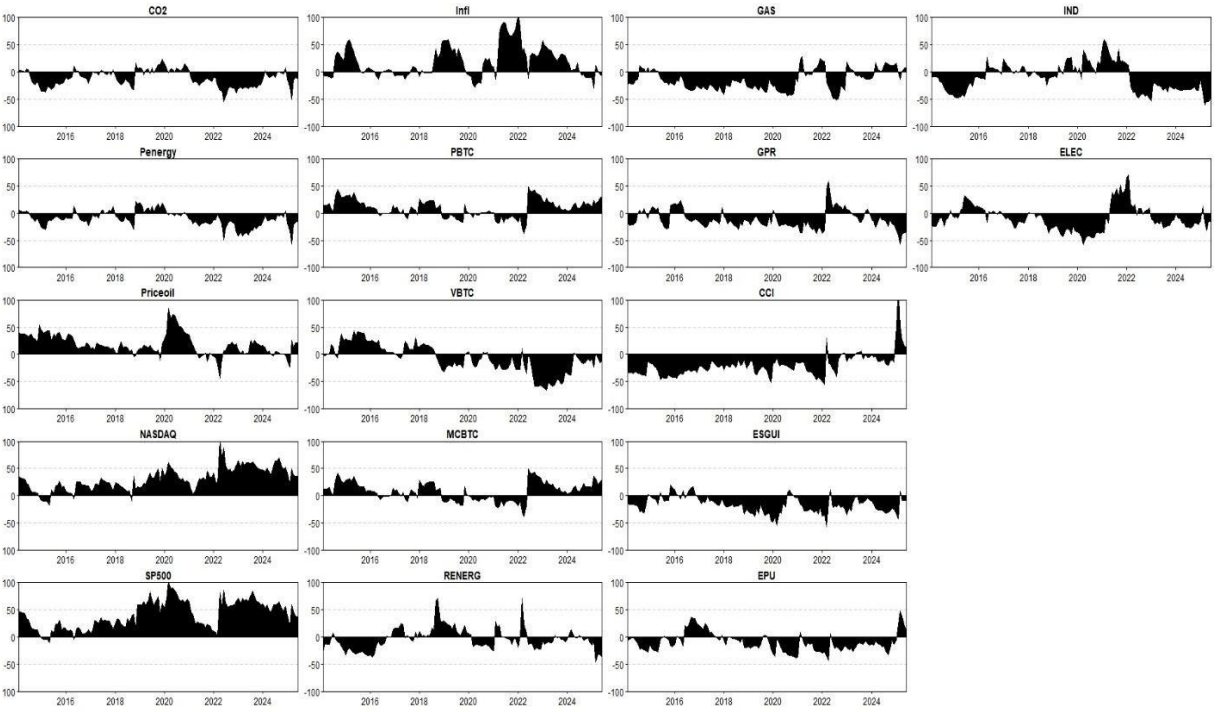

Figure A6. Network connectedness of the raw series

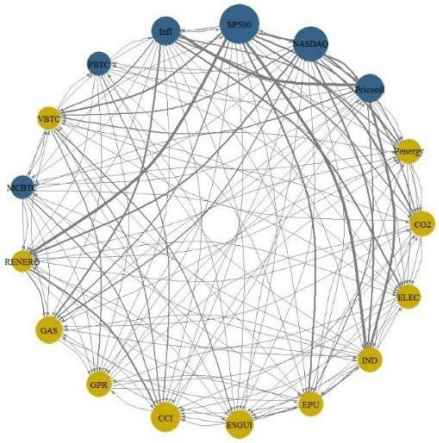

Figure A7. Comovement between environmental factors and energy measures

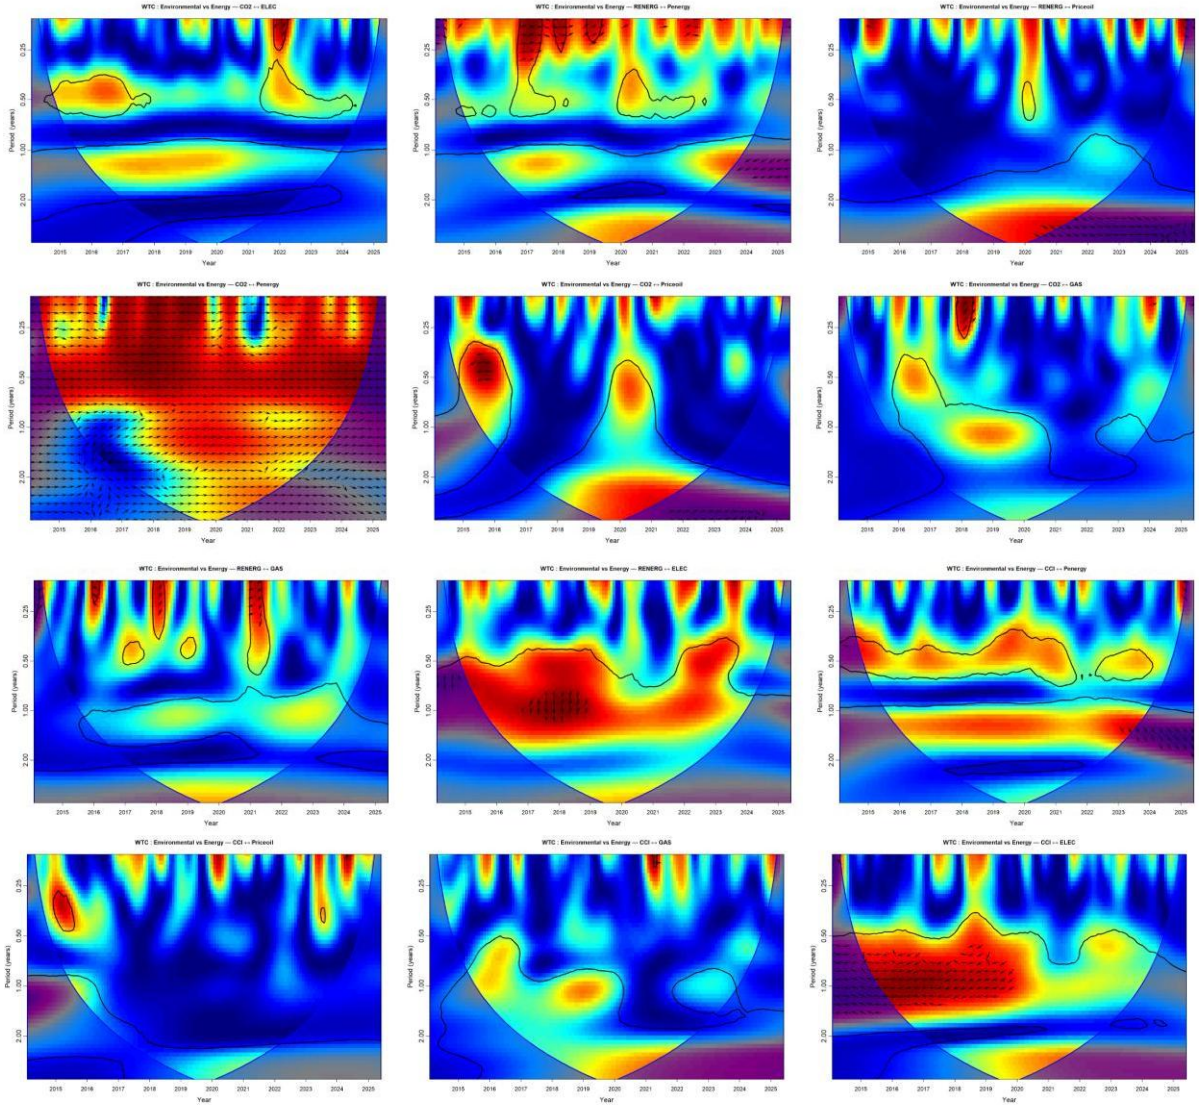

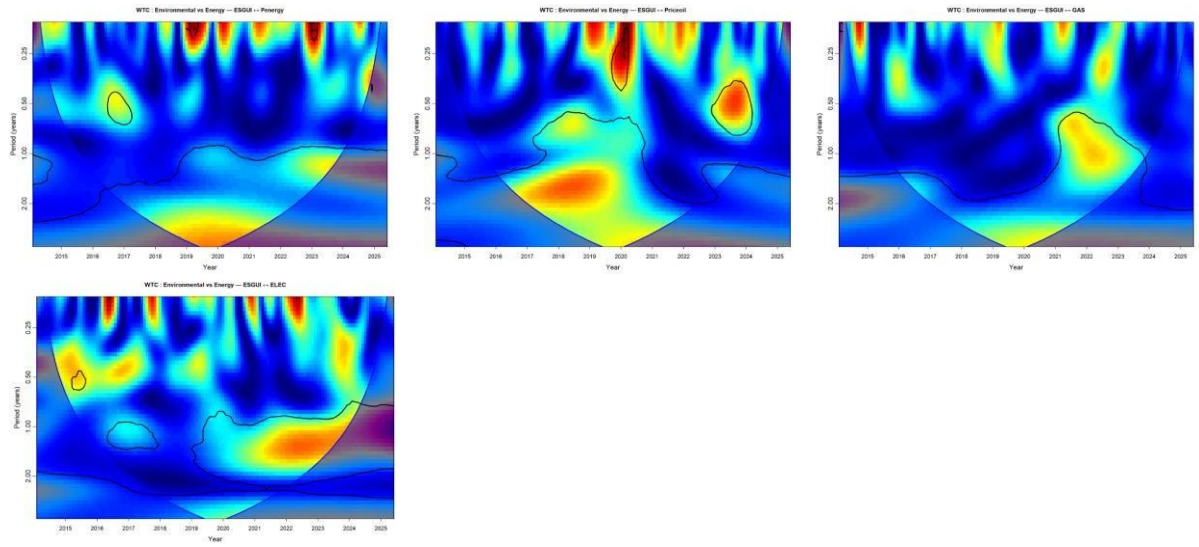

Figure A8. Comovement between environmental factors and Macrofinancial & Uncertainty Indicators

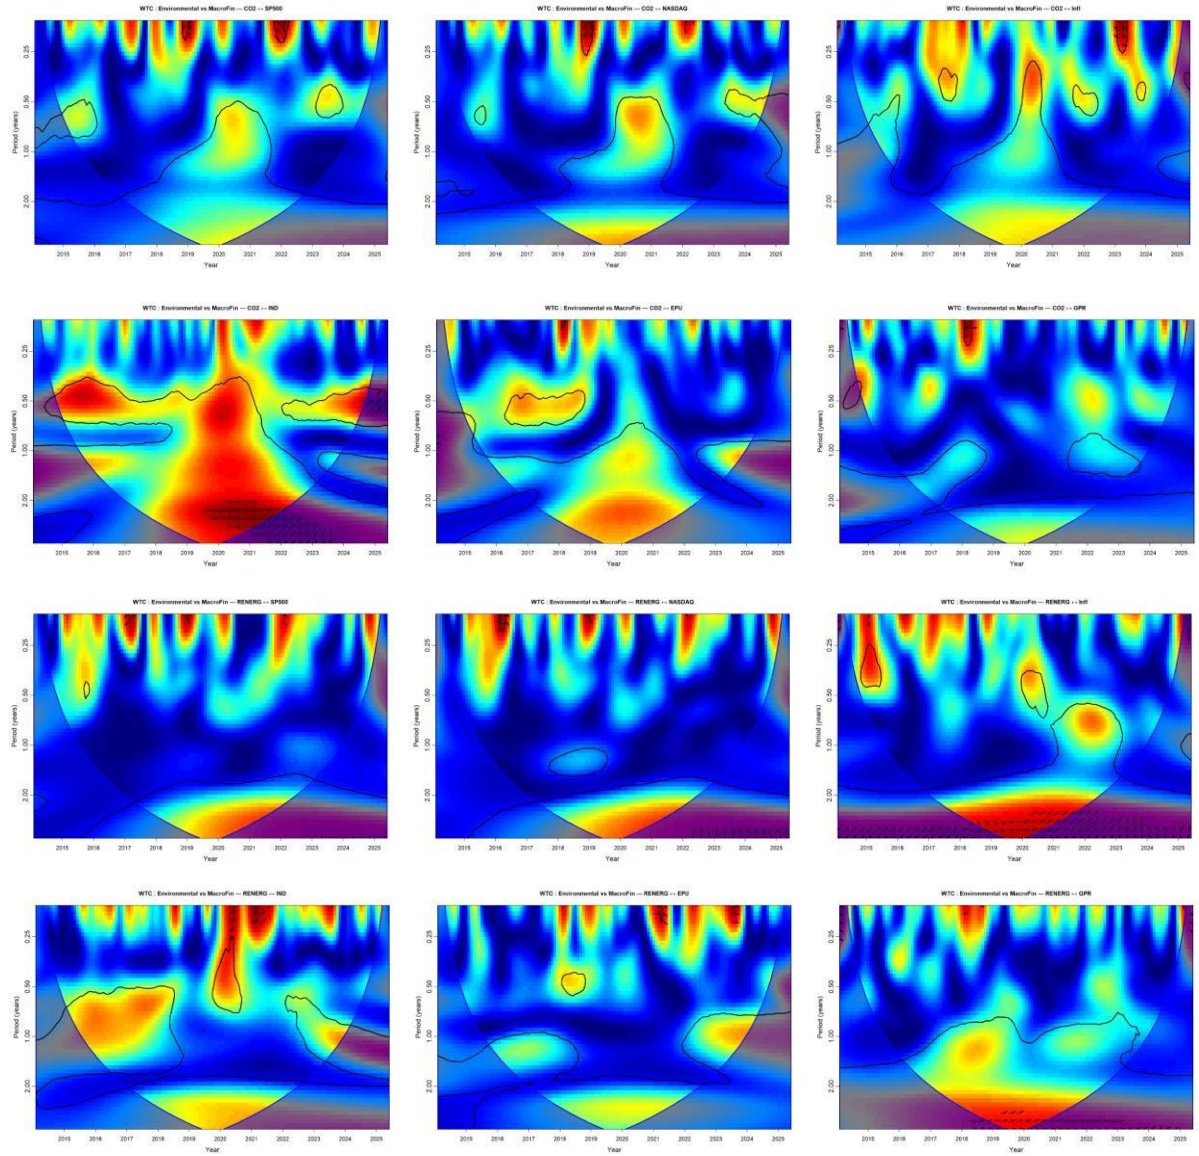

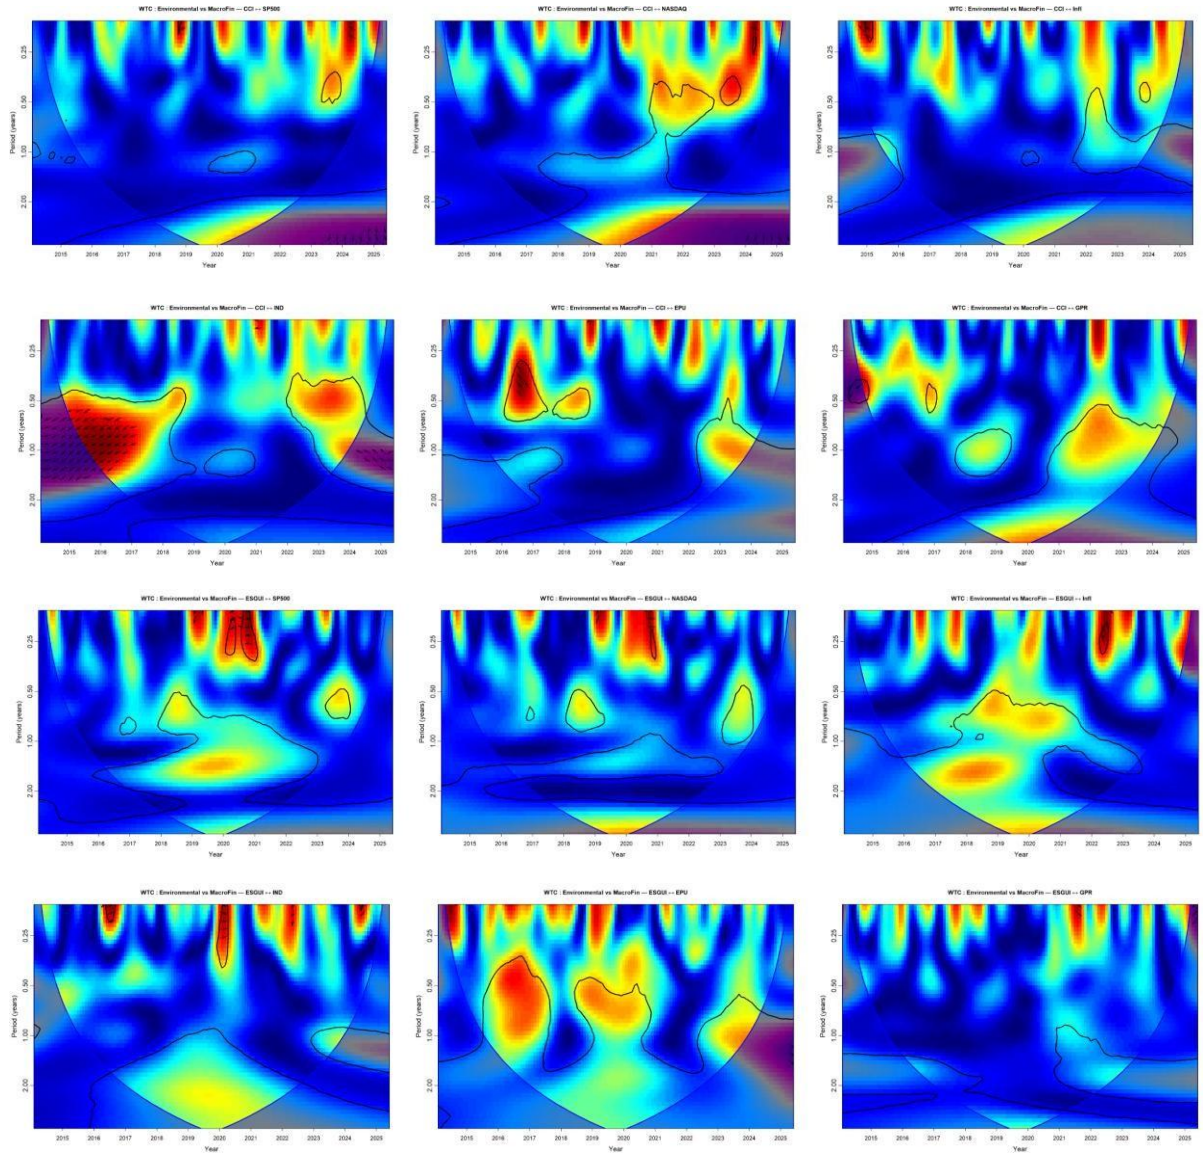
WTC : Environmental vs MacroFin — CCI -- SP500
WTC : Environmental vs MacroFin — CCI -- NASDAQ
WTC : Environmental vs MacroFin — CCI -- Infl
WTC : Environmental vs MacroFin — CCI -- IND
WTC : Environmental vs MacroFin — CCI -- EPU
WTC : Environmental vs MacroFin — CCI -- GPR
WTC : Environmental vs MacroFin — ESGUI -- SP500
WTC : Environmental vs MacroFin — ESGUI -- NASDAQ
WTC : Environmental vs MacroFin — ESGUI -- Infl
WTC : Environmental vs MacroFin — ESGUI -- IND
WTC : Environmental vs MacroFin — ESGUI -- EPU
WTC : Environmental vs MacroFin — ESGUI -- GPR
Period (years)
0.25
0.50
1.00
2.00
Year
2015
2016
2017
2018
2019
2020
2021
2022
2023
2024
2025

Figure A9. Comovement between environmental factors and Bitcoin Indicators

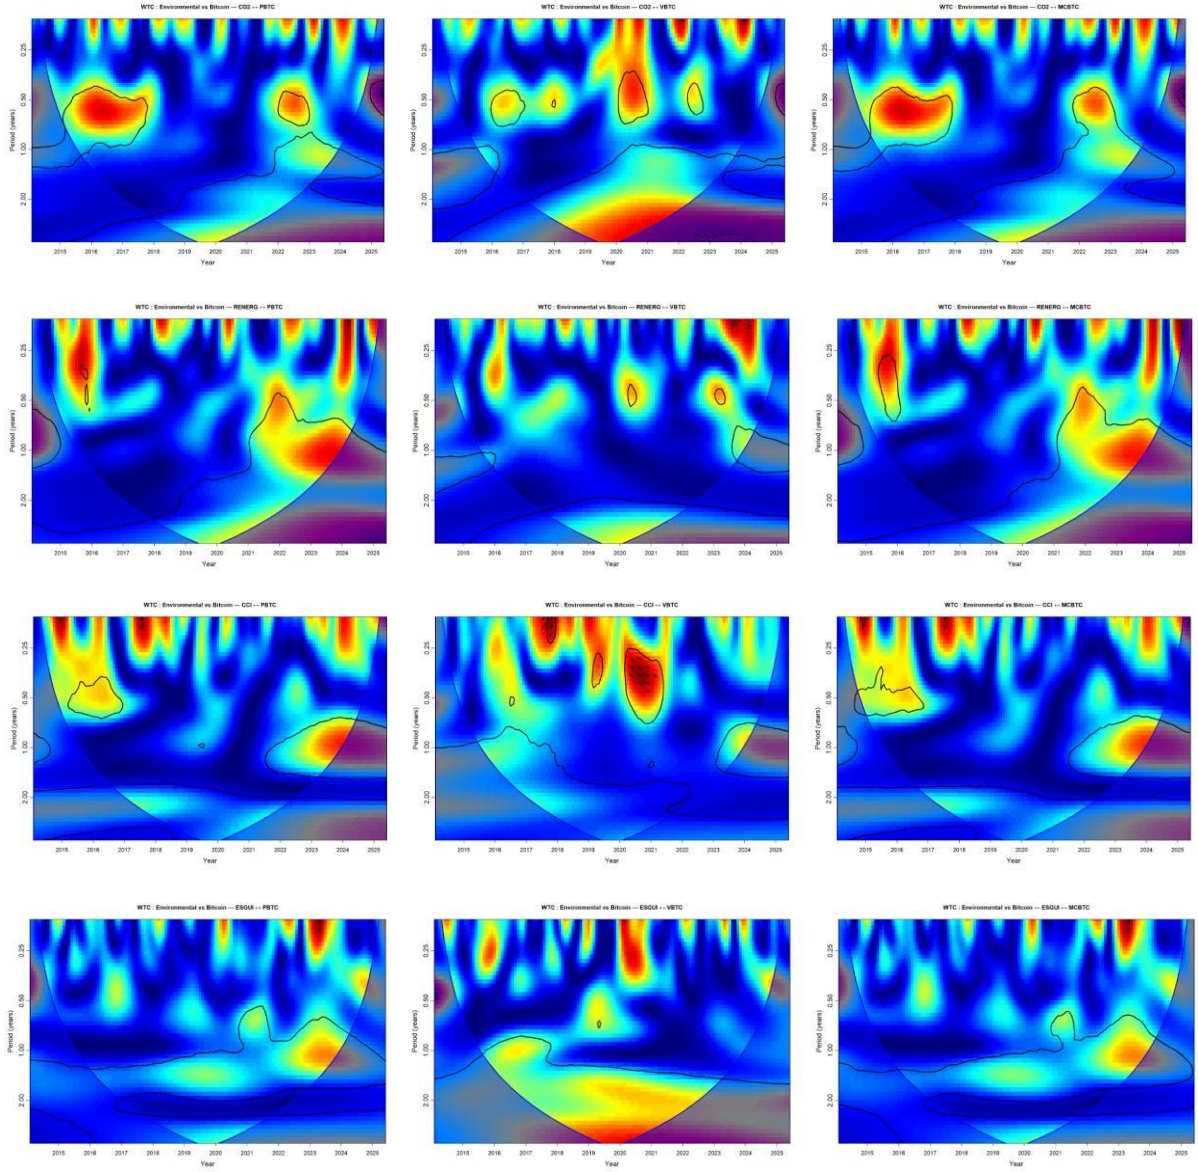

Figure A10. Comovement between energy measures and Macrofinancial & Uncertainty Indicators

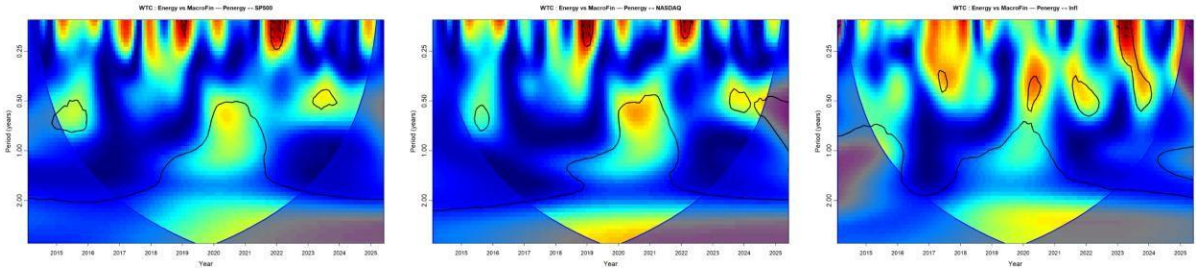

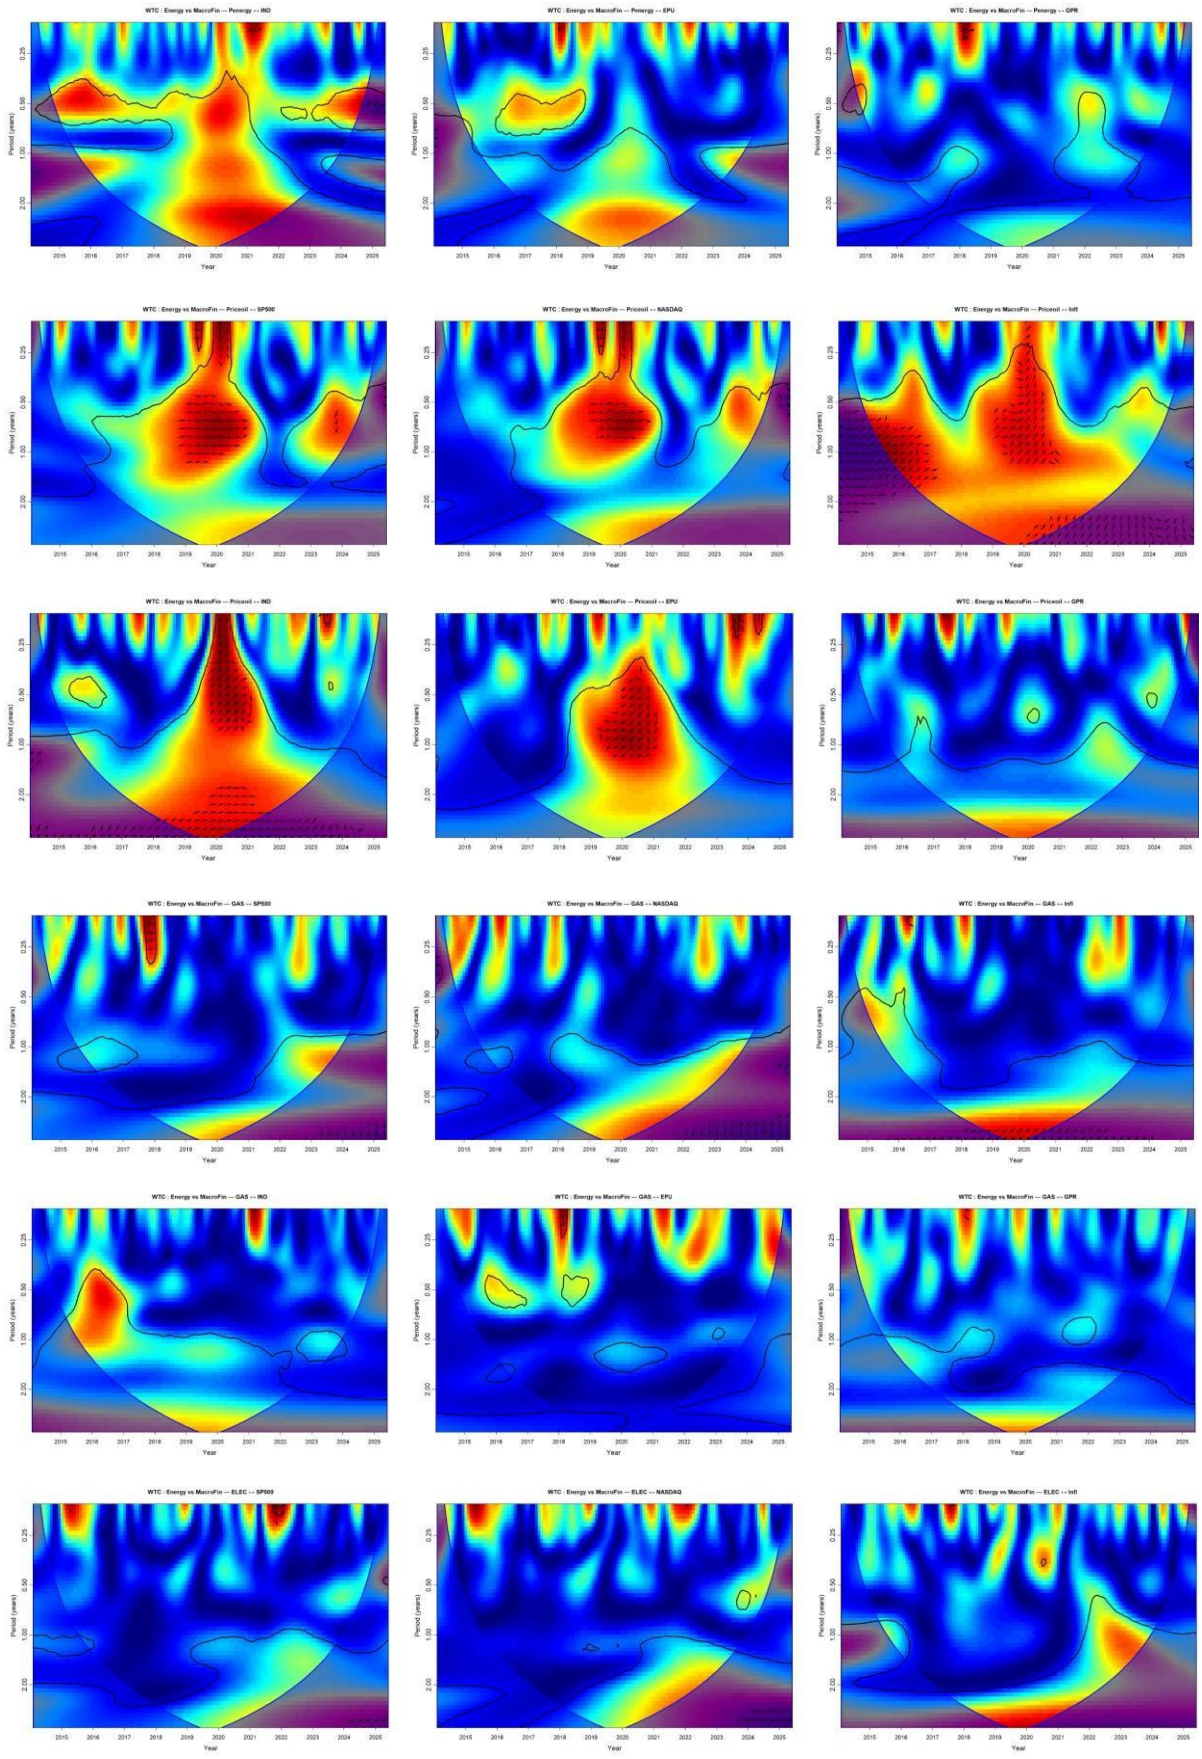
WTC : Energy vs MacroFin — Penergy ~ IND
WTC : Energy vs MacroFin — Penergy ~ EPU
WTC : Energy vs MacroFin — Penergy ~ GPR
WTC : Energy vs MacroFin — Pricoil ~ SP500
WTC : Energy vs MacroFin — Pricoil ~ NASDAQ
WTC : Energy vs MacroFin — Pricoil ~ Infl
WTC : Energy vs MacroFin — Pricoil ~ IND
WTC : Energy vs MacroFin — Pricoil ~ EPU
WTC : Energy vs MacroFin — Pricoil ~ GPR
WTC : Energy vs MacroFin — GAS ~ SP500
WTC : Energy vs MacroFin — GAS ~ NASDAQ
WTC : Energy vs MacroFin — GAS ~ Infl
WTC : Energy vs MacroFin — GAS ~ IND
WTC : Energy vs MacroFin — GAS ~ EPU
WTC : Energy vs MacroFin — GAS ~ GPR
WTC : Energy vs MacroFin — ELEC ~ SP500
WTC : Energy vs MacroFin — ELEC ~ NASDAQ
WTC : Energy vs MacroFin — ELEC ~ Infl
Period (years)
Year

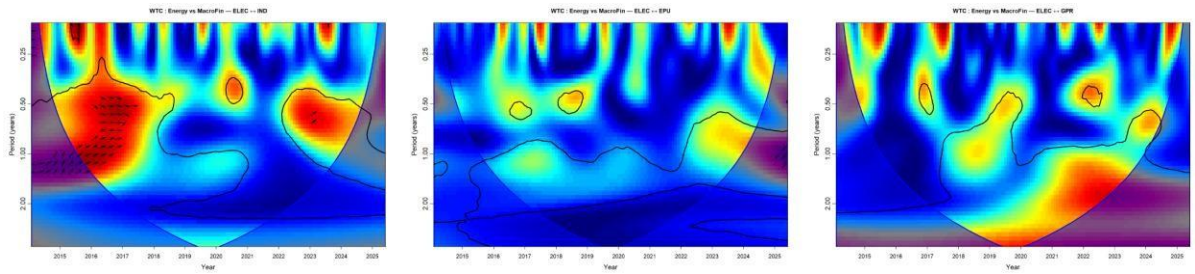

Figure A11. Comovement between energy measures and Bitcoin Indicators

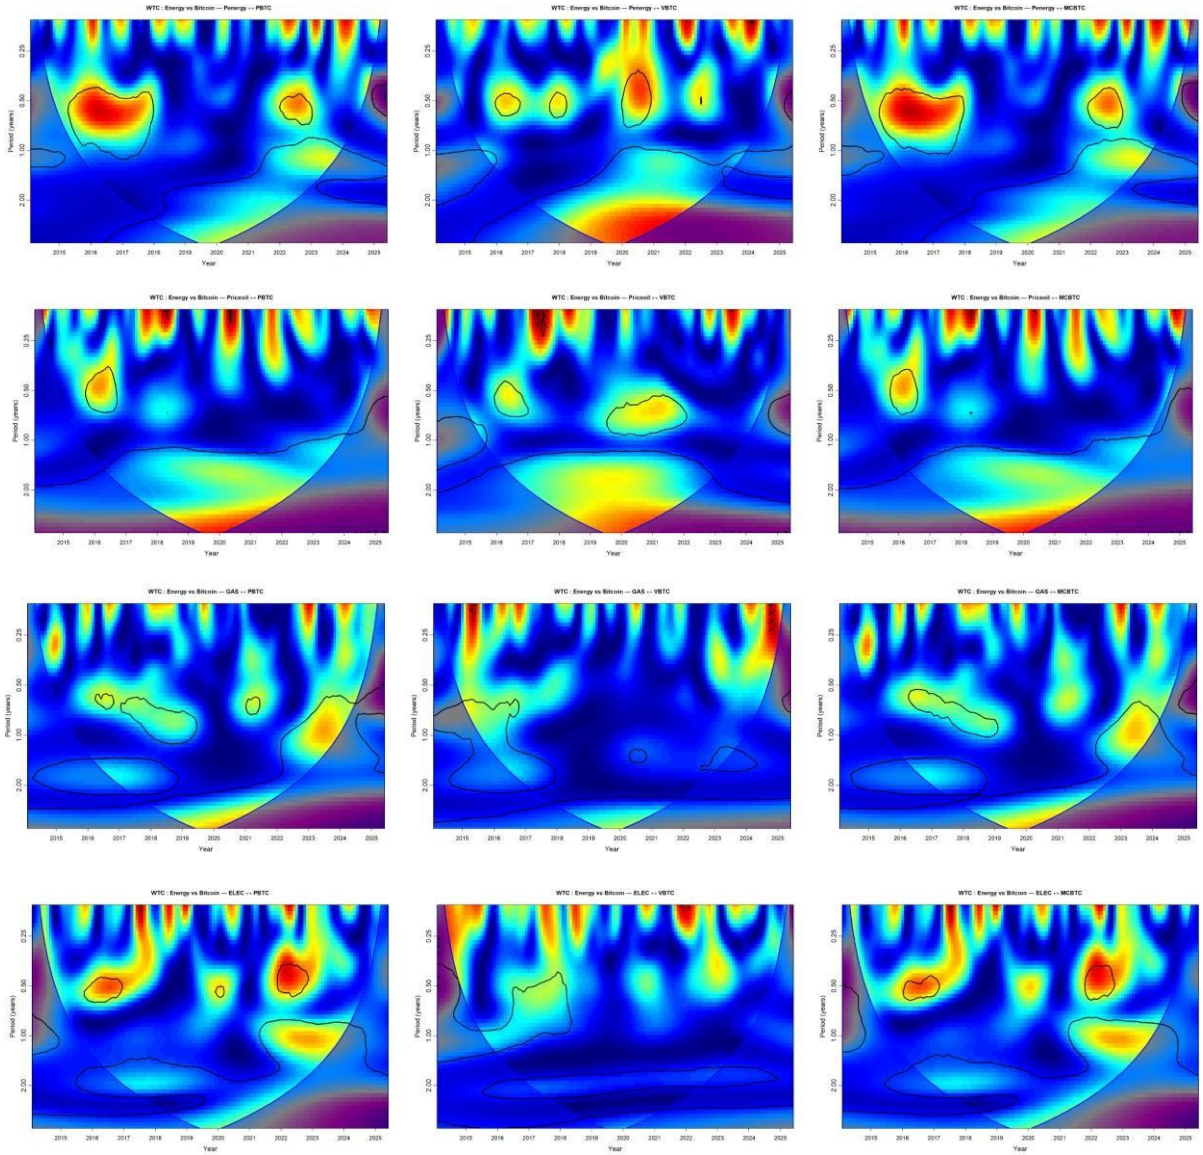

Figure A12. Comovement between Macrofinancial & Uncertainty Indicators variables and Bitcoin Indicators

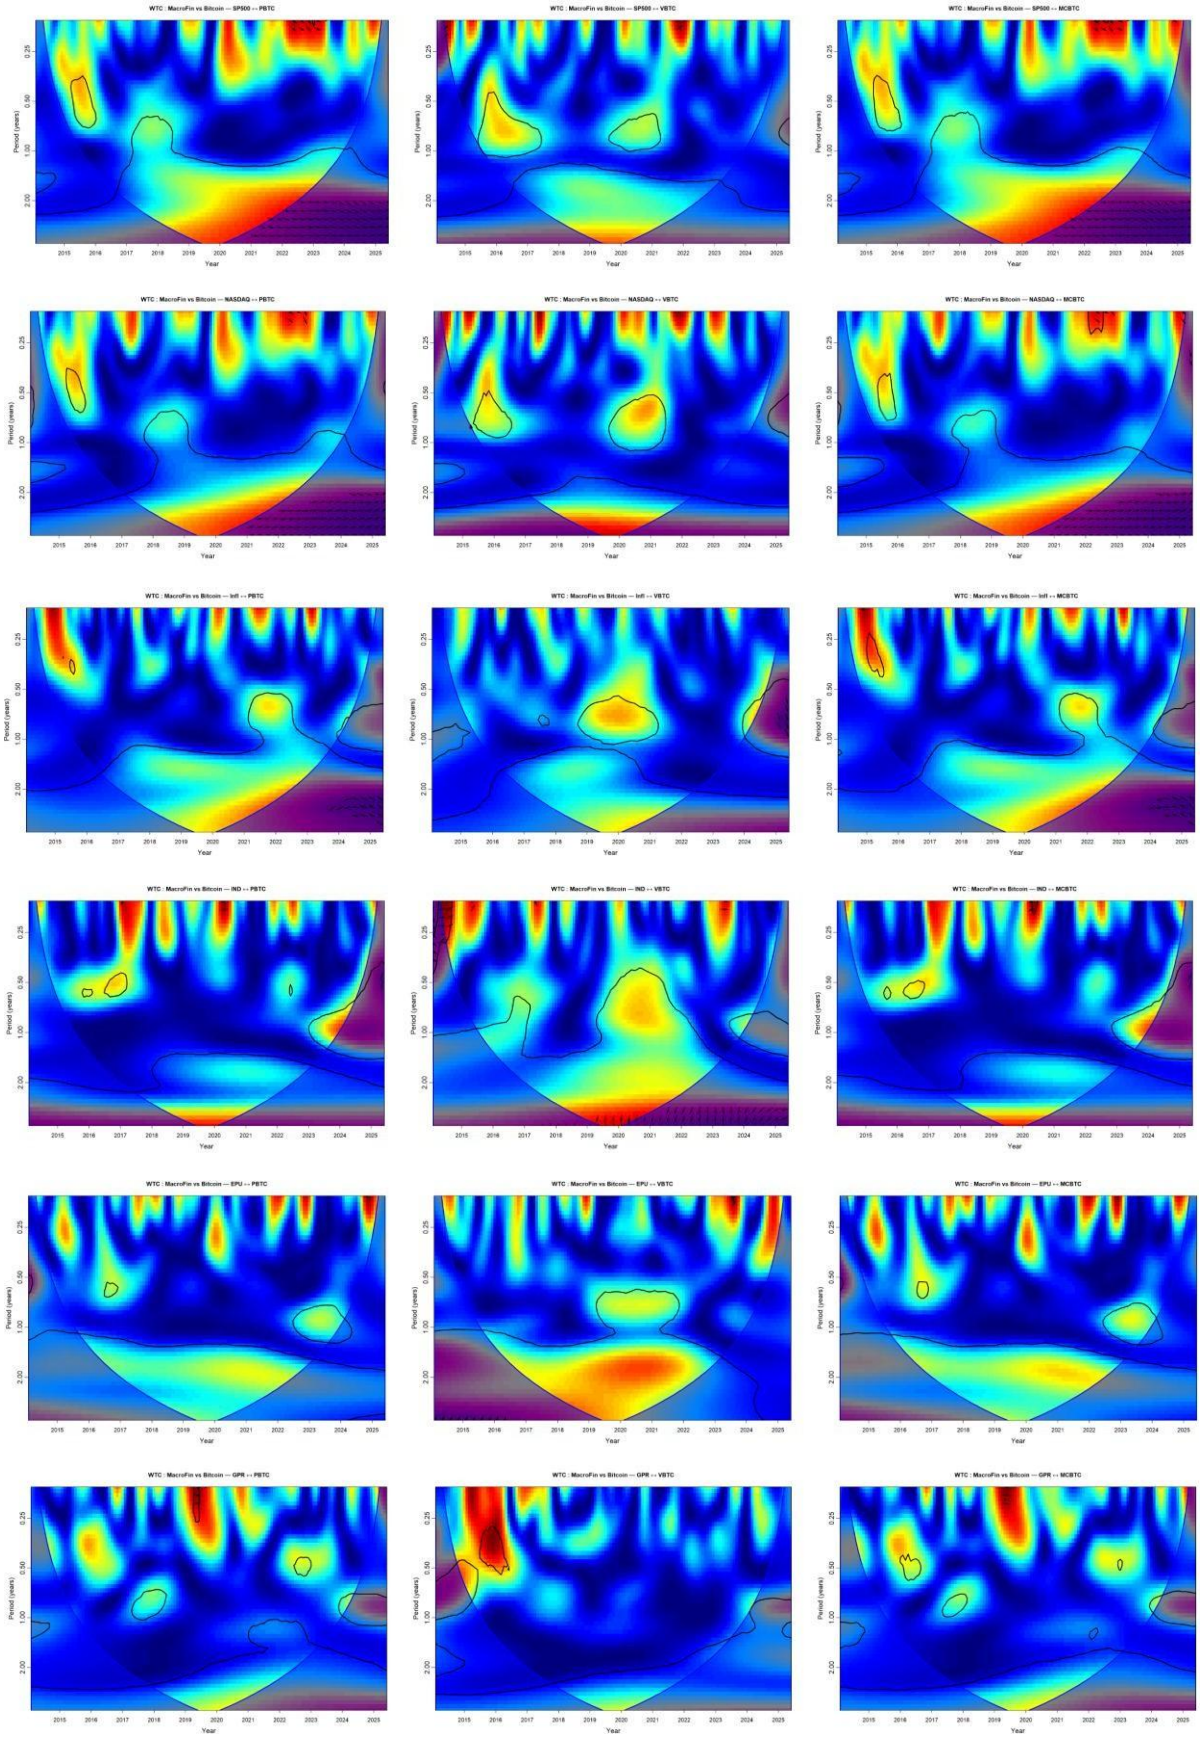

4 Chapter 3. Shocks, Transmissions, and Sustainability: Mapping the Crypto-Energy-Environment Nexus

- Publication notes: This chapter is currently under revise-and-resubmit at the *International Journal of Finance & Economics* (Quartile: Q1 / ABS: 3)

Shocks, Transmissions, and Sustainability: Mapping the Crypto-Energy-Environment Nexus

Abstract

This paper provides the first empirical application of the Clustered Network Connectedness (CNC) framework to the interconnected system of cryptocurrencies, energy markets, financial indicators, and environmental assets. Using daily data for 14 variables grouped into four clusters, we focus on the highly volatile period from January 2022 to October 2024, characterized by post-COVID adjustments, global monetary tightening, the Russia-Ukraine energy crisis, and large fluctuations in cryptocurrency markets. The CNC framework separates within-cluster comovement from between-cluster contagion, addressing a key limitation of standard Diebold–Yilmaz-type connectedness measures, including TVP-VAR implementations. Our results show that traditional approaches overestimate total spillovers by 8-12% because they conflate within-cluster comovement with cross-cluster transmission. The energy cluster emerges as a persistent net transmitter, with net connectedness peaking at approximately +0.96 during periods of heightened energy stress. Following the collapse of FTX, a major cryptocurrency exchange, in late 2022, cryptocurrencies shift from net receivers to net transmitters, consistent with deeper integration into broader macrofinancial dynamics. We also document strong transmission from energy to environmental assets, with around 60% of environmental return variance explained by energy shocks, highlighting the role of energy-climate linkages in systemic risk. Monte Carlo evidence shows that GC and CNC

converge to different connectedness objects, with the GC–CNC gap reflecting an identification difference rather than a finite-sample artifact. Overall, the CNC framework provides a structurally consistent measure of connectedness, with direct implications for systemic risk monitoring, stress testing, and portfolio allocation in highly interconnected markets.

JEL classification : C32, C58, G15, Q43, Q54

Keywords: Clustered Network Connectedness; Systemic Risk; Dynamic Spillovers; Cryptocurrencies; Energy Markets; Environmental Finance; Climate-Finance Linkages

3.1 Introduction

The accelerating digitalization of financial markets and the global shift toward sustainable energy systems have made the dynamic relationships among cryptocurrencies, energy markets, and environmental assets more complex. These interlinkages have intensified since the COVID-19 pandemic and the escalation of the Russia-Ukraine conflict. This evolution has increased the potential for shocks to propagate across markets, generating new forms of systemic risk across asset classes (IMF, 2023; Emiliozzi et al., 2023). Once regarded primarily as speculative instruments, cryptocurrencies now sit firmly within broader macrofinancial dynamics, influenced by energy-intensive mining processes, sentiment-driven liquidity flows, and regulatory developments. For instance, Bitcoin mining alone consumes nearly 0.5% of global electricity output, illustrating a direct connection between digital-asset infrastructure and fossil-fuel-driven energy demand and, by extension, CO2 emissions (Cambridge Centre for Alternative Finance, 2023; Benetton et al., 2023; Krause and Tolaymat, 2018; Stoll et al., 2019). At the same time, strict monetary tightening in developed economies, big jumps in energy prices, and inflation have all made the market more volatile, complicating portfolio allocation and regulatory monitoring (IMF, 2023).

This relationship between cryptocurrencies and energy raises an important policy and sustainability debate. Cryptocurrencies may broaden access to financial services; however, proof-of-work mining consumes substantial amounts of energy and generates significant carbon emissions. Regulators and central banks increasingly treat crypto-related energy use as a relevant element in assessments of climate-related financial stability (Auer et al., 2022; Reboredo and Ugolini, 2020).

Meanwhile, energy markets themselves have become more volatile due to supply disruptions, changing fossil-renewable price dynamics, and the push toward net-zero emissions (Emiliozzi et al.,

2023). These trends indicate a developing, bidirectional contagion between energy shocks and digital asset prices, a phenomenon that remains inadequately comprehended in empirical finance (Baruník and Křehlík, 2018; Bouri et al., 2021).

A growing body of empirical work seeks to map these cross-market dynamics. Studies using Diebold-Yilmaz spillover indices and related measures show that volatility transmission between energy and crypto assets intensifies during crises (Diebold and Yilmaz, 2014; Ji et al., 2020; Bouri et al., 2021). However, standard connectedness models, based on symmetric VARs with generalized variance decompositions, do not distinguish comovement within sectors from true contagion across sectors (Baruník and Křehlík, 2018; Demirer et al., 2018). As a result, they may overstate systemic risk by conflating correlated internal sectoral dynamics (e.g., oil and gas) with genuine cross-market transmission channels (e.g., energy to crypto or environment).

Theoretically, at least three channels shape the structure of spillovers. First, common-factor channels: assets in the same sector share fundamental drivers, such as technology cycles for crypto or supply shocks for energy, producing high intra-sector comovement (Forbes and Rigobon, 2002). Second, cross-market contagion channels: shocks propagate through investor sentiment, liquidity constraints, or portfolio rebalancing between risky and safe assets (Pastor and Veronesi, 2013). Third, environmental and policy channels: changes in carbon pricing or ESG[14] regulation can affect energy producers, clean-energy indices, and crypto valuations simultaneously (Reboredo and Ugolini, 2020; Dutta, 2017). These mechanisms suggest that spillovers evolve not only across clusters but also across market states, a subtlety that conventional connectedness approaches often fail to capture.

Despite methodological advances, existing connectedness frameworks measure transmission but do not identify its origin. In particular, they do not distinguish within-cluster comovement driven by shared fundamentals from between-cluster contagion arising from genuine cross-market transmission. In fact, standard connectedness techniques, which typically rely on symmetric VAR systems with generalized variance decompositions, blur this distinction (Baruník and Křehlík, 2018; Demirer et al., 2018). As a result, they risk overstating the degree of systemic interdependence. This distinction is not merely technical; it has real implications for interpretation. Assets within the same sector can move in tandem because they are influenced by shared shocks, for example, oil and

[14] Environmental, Social, and Governance (ESG) refers to a set of non-financial criteria used to evaluate firms' sustainability, ethical impact, and risk exposure

natural gas responding jointly to supply disruptions, without implying that such dynamics spill over into cryptocurrency or environmental markets.

The CNC framework, recently introduced by Buchwalter et al. (2026), fills this gap by permitting within-cluster correlation while enforcing cross-cluster orthogonality. This structure reconciles the theoretical distinction between comovement and contagion (Forbes and Rigobon, 2002) and facilitates an operational disaggregation of intra- and inter-cluster linkages. CNC also suggests that traditional connectedness metrics may overstate contagion because they combine internal dynamics with cross-market spillovers.

This paper represents the first attempt to rigorously separate comovement from contagion within a multi-sector system encompassing cryptocurrencies, energy markets, macrofinancial indicators, and environmental assets. We use daily data spanning from January 2022 to October 2024, a period of rising inflation, geopolitical instability, and high volatility in the crypto market. The CNC approach combines adaptive Elastic-Net VAR estimation (Zou and Zhang, 2009) with block-orthogonalized forecast-error variance decomposition to handle a relatively high-dimensional system while preserving cluster structure (Demirer et al., 2018). Although the sample period is relatively short, it is well suited to the analysis because it includes major exogenous shocks and detailed sustainability-linked market proxies.

This study contributes to the literature in several ways. First, we enhance systemic-risk measurement by distinguishing comovement within clusters from contagion across clusters, thereby contributing to the connectedness literature (Diebold and Yilmaz, 2014; Baruník and Křehlík, 2018). Second, we demonstrate empirically that disregarding cluster structure results in inflated connectedness estimates, a phenomenon exacerbated during times of stress, such as the 2023 energy crisis and banking instability (IMF, 2023; Buchwalter et al., 2026). Third, we show that Elastic-Net regularization makes CNC work better in situations where there are many different types of assets. We construct a cluster-aware systemic-risk dashboard that separates "shock-transmitting" clusters from "shock-receiving" clusters. This can support macroprudential monitoring and strategic asset allocation from both policy and investment perspectives. Our research shows that cryptocurrencies act more like high-beta assets that are linked to macrofinancial cycles than as diversifiers. On the other hand, energy markets always act as systemic shock transmitters (Bouri et al., 2021; Auer et al., 2022). This distinction is not merely technical: it implies that widely used connectedness measures do not recover the correct transmission object when within-cluster dependence is present.

The remainder of the article is organized as follows. Section 3.2 reviews the relevant literature and situates our work within the energy-finance-macrofinance-environment nexus. Section 3.3 presents the dataset and clustering approach. Section 3.4 details the CNC methodology, including Elastic-Net VAR estimation and block-orthogonalized variance decomposition. Section 3.5 reports the empirical results on dynamic and structural spillovers. Section 3.6 discusses the implications for investors and regulators. Section 3.7 concludes and presents useful policy implications.

3.2 Literature Review

Over the last few years, research on cross-market spillovers and systemic risk has grown quickly, giving us a wide range of tools for tracking how shocks move through both financial and real-asset markets. Diebold and Yilmaz's groundbreaking work in 2009 and 2014 introduced forecast-error variance decomposition into VAR systems, allowing for both directional and system-wide measurement of shock propagation. Later improvements made the method work over time and across different time periods using frequency-domain and TVP-VAR models (Antonakakis and Gabauer, 2017). Even with these changes, most connectedness methods still assume that variables interact in the same way and in a symmetric manner, which isn't true in environments that are complex and have many sectors. Consequently, they find it challenging to differentiate between comovement induced by shared fundamentals within sectors and authentic cross-sector contagion, a distinction that significantly influences systemic-risk assessment and regulatory framework (Demirer et al., 2018).

This limitation becomes particularly pronounced within the nascent crypto-energy-macro-finance-environment nexus. Since 2020, mounting evidence suggests that digital assets have become increasingly linked to commodity markets, climate policy indicators, and macrofinancial drivers. Research has shown that crypto assets and energy commodities have moved together more often and have affected each other more during events like the COVID-19 shock, global energy-price surges, and the Russia-Ukraine conflict (Bouri et al., 2021; Umar et al., 2022; Patel et al., 2023; Chen et al., 2024). As the field has grown, researchers have started to use wavelet-based, quantile, and time-varying connectedness models to capture dynamics that depend on the horizon and the regime (Antonakakis and Gabauer, 2017; Sebai and Jaber, 2025; Annamalaisamy and Jayaraman, 2023). Research by Afjal and Sajeev (2022), Pham et al. (2023), and Wang et al. (2024) shows that energy-to-crypto contagion is very dependent on volatility regimes, while the connection between clean and dirty energy changes depending on the market state. Also, Nasir et al. (2025), alongside Harasheh et al. (2022), show that asymmetric contagion runs through sustainability-linked assets.

Although the latest advances have improved connectedness methods, they still share a core shortcoming: most models tacitly treat variables as either independent or evenly linked. This simplification precludes the separation of comovement from true cross-cluster contagion. In fact, when the transmission pathways aren't clearly separated, systemic risk can appear inflated, which erodes the usefulness of stress tests and nudges diversification and policy decisions onto the wrong track.

A significant challenge is identifying the origins of the observed interdependencies; current frameworks are unable to determine whether they arise from shocks or from genuine cross-sector spillovers. Distinguishing between comovement and transmission is important for the design of risk-reduction strategies and for policies aimed at strengthening an integrated system linking energy markets, climate-linked assets, and digital finance.

This paper investigates the crypto-energy-environment-macrofinance nexus using the CNC framework. The research by Buchwalter et al. (2026) presented the CNC model which helps to distinguish between fundamental-based comovement and cross-market transmission-driven contagion. Using an adaptive Elastic-Net VAR estimator (Zou and Zhang, 2009) with block-orthogonalized variance decomposition, this paper uses data from 2022 to 2024 to analyze digital asset market behavior. The system framework maintains spatial integrity through its cluster architecture which enables it to manage changes that affect contemporary financial systems and energy and environmental networks. The short analysis window contains shocks which enable us to study the transmission of systemic risk.

The research presents three contributions. To start, it improves the measurement of risk by separating intra-cluster interdependence from inter-cluster contagion, which gives the connectedness literature a new point of view (Diebold and Yilmaz 2014). Ignoring cluster structure can overstate connectedness estimates, especially during events of market stress like the 2023 energy shock and banking stress (IMF, 2023; Buchwalter et al., 2026). Second, it shows that Elastic-Net regularization improves the stability of CNC estimation in high-dimensional and time-varying environments. Third, it adds a cluster-aware systemic-risk dashboard that separates persistent shock transmitters from receivers. This dashboard can support stress testing, macroprudential surveillance, and portfolio allocation. In line with recent findings (Bouri et al., 2021; Auer et al., 2022), the results confirm that cryptocurrencies operate as high-beta instruments closely associated with macrofinancial cycles, whereas energy markets serve as stable net transmitters of systemic shocks.

Despite the rapid spread of time-frequency and quantile-based connectedness methods, a thorough structural separation of intra- versus inter-cluster risk channels, using CNC or related approaches, has not yet been applied to the crypto-energy-environment nexus. Previous research either focused on dynamic visualization of dependencies or on overall network metrics, but did not rigorously address the identification challenge. This matters not only for the precision of systemic risk measurement, but also for the credibility of macroprudential stress tests, the calibration of capital buffers, and the design of climate-energy-finance policies. The present study addresses this gap by applying the CNC framework to a comprehensive four-cluster system covering cryptocurrencies, energy markets, macrofinancial indicators, and environmental assets. Instead of adding another layer of descriptive analysis, this study offers a structurally grounded and policy-relevant framework for identifying the real transmission channels of systemic fragility in today's highly integrated digital-energy-environmental landscape.

3.3 Data

This study uses daily log returns (i.e., first differences of natural logarithms) for 14 variables grouped into four clusters: cryptocurrencies, energy variables, macrofinancial indicators, and environmental assets. The sample spans January 3, 2022 to October 30, 2024, excluding weekends and U.S. public holidays. This period includes major geopolitical and macrofinancial disturbances that are particularly relevant for the analysis of systemic transmission. It was marked by sharp post-pandemic inflationary pressures and an aggressive monetary tightening cycle in the United States. In response, the Federal Reserve raised the federal funds rate from near zero in early 2022 to above 5% by mid-2023, after inflation had peaked at 9.1% in June 2022. Besides, geopolitical tensions mainly caused by the Russian invasion of Ukraine in February 2022 have led global energy markets to experience disruptions, leading to higher prices of natural gas and oil.

These events provide a useful framework for analyzing the dynamic relationships across these sectors. The study period allows for the investigation of market behaviors under different economic conditions, during periods of worry and bounce-back, giving essential data about how systemic risk generates financial market instability. Our clustering approach, as shown in Table 3.1, is based on variables typology, their dominant underlying economic drivers, and how they usually react during systemic events, as extensively documented in prior literature (Bouri et al., 2021; Corbet et al., 2018; Ji et al., 2020). This classification allows us to analyze how variables from different clusters interact with one another.

Table 3.1 contains details regarding variable definitions together with their sources and measurement units. The first cluster includes Bitcoin (BTC), Ethereum (ETH), Ripple (XRP), and

Solana (SOL) prices as its main components, which form a separate digital asset type marked by high volatility, speculative trading behaviors, and low correlation with regular money markets (Corbet et al., 2018). Second, the energy cluster, including West Texas Intermediate (WTI) crude oil, natural gas (GAS), and US electricity demand (ELECD), is mainly shaped by global economic activities, supply-demand shocks, along with geopolitical tensions. These commodities present strong comovements correlated with industrial production and major policy changes, such as decisions by the Organization of the Petroleum Exporting Countries (OPEC).

The third cluster contains environmental indicators, namely, carbon dioxide emissions (CO_2), the S&P Global Clean Energy Transition Index, and ESG Aware MSCI USA ETF, an exchange-traded fund offering U.S. stock exposure with an environmental, social, and governance (ESG) focus. This cluster shows how environmental risk pricing and sustainable investment flows affect the market. It can reflect average market fluctuations and respond to policy changes through carbon pricing and incentives for renewable energy (Bouri et al., 2021).

Table 3.1 Variables and data sources

Cluster	Variable	Detail	Data sources
Environmental Factors	**CO2**	U.S. total daily CO2 emissions from fossil fuel combustion (MtCO2/day)	Carbon Monitor
	ESG	iShares ESGU ETF	Yahoo Finance
	RENERG	S&P Global Clean Energy Transition Index.	S&P Dow Jones Indices
Energy measures	**WTI**	WTI Crude Oil Price (Dollars per Barrel)	U.S. Energy Information Administration (EIA)
	GAS	Natural Gas Price (Dollars per 1 BTU)	
	ELECD	Daily U.S. electricity demand (MWh).	
Macroeconomic indicators	**EPU**	Economic Policy Uncertainty Index.	FRED
	NASDAQ	NASDAQ Composite indicators of the performance of the stock market	Yahoo Finance
	VIX	CBOE Volatility Index (VIX)	
	GOLD	Gold price per troy ounce in USD	
Cryptocurrency	**BTC**	Bitcoin (BTC) price in USD	CoinMarketCap
	XRP	XRP price in USD	
	SOLANA	Solana (SOL) price in USD	
	ETH	Ethereum (ETH) price in USD	

Finally, the macrofinancial variables cluster, which includes the NASDAQ Composite Index and the Chicago Board Options Exchange Volatility Index (VIX), as well as the Economic Policy Uncertainty (EPU) index along with gold prices (GOLD). The group enables us to conduct

measurements throughout wider market risk, uncertainty, and behaviors toward safe havens. Diebold and Yilmaz (2014) specify that macrofinancial variables exhibit lower volatility and get greatly impacted by systemic shocks, which can operate as a transmission system or absorption system depending on what market conditions exist. Overall, the dataset enables us to capture the dynamic evolution of digital, energy, financial, and environmental systems during one of the most turbulent macrofinancial periods of the decade.

3.4 Methodology

This section examines cross-cluster relationships and spillover transmission across asset classes and financial indicators during a period of severe geopolitical and macrofinancial instability. The complexity of market behaviors highlights the need for an econometric model which can identify asymmetric shock transmission between variables while effectively modeling heterogeneity among clusters. To meet this need we employ the introduced CNC methodology of Buchwalter et al. (2026). This framework extends the classical connectedness literature by allowing correlations within each cluster while imposing orthogonality across clusters. The framework allows within-cluster comovement driven by shared fundamentals while isolating between-cluster transmission. The next sections will walk through the estimation process in detail.

3.4.1. Model overview

We employ the CNC framework, first introduced by Buchwalter et al. (2026), which is an outgrowth of the connectedness approach pioneered by Diebold and Yilmaz (2012, 2014). Standard VAR-FEVD models are useful for analyzing market relationships and transmission pathways, but they do not distinguish internal cluster dependence from actual cross-cluster transmission. Regular comovement among assets within the same sector can create the impression that markets are more strongly linked than they actually are. The CNC method solves this problem directly by enabling complete correlation between variables within clusters while imposing orthogonality across clusters. The design establishes two separate elements which show how cluster members move together in comovement and how actual cross-market transmission operates as an independent process. For instance, natural comovements of assets within a cluster (e.g., energy markets) arise from shared fundamentals such as industrial activity, weather conditions, or policy interventions. Imposing full orthogonality at the individual-asset level, as in conventional FEVDs, would mask these genuine intra-sector relations and distort the true network structure. By contrast, CNC preserves within-cluster dependence and isolates cross-cluster causal transmission, enhancing the interpretability and credibility of systemic-risk assessments.

3.4.2. VAR Estimation via Adaptive Elastic Net

We start by verifying the stationarity assumption using the Augmented Dickey-Fuller (ADF) test. We then estimate a VAR model to capture the joint dynamics of returns. The optimal lag order, reported in Table 3.2, is found to be 1 according to the Akaike (AIC), Bayesian (BIC), and Hannan-Quinn (HQIC) information criteria.

Table 3.2 Optimal VAR Lag Selection

Lag	AIC	BIC	HQIC
1	-22,4451*	-21,1342*	-21,9375*
2	-21,8626	-19,2377	-20,8462
3	-21,2785	-17,3365	-19,7519
4	-20,6925	-15,4305	-18,6546
5	-20,1048	-13,5197	-17,5544

This finding highlights the necessity of evaluating short-term shock transmission across markets, illustrating the swift integration of new information within financial systems. It also fits with literature about high-frequency connectedness, showing how quickly markets adapt to new changes (Ji et al., 2020).

We consider the following standard VAR(p) model:

$$\boldsymbol{Y_t} = \sum_{i=1}^{p} A_i Y_{t-i} + u_t \qquad (\mathbf{3.1})$$

where Y_t is a Nx1 vector of asset returns, A_i denotes N×N autoregressive coefficient matrices, and u_t is a vector of $i.i.d$ residuals. Following Buchwalter et al. (2026), the VAR is estimated without intercept, consistent with the near-zero mean of return series. Under standard stability conditions, the VAR admits a moving-average representation $Y_t = \sum_{h=0}^{\infty} \boldsymbol{\Psi}_h u_{t-h}$, where $\boldsymbol{\Psi}_h$ are the impulse response matrices (Lütkepohl, 2005).

Considering the significant number of variables in relation to the effective sample size within rolling windows, we employ the Adaptive Elastic Net regularization method as outlined by Zou and Zhang (2009), adhering to the implementation instructions provided by Demirer et al. (2018). Here, regularization is important because the high volatility and marked non-normality of cryptocurrency returns increase the risk of overfitting. The adaptive penalization strategy guarantees stable and dependable parameter estimates, while maintaining compatibility with the cluster-aware CNC structure (Baruník and Křehlík, 2018).

In particular, for each equation we solve:

$$\boldsymbol{\beta} = argmin_{\boldsymbol{\beta}} \left(\sum_{t=1}^{T} (y_t - \sum_{i} \beta_i x_{it})^2 + \lambda \sum_{i=1}^{K} w_i \left(\frac{1}{2}|\beta_i| + \frac{1}{2}\beta_i^2 \right) \right) \quad \textbf{(3.2)}$$

where adaptive weights $w_i = 1/|\hat{\beta}_i^{OLS}|$ steer extra shrinkage towards small OLS coefficients. Following Buchwalter et al. (2026), we adopt an adaptive elastic-net penalty combining equally weighted Lasso and Ridge components (α = 0.5). The regularization parameter λ is determined through ten-fold cross-validation. In the adaptive elastic-net, the penalty term integrates both the LASSO (L1) and ridge (L2) components, where variable-specific weights assign heavier penalties to coefficients with smaller OLS magnitudes. This adaptive weighting intensifies shrinkage on weak predictors, shrinking them toward zero while allowing stronger coefficients to remain relatively unpenalized.

3.4.3. Cluster orthogonalization

Once residuals u_t are obtained, we apply the CNC cluster orthogonalization procedure. Let the N variables split into C clusters such that contemporaneous shocks are orthogonal across clusters but may be correlated within a cluster. We define recursively

$$\boldsymbol{Q_C^{-1}} = \begin{bmatrix} I & 0 & \cdots & 0 \\ -\Sigma_{21}\Sigma_{11}^{-1} & I & 0 & \cdots \\ \vdots & & \ddots & \vdots \\ -[\Sigma_{C1} \cdots \Sigma_{C,C-1}] \begin{pmatrix} \Sigma_{11} & \cdots & \Sigma_{1,C-1} \\ \vdots & \ddots & \vdots \\ \Sigma_{C-1,1} & \cdots & \Sigma_{C-1,C-1} \end{pmatrix}^{-1} & & I & \end{bmatrix}, \quad \textbf{(3.3)}$$

with Q_C^{-1} the inverse orthogonalization matrix for C clusters. It transforms the residuals to obtain orthogonal shocks across clusters; Σ_{ab} is the block of the residual covariance matrix that cross-couples clusters a and b.

$$\boldsymbol{\epsilon_t} = Q_C^{-1} u_t, \quad \text{Var}[\boldsymbol{\epsilon_t}] = \text{diag}(\Omega_{11}, \ldots, \Omega_{CC}) \quad \textbf{(3.4)}$$

where ϵ_t is the vector of orthogonalized shocks at time t, obtained after applying Q_C^{-1} to the residuals u_t. $\text{Var}[\epsilon_t]$ is the block-diagonal variance-covariance matrix of the orthogonalized shocks ε_t. Setting C=1 yields the generalized shocks of Koop, Pesaran, and Potter (1996), while C=N reproduces the Cholesky identification of Sims (1980) - CNC nests both. Since the block-Cholesky transformation Q^{-1} orthogonalizes shocks across clusters but leaves within-cluster correlations intact, the ordering of the clusters themselves still shapes the resulting FEVDs. We compute cluster-

orthogonalized FEVDs across all 4!=24 cluster orderings and average the results to ensure robustness, as suggested in Buchwalter et al. (2026). This procedure ensures that shocks are uncorrelated across clusters while preserving the within-cluster correlation structure. Cluster orthogonalization acknowledges cluster interdependencies while reducing spurious cross-sector dependence, which is critical when distinguishing contagion from comovement (Baruník and Křehlík, 2018).

3.4.4. Forecast Error Variance Decompositions

Once the VAR coefficients and orthogonalized residuals are obtained, we compute the forecast-error variance decompositions at a H-day horizon. Following the work of Diebold and Yilmaz (2014), Ji et al. (2020), and Bouri et al (2021), we examine short-term economic shock effects on the economy through a 10-day period which minimizes random variations.

Variance decompositions (VDs) let us figure out how much of an asset's return variability is caused by its own innovations and how much is caused by shocks from other assets. This framework provides a tractable way to assess interdependence across variables. The matrix of VDs can be viewed as the adjacency matrix of a weighted directed network, as emphasized in Diebold and Yilmaz (2014), bringing powerful network perspectives and tools in touch with connectedness measurement. Following Buchwalter et al. (2026), we define the H-step-ahead cluster-aware variance decomposition as the ratio of the squared cluster-adjusted impulse responses to the total squared forecast error. We denote $\boldsymbol{\theta_{ij}^{C}(H)}$ the share of the H-step-ahead forecast error variance of asset i due to shocks from asset j:

$$\boldsymbol{\theta_{ij}^{C}(H)} = \omega_{C,jj}^{-1} \frac{\sum_{h=0}^{H-1} (e_i' \psi_h Q_C \Omega_C e_j)^2}{\sum_{h=0}^{H-1} (e_i' \psi_h \Sigma A \psi_h' e_i)} \qquad \textbf{(3.5)}$$

$$\sum_{j=1}^{N} \theta_{ij}^{(C)}(H) \neq 1$$

where ψ_h are the moving average coefficients; Ω_C is the covariance matrix of cluster-orthogonalized shocks, Q_C is the cluster orthogonalization matrix, Σ is the reduced-form residual covariance matrix, e_i is a selection vector with 1 at position i and 0 elsewhere. All FEVD rows are normalized to sum to one for interpretability. In line with Diebold and Yilmaz (2012), we can normalize to obtain $\theta_{ij}^{C}(H) = \frac{\theta_{iy}^{C}(H)}{\sum_{j=1}^{N} \theta_{iy}^{C}(H)}$, so that $\sum_{j=1}^{N} \theta_{ij}^{(C)}(H) = 1$.

3.4.5. Rolling estimation procedure

To capture the time-varying nature of connectedness and address possible structural shifts, we employ a rolling-window approach, according to recent empirical studies (Demirer et al., 2018; Ji et al., 2020). Over rolling windows of 126 trading days (about six months), the whole estimation pipeline, Elastic Net VAR, CNC-based cluster orthogonalization, and FEVD decomposition, is moving forward one day at a time. This window length provides a reasonable compromise between estimation stability and responsiveness to changes in network topology. We recalculate the FEVD matrices, reapply the cluster orthogonalization, and re-estimate the Elastic Net VAR for each window. The time series of connectedness metrics that we get lets us follow how systemic risk and spillover dynamics change over time in different market regimes.

3.4.6. Connectedness measurements.

Decomposing connectedness into own, comovement, and contagion provides a better understanding of sector-specific relationships and systemic risk sources.

From the CNC-based FEVD matrices, we derive the following:

Let $\Theta^{(C)}(H) = [\theta_{ij}^{(C)}(H)]$

- **Own connectedness**: Share of forecast error variance explained by an asset's own innovations.

$$\Theta_{c}^{\text{own}} = \frac{1}{\overline{N_c}} \sum_{i \in \mathcal{G}_c} \theta_{ii} \qquad (\mathbf{3.6})$$

- **Comovement connectedness**: Average contribution of shocks from assets within the same cluster.

$$\Theta_{c}^{\text{comv}} = \frac{1}{N_c} \sum_{i \in \mathcal{G}_c} \sum_{\substack{j \in \mathcal{G}_c \\ i \neq j}} \theta_{ij} \qquad \mathbf{(3.7)}$$

- **Contagion connectedness**: Average contribution of shocks from assets in different clusters.

$$\Theta_{c \leftarrow k}^{\text{cont}} = \frac{1}{\overline{N_c}} \sum_{i \in \mathcal{G}_c} \left(\frac{1}{\overline{N_k}} \sum_{j \in \mathcal{G}_k} \theta_{ij} \right) \qquad \mathbf{(3.8)}$$

where N_c denotes the number of assets in cluster c. System-wide averages are computed as the mean of cluster-level own, comovement, and contagion components, which satisfy $\Theta^{own} + \Theta^{comv} +$

Θ^{cont} = 1. Directional "to", "from", and "net" connectedness indices are then obtained from the

row-, column-, and difference-sums of $\Theta^{(C)}$

3.4.7. Monte Carlo evidence on identification and measurement differences

This section provides Monte Carlo evidence on whether the difference between Generalized Connectedness (GC) and Clustered Network Connectedness (CNC) reflects a finite-sample artifact or a deeper identification difference. The key concern is that GC, by construction, incorporates contemporaneous cross-cluster correlation in reduced-form innovations, which may be interpreted as spillovers. In contrast, the CNC framework explicitly separates within-cluster comovement from cross-cluster transmission by imposing orthogonality across clusters while preserving within-cluster dependence.

To evaluate this distinction, we design controlled data-generating processes (DGPs) that allow us to isolate the roles of within-cluster dynamics, cross-cluster correlation, and cross-cluster contagion.

3.4.7.1. Monte Carlo design

We consider VAR(1) systems with variables grouped into economically meaningful clusters. The true data generating process is

$$y_t = Ay_{t-1} + u_t, \qquad E(u_t) = 0, \qquad E(u_t u') = \Sigma_u, \tag{3.9}$$

where u_t denotes reduced-form innovations with covariance matrix Σ_u. Structural shocks ε_t have covariance matrix $\Omega = E(\varepsilon_t \varepsilon_t')$ and satisfy $u_t = Q^{-1}\varepsilon_t$ so that $\Sigma_u = Q^{-1}\Omega(Q^{-1})'$.

Variables are grouped into economically meaningful clusters, and the structure of A, Ω, and Q^{-1} determines the nature of comovement and contagion. Within-cluster dynamics capture lagged interactions across variables within the same cluster, while within-cluster comovement reflects their tendency to move together contemporaneously.

Table 3.3 Data-generating processes and identification structure

DGP	Within-cluster structure	Between-cluster structure	Identification objective
DGP0 (Block-segmented system)	Within-cluster dynamics only	No between-cluster dependence (no correlation, no transmission)	Benchmark: absence of cross-cluster connectedness
DGP1 (Correlation without transmission)	Within-cluster dynamics and within-cluster comovement	Cross-cluster correlation in innovations, no dynamic transmission	Identification of correlation-driven overstatement of cross-cluster connectedness
DGP2 (Comovement and transmission)	Within-cluster dynamics and within-cluster comovement	Cross-cluster correlation and dynamic transmission	Identification of cross-cluster transmission

As shown in Table 3.3, we consider three DGPs:

- **DGP0:** The VAR coefficient matrix is block diagonal, allowing for own persistence and within-cluster lagged interactions. Reduced-form innovations are independent across clusters. The system therefore exhibits within-cluster dynamics but no cross-cluster correlation and no cross-cluster dynamic transmission. This serves as a benchmark in which GC and CNC coincide.

- **DGP1 :** The VAR structure remains block diagonal, but reduced-form innovations exhibit cross-cluster correlation induced by a cluster-level mixing structure. This setting isolates the case where cross-cluster correlation exists in the covariance matrix without any lagged cross-cluster transmission. It allows us to assess whether connectedness measures attribute correlation to contagion.

- **DGP2 :** The system combines within-cluster dynamics, cross-cluster correlation in reduced-form innovations, and explicit cross-cluster lagged transmission through the VAR structure. This setting captures both comovement and cross-cluster dynamic transmission.

For each DGP, we compute population connectedness measures implied by each identification scheme. CNC measures are averaged across all admissible cluster orderings to ensure robustness to identification ordering. Monte Carlo settings are R=1000 replications, sample sizes T∈{200, 500, 1000}, Gaussian and Student-t innovations. In each replication, VAR models are estimated using OLS to isolate identification effects from regularization, ensuring that any difference between GC and CNC arises from the identification scheme rather than from estimation bias.

In the baseline design, parameters are chosen to generate realistic and interpretable levels of dependence across clusters. Within-cluster shock correlation is set to 0.60 and cluster-mixing strength to 0.50, creating strong contemporaneous comovement in the data. Dynamic persistence is introduced through an own-lag coefficient of 0.35 and within-cluster spillovers of 0.10, which capture moderate short-run interactions within sectors. In DGP2, cross-cluster lagged transmission is set to 0.07 to introduce a limited but meaningful degree of true inter-cluster contagion. Innovations follow a Student-t distribution with 5 degrees of freedom to reflect the heavy tails typically observed in financial returns. This calibration is designed to clearly separate correlation from transmission: cross-cluster dependence is strong enough to inflate GC measures, while true dynamic transmission remains moderate, allowing CNC to correctly isolate genuine spillovers.

Moving-average coefficients $\{A_h\}_{h=0}^{H-1}$ are obtained by standard recursion with horizon H=10. GC and CNC FEVDs are computed using the common denominator based on $\mathrm{diag}(A_h \Sigma_u A_h')$, ensuring

comparability across identification schemes.

3.4.7.2 Population connectedness

Population connectedness is computed by applying GC and CNC directly to the true parameters (A, Σ_u), thereby characterizing the connectedness objects implied by each identification scheme. We define the population gap

$$\Delta^{\text{pop}}_{\text{cross}} = \text{Cross}^{\text{pop}}_{\text{GC}} - \text{Cross}^{\text{pop}}_{\text{CNC}} \quad \textbf{(3.10)}$$

We test:

- **H1**: $\Delta^{\text{pop}}_{\text{cross}} = 0$ in DGP0.
- **H2**: $\Delta^{\text{pop}}_{\text{cross}} > 0$ in DGP1.
- **H3**: In DGP1 and DGP2, the Monte Carlo mean of the GC–CNC cross-cluster difference approaches the corresponding population gap $\Delta^{\text{pop}}_{\text{cross}}$ as the sample size increases.

Under Student-t innovations, higher-order moments differ from the Gaussian case and unconditional scale may also change; this robustness check captures the impact of heavy tails and extreme realizations on connectedness measures. All connectedness measures are normalized by the number of variables and scaled by 100, so that values can be interpreted as average shares of forecast error variance.

Table 3.4 Population connectedness measures (scaled ×100)

DGP	Total GC	Total CNC	Δ Total	Within GC	Within CNC	Δ Within	Cross GC	Cross CNC	Δ Cross
DGP0	25.18	25.18	0.00	25.18	25.18	0.00	0.00	0.00	0.00
DGP1	55.38	17.19	38.19	19.07	17.19	1.88	36.31	0.00	36.31
DGP2	72.52	54.41	18.11	18.99	17.13	1.86	53.53	37.28	16.25

Table 3.4 reports population connectedness across the three data-generating processes.

Under DGP0, GC and CNC coincide exactly for total, within-cluster, and cross-cluster components, confirming that CNC does not mechanically reduce connectedness when no cross-cluster dependence and contagion is present.

Under the GC framework, this decomposition is constructed ex post by aggregating pairwise FEVD shares according to cluster membership, as GC itself does not impose any structural separation between within- and cross-cluster effects. Consequently, cross-cluster connectedness under GC reflects both contemporaneous correlation and dynamic transmission effects.

Under DGP1, where the system features within-cluster dynamics and cross-cluster correlation in reduced-form innovations but no dynamic cross-cluster transmission, GC generates substantial cross-cluster connectedness (ΔCross = 36.31). By contrast, CNC assigns zero cross-cluster connectedness, correctly reflecting the absence of lagged cross-cluster transmission. This result shows that GC attributes cross-cluster spillovers to what is in fact only correlation in reduced-form innovations, whereas CNC successfully isolates genuine transmission.

Under DGP2, both measures increase with the introduction of genuine cross-cluster transmission. However, GC remains systematically higher (ΔCross = 16.25), indicating that it combines correlation and transmission effects, whereas CNC isolates cross-cluster transmission by removing the component driven by contemporaneous correlation.

Overall, the GC–CNC difference reflects a structural identification gap rather than a finite-sample artifact. While GC combines contemporaneous correlation and dynamic transmission into a single measure, CNC explicitly separates within-cluster comovement from cross-cluster transmission, providing a more economically interpretable measure of spillovers.

3.4.7.3. Finite-sample Monte Carlo results

Under Gaussian innovations, the finite-sample mean difference in cross-cluster connectedness between GC and CNC moves toward the population benchmark as the sample size increases:

- T=200 : mean (GC−CNC)= 33.17,
- T=500 : mean (GC−CNC)= 33.57,
- T=1000: mean(GC−CNC)= 36.05,

As shown in Table 3.5, Panel A indicates that GC consistently produces higher cross-cluster connectedness than CNC under DGP1, where the system features within-cluster dynamics and cross-cluster correlation in reduced-form innovations but no dynamic cross-cluster transmission. CNC cross-cluster connectedness remains close to zero and declines with the sample size, while GC remains close to its population level.

The GC–CNC gap remains strictly positive across all sample sizes and approaches its population value, indicating that the difference reflects a stable identification-driven discrepancy rather than a finite-sample artifact.

CNC delivers stable estimates with lower dispersion and remains closer to its population benchmark, while GC systematically attributes part of cross-cluster correlation to spillovers.

Panel B shows that this difference extends to total connectedness, with GC uniformly exceeding CNC across all sample sizes. This pattern reflects the fact that GC combines both correlation and

transmission effects, whereas CNC separates within-cluster comovement from cross-cluster transmission.

Table 3.5 Monte Carlo Summary Statistics - DGP1 (scaled ×100)

Panel A - Cross-cluster connectedness

Measure	T=200 (Mean)	T=200 (SD)	T=500 (Mean)	T=500 (SD)	T=1000 (Mean)	T=1000 (SD)
GC (Cross)	35.29	2.46	35.03	1.62	36.91	1.11
CNC (Cross)	2.12	0.72	1.46	0.32	0.86	0.22
GC−CNC (Cross)	33.17	0.64	33.57	0.40	36.05	0.28

Panel B - Total connectedness

Measure	T=200 (Mean)	T=200 (SD)	T=500 (Mean)	T=500 (SD)	T=1000 (Mean)	T=1000 (SD)
GC (Total)	54.28	2.41	55.04	1.59	55.94	1.08
CNC (Total)	15.46	2.71	18.69	1.88	17.06	1.30
GC−CNC (Total)	38.82	0.64	36.35	0.44	38.88	0.31

Figure 3.1 shows that the GC–CNC gap becomes closer to a strictly positive population value as the sample size increases. This indicates that GC and CNC do not converge to the same connectedness object. Instead, GC embeds contemporaneous cross-cluster correlation, while CNC isolates cross-cluster transmission under a cluster-based identification structure. The persistence of the gap confirms that the difference between GC and CNC reflects identification assumptions rather than estimation noise.

Fig 3.1 Convergence of the GC-CNC difference in cross-cluster connectedness under DGP1

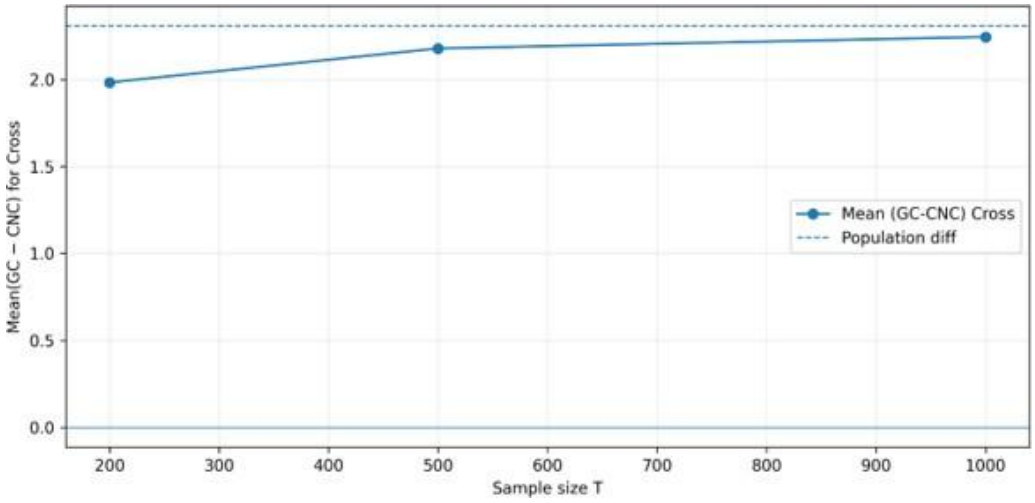

Note: Values are reported in fraction form and are not scaled by 100.

As shown in Table 3.6, under DGP2, where within-cluster comovement and cross-cluster transmission coexist, GC continues to produce higher cross-cluster connectedness than CNC. The GC–CNC gap remains strictly positive under both Gaussian and Student-t innovations and moves toward the population value as the sample size increases. The fact that P(GC>CNC)= 1 in all cases confirms that the difference between the two measures is systematic and persistent.

While both measures capture genuine cross-cluster transmission, GC reflects both contemporaneous cross-cluster correlation and dynamic spillovers, whereas CNC separates within-cluster comovement from cross-cluster transmission under the cluster-based identification. The results under Student-t innovations show that this pattern remains robust to heavy-tailed shocks, with higher dispersion and slightly lower mean differences compared to the Gaussian case, indicating that the GC–CNC gap is not driven by distributional assumptions.

Table 3.6 Monte Carlo Summary Statistics - DGP2 (scaled ×100)

Panel A - Gaussian innovations

Measure	***T=200 (Mean)***	***T=200 (SD)***	***T=500 (Mean)***	***T=500 (SD)***	***T=1000 (Mean)***	***T=1000 (SD)***
GC−CNC (Cross)	13.99	0.66	15.35	0.43	15.81	0.31
P(GC > CNC)	1.000		1.000		1.000	

Panel B - Student-t innovations (heavy-tailed shocks)

Measure	***T=200 (Mean)***	***T=200 (SD)***	***T=500 (Mean)***	***T=500 (SD)***	***T=1000 (Mean)***	***T=1000 (SD)***
GC−CNC (Cross)	13.26	1.04	14.96	0.68	15.59	0.47
P(GC > CNC)	1.000		1.000		1.000	

These findings are consistent with the population benchmark and provide a structural interpretation of the empirical results. The lower connectedness levels observed under CNC do not reflect a loss of information, but rather a different decomposition of dependence, in which within-cluster comovement and cross-cluster transmission are separated. CNC therefore provides a more structurally interpretable decomposition of connectedness, whereas GC reflects a composite measure that combines correlation and transmission effects.

3.5 Results

3.5.1. Summary statistics

Table 3.7 reports the summary statistics of the daily return series for the variables defined in Table 3.1. The results of ADF test show that all series reject the null hypothesis of a unit root at the 1 % or 5 % significance levels, confirming that the data are stationary. Among financial assets, Bitcoin (0.066%) and Gold (0.064%) record slightly positive mean returns, confirming their dual role as speculative and hedging instruments (Bouri et al., 2021). Conversely, energy-related variables such as WTI (−0.015%) and GAS (−0.043%) show slightly negative average returns, consistent with the partial normalization of fossil-fuel markets after the 2022 energy shock (Bauer et al., 2013).

The environmental gauges CO2, RENERG and ESG show average returns that are slightly negative or remain at zero which matches research findings about the weakening link between emission patterns and economic performance (Chevallier, 2011). Cryptocurrencies return exhibit the highest dispersion in the sample with standard deviations above 4.5% with SOLANA topping the list at 6.7%. Those levels dominate the variations observed in more conventional assets such as gold (0.9%) and Nasdaq (1.5%). The evidence points to digital-asset markets bearing a markedly higher risk profile (Corbet et al., 2020). In contrast the VIX and CO2 series both tumble dramatically, exceeding 7 % volatility, underscoring how uncertainty and environmental metrics are especially prone to shocks. Also, the ESG index (1.15 %) and RENERG index (1.84 %) showed changes in their values because sustainability-oriented benchmarks maintained a stable risk profile throughout this time. While most energy and environmental variables display a slight positive skewness, major crypto assets exhibit a negative skewness. On the other hand, XRP demonstrates a skew of 1.88 which indicates its price movements stem from short-term speculative activities. The VIX (7.14) and some cryptocurrencies (ETH: 8.78; SOLANA: 8.40) show high excess kurtosis values which indicate their returns follow heavy-tailed distributions and experience regular extreme price fluctuations (Ji et al., 2020).

The set of stylized facts reveals two main characteristics which show significant deviations from normal behavior and display strong differences between clusters. These results support the use of a cluster-aware time-varying connectedness framework capable of capturing heterogeneous and asymmetric transmission paths across cryptocurrency, energy, environmental, and macrofinancial markets, in line with Diebold and Yılmaz (2014) and Wang et al. (2021).

Table 3.7 Summary statistics

Variable	Mean	Std Dev (%)	Skewness	Kurtosis	ADF
CO2	-0.021	7.03	-0.48	2.83	−14.8***
GAS	-0.043	5.37	0.25	5.52	−9.32***
ELECD	-0.013	3.1	0.21	4.69	−10.6***
WTI	-0.015	2.51	-0.41	1.43	−10.5***
RENERG	-0.068	1.84	0.47	1.49	−8.45***
EPU	-0.108	2.06	0.02	1.05	−14.6***
NASDAQ	0.024	1.54	-0.22	1.26	−8.64**
VIX	0.024	7.68	0.20	7.14	−9.78***
BITCOIN	0.066	3.68	-0.60	6.89	−8.39**
ETH	-0.051	4.57	-0.65	8.78	−8.19***
XRP	-0.069	5.02	1.88	4.57	−8.29***
ESG	0.028	1.15	-0.21	1.63	−8.51***
GOLD	0.064	0.92	-0.09	0.82	−8.82***
SOLANA	0.004	6.74	-0.81	8.40	−7.65**

Note: ADF statistics are reported with significance levels denoted by ***, **, and *, indicating rejection of the null hypothesis at the 1%, 5%, and 10% levels, respectively

3.5.2. Overview of connectedness distributions

3.5.2.1. Directional and net connectedness densities

Figure 3.2 shows the kernel densities of directional ("To" and "From") and net connectedness estimates that were made using the GC and CNC frameworks. In the GC specification, the “To” distribution exhibits a moderate right-skew and an extended right tail, suggesting that a limited number of variables act as relatively stronger systemic transmitters (Diebold and Yılmaz, 2014). The “From” distribution is tightly concentrated around a positive mean rather than zero, reflecting the generalized variance-decomposition structure. The net-connectedness density is centered close to zero with a slight positive tilt, indicating that most assets remain near a neutral position with a small subset of persistent net transmitters, consistent with asymmetric contagion patterns documented in the literature (Baruník and Křehlík, 2018).

Under the CNC framework, these distributions become more compact. The orthogonalization step increases the concentration of the “To” density around its mode and reduces its dispersion, consistent with the removal of intra-cluster comovement effects. The “From” density shows lower variance rather than a directional mean shift, indicating a clearer separation of internal and

external spillover contributions. The CNC net-connectedness density presents a mild bimodal structure with a slightly sharper positive mass, facilitating the identification of net transmitting clusters. Overall, this distributional reshaping illustrates how CNC separates within-cluster comovement from between-cluster contagion, preventing the misclassification inherent in generalized connectedness, in line with the stabilizing role of block-orthogonalized variance decomposition highlighted in Buchwalter et al. (2026).

Figure 3.2 Kernel density of directional and net connectedness: Generalized GC vs. CNC

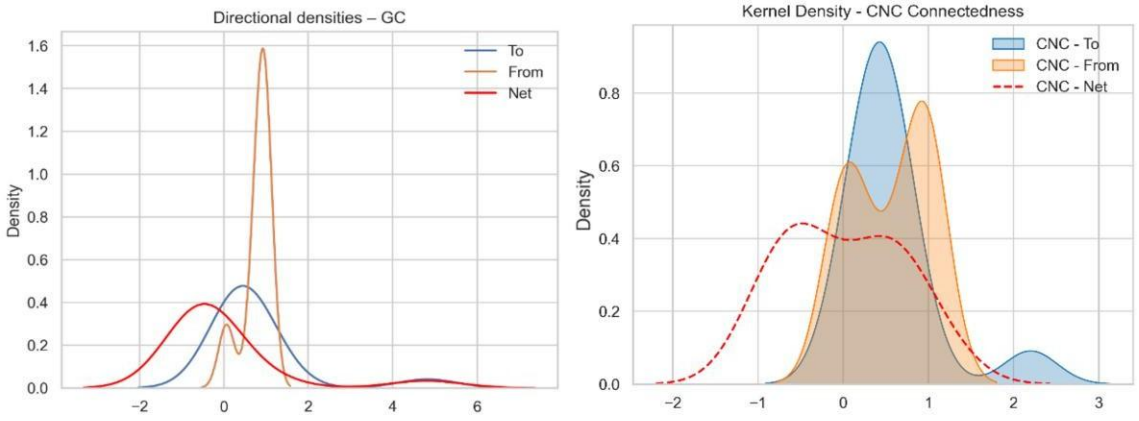

3.5.2.2. Clustered network connectedness

The CNC layout for the four market groups is depicted in Figure 3.3. The diagram shows network connectivity through node size and edge thickness represents the strength of spillover effects. The cross-market information landscape is shaped primarily by NASDAQ, BTC, and RENERG, which act as the key information transfer points across clusters, while GOLD plays a secondary yet relevant bridge role. GOLD functions as a dual-purpose asset: it provides stability to portfolios while also acting as a conduit for volatility transmission, particularly during periods of financial stress (Shahzad et al., 2019). CO_2 remains mostly a spillover receiver rather than a transmitter, reflecting its role as an environmental end-point variable sensitive to energy-use shocks. NASDAQ operates as a fast market platform which responds immediately to technological changes and market participant emotions. The research shows that equity cycles follow a specific pattern which investors must understand how to perform successful market analysis (Bouri et al. 2021).

In parallel, Bitcoin remains the dominant source of volatility within the cryptocurrency cluster and its price swings echo back and forth with Ethereum, Solana and XRP. The two-way spillover effect makes this instrument behave as a high-beta instrument instead of delivering effective hedging performance (Corbet et al., 2020). Moreover, RENERG functions as a market indicator which connects energy and environmental sectors to detect changes in commodity values and new policy

initiatives and ESG-based investment movements (Reboredo and Ugolini, 2020).

Dense intra-cluster transmission patterns are visible mainly among NASDAQ, GOLD, and VIX, while EPU appears more peripheral and primarily reacts to macrofinancial stress (Diebold and Yilmaz, 2014). Spillovers from NASDAQ and VIX to Bitcoin show that digital assets make changes in macrofinancial sentiment stronger rather than providing diversification. The observed inflow into EPU indicates that it responds to macrofinancial stress events, although its role appears more reactive than central within the network (Baker et al., 2016; Pastor and Veronesi, 2013; Caldara and Iacoviello, 2022).

Figure 3.3 Clustered network connectedness spring-graph

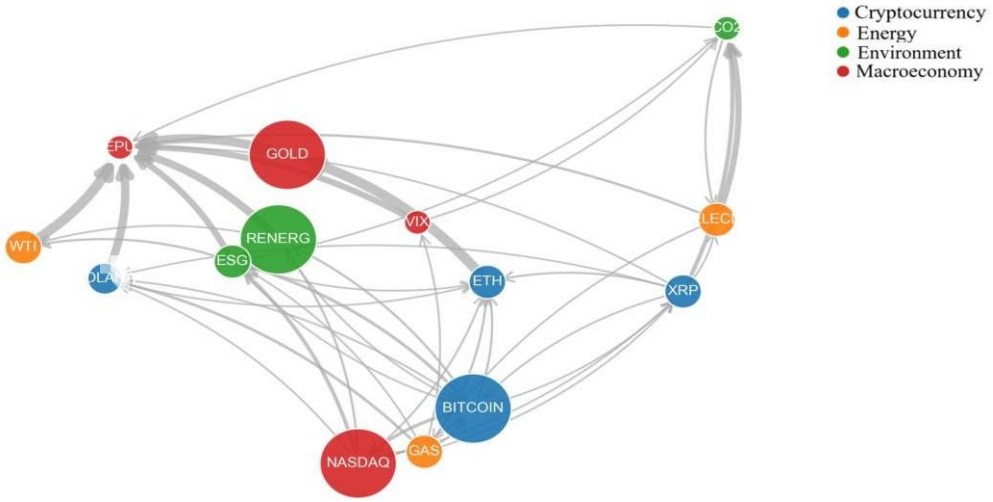

On the other hand, the feedback effect between WTI, GAS, and ELECD in the energy cluster shows cycles of supply-demand rebalancing and price adjustment. The directed flow from electricity demand to CO_2 shows how emissions respond to changes in energy use, which is in line with established short-run links between energy and the environment (Chevallier, 2011). Within the environmental cluster, RENERG appears as the primary connector, while ESG and CO_2 mainly reflect spillovers from policy and market signals, consistent with increasing financialization of sustainability assets (Engle et al., 2020).

Taken together, the CNC network shows a hierarchical interdependence structure in which systemic pressures come from a few key transmitters, NASDAQ, GOLD, BTC, and RENERG, and spread through different bridge nodes across clusters. The NASDAQ-ESG channel shows how financial and sustainable investment cycles are in sync. The WTI-RENERG link suggests directional influence between fossil and renewable energy markets, reflecting policy spillovers and market adjustment rather than simple substitution. The ELEC-CO2 pathway shows how electricity use has

a direct effect on the environment.

In general, these patterns show that cluster-based orthogonalization makes things easier to understand by separating intra-cluster cohesion from inter-cluster contagion and by finding the few bridging nodes that are responsible for systemic transmission. This structure aligns with the multi-market contagion dynamics identified in recent connectedness frameworks (Baruník and Křehlík, 2018; Buchwalter et al., 2026).

3.5.2.3. Dynamic net transmissions

The evolution in net cluster connectedness (Figure 3.4) clearly indicates how the four market clusters are ranked in terms of transmission and absorption. The energy cluster consistently serves as the primary net transmitter (average +0.64), maintaining positive spillovers throughout most of the sample period. Its highest point (+0.96) in mid-2023 came at the same time as disruptions in global energy markets after the EU banned Russian hydrocarbons. This was also when Asian LNG demand rose sharply while European supply was limited (Pisani-Ferry et al., 2023). On the other hand, the macrofinancial cluster (red line) remains a net absorber throughout the sample (mean −1.1). It dropped sharply below −1.5 in March 2023 when U.S. regional banks were under stress, liquidity frictions were rising, and global funding conditions were getting tighter (Acharya et al., 2023; Jiang et al., 2023; IMF Global Financial Stability Report, 2023). The magnitude and persistence of these adverse net-transmission values substantiate the notion that macrofinancial indicators are more inclined to mitigate stress within the system rather than initiate a chain reaction. They serve as endpoints for the aggregation of shocks within the market.

The cryptocurrency cluster (blue line) shows clear changes in the way it transmits shocks. It is a net receiver (about −0.3) during the confidence shock caused by the FTX collapse in late 2022. However, starting in the second quarter of 2023, it becomes a net transmitter (about +0.7) as volatility decreases and investor sentiment slowly stabilizes (Auer et al., 2022). This change suggests that digital asset markets are regaining autonomy while becoming more closely aligned with macrofinancial and energy-related trends.

Finally, the environmental cluster (green line) generally follows the energy trajectory, but with a delayed positive pattern. This is in line with an energy-to-ESG transmission mechanism. The smoother trajectory and delayed movement compared to the energy curve support the idea that shocks to fossil fuel prices are slowly being built into sustainability-linked valuations. This is in line with the energy-price → ESG-valuation → carbon-pricing channel described by Reboredo and Ugolini (2020). The evidence suggests that environmental assets absorb and transmit shocks in a manner subordinate to energy market dynamics, albeit with a slower adjustment process.

Figure 3.4 Dynamic net directional connectedness

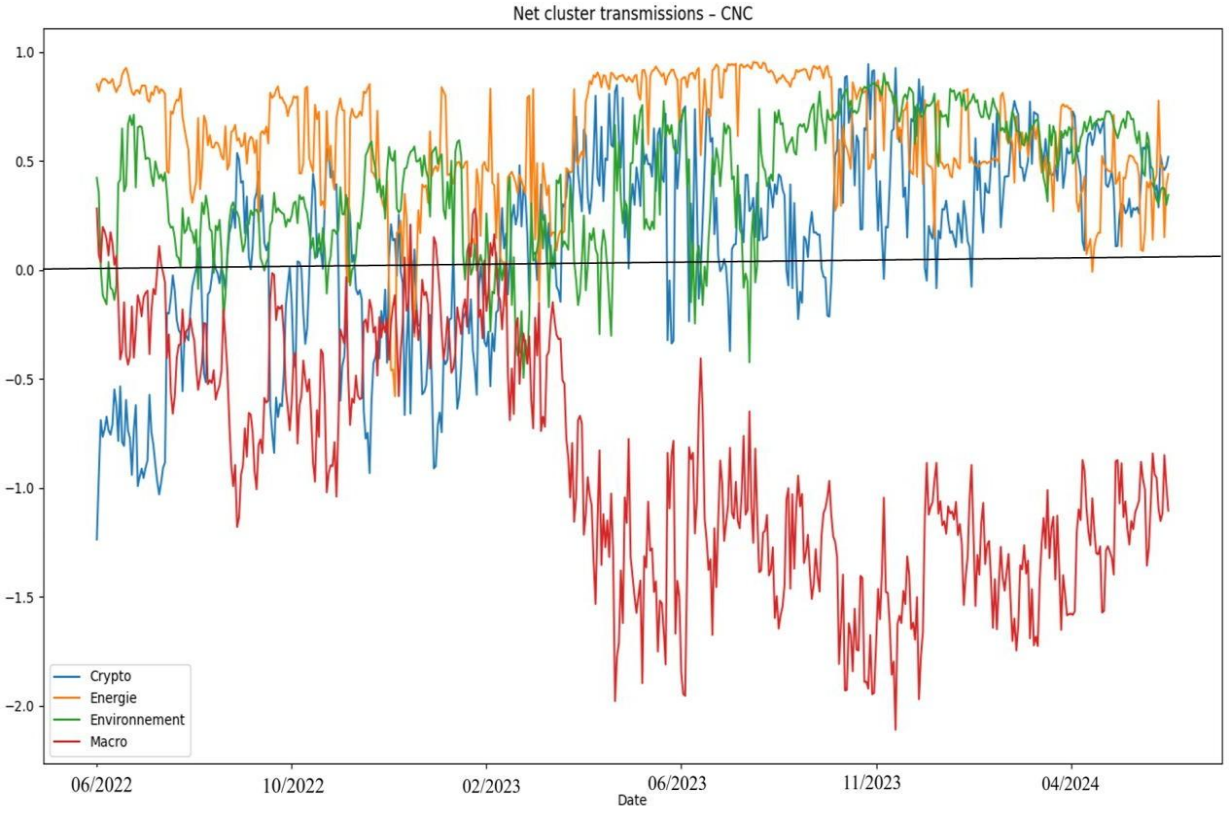

3.5.3. Within-cluster vs. cross-cluster spillovers

The variance decomposition results (Figure 3.5) indicate that the Crypto, Energy, Environment, and Macro clusters are interconnected in various manners. Each bar delineates the variance of forecast errors into three components: idiosyncratic, intra-cluster (comovement), and cross-cluster (contagion). This breakdown shows autonomous dynamics, internal coherence, and exposure to external shocks, in that order. 9% of the cryptocurrency cluster's variance is internal while 76 % comes from external spillovers. This stark split shows how strongly the cluster depends on external factors. The configuration is consistent with the market upheaval that followed FTX's collapse in 2022, when a crypto-specific shock propagated more broadly through liquidity stress and weaker sentiment (Auer et al., 2022).

Figure 3.5 Variance decomposition across clusters: Own, CoMove, Contagion

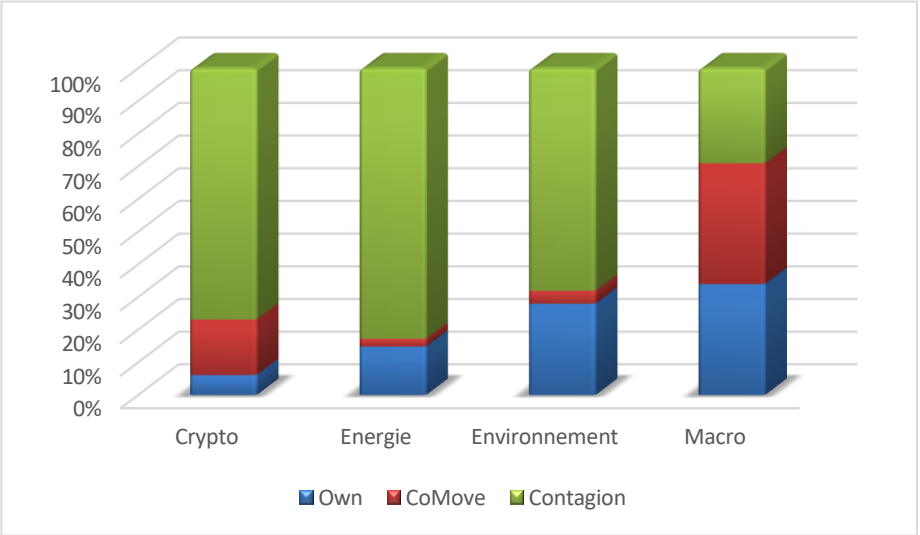

The macrofinancial group, by contrast, is the most self-contained: 38% of its variance originates internally, and it shows fairly strong internal comovement of roughly 30%. Instruments such as the Nasdaq, the VIX, the EPU index and gold all tend to move in tandem. This pattern suggests that traditional benchmarks are largely steered by a shared set of drivers and are only marginally rattled by shocks that affect a sector. This structure mirrors findings reported earlier (Diebold and Yılmaz 2014; Baruník and Křehlík, 2018).

Furthermore, the energy and environmental clusters hover near the center, each with contagion components topping 60 %. That level points to a sensitivity to market movements while still preserving distinct internal patterns, about 18 % for the energy side and roughly 32 % for the environmental side. Since the environmental segment is assembled from ESG indices, carbon-price signals, and renewable-energy equities, its external exposure is naturally tied to fossil-fuel price fluctuations. This composition is aligned with the identified energy-to-ESG transmission documented by Reboredo and Ugolini (2020) and Dutta (2017).

In sum, the variance decomposition suggests that cross-cluster propagation is a central driver of fragility, outweighing within-sector dynamics over this sample. This finding reinforces the argument for adaptive, multifactorial risk management frameworks. The strong linkage between energy and the environmental clusters (about 60%) underscores the importance of consistent climate and energy policies to mitigate volatility spillovers and support a steady regulatory path during the low-carbon transition.

3.5.4. Connectedness assessment: CNC vs GC

The differential measure between generalized connectedness and clustered network connectedness is illustrated in Figure 3.6. The series has a positive mean of about 0.09, meaning that CNC always gives lower estimates of system-wide spillovers than the GC framework. In late 2022, when the post-FTX contagion episode happened, the difference was more than 0.35. During this time, GC misclassified movements within a cluster as broad systemic transmission because of high cross-asset volatility. The gap narrows from 2023 to 2024, indicating that the market is again behaving in a more segmented manner as adjustments specific to clusters become more important in the propagation structure.

These findings align with Buchwalter et al. (2026), who reported in their analysis that GC essentially fuses intra-cluster correlation, with inter-cluster contagion driving systemic risk upward. CNC, by contrast, relies on a structural-separation framework to tease apart pre-defined groups: Crypto, Energy, Environment, and Macro. This separation highlights cross-cluster spillovers, a piece of the puzzle when attempting to pin down risk.

The observed divergence suggests that regulatory frameworks relying on GC-based metrics may overstate vulnerability, potentially resulting in capital or margin requirements that are higher than warranted. By employing CNC-adjusted indicators, policymakers can clearly separate comovement from genuine contagion. This refinement sharpens the accuracy of systemic-risk surveillance tools enabling them to flag emerging problems (Hałaj and Hipp, 2024).

Figure 3.6 Differences in connectedness: GC Minus CNC

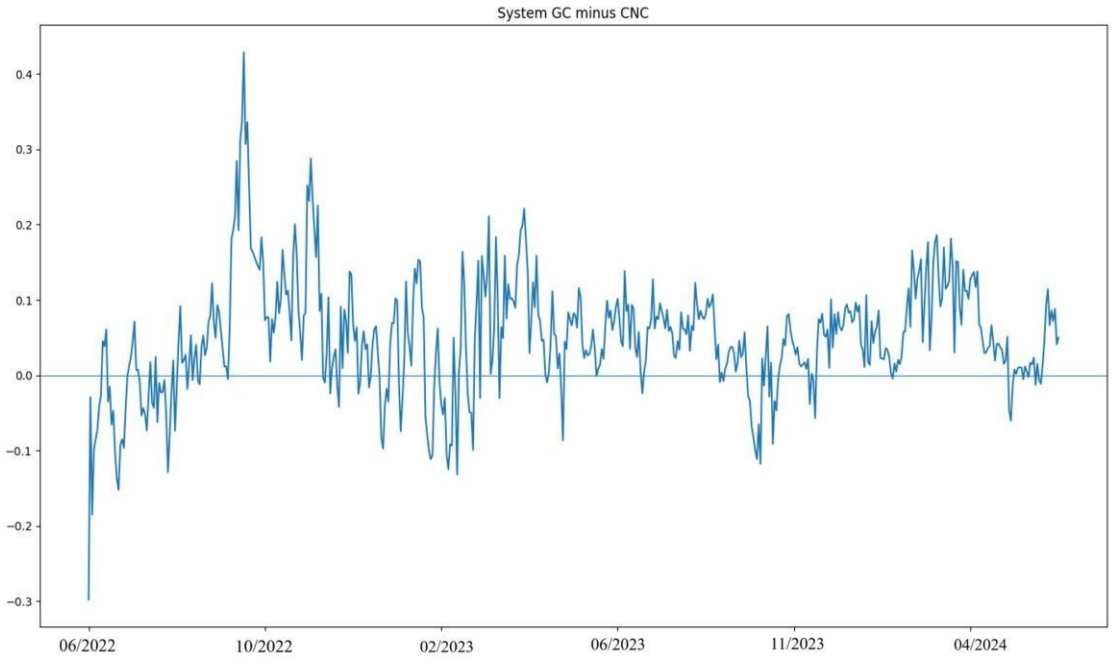

Importantly, these differences between GC and CNC are consistent with the identification bias documented in Section 3.4.7, where GC is shown to overstate between-cluster spillovers in the presence of within-cluster comovement.

3.6 Discussion and policy implications

Empirical findings emerging from the clustered network connectedness framework consistently reveal that transmission patterns fluctuate across market clusters, a heterogeneity that proves crucial for portfolio construction, financial-stability assessment and regulatory design. According to CNC estimates, the energy cluster emerges as the transmitter of shocks averaging +0.64, while the cryptocurrency and environmental-asset clusters behave mainly as net receivers. With only 9% own variance and 76% of dynamics explained by external spillovers, the crypto cluster cannot be employed as a reliable diversification tool. Besides, it tends to comove with macrofinancial and energy market shocks effectively acting as a high-beta satellite circling the financial system, exactly the kind of amplification observed after the FTX collapse (Auer et al., 2022). On the other hand, since the energy cluster acts as a significant shock transmitter, portfolio strategies must embed real-time monitoring of geopolitical changes and OPEC-driven supply fluctuations. Given the environmental cluster's response, roughly a 60% contagion share, it bolsters a tactical ESG allocation that anticipates shifts in the energy markets. These structural imbalances underline how CNC-based indicators may help investors adjust exposures dynamically and, through cluster-based allocation strategies, potentially improve risk-adjusted performance.

From a macroprudential perspective, CNC reveals that macrofinancial assets (NASDAQ, VIX, EPU, GOLD) serve as consistent shock absorbers (mean = -1.1), particularly during the March 2023 U.S. banking turmoil, when "flight-to-quality" effects prevailed (Acharya et al., 2023; Jiang et al., 2023). Comparative analysis between CNC and the GC framework shows that GC overstates system-wide connectedness by roughly 8-10 percent, mainly because it aggregates intra-cluster comovements into systemic spillovers. This finding aligns with Buchwalter et al. (2026), who show that CNC isolates genuine inter-cluster contagion by constraining within-cluster covariance. Relying solely on GC-based metrics may therefore lead to overly conservative capital buffers and less informative stress-testing outcomes.

Furthermore, the strong energy → environmental transmission (60%) implies that energy shocks and carbon-pricing fluctuations must be explicitly embedded into climate-related financial stress tests, as volatility in fossil-fuel markets directly affects the stability of ESG and green-finance instruments (Reboredo and Ugolini, 2020).

The time-varying CNC metrics provide dynamic insights that can be used as early warning signs. Tracking changes in net-transmission hierarchies, such as reversals in the direction of crypto-to-macro transmission or times of energy-driven contagion, helps policymakers and market participants find structural breaks before they spread to the rest of the system. This study does not include forecasting, but the CNC series can significantly enhance current macrofinancial monitoring frameworks by differentiating structural comovement from externally induced contagion, thereby improving the anticipatory capacity of policy responses.

3.7 Conclusion

This study examined the interrelated dynamics of cryptocurrencies, energy markets, macrofinancial indicators, and environmental assets from January 3, 2022, to October 30, 2024, a timeframe marked by the post-pandemic energy shock, intensified geopolitical conflict, and significant volatility in digital asset markets. We differentiate intra-sector comovement from cross-sector contagion using the CNC framework and identify four key findings. First, energy markets are always the main channel that systemic disturbances spread through, especially when there are shocks with supply or political tensions. Second, cryptocurrencies change from net receivers of shocks to net transmitters after 2023. This pattern is consistent with increased sensitivity to macrofinancial and energy shocks.

Third, assets that focus on the environment and ESG respond more slowly but still show fluctuations in fossil fuel dynamics. This shows that there is a significant and measurable energy-to-sustainability spillover channel. Finally, conventional generalized connectedness models systematically overstate systemic risk by about 8-12% because they don't separate cluster-internal propagation from true cross-sector transmission. These results indicate that standard connectedness measures may overestimate systemic risk by conflating within-cluster comovement with between-cluster contagion, whereas CNC provides a more structurally consistent decomposition.

These results suggest that incorporating cluster-aware connectedness measures into macroprudential frameworks could improve the accuracy of systemic-risk assessment. Besides, energy-related variables should be included in climate stress testing frameworks because shocks to energy and digital assets propagate through financial conditions, liquidity, and market sentiment channels. Furthermore, dynamic capital requirements and margin practices tailored to a cluster net-transmitter status could mitigate shock amplification during stress episodes. This suggests that cryptocurrencies behave as high-beta assets closely linked to macrofinancial and energy shocks, limiting their diversification role during periods of systemic stress. However, gold and ESG indices still display some defensive properties when volatility is moderate. A dynamic multi-cluster allocation strategy,

guided by CNC indicators, can enhance resilience by reallocating exposure between shock-transmitting and shock-absorbing clusters in response to changing market conditions.

Future research can expand this framework to encompass carbon-credit, green-bond, and climate policy uncertainty indices, as well as integrate frequency-domain or time-varying Bayesian extensions to elucidate structural transition risks and policy modifications related to decarbonization and digital asset integration. Overall, the CNC architecture improves systemic-risk assessment by separating synchronization from cross-cluster transmission. This gives policymakers and investors a stronger basis for assessing the fragility of the crypto-energy-environment nexus as it becomes more intertwined during the low-carbon digital transition.

5 Chapter 4. From Network Spillovers to Trading Signals: Clustered Graph Neural Networks for Bitcoin Return Prediction

- Publication notes: This chapter is a joint paper with Amine Lahiani and Foued Bad Gabsi. The article was submitted to the *Journal of Forecasting* and is currently under review (Quartile: Q1 /ABS: 2)

From Network Spillovers to Trading Signals: Clustered Graph Neural Networks for Bitcoin Return Prediction

Abstract

Connectedness measures derived from forecast error variance decompositions (FEVDs) are widely used to characterize spillovers in financial and macrofinancial systems, but their predictive content is often left unexploited. This paper examines whether economically identified connectedness improves Bitcoin return prediction across multiple horizons. We construct time-varying directed spillover networks using clustered FEVD identification, which separates own effects, within-cluster dependence, and cross-cluster transmission, and we use these networks as inputs to a temporal graph-learning model combining graph attention and gated recurrent dynamics (GAT-GRU). We then evaluate forecasting performance out of sample using statistical loss measures and risk-adjusted trading metrics. The evidence suggests that the predictive content of connectedness is horizon-dependent: gains are modest at the shortest horizon, become pronounced at intermediate horizons, and are the highest when the forecasting model learns from economically structured spillover networks rather than from undifferentiated dependence.

Keywords: Bitcoin returns, Network connectedness, FEVD spillovers, Cluster identification, Contagion and comovement, Temporal graph learning, Graph attention, GRU, Multi-horizon forecasting

4.1 Introduction

Over the last decade, Bitcoin has evolved from a niche digital asset into an increasingly integrated component of the global financial system. Empirical evidence documents its growing exposure to macroeconomic conditions, monetary policy uncertainty, energy markets, and broader risk sentiment, challenging the early view of Bitcoin as an isolated or purely speculative instrument. This structural integration has intensified the importance of understanding shock transmission mechanisms linking Bitcoin to other macrofinancial and environmental variables, particularly during periods of heightened market stress. Forecasting performance should depend not only on Bitcoin's own history but also on how information is transmitted across economically distinct groups of variables (Bouri et al., 2017; Corbet et al., 2018; Ji et al., 2019).

A large and influential literature addresses this question through connectedness measures derived from forecast error variance decompositions (FEVDs) in vector autoregressive frameworks. These measures have proven useful for mapping spillovers, identifying systemic risk contributors, and characterizing crisis dynamics across financial markets (Diebold and Yilmaz, 2012, 2014). In this strand of research, connectedness is primarily employed as a descriptive tool, offering ex post diagnostics of shock transmission and interdependence patterns. Despite its widespread adoption, the predictive content of connectedness remains ambiguous. In practice, connectedness measures are rarely exploited as structured inputs for forecasting models, and when they are, they are often reduced to ad hoc summaries or correlation-based proxies.

A key limitation lies in the identification of spillovers. Orthogonalized FEVDs deliver economically interpretable shocks but are inherently sensitive to variable ordering, while generalized FEVDs are order-invariant yet confound true transmission effects with contemporaneous correlation and comovement. As a result, connectedness measures may overstate contagion by attributing correlated shocks to causal spillovers, thereby blurring the distinction between genuine cross-market transmission and common-factor dynamics.

Recent advances in clustered identification offer a principled resolution to this dilemma. By allowing shocks to be correlated within economically meaningful clusters while enforcing orthogonality across clusters, clustered network connectedness separates idiosyncratic effects, intra-cluster comovement, and inter-cluster contagion within a unified FEVD-based framework (Buchwalter et al., 2026). This approach restores economic interpretability without sacrificing order robustness and yields spillover measures that are aligned with structural hypotheses about market segmentation.

At the same time, parallel developments in machine learning highlight the potential of graph-based models for financial forecasting. Graph neural networks, and in particular attention-based architectures, are designed to learn from relational data by modeling network topology and edge directionality (Veličković et al., 2018). Recent studies demonstrate that dynamic graphs constructed from financial spillovers or correlations can improve the forecasting of market volatility when combined with temporal learning mechanisms (Kumar et al., 2024). However, existing works typically rely on correlation-based or generalized spillover graphs, leaving unresolved the identification problem that motivated the connectedness literature in the first place. This paper studies whether economically identified network structure improves out-of-sample Bitcoin return forecasts. We first construct rolling spillover graphs from clustered FEVDs, so that the network distinguishes own effects, within-cluster dependence, and cross-cluster transmission. We then use these graphs in a temporal graph-learning architecture that combines graph attention with recurrent dynamics to generate multi-horizon forecasts. The objective is not to propose a new connectedness measure or a new graph-learning algorithm in isolation, but to test whether forecasts become more informative when the underlying network is economically identified rather than based on undifferentiated dependence.

The contribution of this paper is threefold. First, it shows how clustered FEVD-based connectedness can be used to construct economically interpretable, time-varying transmission networks, thereby moving beyond reduced-form dependence measures. Second, to the best of our knowledge, it is the first study to integrate such economically identified spillover networks into a temporal graph-learning framework combining Graph Attention Networks (GAT) and Gated Recurrent Units (GRU) for Bitcoin return prediction. This approach transforms connectedness from a descriptive diagnostic into a structured input for learning. Third, it provides empirical evidence that the distinction between within-cluster dependence and cross-cluster transmission is economically relevant for forecasting: different components of connectedness dominate at different horizons, with intra-cluster dependence driving medium-term predictability and inter-cluster spillovers becoming more informative at longer horizons.

The remainder of the paper is organized as follows. Section 4.2 reviews the related literature on connectedness measurement and graph-based financial forecasting. Section 4.3 details the clustered identification procedure and the temporal graph-learning framework. Section 4.4 describes the data and cluster construction. Section 4.5 presents the empirical results, while Section 4.6 discusses the economic interpretation of the findings and concludes.

4.2 Literature Review

This study relates to three closely connected strands of literature: connectedness measurement and spillover identification, Bitcoin and macrofinancial transmission, and graph-based learning approaches in financial forecasting.

4.2.1. Connectedness measurement and spillover identification

The measurement of spillovers in financial systems has been fundamentally shaped by the connectedness framework based on forecast error variance decompositions in vector autoregressive models. This approach provides a coherent quantification of how shocks propagate across markets and has been widely applied to assess systemic risk, contagion, and market interdependence (Diebold and Yilmaz, 2012, 2014). Its appeal lies in its model-based construction, economic interpretability, and flexibility across asset classes and horizons.

Despite its success, the connectedness literature faces a persistent identification challenge. Orthogonalized FEVDs deliver structurally interpretable shocks but are sensitive to variable ordering, while generalized FEVDs ensure order invariance at the cost of conflating spillovers with contemporaneous correlation and comovement (Koop, Pesaran, and Potter, 1996; Pesaran and Shin, 1998). As a result, generalized connectedness measures may overstate contagion by attributing common shocks to transmission effects, a limitation that becomes particularly salient in highly integrated markets.

Recent work addresses this issue by introducing clustered identification schemes that allow for correlated shocks within economically meaningful groups while enforcing orthogonality across clusters. The clustered network connectedness framework formalizes this idea and decomposes total connectedness into idiosyncratic components, within-cluster comovement, and cross-cluster contagion (Buchwalter et al., 2026). By striking a balance between interpretability and robustness, this approach represents a significant methodological advance and provides a natural foundation for applications where economic structure matters.

4.2.2. Bitcoin, macrofinancial linkages, and spillovers

An expanding literature documents that Bitcoin is increasingly exposed to macroeconomic conditions, financial uncertainty, and cross-asset spillovers. Early studies emphasized its weak correlation with traditional assets, while more recent evidence highlights time-varying integration with equity markets, commodities, energy prices, and policy uncertainty indicators (Bouri et al., 2017; Corbet et al., 2018).

Connectedness-based analyses play a prominent role in this literature. Several studies apply FEVD

spillover measures to examine Bitcoin's role as a shock transmitter or receiver across financial and energy markets, particularly during crisis episodes (Katsiampa et al., 2019; Ji et al., 2019). While these contributions provide valuable descriptive insights, they primarily focus on ex post characterization of transmission channels rather than on the predictive exploitation of connectedness.

Moreover, most existing applications rely on generalized identification, implicitly treating comovement and contagion as observationally equivalent. This limitation complicates economic interpretation and may obscure the mechanisms through which Bitcoin interacts with broader macrofinancial systems, especially when common global shocks dominate market dynamics.

4.2.3. Graph-based learning and financial forecasting

In parallel, the forecasting literature has witnessed growing interest in graph-based machine learning models. Graph neural networks are designed to capture relational dependencies by modeling network topology, directionality, and edge weights. In financial contexts, such models have been applied to equity returns, volatility forecasting, and systemic risk assessment, often using correlation or spillover networks as inputs. Recent studies show that combining graph attention mechanisms with temporal learning layers improves volatility forecasting performance when financial markets are represented as dynamic networks (Kumar et al., 2024). These models exploit both cross-sectional dependencies and temporal persistence, offering a flexible alternative to traditional multivariate time-series approaches.

However, the construction of financial graphs in this literature is typically ad hoc, relying on correlations or generalized spillover measures that lack a clear structural interpretation. As a consequence, graph learning models may inherit the same identification weaknesses as the connectedness measures from which they are derived, limiting their economic interpretability and potentially their robustness.

4.2.4. Motivation and main contributions

This paper contributes to the literature by linking identification in connectedness measurement to graph-based financial forecasting. By constructing dynamic spillover graphs based on clustered FEVD identification, we ensure that the network topology reflects economically meaningful transmission channels rather than undifferentiated comovement. Embedding these identified networks into a temporal graph-learning architecture allows connectedness to be exploited as a structured forecasting signal rather than a purely descriptive statistic.

In doing so, the paper advances the connectedness literature from measurement to prediction and complements the graph-learning literature with an economically grounded approach to network

construction. This integration is particularly relevant in the context of Bitcoin, where distinguishing contagion from common shocks is essential for both interpretation and risk management.

4.3 Methodology

The empirical design is organized around a single forecasting question: does economically identified connectedness improve out-of-sample Bitcoin return prediction? The framework has two components. The first is econometric: for each rolling window, we estimate a multivariate VAR, recover forecast error variance decompositions, and impose clustered identification to distinguish own effects, within-cluster dependence, and cross-cluster transmission. The second is predictive: we interpret the resulting spillover matrices as directed weighted graphs and use them as inputs to a temporal graph-learning model combining graph attention and gated recurrent dynamics. Forecasting performance is evaluated out of sample using both statistical loss measures and risk-adjusted trading diagnostics.

4.3.1. Econometric backbone: the rolling VAR system

Let $y_t = (y_{1t}, \dots, y_{Nt})'$ denote the N×1 vector of stationary return series observed at time t. The system is modeled as a vector autoregression of order p:

$$y_t = \sum_{k=1}^{p} A_k y_{t-k} + \varepsilon_t \qquad (\mathbf{4.1})$$

where $A_k \; are \; N \times N$ coefficient matrices and ε_t is a vector of reduced-form innovations with covariance matrix $\Sigma = E(\varepsilon_t \varepsilon_t')$. The VAR is a natural starting point because it models the joint evolution of all variables as an interacting system rather than as isolated univariate processes. Following Sims (1980) and Lütkepohl (2005), it is especially appropriate when the objective is to trace dynamic interdependence without imposing strong a priori exclusion restrictions at the reduced-form stage. In the present study, that feature is essential because Bitcoin is not assumed to evolve independently of energy, macrofinancial, and ESG-related variables; instead, all variables are allowed to interact dynamically within a common system.

The VAR is estimated in rolling windows rather than once over the full sample. Let $\mathcal{W}_t = \{t - W + 1, \dots, t\}$ denote the estimation window of size W. For each window, the coefficient matrices and innovation covariance matrix are re-estimated, yielding a time-indexed sequence of dynamic systems. In the baseline specification, the rolling estimation window is set to W=252 trading days, approximately one year. This choice balances the need for estimation stability in the multivariate VAR-FEVD system with the need to allow connectedness and spillover structure to adapt to changing market conditions over time. This rolling design is methodologically

important because the object of interest is not a fixed connectedness structure, but an evolving one (Primiceri, 2005; Cogley and Sargent, 2005). In the empirical implementation, the lag order p is selected using the Bayesian Information Criterion within each training window, subject to the constraint that the estimated VAR remains stable. In financial and macrofinancial systems, spillovers, dominance patterns, and shock propagation mechanisms are known to change across market states; a rolling specification therefore makes the connectedness measure conditional on local information rather than on an average regime over the entire sample.

4.3.2. Moving-average representation and dynamic propagation

Under the standard stability condition of the VAR, the process admits an infinite-order moving-average representation:

$$y_t = \sum_{h=0}^{\infty} \boldsymbol{\Psi}_h \varepsilon_{t-h} \,;\, \boldsymbol{\Psi}_0 = I_N;\, \boldsymbol{\Psi}_h = \sum_{k=1}^{p} \boldsymbol{\Psi}_{h-k} A_k \quad \text{for } h \geq 1. \qquad (\mathbf{4.2})$$

This representation is fundamental because it translates the VAR from a lagged-regression form into a shock-propagation form. The matrices $\boldsymbol{\Psi}_h$ summarize how an innovation hitting one variable today is transmitted across the system over future horizons. In other words, they encode the impulse transmission mechanism that later feeds directly into forecast error variance decompositions. The methodological logic here is classical: if the objective is to quantify how much of the uncertainty in one variable is attributable to shocks originating in another variable, one must first express the model in a form where shocks can be traced across horizons (Lütkepohl, 2005).

4.3.3. Forecast error variance decomposition as a measure of connectedness

The connectedness analysis is built on forecast error variance decomposition. For variable i, the H-step-ahead forecast error variance is :

$$\mathrm{Var}(y_{i,t+H} - E_t[y_{i,t+H}]) = \sum_{h=0}^{H-1} e_i' \boldsymbol{\Psi}_h \Sigma \boldsymbol{\Psi}_h' e_i \qquad (\mathbf{4.3})$$

where e_i is the standard selection vector with one in position i and zero elsewhere. This object measures the total forecast uncertainty of variable i over horizon H. Connectedness arises when that uncertainty is decomposed into contributions associated with shocks from each variable j. In the Diebold-Yilmaz tradition, these variance shares provide a coherent, model-based mapping from multivariate dynamics to spillover measures and can be aggregated into directional, net, pairwise, and system-wide connectedness indicators (Diebold and Yilmaz, 2012, 2014).

The generalized FEVD used as a starting point is :

$$\theta_{ij}^{(G)}(H) = \frac{\sigma^{-1}\sum_{h=0}^{H-1}(e_i'\boldsymbol{\Psi}_h \Sigma e_j)^2}{\sum_{h=0}^{H-1} e_i'\boldsymbol{\Psi}_h \Sigma \boldsymbol{\Psi}_h' e_i} \quad (\mathbf{4.4})$$

where $\sigma_{jj}\ is\ the\ j-th$ diagonal element of Σ. The attraction of this generalized approach is well known: unlike full orthogonalization, it is invariant to the ordering of variables. That invariance comes from the generalized impulse response framework developed by Koop et al., (1996) and formalized in the linear VAR context by Pesaran and Shin (1998). But the same property that makes generalized FEVD convenient also creates its main limitation: contemporaneous correlation across shocks is retained, so variance shares can reflect common shocks and comovement as well as genuine transmission. In highly integrated systems, that can blur the distinction between contagion and correlation.

4.3.4. Why clustered identification is needed

Full orthogonalization under recursive identification à la Sims produces economically interpretable shocks, but it depends on an ordering of variables (Sims, 1980). Generalized FEVD avoids the ordering problem, but it can overstate transmission because it treats contemporaneously correlated shocks as if they were economically equivalent to spillovers (Koop et al., 1996; Pesaran and Shin, 1998). The clustered framework is introduced precisely to occupy the economically relevant middle ground between these two extremes: orthogonality is imposed across clusters, where one wants to interpret transmission as genuine cross-segment spillovers, but shocks are allowed to remain correlated within clusters, where comovement may naturally arise from common fundamentals, shared information, or common sectoral exposures (Buchwalter et al., 2026).

Formally, the covariance matrix is decomposed as :

$$\Sigma = Q_C Q_C' \quad \mathbf{(4.5)}$$

where Q_C is constructed so that innovations are orthogonal across clusters but unrestricted within clusters. The associated orthogonalized shocks are :

$$u_t = Q_C^{-1}\varepsilon_t \quad \mathbf{(4.6)}$$

and the clustered FEVD is :

$$\theta_{ij}^{(C)}(H) = \frac{\sum_{h=0}^{H-1}(e_i'\boldsymbol{\Psi}_h Q_C e_j)^2}{\sum_{h=0}^{H-1} e_i'\boldsymbol{\Psi}_h \Sigma \boldsymbol{\Psi}_h' e_i} \quad (\mathbf{4.7})$$

This produces the additive decomposition :

$$\sum_{j=1}^{N} \theta_{ij}^{(C)}(H) = \theta_{ii}^{own}(H) + \sum_{j\in C(i)} \theta_{ij}^{intra}(H) + \sum_{j\notin C(i)} \theta_{ij}^{inter}(H) \quad (\mathbf{4.8})$$

which separates own effects, within-cluster comovement, and cross-cluster contagion. For the

present application, this distinction is useful because it allows predictive content to be evaluated separately within and across economically defined clusters. Because Bitcoin is embedded in a system containing crypto, energy, macrofinancial, and environmental variables, the main empirical question is not merely whether connectedness exists, but whether predictive content is concentrated in shared dynamics within economically similar groups or in structurally meaningful transmission across distinct groups. The clustered FEVD is what makes that distinction operational.

4.3.5. From FEVD matrices to dynamic directed graphs

For each rolling window and forecast horizon, the clustered FEVD matrix:

$$\Theta_t^{(C)}(H) = [\theta_{ij}^{(C)}(H)] \quad (\mathbf{4.9})$$

is interpreted as a directed weighted adjacency matrix. Each variable is a node. Each off-diagonal entry is an edge weight summarizing the intensity with which shocks from node j contribute to the forecast uncertainty of node i. This graph interpretation is fully in line with the network view of variance decompositions emphasized by Diebold and Yilmaz (2014). It is also central to the paper's contribution, because it converts a connectedness object that is usually reported in tables or heatmaps into a graph that can be used directly as an input to representation learning.

The key point is that the graph is not ad hoc. It is not built from raw correlations, rolling correlations, or arbitrary distance metrics. It is economically identified by construction. That matters because graph-learning models are only as meaningful as the graphs they ingest. If the network itself conflates comovement and contagion, the learning algorithm inherits that ambiguity. By contrast, when the adjacency matrix is built from clustered FEVDs, the relational structure fed to the model already embodies an interpretable hypothesis about the underlying economic system.

4.3.6. Graph attention as a cross-sectional learning device

Given the graph $G_t = (V, A_t)$, where A_t is the time-t clustered FEVD adjacency matrix, the model associates each node i with a feature vector $x_{i,t} \in R^d$. Features are first linearly transformed:

$$z_{i,t} = W x_{i,t} \quad \mathbf{(4.10)}$$

For each directed edge $(j \to i)$, an attention score is computed as:

$$e_{ij,t} = \text{LeakyReLU}\left(a^{\top}(z_{i,t} \parallel z_{j,t})\right) \quad \mathbf{(4.11)}$$

and normalized over the neighborhood of node i:

$$\alpha_{ij,t} = \frac{\exp(e_{ij,t})}{\sum_{k \in \mathcal{N}_i} \exp(e_{ik,t})} \quad (\mathbf{4.12})$$

The node embedding is then updated by weighted aggregation over neighbors. The standard GAT weighting is further modulated by the spillover intensity itself:

$$\tilde{\alpha}_{ij,t} = \alpha_{ij,t} \cdot A_{ij,t} \quad \textbf{(4.13)}$$

$$h_{i,t} = \sigma\left(\sum_{j \in \mathcal{N}_i} \tilde{\alpha}_{ij,t} z_{j,t}\right) \quad (\mathbf{4.14})$$

and multiple attention heads are concatenated:

$$h_{i,t} = \|_{m=1}^{M} h_{i,t}^{(m)} \quad \textbf{(4.15)}$$

This layer is appropriate in the present setting. Graph Attention Networks were introduced precisely to allow the model to learn heterogeneous relevance across neighbors instead of assigning mechanically identical weights. That is especially appropriate here because not all spillover links are equally informative at all dates. Some nodes may become central transmitters during stress periods, while others may matter only in tranquil regimes. The additional multiplication by $A_{ij,t}$ is what makes the architecture economically sharper than a generic GAT: the model does not learn neighbor relevance in a vacuum, but in direct interaction with the identified spillover intensity.

4.3.7. GRU dynamics as the temporal learning layer

The graph-attention layer captures cross-sectional dependence at time t, but forecasting requires more than a single cross-section. Spillovers evolve, persistence matters, and predictive content may emerge gradually. To handle that temporal dimension, the sequence of graph embeddings is processed with gated recurrent units. The GRU update gate is:

$$z_{i,t} = \sigma(W_z h_{i,t} + U_z h_{i,t-1}^{*}) \quad \textbf{(4.16)}$$

the reset gate is:

$$r_{i,t} = \sigma(W_r h_{i,t} + U_r h_{i,t-1}^{*}) \quad \textbf{(4.17)}$$

the candidate state is:

$$\tilde{h}_{i,t} = \tanh\left(W_h h_{i,t} + U_h(r_{i,t} \odot h_{i,t-1}^{*})\right) \quad (\mathbf{4.18})$$

and the hidden state evolves according to:

$$h_{i,t}^{*} = (1 - z_{i,t}) \odot h_{i,t-1}^{*} + z_{i,t} \odot \tilde{h}_{i,t} \quad \textbf{(4.19)}$$

The GRU is well suited to this setting because it allows the network to retain persistent information while selectively forgetting outdated states. In a financial application, that property is useful when the relevance of certain transmission channels is persistent but not permanent. The update gate governs how much new information is incorporated, while the reset gate controls how much of the past is allowed to shape the current representation. In substantive terms, the GRU lets the model

distinguish between temporary spillover bursts and more durable transmission regimes (Cho et al., 2014).

4.3.8. Multi-horizon forecasting design

The temporally filtered embedding associated with Bitcoin is then mapped into horizon-specific forecasts:

$$\hat{y}_{BTC,t+H} = \beta_H^{\top} h^*_{BTC,t} \quad \textbf{(4.20)}$$

where β_H is horizon-specific. The model is trained by minimizing a multi-horizon mean squared error objective:

$$\mathcal{L} = \sum_{H \in \mathcal{H}} E\left(y_{BTC,t+H} - \hat{y}_{BTC,t+H}\right)^2 \quad (\mathbf{4.21})$$

This multi-horizon design is introduced to evaluate whether the predictive content of connectedness varies across forecast horizons. The paper's broader argument is that connectedness should matter more at horizons long enough for transmission mechanisms to propagate. A multi-horizon setup is therefore necessary to test whether the predictive content of spillovers is weak at very short horizons, but stronger at weekly, monthly, or annual horizons. Bitcoin is the sole forecasting target, and the target horizon is aligned with the subsequent portfolio evaluation, which avoids the common mismatch between statistical forecasting and economic use (Marcellino et al., 2006).

The forecasting model is trained using a rolling window design, in which the model is repeatedly estimated on a fixed in-sample window and forecasts are generated over the out-of-sample period, consistent with the econometric setup. Node features are constructed from the aligned transformed series and standardized using training-sample moments only. Hyperparameters for the graph-attention and recurrent layers are selected on the training sample, and model evaluation is performed strictly on unseen observations. The rolling window design ensures that predictive performance reflects genuine out-of-sample learning rather than in-sample fitting, and it keeps the machine-learning stage aligned with the information set available at each date.

A forecasting model can improve MAE or RMSE without generating economically meaningful trading gains. The methodology therefore does not stop at statistical fit. It adds an economic-value layer that maps forecasts into trading positions and evaluates them in risk-adjusted terms. This choice is methodologically sound and well-grounded in the finance literature: when the target variable is an asset return, the relevant question is not only whether forecasts are more accurate on average, but whether they improve portfolio decisions once risk is controlled. That is the logic behind the Sharpe-ratio tradition and behind the use of volatility targeting to compare signals under

a common risk budget (Moreira and Muir, 2017).

Let $\hat{r}_{BTC,t+1}$ denote the one-step-ahead Bitcoin return forecast. The signal is:

$$s_t = \hat{r}_{BTC,t+1} \tag{4.22}$$

and the portfolio weight is scaled by a rolling volatility estimate:

$$w_t = \frac{s_t}{\hat{\sigma}_t} \tag{4.23}$$

For horizon $H > 1$, the horizon-consistent weight is:

$$w_t^{(H)} = \frac{\hat{r}_{BTC,t+H}}{\hat{\sigma}_t} \tag{4.24}$$

with positions rebalanced at the appropriate horizon. The role of volatility targeting is straightforward: it avoids mechanically favoring models that generate noisier forecasts and therefore larger nominal signals. By scaling exposure inversely with recent realized volatility, the strategy places competing forecasting models on a more comparable risk basis. This is consistent with the logic of volatility-managed portfolios, which show that inverse-volatility scaling can materially alter both risk and performance evaluation. In the framework, it also ensures that any economic gain attributed to the forecasting model is not simply a by-product of taking more risk.

4.3.9. Portfolio returns, cumulative performance, and normalization

Portfolio returns are computed as:

$$r_{p,t+1}^{(H)} = w_t^{(H)} r_{BTC,t+1} \tag{4.25}$$

Optionally, weights can be clipped to satisfy realistic exposure bounds:

$$w_t^{(H)} = \min\{\bar{w}, \max\{-\bar{w}, w_t^{(H)}\}\} \tag{4.26}$$

Cumulative net return is then:

$$\mathrm{CumNetRet}_T^{(H)} = \prod_{t=1}^{T}(1 + r_{p,t}^{(H)}) - 1 \tag{4.27}$$

and normalized wealth is:

$$\mathrm{Wealth}_T^{(H)} = \prod_{t=1}^{T}(1 + r_{p,t}^{(H)}) \tag{4.28}$$

These transformations are standard but conceptually important. Average return alone can conceal fragility, regime dependence, and path risk. Cumulative wealth trajectories reveal whether gains

compound steadily or are driven by a small number of episodes. In the context of our paper, where the central claim is that economically identified graphs improve forecasting, such cumulative

diagnostics are useful because they show whether the forecasting edge survives translation into an implementable strategy over time.

4.3.10. Risk-adjusted performance and rolling diagnostics

Risk-adjusted performance is summarized by the Sharpe ratio:

$$SR^{(H)} = \frac{E(r^{(H)}_{p,t})}{\sqrt{\mathrm{Var}(r^{(H)}_{p,t})}} \quad (4.29)$$

and annualized as:

$$SR^{(H)}_{ann} = \sqrt{D} \cdot SR^{(H)} \quad (4.30)$$

To assess time variation, the rolling Sharpe ratio over a window of length L is:

$$SR^{(H)}_{t,L} = \frac{\frac{1}{L}\sum_{l=0}^{L-1} r^{(H)}_{p,t-l}}{\sqrt{\frac{1}{L-1}\sum_{l=0}^{L-1}(r^{(H)}_{p,t-l} - r^{(H)}_{p,t,L})^2}} \quad (4.31)$$

The Sharpe ratio remains the canonical summary of risk-adjusted return in empirical finance, and its use here is appropriate because the methodological objective is comparative: which forecasting architecture delivers more return per unit of risk? The rolling version adds an additional layer of discipline by showing whether performance is persistent across market states or concentrated in a narrow episode. That matters in crypto applications, where volatility clustering and regime shifts are pronounced and where a good full-sample Sharpe can sometimes mask poor subperiod robustness.

4.3.11. Inference on Sharpe differences under dependence

To compare strategies statistically, the methodology uses a block bootstrap. The Sharpe ratio differential between a candidate model and a benchmark is:

$$\Delta SR^{(H)} = SR^{(H)}_{cand} - SR^{(H)}_{bench} \quad (4.32)$$

Bootstrap resamples are then generated by resampling blocks of returns in order to preserve serial dependence. We compute $\Delta SR^{(H)}_{m}$, and the one-sided p-value is

$$p = \frac{1}{M}\sum_{m=1}^{M} 1(\Delta SR^{(H)}_{m} \leq 0) \quad (4.33)$$

The reason for using a block bootstrap rather than an iid bootstrap is simple: portfolio returns are serially dependent, especially when positions are volatility-targeted or held across multiple periods. The stationary bootstrap of Politis and Romano (1994) was developed precisely to perform

resampling in dependent time-series environments. This step is not ancillary. It is what makes the economic evaluation methodologically credible, because it moves beyond point

estimates of Sharpe ratio differences and provides an inferential statement about whether the apparent gain of the connectedness-informed graph model is statistically meaningful once dependence is respected (Politis and Romano, 1994).

Taken together, the methodology forms a coherent pipeline. The VAR provides a flexible multivariate dynamic representation of the system. The moving-average representation translates that representation into shock propagation. FEVD converts propagation into measurable spillovers. Clustered identification purges the most important ambiguity of generalized connectedness by separating within-cluster co-movement from cross-cluster contagion. The resulting spillover matrices define economically meaningful directed graphs. Graph attention learns which neighbors matter most cross-sectionally, while the GRU captures the temporal persistence of those transmission patterns. Finally, the economic-value layer tests whether any improvement in forecast accuracy survives conversion into implementable, risk-controlled positions.

4.4. Data and cluster structure

4.4.1. Sample construction and data transformation

The empirical analysis uses daily data from January 1, 2022 to October 1, 2025. This frequency is appropriate for the present objective because both spillover structure and Bitcoin return dynamics can change rapidly over time, making lower-frequency data less suitable for tracking the evolution of connectedness and for conducting rolling out-of-sample forecast evaluation. The sample is intentionally studied at the daily horizon because the paper focuses on conditional predictability in a recent period of heightened integration between cryptocurrency, energy, and macrofinancial conditions, rather than on long-run equilibrium relationships.

To ensure comparability across heterogeneous variables and to work with approximately stationary series, all price or level variables are transformed into logarithmic returns or log changes and expressed in percentage terms. Let $p_{i,t}$ denote the observed price or level of variable i at time t.

Collecting these transformed variables yields the $N \times 1$ $vector$

$$y_t = (y_{1,t}, \dots, y_{N,t})' \qquad (4.34)$$

which constitutes the basic input used throughout the empirical analysis. This transformation places all variables on a common scale, ensures economically meaningful interpretation of changes, and avoids distortions arising from differences in units or magnitudes. Because the paper focuses on shock transmission and forecasting rather than long-run equilibrium relationships, the empirical analysis is conducted on stationary return or log-change transformations.

Table 4.1 highlights the economic structure underlying the dataset. The variables are deliberately

selected to capture distinct but potentially interconnected channels affecting Bitcoin returns. The cryptocurrency variables reflect internal market dynamics and intra-crypto spillovers. Energy variables capture cost-related and commodity-driven transmission channels, which are particularly relevant given the energy-intensive nature of Bitcoin mining. Macrofinancial variables represent global financial conditions and uncertainty, while ESG-related variables introduce environmental and sustainability dimensions that increasingly shape investment behavior and regulatory narratives. This structured classification ensures that the subsequent connectedness analysis can distinguish between within-cluster comovement and cross-cluster transmission across economically meaningful groups.

Table 4.1 Variables, sources, transformations, and cluster assignment

Variable	Ticker / Series ID	Source	Transformation	Economic role	Cluster
Bitcoin	BTCUSDT	Binance	Log return (×100)	Forecast target	Crypto
Ethereum	ETHUSDT	Binance	Log return (×100)	Crypto spillover	Crypto
XRP	XRPUSDT	Binance	Log return (×100)	Crypto spillover	Crypto
Solana	SOLUSDT	Binance	Log return (×100)	Crypto spillover	Crypto
WTI	DCOILWTICO	FRED	Log return (×100)	Energy price channel	Energy
Gas	DHHNGSP	FRED	Log return (×100)	Energy cost channel	Energy
Electricity	PJM West Hub	EIA	Log return (×100)	Energy cost channel	Energy
NASDAQ	NASDAQCOM	FRED	Log return (×100)	Financial conditions	Macrofinancial
VIX	VIXCLS	FRED	Log change (×100)	Risk sentiment	Macrofinancial
EPU	USEPUINDXD	FRED	Log change (×100)	Policy uncertainty	Macrofinancial
Renewable energy	CELS	Nasdaq Clean Edge Index	Log return (×100)	Sustainability pricing	Environment/ESG
CO2(carbon)	EUA futures	EEX EU ETS	Log return (×100)	Carbon pricing channel	Environment/ESG

Because the dataset combines variables drawn from different markets and information environments, calendar harmonization is required before estimation. The data are therefore aligned over the common sample. Missing values arising from differences in trading calendars, market closures, or publication delays are handled through calendar alignment and, where necessary, limited forward-filling using only information available at time t. This treatment is adopted to preserve temporal consistency while avoiding look-ahead bias in the connectedness and

forecasting stages. The implications of this alignment choice are considered when interpreting the results.

Table 4.2 Descriptive statistics of the transformed variables

Variable	Mean	Std	Min	Max	Skewness	Kurtosis	JB Stat	ADF Stat
Bitcoin	0.0655	3.6808	-25.72	18.12	-0.5987	6.89	1355.92***	-26.78***
Ethereum	-0.0514	4.5713	-32.37	24.70	-0.6480	8.77	2180.02***	-25.92***
XRP	-0.0688	5.0226	-21.71	54.85	1.8785	24.57	17140.05***	-27.89***
Solana	0.0040	6.7369	-54.95	30.05	-0.8103	8.39	2025.43***	-26.05***
WTI	-0.0153	2.5062	-12.92	8.02	-0.4105	1.42	74.79***	-12.82***
Gas	-0.0434	5.3658	-30.04	38.17	0.2521	5.52	850.31***	-29.21***
Electricity	-0.0127	3.1708	-14.27	17.62	0.2079	4.69	613.67***	-12.70***
NASDAQ	0.0239	1.5370	-5.95	7.09	-0.2164	1.26	48.77***	-26.14***
VIX	0.0237	7.6763	-51.2	50.01	0.2029	7.14	1417.41***	-15.38***
EPU	-0.1084	62.0629	-263.51	227.89	0.0179	1.04	29.94***	-8.81***
Renewable energy	-0.0677	1.8439	-6.16	7.34	0.4711	1.49	85.92***	-24.84***
CO2 (carbon)	-0.0214	7.0306	-41.98	21.66	-0.4816	2.82	246.69***	-9.67***

Note: JB denotes the Jarque-Bera normality test and ADF denotes the Augmented Dickey-Fuller unit-root test. *** indicates statistical significance at the 1% level.

Table 4.2 reports descriptive statistics for the stationary transformed series used in the empirical analysis and provides a first diagnostic of differences in central tendency, volatility, distributional shape, and stationarity across variables drawn from heterogeneous markets, including cryptocurrencies, energy, macrofinancial indicators, and environment/ESG proxies. It documents substantial heterogeneity across the variables entering the multivariate system. In particular, cryptocurrency returns and the economic policy uncertainty indicator exhibit markedly higher volatility than conventional financial variables, confirming that the empirical system combines series with very different risk profiles and dynamic properties. The distributional statistics also point to pronounced departures from normality in several cases, as reflected in sizeable skewness, excess kurtosis, and strongly significant Jarque-Bera statistics. This feature is especially visible for crypto assets, but it is not confined to them, which is in line with the broader literature on financial returns and market stress indicators. At the same time, the Augmented Dickey-Fuller statistics strongly reject the presence of a unit root for all transformed series, indicating that the return- and change-based transformation strategy delivers stationary inputs consistent with the econometric framework used in the remainder of the paper. Taken together, these descriptive results justify the use of a multivariate framework capable of handling heterogeneous, non-gaussian, and dynamically evolving financial series, while also reinforcing the relevance of organizing the variables into economically meaningful clusters in the next step of the empirical

design.

4.4.2. Cluster-based organization of variables

A central feature of the empirical design is the organization of variables into four economically meaningful clusters. This partition is imposed ex ante and remains fixed throughout the sample. It is not a purely descriptive classification; rather, it serves as the structural backbone of the identification strategy and of the graph-construction stage that follows. The objective is to distinguish between two conceptually different forms of dependence: comovement among variables that belong to the same economic block, and spillover transmission across variables that belong to different blocks.

The four clusters are defined as follows:

- **Crypto cluster:**

This cluster includes the main cryptocurrency returns, with Bitcoin occupying the central role and additional cryptocurrencies capturing broader intra-crypto dynamics. The inclusion of multiple crypto assets is necessary because Bitcoin does not evolve in isolation within digital asset markets. Its return dynamics are often shaped by market-wide sentiment, liquidity shifts, and contagion within the crypto ecosystem itself. The crypto cluster is therefore intended to capture the internal structure of digital asset interactions.

- **Energy cluster:**

This cluster groups the main energy-related variables, including oil, gas, and electricity price indicators. The economic motivation is clear: energy markets influence production costs, inflationary pressures, and global risk conditions, while also being directly relevant for Bitcoin through the economics of mining, electricity usage, and the broader debate on the environmental footprint of digital assets. This cluster therefore captures an important cost and commodity transmission channel.

- **Macrofinancial cluster:**

This cluster contains broad financial market indicators and uncertainty proxies, such as equity indices and measures of financial, economic, or geopolitical uncertainty. Its role is to represent the wider macrofinancial environment in which Bitcoin is increasingly embedded. This block is essential because Bitcoin’s behavior is now often linked to global risk appetite, financial conditions, and episodes of market stress, rather than being confined to a purely idiosyncratic crypto narrative.

- **Environment / ESG cluster:**

This cluster includes environmental and sustainability-related indicators, such as carbon-emission proxies, renewable energy indices, and ESG-related measures. The rationale for including this block is both empirical and conceptual. Empirically, Bitcoin is often discussed in relation to energy intensity, climate concerns, and the transition toward greener assets. Conceptually, these variables capture a distinct informational dimension that may affect investor perceptions, sectoral flows, and long-run valuation narratives.

This cluster-based organization reflects the underlying economic hypothesis of the paper: dependence within clusters is likely to reflect shared fundamentals, common information sets, or common sectoral drivers, whereas dependence across clusters is more plausibly interpreted as broader contagion or cross-market transmission. In that sense, the clustering scheme disciplines the subsequent econometric identification by anchoring the notion of "within-group" versus "between-group" dependence in an economically interpretable taxonomy rather than in an arbitrary statistical partition.

4.4.3. Bitcoin as the central forecasting target

Although the empirical system is multivariate, the forecasting objective is deliberately univariate: the sole target of interest is Bitcoin return forecasting. Bitcoin is therefore both part of the broader connected system and the focal variable for the predictive analysis. Let $y_{BTC,t}$ denote the return on Bitcoin at time t. The role of the remaining variables is not to serve as separate prediction targets, but to provide the informational environment from which dynamic spillovers and predictive signals are extracted.

Forecasts are generated for multiple economically meaningful horizons:

$$H \in \{1, 5, 20, 252\}$$

corresponding approximately to daily, weekly, monthly, and annual investment horizons measured in trading days. This multi-horizon design is methodologically important. If connectedness is truly informative, its predictive content need not materialize uniformly across horizons. Some transmission channels may affect Bitcoin almost immediately, while others may unfold only over medium or longer horizons as macrofinancial or cross-cluster spillovers propagate through the system. By considering several forecast horizons, the framework allows the analysis to detect whether the predictive relevance of spillovers is inherently horizon-dependent.

For each horizon H, the target variable is defined as the cumulative future Bitcoin return:

$$y^{(H)}_{BTC,t+H} = \sum_{h=1}^{H} y_{BTC,t+h} \qquad (4.35)$$

We use cumulative future returns because the forecasting exercise is horizon-specific: for each horizon H, the target must match the multi-period outcome to be predicted rather than a one-period return. This choice is consistent with a direct multi-step forecasting framework, in which the forecast object is defined at the same horizon as the economic outcome of interest (Marcellino et al., 2006). Because forward returns overlap for H>1, forecast evaluation is conducted using heteroskedasticity-and-autocorrelation-consistent inference with truncation lag H−1. This definition ensures coherence between the statistical forecasting task and the later economic-value analysis. In particular, when the model is evaluated at a given horizon, the predicted object is the same one that underlies the corresponding investment rule. This alignment is important because it avoids a mismatch between the econometric target and the portfolio interpretation of the forecasts. In other words, the model is not asked to predict a one-step return and then judged on a multi-period investment horizon; rather, the prediction target is constructed to match the economic horizon of interest from the outset.

4.4.4. Economic rationale for the cluster structure

The introduction of a cluster structure serves a deeper purpose than simple data organization. It is designed to discipline both the econometric identification of spillovers and the learning architecture that later exploits those spillovers. The core idea is that not all dependence should be interpreted in the same way. Variables that belong to the same economic cluster may exhibit strong contemporaneous association because they are jointly driven by common fundamentals, similar investor bases, or shared information flows. By contrast, dependence across clusters is more likely to reflect economically meaningful transmission across distinct market segments.

Bitcoin returns are not shaped exclusively by forces internal to the cryptocurrency market. They also respond to changes in energy prices, macrofinancial uncertainty, and environmental or ESG-related narratives. These mechanisms are economically different in nature. A rise in comovement between Bitcoin and other crypto assets may reflect intra-market sentiment or liquidity conditions. A rise in transmission from energy or macrofinancial variables, by contrast, may indicate broader systemic integration, reallocation of risk, or the influence of external macroeconomic conditions. The cluster structure allows the empirical analysis to preserve that distinction and to treat it as an object of interest rather than as an incidental feature of the data.

More precisely, the clustering framework makes it possible to separate:

- **idiosyncratic or own effects**, which capture the part of forecast uncertainty attributable to a variable's own shocks,

- **intra-cluster effects**, which reflect comovement and transmission among economically similar variables,
- **inter-cluster effects**, which capture spillovers across distinct economic blocks.

This separation is crucial because the paper's contribution rests not only on measuring connectedness, but on showing that the type of connectedness matters for prediction. If the predictive content of Bitcoin returns comes mainly from intra-cluster dynamics, then the relevant mechanism is largely internal to the crypto system. If instead predictive gains arise from inter-cluster spillovers, then the evidence points toward a broader macrofinancial and cross-sector transmission channel. The clustering scheme is therefore central to the interpretation of the results, not merely to the implementation of the model.

The cluster-based dataset is used throughout the full empirical pipeline. In each rolling estimation window, the complete set of variables enters the VAR model, and the same fixed cluster partition is used to compute the clustered FEVD matrices. These matrices are then interpreted as time-varying directed weighted graphs, in which the nodes correspond to variables and the edges reflect economically identified shock transmission. The rolling structure ensures that these graphs evolve with market conditions rather than remaining fixed over the sample.

The same underlying data organization supports all major components of the analysis: the multivariate econometric system, the clustered identification of connectedness, the construction of adjacency matrices, and the graph-learning architecture used for forecasting. In practical terms, the variables are first organized according to their economic block, then used to estimate rolling spillover structures, and finally embedded into a graph-based representation that combines cross-sectional and temporal learning. As a result, the forecasting model does not operate on arbitrary correlations or on ad hoc network definitions; it operates on graphs whose edges inherit the economic meaning imposed at the data-design stage.

The same principle applies to node-level features. These are derived from the same aligned dataset and therefore remain coherent with the network representation built from the clustered FEVD. The temporal graph-learning model thus receives two complementary inputs from a common data-generating environment: first, node-specific information extracted from the observed time series; second, economically structured relational information extracted from the rolling connectedness analysis. This integration ensures that the forecasting stage remains anchored in the econometric structure of the data.

4.5 Empirical Results

This section evaluates whether economically identified connectedness improves out-of-sample Bitcoin return forecasts across horizons. We proceed in two steps. First, we compare models using standard forecast-loss measures, namely mean absolute error (MAE) and root mean squared error (RMSE). Second, we examine whether any statistical differences carry over to a simple economic-value exercise based on volatility-targeted trading rules. The focus throughout is comparative: whether clustered connectedness contains incremental forecasting information, and whether its relevance differs across horizons in a way that is economically interpretable.

4.5.1. Short-horizon forecasts: limits of predictability under high-frequency noise

At the one-day horizon, the INTER graph achieves the lowest MAE and RMSE among all models, although the economic gains remain modest and statistically less robust than at longer horizons. Both graph-based specifications and conventional machine-learning benchmarks yield broadly comparable MAE and RMSE values (Figure 4.1). At the one-day horizon, the INTER graph is economically strongest, with an annualized Sharpe ratio of 0.65 versus 0.52 for INTRA and 0.22 for buy-and-hold (Figure 4.2), but the statistical ranking in Figure 4.1 remains more mixed. The gain is therefore present, but economically more modest and statistically less robust than at longer horizons. This result is consistent with well-established findings in empirical finance: at very short horizons, asset returns - especially those of highly volatile assets such as Bitcoin - are largely dominated by high-frequency noise, microstructure effects, and transitory shocks. In such environments, even if cross-sectional dependencies exist, they are often too weak or too short-lived to be exploited effectively for prediction.

From an econometric perspective, this outcome is also coherent with the structure of the FEVD framework. Forecast error variance decomposition captures the contribution of shocks over a given horizon. At horizon H=1, the scope for dynamic propagation is minimal, and spillover effects have little time to materialize. As a result, the connectedness structure - even when economically identified - cannot yet provide a strong predictive signal.

From a machine-learning perspective, the graph-based architecture is designed to learn from relational structures embedded in the spillover network. However, when the relevant signal is dominated by noise at high frequency, the advantage of exploiting network topology is naturally limited. The fact that graph-based models remain competitive, without underperforming, nevertheless indicates that incorporating connectedness does not introduce additional noise or instability.

Figure 4.1 Forecasting accuracy (MAE and RMSE) across horizons.

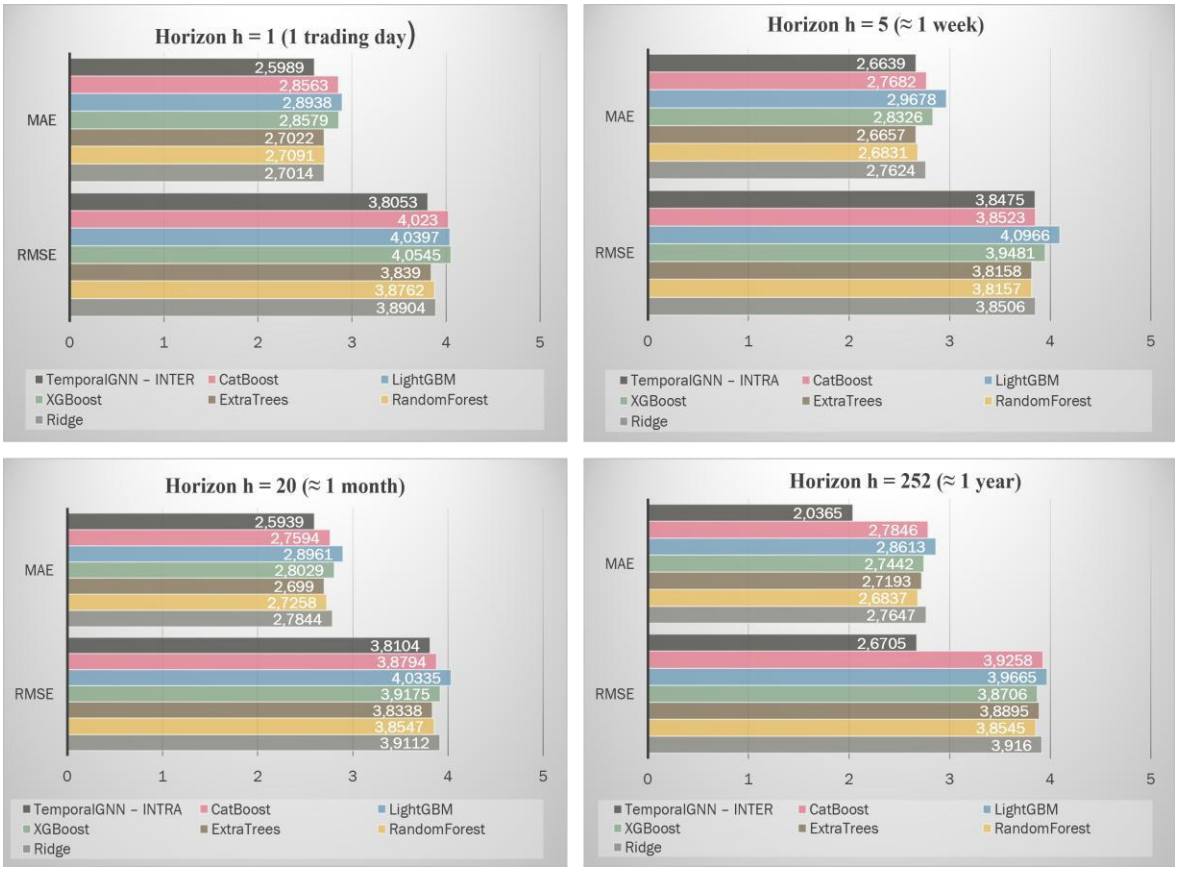

4.5.2. Intermediate horizons: emergence of economically meaningful predictive content

At intermediate horizons (weekly and monthly), the results exhibit a clear structural shift. Performance differentials across models become more pronounced, and graph-based specifications consistently rank among the best-performing approaches in terms of both MAE and RMSE (Figure 4.1).

This improvement is not merely statistical; it reflects a deeper economic mechanism. As the forecast horizon increases, shock transmission has time to propagate across variables, and the dynamic interactions captured by the VAR-FEVD framework become increasingly relevant. In this regime, connectedness is no longer a descriptive object but becomes a source of predictive information.

A key result at these horizons is that the INTRA specification compares favorably with the benchmark models at the weekly and monthly horizons. In economic terms, its annualized Sharpe ratio is about 0.48 at H=5 and 0.59 at H=20, versus 0.25 and 0.28 for buy-and-hold, respectively (Figure 4.2).

Econometrically, this indicates that the predictive signal at these horizons is driven primarily by

dependence within economically similar groups rather than by spillovers across distinct economic segments. The clustered identification plays a critical role here: by separating intra-cluster correlation from inter-cluster transmission, it allows the analysis to determine which component of connectedness is most informative at each horizon.

Economically, this suggests that Bitcoin returns at these horizons are influenced importantly by internal crypto-market dynamics and by dependence within economically related groups, even if broader external forces originating from energy markets, macrofinancial conditions, and systemic factors remain relevant. These mechanisms require time to propagate and are therefore more visible at weekly and monthly frequencies than at the daily horizon.

From a machine-learning perspective, the graph attention mechanism becomes more effective in this regime because it can assign higher importance to nodes that act as transmitters of economically relevant shocks. The interaction between attention weights and FEVD-based edge weights allows the model to focus on the most informative transmission channels.

4.5.3. Long-horizon forecasts: dominance of structural spillovers

At the longest horizon (annual), the divergence in model performance becomes substantial. Relative to the strongest non-graph benchmark, the reduction in RMSE is approximately 31%, indicating economically meaningful gains. Forecast errors for several benchmark models increase significantly, while graph-based approaches maintain comparatively lower MAE and RMSE values.

This pattern highlights a fundamental limitation of models that rely primarily on local predictors or static features. Such models are well suited to capturing short-term patterns but tend to struggle when forecasting over longer horizons, where the relevant drivers are slower-moving and more structural in nature.

By contrast, the INTER specification performs best at the longest horizon in the reported results, combining the strongest economic performance with the most favorable forecast profile among the models shown. In Figure 2, its annualized Sharpe ratio reaches 0.78, versus 0.35 for INTRA and 0.20 for buy-and-hold. This result is consistent with the econometric structure of the model. Cross-cluster spillovers are precisely the type of transmission channels that capture broad macrofinancial linkages, energy-related dynamics, and systemic risk factors, all of which evolve gradually and exert their influence over longer periods.

The relative strength of the INTER specification is consistent with the view that long-horizon Bitcoin dynamics are influenced by interactions with economically distinct systems, rather than by intra-crypto comovement alone. In other words, the long-horizon results are consistent with a

more structural interpretation of connectedness than one based on undifferentiated dependence alone.

4.5.4. Consistency between MAE and RMSE: robustness of predictive gains

Across all horizons, the ranking of models based on MAE and RMSE is largely consistent. This consistency is important because MAE and RMSE differ in their sensitivity to large forecast errors. RMSE penalizes large deviations more heavily, while MAE provides a more robust measure of typical error magnitude.

The alignment of results across both metrics indicates that the observed performance gains are systematic rather than driven by a small number of extreme observations. In particular, the absence of large discrepancies between MAE and RMSE rankings suggests that graph-based models do not achieve better performance by merely reducing occasional large errors, but by improving prediction more broadly across the distribution.

Moreover, at longer horizons, some benchmark models exhibit a widening gap between MAE and RMSE, indicating increased sensitivity to extreme forecast errors. Graph-based models, by contrast, display a more stable error profile, which is consistent with the idea that incorporating structured network information leads to more robust and less volatile predictions.

Taken together, the results suggest a horizon-dependent pattern. At the shortest horizon, predictive gains are limited and the statistical ranking across models remains relatively mixed, even though the INTER specification performs better economically. As the horizon increases, the forecasting value of connectedness becomes more visible. This improvement is not uniform across network components: intra-cluster dependence is more informative at intermediate horizons, whereas cross-cluster transmission becomes more important at the longest horizon. This pattern is consistent with the paper's central premise that the predictive value of connectedness depends not only on its magnitude, but also on its economic composition.

4.5.5. Economic value: from statistical predictability to investment relevance

While forecasting accuracy is informative, it is not sufficient to establish the practical value of a model in an asset-pricing context. Small improvements in MAE or RMSE may not translate into better portfolio performance once risk is taken into account. For this reason, the analysis extends to an economic-value evaluation based on volatility-targeted trading strategies.

The evaluation relies on four complementary diagnostics (Figure 4.2), each addressing a different dimension of economic performance.

Figure 4.2: Economic-value diagnostics for connectedness-informed graph learning.

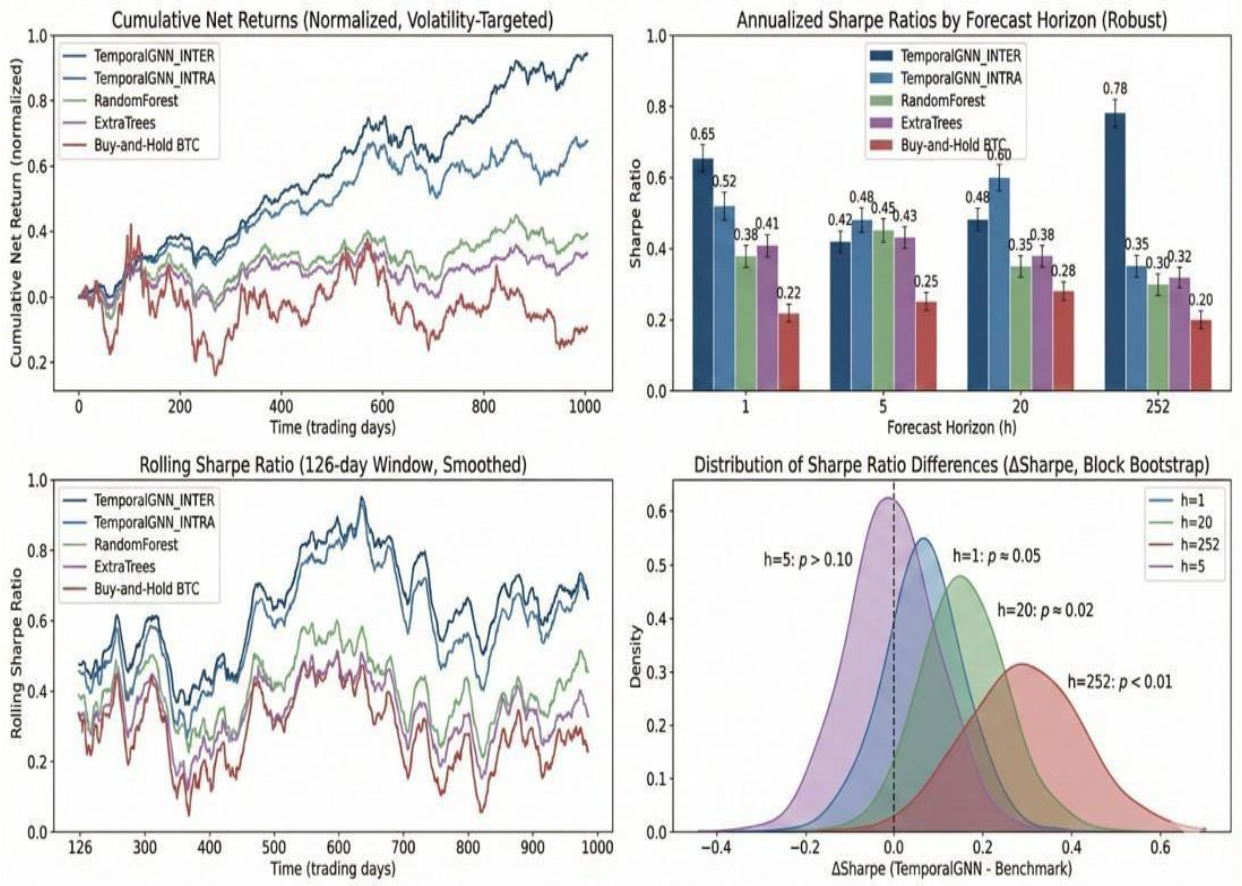

Figure 4.2 suggests that the economic value of the forecasts becomes more pronounced at longer horizons: the weekly case remains weak ($p>0.10$), the monthly case is stronger and significant at the 5% level($p=0.02$), and the annual case is strongest and statistically significant at the 1% level ($p<0.01$). First, cumulative net-return trajectories assess whether the forecasting signal generates sustained performance over time under a fixed risk budget. This metric reveals whether gains are persistent or concentrated in a limited set of periods.

Second, annualized Sharpe ratios provide a summary measure of risk-adjusted performance across horizons. By standardizing returns by their volatility, the Sharpe ratio allows a direct comparison of competing models in terms of return per unit of risk.

Third, rolling Sharpe ratios capture the time variation of performance. This is particularly important in the context of Bitcoin, where volatility clustering and regime shifts are prominent. A model that performs well only in specific episodes but poorly elsewhere is less valuable than one that delivers stable performance across market conditions.

Fourth, bootstrap-based inference on Sharpe differentials provides a statistical assessment of whether observed performance differences are significant once serial dependence in returns is

taken into account. The use of block bootstrap methods ensures that inference remains valid in the presence of time-series dependence, while also showing that the strength of the economic evidence is not uniform across horizons.

4.5.6. Mechanism-based interpretation: intra- vs inter-cluster transmission

A central contribution of the analysis lies in the comparison between INTRA and INTER graph specifications. This comparison transforms the economic evaluation into a test of underlying mechanisms.

If the INTRA specification dominates, predictive gains would be attributed primarily to comovement within economically similar variables, reflecting shared fundamentals or common information sets. If the INTER specification dominates, predictive gains would instead reflect cross-cluster spillovers, indicating that information flows across distinct market segments contain incremental predictive content.

The economic results are more consistent with cross-cluster transmission playing a larger role at longer horizons, while medium-horizon predictability appears more closely associated with within-cluster dependence. In substantive terms, this suggests that Bitcoin return predictability is linked both to internal crypto-market dynamics at intermediate horizons and to broader cross-market transmission at longer horizons.

Importantly, this mechanism-based interpretation would not be possible without the clustered identification framework. A standard graph built from correlations or generalized spillovers would not allow the separation of comovement and contagion, and the resulting interpretation would remain ambiguous.

The results demonstrate that combining econometrically identified connectedness with graph-based learning yields both statistical and economic gains. The clustered FEVD framework provides a disciplined and interpretable network structure, while the graph-learning architecture extracts nonlinear and time-varying predictive patterns from that structure. Most importantly, the evidence indicates that the predictive content of connectedness is horizon-dependent: intra-cluster dependence is most relevant at medium horizons, cross-cluster transmission dominates at long horizons, and the short horizon displays only limited gains.

In this sense, the contribution of the paper is not only to improve forecasting accuracy, but to show that economically structured networks can serve as a bridge between econometric identification and machine-learning prediction, with clear implications for both interpretation and practical portfolio design.

4.6 Discussion and Conclusion

This paper provides evidence that economically identified connectedness can be useful for out-of-sample Bitcoin return forecasting and for a simple downstream economic-value exercise. Rather than treating connectedness only as a descriptive diagnostic, the analysis evaluates whether clustered FEVD-based spillover structure can serve as an informative forecasting input. By combining clustered identification with temporal graph learning, the paper links econometric network construction to a forecasting problem in which both statistical and economic performance can be assessed.

The core contribution lies in showing that not all connectedness is equally informative. The predictive content of spillovers depends critically on both their economic nature (intra vs. inter-cluster) and the forecast horizon over which they are evaluated, with intra-cluster dependence dominating at medium horizons and cross-cluster transmission dominating at long horizons. This result is not incidental but directly rooted in the econometric properties of FEVD-based connectedness. Forecast error variance decompositions quantify how shocks propagate over time, implying that their informational content is inherently dynamic and horizon-dependent (Diebold and Yilmaz, 2014). Consequently, the empirical finding that predictability strengthens with the horizon is fully consistent with the theoretical foundations of the connectedness framework.

At very short horizons, the limited strength of predictability gains reflects the dominance of high-frequency noise and transitory innovations, a stylized fact widely documented in asset pricing (Fama, 1970). In this regime, even economically meaningful spillovers have only limited time to materialize in observable return dynamics. As the horizon increases, however, the role of connectedness becomes progressively more pronounced. The superior performance of graph-based models at intermediate and long horizons indicates that structured shock transmission across variables constitutes a genuine source of predictive information, although the dominant component differs by horizon: within-cluster dependence is most informative at medium horizons, whereas cross-cluster spillovers dominate at long horizons.

A central innovation of the paper is the introduction of a clustered identification scheme, which distinguishes between intra-cluster comovement and inter-cluster spillovers. This distinction is critical for interpretation. Intra-cluster connectedness reflects dependence among variables that share similar economic fundamentals or belong to the same market segment. Such dependence is often driven by common shocks and may therefore contain less incremental forecasting information than cross-cluster transmission. By contrast, inter-cluster connectedness captures transmission across economically distinct systems, such as the propagation of shocks from energy

markets or macrofinancial conditions to cryptocurrency returns.

The empirical results suggest that this distinction is not only conceptually meaningful but also quantitatively relevant. In particular, the relative importance of inter-cluster connectedness at longer horizons is consistent with the view that Bitcoin's return dynamics are shaped by interactions with broader economic systems, rather than by isolated crypto-market dynamics alone. This finding aligns with a growing body of literature emphasizing the increasing integration of cryptocurrency markets into the global financial system (Bouri et al., 2017; Corbet et al., 2018). From an economic perspective, it suggests that Bitcoin behaves less as a purely idiosyncratic asset and more as a component of a multi-layered system of interconnected markets, where energy costs, financial conditions, and macroeconomic uncertainty jointly influence its valuation.

From a methodological standpoint, the paper highlights the importance of economically disciplined network construction in graph-learning applications. Graph neural networks, particularly attention-based architectures, are highly flexible and capable of capturing complex nonlinear dependencies (Veličković et al., 2018). However, their performance depends crucially on the quality and interpretability of the underlying graph structure. By constructing graphs from clustered FEVD spillovers, the analysis ensures that the edges of the network correspond to economically meaningful transmission channels, rather than arbitrary correlations.

This integration generates a complementarity between econometrics and machine learning. The econometric component - through the VAR and clustered FEVD - provides a structurally identified representation of shock transmission, grounded in economic theory. The machine-learning component - through the GAT-GRU architecture - leverages this structure to extract nonlinear, time-varying predictive patterns. In this framework, machine learning does not replace econometric modeling but rather builds upon it, enhancing its predictive capacity while preserving interpretability.

The economic-value analysis further strengthens these conclusions. When forecasts are translated into volatility-targeted portfolio strategies, connectedness-informed graph learning yields improvements in risk-adjusted performance, as measured by Sharpe ratios (Sharpe, 1966). Importantly, these gains are observed across multiple diagnostics, including cumulative returns, rolling Sharpe ratios, and bootstrap-based inference on performance differentials. Taken together, the evidence indicates that the forecasting improvements are economically meaningful, although their statistical strength varies across horizons.

The use of volatility targeting plays a key role in this evaluation. By scaling positions to maintain a constant risk level, the analysis isolates the contribution of the forecasting signal from variations

in volatility (Moreira and Muir, 2017). This ensures that performance differences across models reflect differences in information extraction and prediction quality, rather than differences in risk exposure. The results therefore suggest that economically identified connectedness can be translated into investment signals under the portfolio design considered here.

More broadly, the paper contributes to an emerging research agenda that seeks to embed economic structure into machine-learning models for financial applications. A common critique of purely data-driven approaches is that they may capture spurious patterns or lack interpretability. By contrast, the proposed framework demonstrates that incorporating economically motivated identification - through clustering and FEVD - can enhance both predictive performance and economic interpretation. In the context of Bitcoin, this approach sheds light on the mechanisms through which different sectors of the global economy influence cryptocurrency returns, offering a more nuanced understanding of market integration and spillover dynamics.

The framework also suggests several extensions. First, the cluster structure could be extended to allow for time-varying or data-driven partitions, capturing potential structural changes in market organization. Second, the analysis could be applied to other asset classes, such as equities, commodities, or sovereign bonds, to assess whether the dominance of inter-cluster spillovers generalizes beyond cryptocurrencies. Third, alternative identification schemes - such as sign restrictions or high-frequency identification - could be incorporated to further refine the interpretation of shocks within the connectedness framework.

In conclusion, the results suggest that connectedness is most informative for forecasting when it is organized around economically interpretable transmission channels rather than undifferentiated dependence. In the present study, the distinction between within-cluster dependence and cross-cluster transmission helps clarify why predictive performance differs across horizons. More broadly, the paper illustrates how econometrically identified networks can be incorporated into graph-based forecasting models without giving up economic interpretation.

6 Conclusion générale

Cette thèse a étudié le nexus émergent entre les cryptomonnaies, l'énergie, la macrofinance et l'environnement en le considérant comme un système économique cohérent, façonné par les interactions entre la finance numérique, les dynamiques des marchés de l'énergie, les conditions macrofinancières et les contraintes environnementales. Son point de départ repose sur le constat que les cryptomonnaies ne peuvent plus être analysées comme de simples actifs spéculatifs isolés. Leur essor s'est accompagné de l'importance croissante des enjeux liés à la sécurité énergétique, à la transition climatique et au développement d'une finance orientée vers la durabilité, faisant ainsi émerger un nouveau champ d'interdépendances au sein duquel les chocs se propagent entre des marchés qui étaient jusqu'alors étudiés de manière distincte. L'objectif général de cette thèse était donc de dépasser les résultats fragmentés de la littérature afin de développer un cadre d'analyse cumulatif permettant de conceptualiser ce nexus, de mesurer l'évolution de ses interdépendances, d'identifier la structure de ses mécanismes de transmission et d'évaluer si cette structure renferme une information prédictive présentant une réelle valeur économique.

La première contribution de cette thèse consiste à avoir établi les fondements conceptuels et analytiques de ce nexus. Le chapitre consacré à l'état de l'art a montré que l'essor des cryptomonnaies est indissociable des infrastructures physiques qui les sous-tendent, en particulier dans les systèmes fondés sur le mécanisme de preuve de travail (*Proof-of-Work*), où l'activité de minage dépend directement de la demande en électricité, de l'efficacité des équipements informatiques et de l'intensité carbone du mix énergétique. Il a également montré que les relations entre les cryptomonnaies, le pétrole brut, l'électricité et les énergies renouvelables ne relèvent pas de simples coïncidences, mais traduisent des mécanismes économiques plus profonds impliquant les structures de coûts, les réponses réglementaires, le

sentiment des investisseurs et les externalités environnementales. Cette étape conceptuelle était essentielle, car elle justifie l'architecture générale de la thèse : les cryptomonnaies ne sont plus considérées comme des actifs numériques autonomes, mais comme des actifs intégrés à un système plus large reliant l'innovation numérique, les marchés de l'énergie et la durabilité environnementale.

Dans le prolongement de cette base conceptuelle, le deuxième chapitre propose la première cartographie empirique globale de ce nexus. En mobilisant un cadre méthodologique combinant la décomposition en ondelettes (*wavelet decomposition*) et les mesures de connectivité issues d'un modèle TVP-VAR, il montre que le système américain réunissant les cryptomonnaies, l'énergie, l'environnement et les variables macroéconomiques présente un degré d'intégration élevé et persistant, l'indice global de connectivité (*Total Connectedness Index*) se situant généralement entre 70 % et 90 %, avec un maximum proche de 93 % aux horizons de long terme. Les résultats mettent également en évidence que cette connectivité n'est pas homogène selon les échelles temporelles. Les mécanismes de contagion de court terme sont principalement alimentés par les dynamiques spéculatives et les marchés de l'énergie, tandis que les interdépendances de long terme reposent davantage sur des variables macroéconomiques fondamentales telles que l'inflation, la production industrielle et les prix de l'électricité. Le chapitre identifie par ailleurs une évolution chronologique du leadership systémique : une domination des interactions énergie–cryptomonnaies avant 2020, suivie d'une forte synchronisation financière durant la crise de la COVID-19, puis d'un régime dominé par les interactions entre énergie et macrofinance après 2021, avant une évolution progressive vers une configuration davantage orientée vers les enjeux de durabilité à l'horizon 2025. Ce chapitre établit ainsi un premier résultat majeur : le nexus se caractérise non seulement par un niveau élevé d'interconnexion, mais également par une connectivité dynamique, multi-échelle et dépendante des régimes économiques.

Le troisième chapitre approfondit cette analyse en s'attaquant à une limite méthodologique majeure des mesures traditionnelles de connectivité. Si les indicateurs classiques fondés sur la décomposition de la variance de l'erreur de prévision (*Forecast Error Variance Decomposition*, FEVD) permettent de mesurer les mécanismes de transmission entre variables, ils ne distinguent pas les co-mouvements observés au sein d'un même groupe des véritables phénomènes de contagion entre groupes économiquement distincts. L'application du cadre de la *Clustered Network Connectedness* montre que cette distinction revêt une importance empirique essentielle. Les résultats indiquent que les mesures généralisées de connectivité surestiment les

spillovers globaux d'environ 8 à 12 %, dans la mesure où elles assimilent les co-mouvements internes aux clusters à des mécanismes de transmission à l'échelle de l'ensemble du système. Une fois ce problème d'identification corrigé, l'architecture du réseau apparaît avec davantage de clarté. Le groupe des marchés de l'énergie se révèle être un transmetteur net persistant de chocs, atteignant des valeurs proches de +0,96 lors des périodes de fortes tensions. Les cryptomonnaies évoluent progressivement d'une position de récepteurs nets vers celle de transmetteurs nets après l'épisode FTX. Quant au groupe des actifs environnementaux, il réagit plus lentement aux perturbations mais demeure fortement exposé aux chocs énergétiques, près de 60 % de la variance de leurs rendements étant expliquée par les innovations provenant des marchés de l'énergie. Les simulations de Monte Carlo confirment que l'écart observé entre la connectivité généralisée et la connectivité fondée sur les clusters traduit un véritable biais d'identification structurelle et ne résulte pas d'un simple effet lié aux propriétés des échantillons finis. Ce chapitre montre ainsi qu'une mesure pertinente de la connectivité suppose une identification économiquement fondée de la structure du réseau.

Le quatrième chapitre prolonge cette démarche en passant de la mesure à la prévision. Plutôt que de considérer la connectivité comme un simple indicateur descriptif, il transforme les matrices de spillovers FEVD clusterisées en graphes dynamiques orientés, qui sont ensuite intégrés dans une architecture d'apprentissage sur graphes temporels combinant les *Graph Attention Networks* (GAT) et les *Gated Recurrent Units* (GRU). Les résultats montrent que le contenu prédictif de la connectivité dépend fortement de l'horizon de prévision. Aux horizons les plus courts, les gains de prévision demeurent limités, car les fluctuations du Bitcoin sont principalement dominées par le bruit de haute fréquence et des chocs transitoires. Aux horizons intermédiaires, les améliorations deviennent nettement plus importantes et sont essentiellement portées par les dépendances intra-clusters. À l'inverse, aux horizons les plus longs, les spillovers inter-clusters deviennent prépondérants, indiquant que les rendements du Bitcoin sont de plus en plus influencés par des mécanismes de transmission macrofinanciers et intersectoriels. L'analyse de la valeur économique confirme ces résultats en montrant que l'intégration de la connectivité dans une architecture d'apprentissage sur graphes améliore sensiblement les performances ajustées du risque lorsque l'horizon de prévision s'allonge. Ce chapitre démontre ainsi que la connectivité ne constitue pas uniquement un outil de diagnostic *ex post* de la structure des marchés ; elle représente également un objet informationnel prospectif pouvant être exploité pour la prévision financière et la construction de portefeuilles.

Pris dans leur ensemble, ces différents chapitres conduisent à une conclusion générale unique :

le nexus cryptomonnaies–énergie–macrofinance–environnement doit être appréhendé comme un système stratifié et évolutif, au sein duquel les mécanismes de transmission diffèrent selon les horizons temporels, les régimes économiques et la structure des variables qui le composent. Cette thèse montre que la progression allant de la synthèse conceptuelle à la caractérisation empirique, puis de cette dernière à l'identification structurelle et enfin à la prévision, ne constitue pas une simple succession d'étapes, mais une démarche cumulative et cohérente. Le premier chapitre explique pourquoi ce nexus existe ; le deuxième montre qu'il présente une connectivité forte, dynamique et dépendante du temps ; le troisième démontre que sa structure interne est déterminante pour son interprétation ; enfin, le quatrième établit que cette structure renferme une information exploitable pour améliorer la prévision des rendements du Bitcoin.

Plusieurs implications découlent de ces résultats. Pour la littérature académique, cette thèse suggère que les recherches futures consacrées aux systèmes financiers interconnectés devraient accorder une place plus importante à la structure économique sous-jacente des mécanismes de transmission, plutôt que de s'appuyer exclusivement sur des mesures agrégées ou bilatérales de dépendance. Plus spécifiquement, pour la littérature sur la connectivité, elle montre que la distinction entre co-mouvements et contagion ne présente pas seulement un intérêt conceptuel, mais revêt également une importance quantitative significative. Enfin, à l'interface entre l'économétrie et l'apprentissage automatique, cette thèse met en évidence que les architectures d'apprentissage sur graphes gagnent simultanément en performance et en capacité d'interprétation lorsque les réseaux qu'elles exploitent sont construits à partir de mécanismes de transmission identifiés sur des fondements économiques, plutôt qu'à partir de simples corrélations ou de mesures de dépendance non différenciées.

Cette thèse présente également plusieurs implications pour les politiques publiques et la pratique financière. Le rôle persistant des marchés de l'énergie en tant que principaux transmetteurs de chocs suggère que la surveillance macroprudentielle ne peut ignorer le canal énergétique dans l'évaluation de la fragilité des marchés d'actifs numériques. La forte transmission des chocs énergétiques vers les actifs environnementaux indique en outre que les exercices de tests de résistance climatique (*climate stress testing*) devraient intégrer explicitement la volatilité des prix des combustibles fossiles et de l'électricité, les instruments financiers liés à la durabilité n'étant pas isolés des perturbations affectant les marchés de l'énergie. Plus largement, les résultats montrent que les cryptomonnaies se comportent moins comme des actifs alternatifs indépendants que comme des composantes à fort bêta d'un système macrofinancier plus vaste, en particulier durant les périodes de tensions systémiques. Ce constat remet en question leur rôle potentiel en tant qu'instruments efficaces de diversification dans les

périodes de turbulences et souligne la nécessité d'une surveillance intégrée des risques liés aux actifs numériques, à l'énergie et à la finance climatique.

Comme tout travail empirique, cette thèse présente néanmoins certaines limites. Tout d'abord, la structure en clusters est définie *a priori* et non estimée de manière endogène. Si ce choix renforce l'interprétabilité économique des résultats, il ne permet pas de prendre pleinement en compte les évolutions temporelles de l'organisation des marchés. Ensuite, l'analyse prédictive est centrée sur le Bitcoin. Ce choix se justifie par son importance systémique au sein de l'écosystème des cryptomonnaies, mais il laisse ouverte la question de la généralisation de ces résultats à d'autres actifs numériques ou à des classes d'actifs plus larges. Par ailleurs, bien que l'architecture d'apprentissage sur graphes démontre que la connectivité peut être transformée en signaux prédictifs, l'analyse de la valeur économique demeure volontairement simple. Elle pourrait être enrichie en intégrant des contraintes de portefeuille plus réalistes, des structures de coûts de transaction plus sophistiquées ainsi que des règles alternatives de gestion du risque. Les résultats prédictifs doivent ainsi être interprétés comme une démonstration de l'intérêt de la connectivité identifiée sur des bases économiques dans le cadre spécifique de cette étude, plutôt que comme une règle universellement applicable à l'ensemble des classes d'actifs.

Ces limites ouvrent naturellement plusieurs perspectives de recherche. Une première consisterait à étendre le cadre d'analyse à un ensemble plus large d'actifs liés à la durabilité, notamment les marchés des crédits carbone, les obligations vertes (*green bonds*) et les indices d'incertitude relatifs aux politiques climatiques. Une deuxième piste viserait à autoriser une évolution dynamique de la structure en clusters elle-même, en combinant l'identification économique avec des méthodes de partitionnement fondées sur les données. Une troisième extension consisterait à intégrer des schémas d'identification variant dans le domaine fréquentiel ou fondés sur des approches bayésiennes à paramètres variables dans le temps, afin de mieux capturer les interactions entre transitions structurelles, régimes de marché et chocs de politique économique. Enfin, le cadre de prévision pourrait être généralisé au-delà du seul Bitcoin afin d'évaluer si des structures de graphes identifiées sur des fondements économiques permettent également d'améliorer la prévision des rendements sur d'autres marchés fortement interconnectés.

Dans son ensemble, cette thèse montre que le nexus cryptomonnaies–énergie–macrofinance–environnement ne peut être réduit à une juxtaposition de relations bilatérales isolées, mais qu'il constitue un système structuré et évolutif de transmission des chocs. Son principal message est que la compréhension de ce nexus exige davantage que la simple mise en évidence de co-mouvements entre variables. Elle nécessite d'identifier l'architecture économique des

mécanismes de transmission, de reconnaître leur dépendance aux horizons temporels et d'exploiter le contenu informationnel qu'ils renferment. En ce sens, cette thèse s'inscrit dans un programme de recherche plus large en économie et en finance, visant à réconcilier la mesure du risque systémique, l'interprétation structurelle des mécanismes économiques et la prévision, dans un contexte marqué par l'accélération de la numérisation, de la transition énergétique et des incertitudes environnementales.

References

Acharya, V. V., Chauhan, R. S., Rajan, R., & Steffen, S. (2023). Liquidity dependence and the waxing and waning of central bank balance sheets. NBER Working Paper No. 31050. https://doi.org/10.3386/w31050

Afjal, M., & Clanganthuruthil Sajeev, K. (2022). Interconnection between cryptocurrency and energy market: An analysis of volatility spillover. OPEC Energy Review, 46(3), 400-421. https://doi.org/10.1111/opec.12227

Akhter, S. (2012). The role of energy consumption and economic growth in climate change: Evidence from Asian countries. Energy Policy, 38(10), 6016-6025.

Andoni, M., Robu, V., Flynn, D., Abram, S., Geach, D., Jenkins, D., McCallum, P., & Peacock, A. (2019). Blockchain technology in the energy sector: A systematic review of challenges and opportunities. Renewable and Sustainable Energy Reviews, 100, 143-174.

Andronicеanu, A., & Georgescu, I. (2023). The impact of blockchain technology on the environment and sustainable economic development. Environmental Science and Pollution Research, 30(1), 123-138. https://doi.org/10.1007/s11356-022-24113-5

Annamalaisamy, B., & Jayaraman, S. V. (2023). Do cryptocurrencies integrate with the indices of equity, sustainability, clean energy, and crude oil? A wavelet coherency approach. International Journal of Finance & Economics, 28(3), 2870-2888. https://doi.org/10.1002/ijfe.2843

Antonakakis, N., Chatziantoniou, I., & Gabauer, D. (2020). Refined measures of dynamic connectedness based on TVP-VAR. Journal of Risk and Financial Management, 13(4), 84. https://doi.org/10.3390/jrfm13040084

Arezki, R., & Nguyen, C. (2022). Ukraine invasion: From oil sanctions to accelerating the energy transition. VoxEU (CEPR).

Auer, R., Cornelli, G., Doerr, S., Frost, J., & Gambacorta, L. (2022). Crypto trading and Bitcoin prices: Evidence from a new database of retail adoption. BIS Working Papers, No. 1049.

Bajra, U. Q., Rogova, E., & Avdiaj, S. (2024). Cryptocurrency blockchain and its carbon footprint: Anticipating future challenges. Technology in Society, 77, 102571.

Baker, S. R., Bloom, N., & Davis, S. J. (2016). Measuring economic policy uncertainty. The Quarterly Journal of Economics, 131(4), 1593-1636. https://doi.org/10.1093/qje/qjw024

Balcilar, M., Bouri, E., Gupta, R., & Roubaud, D. (2017). Can volume predict Bitcoin returns and volatility? A quantiles-based approach. Economic Modelling, 64, 74-81. https://doi.org/10.1016/j.econmod.2017.03.019

Baruník, J., & Křehlík, T. (2018). Measuring the frequency dynamics of financial connectedness and systemic risk. Journal of Financial Econometrics, 16(2), 271-296. https://doi.org/10.1093/jjfinec/nby001

Baujat, B., Mahé, C., Pignon, J.-P., & Hill, C. (2002). A graphical method for exploring heterogeneity in meta-analyses: Application to a meta-analysis of 65 trials. Statistics in Medicine, 21(18), 2641-2652.

Baur, D. G., Dimpfl, T., & Kuck, K. (2018). Bitcoin, gold and the US dollar: A replication and extension. Finance Research Letters, 25, 103-110.

Bauer, N., Mouratiadou, I., Luderer, G., Baumstark, L., Kriegler, E., Amann, M., & Leimbach, M. (2013). Global fossil energy markets and climate change mitigation: An analysis with REMIND. Climatic Change, 136(1), 69-82. https://doi.org/10.1007/s10584-013-0901-6

Benetton, M., Compiani, G., & Morse, A. (2023). When cryptomining comes to town: High electricity-use spillovers to the local economy. NBER Working Paper No. 31312. https://doi.org/10.3386/w31312

BIS & CPMI. (2024). Tokenisation in the context of money and other assets: Concepts and implications for central banks. Bank for International Settlements / Committee on Payments and Market Infrastructures.

Blandin, A., Pieters, G., Wu, Y., Eisermann, T., Dek, A., Taylor, S., & Njoki, D. (2020). 3rd Global Cryptoasset Benchmarking Study. Cambridge Centre for Alternative Finance.

Borenstein, M., Hedges, L. V., Higgins, J. P. T., & Rothstein, H. R. (2009). Introduction to Meta-Analysis. Wiley.

Borenstein, M., Hedges, L. V., Higgins, J. P. T., & Rothstein, H. R. (2010). A basic introduction to fixed-effect and random-effects models for meta-analysis. Research Synthesis Methods, 1(2), 97-111.

Bouri, E., Cepni, O., Gabauer, D., & Gupta, R. (2021). Return connectedness across asset classes around the COVID-19 outbreak. International Review of Financial Analysis, 73, 101646. https://doi.org/10.1016/j.irfa.2020.101646

Bouri, E., Jalkh, N., Molnár, P., & Roubaud, D. (2020). Bitcoin for energy commodities before and after the November 2018 crash: Diversifier, hedge or safe haven? Applied Economics, 52(53), 5808-5830. https://doi.org/10.1080/00036846.2020.1767280

Bouri, E., Molnár, P., Azzi, G., Roubaud, D., & Hagfors, L. I. (2017). On the hedge and safe haven properties of Bitcoin: Is it really more than a diversifier? Finance Research Letters, 20, 192-198.

Bouri, E., Saeed, T., Vo, X. V., & Roubaud, D. (2021). Quantile connectedness in the cryptocurrency market. Journal of International Financial Markets, Institutions and Money, 71, 101302. https://doi.org/10.1016/j.intfin.2021.101302

Bouri, E., Shahzad, S. J. H., Roubaud, D., Kristoufek, L., & Lucey, B. (2018). Bitcoin, gold, and commodities as safe havens for stocks: New insight through wavelet analysis. The Quarterly Review of Economics and Finance, 77, 156-164.

Buchwalter, B., Diebold, F. X., & Yilmaz, K. (2026). *Clustered network connectedness: A new measurement framework with application to global equity markets*. **Journal of Econometrics**. https://doi.org/10.1016/j.jeconom.2026.106243

Cambridge Centre for Alternative Finance. (2023). Cambridge Bitcoin Electricity Consumption Index (CBECI).

Caldara, D., & Iacoviello, M. (2022). Measuring geopolitical risk. American Economic Review, 112(4), 1194-1225. https://doi.org/10.1257/aer.20191823

Caporale, G. M., Plastun, A., & Oliinyk, V. (2019). Bitcoin fluctuations and the frequency of price overreactions. Financial Markets and Portfolio Management, 33(2), 113-131. https://doi.org/10.1007/s11408-019-00331-0

Chen, C., & Lin, B. (2021). On the dynamic return and volatility connectedness of cryptocurrency, crude oil, clean energy, and stock markets: A time-varying analysis. Environmental Science and Pollution Research, 28, 61506-61525. https://doi.org/10.1007/s11356-021-15074-4

Chen, Y., Zhang, L., & Bouri, E. (2024). Co-bubble transmission and portfolio implications: A dynamic network approach covering two crisis periods and clean versus dirty cryptocurrencies. Journal of International Money and Finance, 145, 103108.

Chevallier, J. (2011). A model of carbon price interactions with macroeconomic and energy dynamics. Energy Economics, 33(6), 1295-1312. https://doi.org/10.1016/j.eneco.2011.03.011

Cho, K., Van Merriënboer, B., Gülçehre, Ç., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning phrase representations using RNN encoder-decoder for statistical machine translation. In Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP) (pp. 1724-1734).

Chung, J., Gülçehre, Ç., Cho, K., & Bengio, Y. (2014). Empirical evaluation of gated recurrent neural networks on sequence modeling. arXiv preprint arXiv:1412.3555.

Clark, E., Lahiani, A., & Mefteh-Wali, S. (2023). Cryptocurrency return predictability: The role of the environment. Technological Forecasting and Social Change, 189, 122350.

Cogley, T., & Sargent, T. J. (2005). Drifts and volatilities: Monetary policies and outcomes in the post-WWII U.S. Review of Economic Dynamics, 8(2), 262-302.

Committee on Payments and Market Infrastructures. (2017). Distributed ledger technology in payment, clearing and settlement: An analytical framework. Bank for International Settlements.

Corbet, S., Larkin, C., & Lucey, B. (2020). The contagion effects of the COVID-19 pandemic: Evidence from gold and cryptocurrencies. Finance Research Letters, 35, 101554. https://doi.org/10.1016/j.frl.2020.101554

Corbet, S., Lucey, B., Urquhart, A., & Yarovaya, L. (2019). Cryptocurrencies as a financial asset: A systematic analysis. International Review of Financial Analysis, 62, 182-199.

Corbet, S., Lucey, B., & Yarovaya, L. (2018). Datestamping the Bitcoin and Ethereum bubbles. Finance Research Letters, 26, 81-88. https://doi.org/10.1016/j.frl.2017.12.006

Corbet, S., Meegan, A., Larkin, C., Lucey, B., & Yarovaya, L. (2018). Exploring the dynamic relationships between cryptocurrencies and other financial assets. Economics Letters, 165, 28-34.

Corbet, S., Lucey, B., & Yarovaya, L. (2021). Bitcoin-energy markets interrelationships: New evidence. Resources Policy, 70, 101916. https://doi.org/10.1016/j.resourpol.2020.101916

de Vries, A. (2018). Bitcoin's growing energy problem. Joule, 2(5), 801-805. https://doi.org/10.1016/j.joule.2018.04.016

de Vries, A. (2021). Bitcoin boom: What rising prices mean for the network's energy consumption. Joule, 5(3), 509-513.

de Vries, A., Gallersdörfer, U., Klaaßen, L., & Stoll, C. (2022). Revisiting Bitcoin's carbon footprint. Joule, 6(3), 498-502.

Demirer, M., Diebold, F. X., Liu, L., & Yilmaz, K. (2018). Estimating global bank network connectedness. Journal of Applied Econometrics, 33(1), 1-15. https://doi.org/10.1002/jae.2585

DerSimonian, R., & Laird, N. (1986). Meta-analysis in clinical trials. Controlled Clinical Trials, 7(3), 177-188.

Diebold, F. X., & Yilmaz, K. (2009). Measuring financial asset return and volatility spillovers, with application to global equity markets. The Economic Journal, 119(534), 158-171. https://doi.org/10.1111/j.1468-0297.2008.02208.x

Diebold, F. X., & Yilmaz, K. (2012). Better to give than to receive: Predictive directional measurement of volatility spillovers. International Journal of Forecasting, 28(1), 57-66. https://doi.org/10.1016/j.ijforecast.2011.02.006

Diebold, F. X., & Yilmaz, K. (2014). On the network topology of variance decompositions: Measuring the connectedness of financial firms. Journal of Econometrics, 182(1), 119-134. https://doi.org/10.1016/j.jeconom.2014.04.012

Dutta, A. (2017). Oil price uncertainty and clean energy stock returns: New evidence from crude oil volatility index. Journal of Cleaner Production, 164, 1157-1166. https://doi.org/10.1016/j.jclepro.2017.07.050

Dyhrberg, A. H. (2016). Hedging capabilities of Bitcoin. Is it the virtual gold? Finance Research Letters, 16, 85-92. https://doi.org/10.1016/j.frl.2015.10.025

Egger, M., Davey Smith, G., Schneider, M., & Minder, C. (1997). Bias in meta-analysis detected by a simple, graphical test. BMJ, 315(7109), 629-634.

Emiliozzi, S., Ferriani, F., & Gazzani, A. (2023). The European energy crisis and the consequences for the global natural gas market. SSRN Electronic Journal. https://doi.org/10.2139/ssrn.4640202

Engle, R. F., Giglio, S., Kelly, B., Lee, H., & Stroebel, J. (2020). Hedging climate change news. Review of Financial Studies, 33(3), 1184-1216. https://doi.org/10.1093/rfs/hhz072

European Commission. (2014). Energy economic developments in Europe. European Economy, 1/2014.

Fama, E. F. (1970). Efficient capital markets: A review of theory and empirical work. The Journal of Finance, 25(2), 383-417.

Fisher, Z., & Tipton, E. (2015). robumeta: An R-package for robust variance estimation in meta-analysis. arXiv preprint arXiv:1503.02220.

Forbes, K. J., & Rigobon, R. (2002). No contagion, only interdependence: Measuring stock market comovements. Journal of Finance, 57(5), 2223-2261. https://doi.org/10.1111/0022-1082.00494

Gallersdörfer, U., Klaaßen, L., & Stoll, C. (2020). Energy consumption of cryptocurrencies beyond Bitcoin. Joule, 4(9), 1843-1846.

Gandal, N., Hamrick, J. T., Moore, T., & Oberman, T. (2018). Price manipulation in the Bitcoin ecosystem. Journal of Monetary Economics, 95, 86-96. https://doi.org/10.1016/j.jmoneco.2017.12.004

Hałaj, G., & Hipp, C. (2024). Decomposing systemic risk: The roles of contagion and common exposures. European Central Bank Working Paper No. 2929.

Harasheh, M., Bouteska, A., & Hammad, M. H. (2022). Dynamic connectedness between energy markets and cryptocurrencies: Evidence from the COVID-19 pandemic. Journal of Energy Markets, 15(1), 1-28. https://doi.org/10.14324/111.444.jem.2022.001

Havránek, T., et al. (2020). Reporting guidelines for meta-analysis in economics. Journal of Economic Surveys, 34(3), 469-475.

Hedges, L. V. (1983). A random effects model for effect sizes. Psychological Bulletin, 93(2), 388-395.

Higgins, J. P. T., Thompson, S. G., Deeks, J. J., & Altman, D. G. (2003). Measuring inconsistency in meta-analyses. BMJ, 327(7414), 557-560.

Hong, Y., Liu, Y., & Wang, S. (2019). Bitcoin and investor attention: Evidence from Google Trends. International Review of Financial Analysis, 63, 15-27. https://doi.org/10.1016/j.irfa.2019.02.008

Huang, Z., Zhu, H., Hau, L., & Deng, X. (2023). The impact of renewable energy consumption on economic growth: Evidence from a panel threshold model. Energy Policy, 161, 112744. https://doi.org/10.1016/j.enpol.2023.112744

Hunter, J. E., & Schmidt, F. L. (2004). Methods of Meta-Analysis: Correcting Error and Bias in Research Findings (2nd ed.). Sage.

IEA. (2017). World Energy Outlook 2017. International Energy Agency.

IEA. (2023). World Energy Outlook 2023. International Energy Agency.

IEA. (2024). World Energy Outlook 2024. International Energy Agency.

IMF. (2020). World Economic Outlook: A Long and Difficult Ascent. International Monetary Fund.

IMF. (2024). Digital money, cross-border payments, international reserves, and the global financial safety net: Preliminary considerations. IMF Notes, 2024/001.

International Monetary Fund. (2023). Global Financial Stability Report: Safeguarding financial stability amid high inflation and geopolitical risks (April 2023).

IRENA. (2019). Blockchain: Innovation landscape brief. International Renewable Energy Agency.

IRENA. (2020). Peer-to-peer electricity trading: Innovation landscape brief. International Renewable Energy Agency.

IRENA. (2024). Renewable Power Generation Costs in 2023. International Renewable Energy Agency.

Jamel, L., & Maktouf, S. (2017). Dynamics of the relationship between oil prices and economic growth in developed and developing countries. Energy Policy, 109, 117-127. https://doi.org/10.1016/j.enpol.2017.06.074

Jareño, F., de la O González, M., Tolentino, M., & Sierra, K. (2021). Cryptocurrencies and oil price shocks: A NARDL analysis in the COVID-19 pandemic. Resources Policy, 74, 102373.

Ji, Q., Bouri, E., Lau, C. K. M., & Roubaud, D. (2019). Dynamic connectedness and integration in cryptocurrency markets. International Review of Financial Analysis, 63, 257-272.

Ji, Q., Zhang, D., & Zhao, Y. (2020). Searching for safe-haven assets during the COVID-19 pandemic. International Review of Financial Analysis, 71, 101526. https://doi.org/10.1016/j.irfa.2020.101526

Jiang, E. X., Matvos, G., Piskorski, T., & Seru, A. (2023). Monetary tightening and U.S. bank fragility in 2023: Mark-to-market losses and uninsured depositor runs? SSRN Working Paper No. 4387676. https://doi.org/10.2139/ssrn.4387676

Jones, B., Westermann, B., & Harder, S. (2019). The impact of renewable energy consumption on economic growth: Evidence from a panel of developed countries. Renewable Energy, 139, 153-163. https://doi.org/10.1016/j.renene.2019.02.024

Katsiampa, P., Corbet, S., & Lucey, B. (2019). High frequency volatility co-movements in cryptocurrency markets. Journal of International Financial Markets, Institutions and Money, 62, 35-52.

Kilian, L. (2008). The economic effects of energy price shocks. Journal of Economic Literature, 46(4), 871-909.

Kiliç, A., & Altan, A. (2023). Who are the receivers and transmitters of volatility spillovers: Oil, clean energy, and green and non-green cryptocurrency markets. Environmental Science and Pollution Research, 30, 12112-12130. https://doi.org/10.1007/s11356-023-25160-2

Klein, T., Pham Thu, H., & Walther, T. (2018). Bitcoin is not the new gold: A comparison of volatility, correlation, and portfolio performance. International Review of Financial Analysis, 59, 105-116.

Kohli, V., Chakravarty, S., Chamola, V., Sangwan, K. S., & Zeadally, S. (2023). An analysis of energy consumption and carbon footprints of cryptocurrencies and possible solutions. Digital Communications and Networks, 9(1), 79-89.

Koop, G., Pesaran, M. H., & Potter, S. M. (1996). Impulse response analysis in nonlinear multivariate models. Journal of Econometrics, 74(1), 119-147. https://doi.org/10.1016/0304-4076(95)01753-4

Krause, M. J., & Tolaymat, T. (2018). Quantification of energy and carbon costs for mining cryptocurrencies. Nature Sustainability, 1(11), 711-718. https://doi.org/10.1038/s41893-018-0152-7

Kumar, P. N., Umeorah, N., & Alochukwu, A. (2024). Dynamic graph neural networks for enhanced volatility prediction in financial markets. arXiv preprint arXiv:2410.16858.

Lei, N., Zhang, X., et al. (2021). Best practices for analyzing the direct energy use of blockchain technology systems: Review and policy recommendations. Energy Policy, 156, 112422.

Li, X., Peng, L., & Baker, R. D. (2018). Bitcoin mining: Economics and externalities. Journal of Financial Stability, 32, 111-120. https://doi.org/10.1016/j.jfs.2017.12.002

Lütkepohl, H. (2005). New Introduction to Multiple Time Series Analysis. Springer.

Marcellino, M., Stock, J. H., & Watson, M. W. (2006). A comparison of direct and iterated multistep AR methods for forecasting macroeconomic time series. Journal of Econometrics, 135(1-2), 499-526.

Melling, A. (2010). Natural Gas Pricing and Its Future: Europe as the Battleground. Carnegie Endowment for International Peace.

Mensi, W., Hammoudeh, S., Yoon, S. M., & Nguyen, D. K. (2023). Time-varying spillovers between oil and commodity markets: A comparative analysis. Energy Economics, 74, 563-582. https://doi.org/10.1016/j.eneco.2022.105443

Mills, D., Wang, K., Malone, B., Ravi, A., Marquardt, J., Chen, C., et al. (2016). Distributed ledger technology in payments, clearing, and settlement. Finance and Economics Discussion Series 2016-095. Board of Governors of the Federal Reserve System.

Miśkiewicz, R., Matan, K., & Karnowski, J. (2022). The role of crypto trading in the economy, renewable energy consumption and ecological degradation. Energies, 15(10), 3805. https://doi.org/10.3390/en15103805

Moher, D., Liberati, A., Tetzlaff, J., Altman, D. G., & The PRISMA Group. (2009). Preferred reporting items for systematic reviews and meta-analyses: The PRISMA statement. PLoS Medicine, 6(7), e1000097.

Mora, C., Rollins, R. L., Taladay, K., Kantar, M. B., Chock, M. K., Shimada, M., & Franklin, E. C. (2018). Bitcoin emissions alone could push global warming above 2°C. Nature Climate Change, 8(11), 931-933. https://doi.org/10.1038/s41558-018-0321-8

Moreira, A., & Muir, T. (2017). Volatility-managed portfolios. The Journal of Finance, 72(4), 1611-1644.

Nakamoto, S. (2008). *Bitcoin: A peer-to-peer electronic cash system*. Available at: https://bitcoin.org/bitcoin.pdf

Narayanan, A., Bonneau, J., Felten, E., Miller, A., & Goldfeder, S. (2016). Bitcoin and Cryptocurrency Technologies: A Comprehensive Introduction. Princeton University Press.

Nasir, R. M., He, F., Asadi, M., & Roubaud, D. (2025). Spillover and return connectedness between uncertainties, digital assets, green bond, green and traditional energy markets: Evidence from quantile VAR. North American Journal of Economics and Finance, 67, 102538. https://doi.org/10.1016/j.najef.2025.102538

OECD. (2022). Environmental Impact of Digital Assets. Organisation for Economic Co-operation and Development.

Okorie, D. I., & Lin, B. (2020). Crude oil price and cryptocurrencies: Evidence of volatility connectedness and hedging strategy. Energy Economics, 87, 104703.

Pastor, L., & Veronesi, P. (2013). Political uncertainty and risk premia. Journal of Financial

Economics, 110(3), 520-545. https://doi.org/10.1016/j.jfineco.2013.08.007
Patel, R., Kumar, S., Bouri, E., & Iqbal, N. (2023). Spillovers between green- and dirty cryptocurrencies and socially responsible investments around the war in Ukraine. International Review of Economics and Finance. https://doi.org/10.1016/j.iref.2023.04.013

Percival, D. B., & Walden, A. T. (2000). Wavelet Methods for Time Series Analysis. Cambridge University Press.

Pesaran, M. H., & Shin, Y. (1998). Generalized impulse response analysis in linear multivariate models. Economics Letters, 58(1), 17-29.

Pham, L. H. M. L., Huynh, T. L. D., & Hanif, W. (2023). Time-varying asymmetric spillovers among cryptocurrency, green and fossil-fuel investments. Global Finance Journal, 58, 100891. https://doi.org/10.1016/j.gfj.2023.100891

Phillips, R. C., & Gorse, D. (2018). Predicting cryptocurrency price bubbles using social media data and epidemic modelling. IEEE Access, 6, 5704-5713. https://doi.org/10.1109/ACCESS.2017.2779181

Pisani-Ferry, J., Tagliapietra, S., & Zachmann, G. (2023). A new governance framework to safeguard the European Green Deal. Bruegel Policy Brief, 18/2023.

Politis, D. N., & Romano, J. P. (1994). The stationary bootstrap. Journal of the American Statistical Association, 89(428), 1303-1313.

Primiceri, G. E. (2005). Time-varying structural vector autoregressions and monetary policy. The Review of Economic Studies, 72(3), 821-852.

Qing, L., & Alnafrah, I. (2025). Environmental attention in cryptocurrency markets: A catalyst for clean energy investments. International Review of Economics & Finance, 99, 104063. https://doi.org/10.1016/j.iref.2025.104063

Ramsey, J. B. (2002). Wavelets in economics and finance: Past and future. Studies in Nonlinear Dynamics & Econometrics, 6(3), 1-29.

Raza, S. A., Shah, N., & Sharif, A. (2020). The impact of renewable energy consumption on CO2 emissions: Evidence from developed and developing countries. Renewable Energy, 154, 1112-1122.

Reboredo, J. C., & Ugolini, A. (2020). Price connectedness between green bond and financial markets. Economic Modelling, 88, 25-38. https://doi.org/10.1016/j.econmod.2019.09.004

Rehman, M. U., & Apergis, N. (2020). Renewable energy consumption and environmental sustainability: Empirical evidence from South and Southeast Asian countries. Renewable and Sustainable Energy Reviews, 134, 110140. https://doi.org/10.1016/j.rser.2020.110140

Ren, B., Lucey, B. M., & Vigne, S. A. (2022). Cryptocurrency and energy markets: Understanding volatility connectedness. Energy Economics, 106, 105443.

https://doi.org/10.1016/j.eneco.2022.105443
Rosenthal, R. (1991). Meta-Analytic Procedures for Social Research (rev. ed.). Sage.

Roth, P. L., Le, H., Oh, I.-S., Van Iddekinge, C. H., & Bobko, P. (2018). Using beta coefficients to impute missing correlations in meta-analysis research: Reasons for caution. Journal of Applied Psychology, 103(6), 644-658.

Rua, A. (2010). Measuring comovement in the time-frequency space. Journal of Macroeconomics, 32(2), 685-691. https://doi.org/10.1016/j.jmacro.2009.12.005

Schmidt, F. L., & Hunter, J. E. (2015). Methods of Meta-Analysis: Correcting Error and Bias in Research Findings (3rd ed.). Sage.

Sebai, L., & Jaber, Y. (2025). Connectedness between green financial and cryptocurrency markets: A multivariate analysis using TVP-VAR model and wavelet-based VaR analysis. Journal of Risk and Financial Management, 18(7), 355. https://doi.org/10.3390/jrfm18070355

Selmi, R., Mensi, W., Hammoudeh, S., & Bouoiyour, J. (2018). Is Bitcoin a hedge, a safe haven or a diversifier for oil price movements? A comparison with gold. Energy Economics, 74, 787-801.

Shahzad, S. J. H., Bouri, E., Roubaud, D., Kristoufek, L., & Lu, C. C. (2019). Safe-haven, hedge and diversification for G7 stock markets: Gold versus Bitcoin. Economic Modelling, 87, 212-224. https://doi.org/10.1016/j.econmod.2019.07.023

Sharpe, W. F. (1966). Mutual fund performance. The Journal of Business, 39(1), 119-138.

Sims, C. A. (1980). Macroeconomics and reality. Econometrica, 48(1), 1-48. https://doi.org/10.2307/1912017

Stanley, T. D., & Doucouliagos, H. (2012). Meta-Regression Analysis in Economics and Business. Routledge.

Sterne, J. A. C., Gavaghan, D., & Egger, M. (2000). Publication and related bias in meta-analysis: Power of statistical tests and prevalence in the literature. Journal of Clinical Epidemiology, 53(11), 1119-1129.

Stoll, C., Klaaßen, L., & Gallersdörfer, U. (2019). The carbon footprint of Bitcoin. Joule, 3(7), 1647-1661. https://doi.org/10.1016/j.joule.2019.05.012

Symitsi, E., & Chalvatzis, K. J. (2019). The economic value of Bitcoin: A portfolio analysis of currencies, gold, oil and stocks. Research in International Business and Finance, 48, 97-110.

Torrence, C., & Compo, G. P. (1998). A practical guide to wavelet analysis. Bulletin of the American Meteorological Society, 79(1), 61-78. https://doi.org/10.1175/1520-0477(1998)079

Truby, J. (2018). Decarbonizing Bitcoin: Law and policy choices for reducing the energy consumption of blockchain technologies and digital currencies. Energy Research & Social

Science, 44, 399-410. https://doi.org/10.1016/j.erss.2018.06.009
Umar, Z., Polat, O., Choi, S.-Y., & Teplova, T. (2022). The impact of the Russia-Ukraine conflict on the connectedness of financial markets. Finance Research Letters, 48, 102976. https://doi.org/10.1016/j.frl.2022.102976

Urom, C., Mzoughi, H., Abid, I., & Brahim, M. (2021). Green markets integration in different time scales: A regional analysis. Energy Economics, 98, 105254. https://doi.org/10.1016/j.eneco.2021.105254

Vejacka, M. (2014). Basic aspects of cryptocurrencies. Journal of Economy, Business and Financing, 2(2), 75-83.

Veličković, P., Cucurull, G., Casanova, A., Romero, A., Liò, P., & Bengio, Y. (2018). Graph attention networks. In Proceedings of the International Conference on Learning Representations (ICLR 2018).

Veroniki, A. A., Jackson, D., Viechtbauer, W., et al. (2016). Methods to estimate the between-study variance and its uncertainty in meta-analysis. Research Synthesis Methods, 7(1), 55-79.

Viechtbauer, W. (2010). Conducting meta-analyses in R with the metafor package. Journal of Statistical Software, 36(3), 1-48.

Vranken, H. (2017). Sustainability of Bitcoin and blockchains. Current Opinion in Environmental Sustainability, 28, 1-9.

Wang, G. J., Feng, Y., Xiao, Y., Zhu, Y., & Xie, C. (2021). Multiscale dynamics of connectedness in the cryptocurrency market: Evidence from Bitcoin, Ethereum, and Ripple. Journal of Economic Behavior & Organization, 184, 105-127. https://doi.org/10.1016/j.jebo.2021.02.022

Wang, J.-N., Vigne, S. A., Liu, H.-C., & Hsu, Y.-T. (2024). Divergent jump characteristics in brown and green cryptocurrencies: The role of energy-related uncertainty. Energy Economics, 138, 107847. https://doi.org/10.1016/j.eneco.2024.107847

Wang, P., Zhang, H., Yang, C., & Guo, Y. (2021). Time and frequency dynamics of connectedness and hedging performance in global stock markets: Bitcoin versus conventional hedges. Research in International Business and Finance, 58, 101479. https://doi.org/10.1016/j.ribaf.2021.101479

World Bank. (2024). Commodity Markets Outlook, October 2024. World Bank.

Yadav, M. P., Tandon, P., Singh, A. B., Shore, A., & Gaur, P. (2025). Exploring time and frequency linkages of green bond with renewable energy and crypto market. Annals of Operations Research, 348(3), 1547-1572. https://doi.org/10.1007/s10479-022-05074-8

Yin, L., Wang, X., Feng, X., & Nie, W. (2021). Understanding cryptocurrency volatility: The role of oil market shocks. The Quarterly Review of Economics and Finance, 81, 559-568.

Zhang, D., Chen, X. H., Lau, C. K. M., & Xu, B. (2023). Implications of cryptocurrency energy usage on climate change. Technological Forecasting and Social Change, 187, 122219.

https://doi.org/10.1016/j.techfore.2022.122219
Zhou, L., Zhang, J.-Y., Zhu, X.-Q., Xu, D.-M., & Zheng, S.-S. (2024). The pollution characteristics and causes of dual sources-iron (Fe) in abandoned coal mines: A literature review. Journal of Cleaner Production, 471, 143358.

Zou, H., & Zhang, H. (2009). On the adaptive elastic-net with a diverging number of parameters. Annals of Statistics, 37(4), 1733-1751. https://doi.org/10.1214/08-AOS625