金融庁
Financial Services Agency

Discussion Paper Series

取引市場不安定化の予兆検知を目的とした詳細時系列データへの DNM 理論の適用

伊藤 真利子　羽佐田 紘之　大西 立顕　本間 裕大

DP 2025-6

2025 年 9 月

金融庁金融研究センター
Financial Research Center (FSA Institute)
Financial Services Agency
Government of Japan

金融庁金融研究センターが刊行している論文等はホームページからダウンロードできます。

https://www.fsa.go.jp/frtc/index.html

本ディスカッションペーパーの内容や意見は、全て執筆者の個人的見解であり、金融庁あるいは金融研究センターの公式見解を示すものではありません。

＜金融庁金融研究センター　ディスカッションペーパー DP2025-6（2025 年９月）＞

取引市場不安定化の予兆検知を目的とした詳細時系列データへの DNM 理論の適用

伊藤　真利子*　羽佐田　紘之**　大西　立顕***　本間　裕大****

概　　要

本研究は、東京証券取引所における詳細な板再現データを用い、市場参加者の発注取引を捉えた多変量時系列に対して、系の不安定性の予兆検知を目的とする DNM（Dynamical Network Marker）理論を適用し、市場不安定化の予測可能性を検討したものである。DNM 理論は、多数の相互作用する因子の中から臨界的状態遷移(急激な状態変化)に寄与する因子集合を特定し、その集合の振る舞いに基づいて不安定性の予兆を捉える手法である。

本研究では、市場参加者を仮想サーバーID のグルーピングに基づき定義し、各市場参加者の発注取引態様を表す時系列を複数の指標を用いて構成した。これらを統合した多変量時系列に対し、DNM 指標を計算し、市場の大幅な変動が生じた 2020 年 3 月のコロナショックを含む期間を対象として、予兆検知の可能性を評価した。

分析の結果、著しい市場不安定化については、日単位のタイムスケールで前兆を捉えられる可能性が示唆された。一方で、検知精度や頑健性は実務的応用にはなお不十分であり、データ特性や指標の安定性に依存する課題が明らかとなった。本稿では、これらの結果を踏まえ、予兆検知精度向上のためのデータ処理やモデル改善の方向性についても論じる。

キーワード：DNM 理論、時系列解析、複雑系、力学系、東京証券取引所

*　東京大学生産技術研究所特任講師（金融庁金融研究センター専門研究員）
**　東京大学生産技術研究所助教（金融庁金融研究センター専門研究員）
***　立教大学大学院人工知能科学研究科教授（金融庁金融研究センター専門研究員）
****　東京大学生産技術研究所准教授（金融庁金融研究センター専門研究員）
本稿の執筆に当たっては、金融庁金融研究センター顧問・慶應義塾大学名誉教授吉野直行氏及び証券取引等監視委員会事務局市場分析審査課海野昌司氏、大山篤之氏、本間敏久氏をはじめとする多くの同庁関係者、東京大学特別教授合原一幸氏、名誉教授渡辺努氏に有益なご意見をいただいた。この場を借りて感謝を申し上げたい。なお、本稿は、筆者たちの個人的な見解であり、金融庁及び金融研究センターの公式見解ではない。

1. はじめに

近年、金融市場の不安定化に対し、複雑系科学などに基づく数理的アプローチを用いてその予測やコントロールを試みる研究が活発に展開されている。複雑系の分野では、多数の要素が複雑に相互作用する中で生じるパターンを解明するための様々な数理的手法が提案されており、社会における意見の極化や噂の拡散、COVID-19 のような感染症の拡大、脳内のニューロン活動の同期、さらには気候・気象変動など、多様な現象の理解に複雑系の視点が応用されている(Kwapień and Drożdż 2012)。金融市場もまた複雑系の典型的な例として広く認識されており、市場における価格変動のゆらぎやその統計的パターンに関する分析等が数多く行われてきた。とりわけ、Battiston ら（2016）の提唱にもあるように、市場の不安定性に対処するためには、複雑系理論を含む数理的アプローチを積極的に取り入れる必要性があるとの指摘がなされており、こうした視点が国際的にも注目を集めている(Battiston et al. 2016; Jackson and Pernoud 2021; May, Levin, and Sugihara 2008; Saracco et al. 2016)。

上述のような数理的アプローチに基づく分析では、複雑な金融市場の全体像を定量的に捉える試みがなされており、価格変動に関する銘柄間の関係性や、取引構造の不均一性といった市場の特徴が明らかにされてきた。例えば、市場や経済状況が不安定化する局面においては、複数銘柄の取引時系列などにおいて、時系列間の強い相関構造が現れることが示されている。これに関連して、多数の金融時系列間の相関関係を複雑ネットワークとして可視化・俯瞰する手法も提案されており、時系列間の関係性を構造的に把握するための有力な枠組みとなっている(Bonanno, Lillo, and Mantegna 2001; Kwapień and Drożdż 2012; Sandoval and Franca 2012)。さらに、金融市場における市場参加者間の取引の関係性をネットワーク表現した研究(Musciotto, Piilo, and Mantegna 2021)では、このネットワーク構造の分析を通して市場参加者間の取引の不均一性を示し、取引の全体像が有する複雑さを明らかにしている。近年では、国際的な公的金融機関や政策当局者の間でも、ネットワーク科学等を用いて複雑な金融システムの状態を捉えるアプローチの有用性が認識されており、この複雑な構造に内在するリスクの検知を目的とした解析も進められている(Abad et al. 2016; Bardoscia et al. 2021; Yellen 2013)。

ここで、複雑に作用し合う多数の要素で構成される系に対しては、不安定化などの著しい状態変化（臨界的状態遷移）の予兆を捉える DNM（dynamical network marker）理論が提案されている。力学系の分野では、臨界的状態遷移が起こるのに先立ち臨界減速という現象が起き得ることが示されている(Scheffer et al. 2009)。この現象を、ネットワーク構造で表されるような複雑な影響関係をもった多数の要素間のダイナミクスに拡張し、臨界的状態遷移の前兆となる特徴的な現象を示したのが DNM 理論である(Aihara et al. 2022; Chen et al. 2012)。DNM 理論では、影響し合う要素のうち臨界減速に関与する要素集合を特定する手法を提案しており、その集合をマーカーとして用いることで、将来的な不安定性の予兆検知ができると期待される。特に、生体に適用する本理論は Dynamical network biomarker（DNB）と呼ばれる。例として、遺伝子制御ネットワーク上で DNB のマーカーを同定し、マーカーに属する遺伝子の発現量の変動を調べることで、発病に先立つ未病の状態を検知し得ることが示されている(Aihara et al. 2022; Chen et

al. 2012; Koizumi et al. 2019)。

個々の市場参加者の発注取引を要素としてもつ金融市場の構造を考慮すると、DNM 理論の適用により市場の不安定性の予測が可能だと期待されるが、そのような解析にあたっては市場の詳細なデータの解析が必要だと考えられる。金融市場では、「取引が取引を呼ぶ」といった市場参加者間の発注取引の相互作用を背景として、個々の市場参加者が発注取引を行うことで価格が変動していく(Hawkes 2018; Wheatley, Wehrli, and Sornette 2019)。しかし、我々が一般的に観察可能な情報は価格時系列に限られることがほとんどである。このことから、金融市場の不安定化に関する多くの先行研究では、市場参加者らの取引行為の結果である個別銘柄等の価格変動データを通して市場の状態を解析してきた(Bonanno, Lillo, and Mantegna 2001; Kwapień and Drożdż 2012; 青山ら 2008)。価格変動の素過程に対応する市場参加者ごとの発注取引を捉えられるような詳細データを分析することができた場合、市場参加者という因子が発注取引を通して相互作用する構造を定量化できる可能性がある。この構造に DNM 理論を適用することにより、市場の不安定性と市場参加者の振る舞いに関するこれまでにない知見が得られると期待できる。

そこで本研究では、東京証券取引所における詳細な板再現データを用いて市場参加者ごとの発注取引を定量化し、DNM 理論の適用により市場不安定化の予兆検知が可能か検討する。本分析で用いる板再現データには発注を行なった仮想サーバーのハッシュ化された ID が付されており、この情報を用いて、一つの市場参加者を発注取引態様が似通った仮想サーバーID 集合として定義する。そして、各市場参加者の発注取引を定量化した時系列を構成し、それに基づいて DNM 理論で提案されている DNM 指標を計算する。「この DNM 指標に基づいて、市場における価格の大きな変動を事前に予測できるか」ということを、本研究の問いとする。分析の結果、著しい市場不安定化については、日単位のタイムスケールで前兆を捉え得ることを示せた。ただし、本分析結果の頑健性や不安定性予兆検知の精度は、実務的な応用にむけた改善の余地があることから、本分析結果を踏まえて、今後の発展可能性と改善点について考察を行なった。

本論文の以降の構成を説明する。まず、2 章では 2.1 で DNM 理論について概説し、2.2 から 2.6 で実際の DNM 解析について説明する。具体的には、分析データの詳細、市場参加者の定義の仕方、各市場参加者の発注取引の定量化（時系列の構成）、DNM 理論適用の流れを示す。 その後、3 章の結果では DNM 指標の推移と市場不安定化のタイミングの比較を行い、市場不安定化の予兆と関連する市場参加者の特徴について議論する。最後に、4 章で考察を、5 章で結論を述べる。

2. 方法

2.1. DNM 理論について

まず、本研究の分析に取り入れる DNM 理論の概要を説明する（本論文の数式の記号を 6.2. 補論 2 にまとめた）。DNM 理論は、力学系の理論に基づく系の不安定性の予兆検知手法である。

本章では、力学系や力学系における安定性、臨界的状態遷移と、比較的新しく着目されている現象である臨界減速、近年提案された DNM 理論について概説する。まず、力学系と安定性の概要を説明する(Strogatz 2000)。

力学系では、状態Xの時間発展を漸化式

$$X(t+1) = f(X(t), \beta) \tag{1}$$

あるいは微分方程式

$$\frac{\mathrm{d}X}{\mathrm{d}t} = f(X, \beta) \tag{2}$$

によって記述し、その挙動や特徴を解析する（ここでβはパラメータを表す）。本論文では、9 時 1 分、9 時 2 分といった離散的な時間のもとで、離散時間力学系(1)を用いて系の振る舞いを記述する。力学系の解析においては、平衡点やその安定性は重要な検討対象となる。平衡点は、時間が進んでもその状態Xが変化しないような点のことである。この平衡点の安定性は、平衡点からわずかに状態が逸脱したときの挙動によって決まる。逸脱後、状態が平衡点に戻っていく場合はその平衡点は安定とみなされ、平衡点からさらに離れていってしまう場合は不安定とみなされる。したがって、安定平衡点に対応する状態は、外乱に対しても比較的頑健に保たれる状態であり、実際の観測対象として持続的に実現されやすいと考えられる。

臨界的状態遷移（分岐現象）とは、安定平衡点が不安定平衡点に切り替わるなど、力学系の振る舞いに質的な変化が生じる現象を指す。先述のように、力学系における状態の時間発展を記述する式 (1)にはパラメータ（β）が含まれており、一般的にはβの変化に伴い平衡点の値も連続的に変化する。しかし、こうしたゆるやかな量的変化とは異なり、例えば、あるβの値を境に平衡点の安定性が切り替わるような場合がある。このように力学系のふるまいが非連続的かつ質的に変化する現象全般を臨界的状態遷移と呼ぶ。この概念を応用の文脈で捉えると、パラメタβの値の変化は環境の変化に対応づけられる。したがって、βの変化により安定平衡点が不安定平衡点に切り替わるような臨界的状態遷移が生じることは、環境の変化によって安定的に実現していた状態が不安定化してしまうことだと解釈することができる。

ノイズを伴う力学系では、臨界的状態遷移に先立って臨界減速が生じる可能性が理論的に示されており、実証や応用に関する研究も進められている。理論的には、式(1)に確率的なノイズを加えた

$$X(t+1) = f(X(t); \beta) + \xi(t) \tag{3}$$

で記述されるランダム力学系を考慮する。ここで、$\xi(t)$は平均が0の正規分布に従う確率変数である。このようなランダム力学系においては、パラメタβが変化し臨界的状態遷移に近づくにつれ、状態$X(t)$がゆっくり大きく振動し、分散が著しく上昇したり自己相関が強まるといった「臨界減速」と呼ばれる現象が現れる。観察対象において臨界減速を捉えられれば、臨界的状態遷移の接近を予測できる可能性があるため、これを用いて早期警戒指標を構築する研究も進められている。実証の観点からは、多くの実世界の事象において状態に確率的ゆらぎ（ノイズ）が存在するという仮定は妥当と考えられ、臨界減速理論が広範な対象への応用可能性をもつこ

とが期待される。実証研究の例としては、ある種の個体数$X(t)$に着目し、集団絶滅に先立って$X(t)$の振る舞いに臨界減速が見られることを報告した研究や、金融危機前の経済時系列$X(t)$に臨界減速が見られるか分析した研究、さらに臨界減速を用いた金融危機の予測手法の構築と評価を行った研究などがある(Battiston et al. 2016; Drake and Griffen 2010; Scheffer et al. 2009; Song and Li 2024)。

近年、互いに影響し合う多数の因子の振る舞いに対して臨界減速の概念を拡張・定式化したDNM（Dynamical Network Marker）理論が提案され、不安定性の予兆検知への応用が試みられている(Aihara et al. 2022; Chen et al. 2012; Masuda, Aihara, and MacLaren 2024)。DNM 理論では、多数の因子間の複雑な関係性（各頂点が各因子を表し各辺が因子間の関係性を表すようなネットワーク）が背景にあることを仮定した上で、各因子の状態の時間変化を考慮する。数学的には、各因子の状態が

$$X_i(t+1) = f_i(\boldsymbol{X}(t); \beta_i) + \xi_i(t) \tag{4}$$

に従って時間変化するような多数の因子の状態変化（高次元力学系）

$$\boldsymbol{X}(t) = \big(X_1(t), \dots, X_i(t), \dots, X_N(t)\big) \tag{5}$$

を考える（ノイズ$\xi_i(t)$は平均が0の正規分布に従う確率変数）。このような系を解析すると、臨界的状態遷移の直前には、それに寄与する因子集合Iが出現し、Iに含まれる各因子の状態$X_i(t)$が大きくゆらぐとともに、Iに含まれる因子同士の状態が強く（正または負に）相関することが示されている(Aihara et al. 2022; Chen et al. 2012)。本論文では、上述のような因子集合Iを DNM 集合と呼ぶことにする。特に、生体システムに DNM 理論を適用した DNB（Dynamical Network Biomarker）理論では、因子として遺伝子を、ネットワークとして遺伝子制御ネットワークを考慮し、発病に先立つ未病の検知を目的とした実証・理論研究が盛んに行われている(Aihara et al. 2022; Koizumi et al. 2019)。

DNM 理論の実証研究では、互いに相互作用し合う多数の因子から DNM 集合を抽出し、その振る舞いに基づいて将来の不安定性の予兆を検知できるかが議論されている。DNM 理論を実際の現象に適用する前提として、式(4)のような力学系が背景に存在し、その力学系に基づく状態の時間変化の結果として、分析対象とする多変量時系列（式(5)）が得られるとみなせる必要がある。ただし、関数fの具体的な記述は解析には用いない。実際の解析では、ある因子集合$U(\subset \{1, \dots, N\})$に含まれる各因子の時系列ゆらぎの平均を表す$\mathrm{SD}_U$、集合内の因子同士の時系列相関の平均を表す$\mathrm{PCC}_U$、集合内外の因子間の時系列相関の強さの平均を表す$\mathrm{PCC}_{\overline{U}}$、およびこれらを統合した指標$D_U$が考慮される：

$$\mathrm{SD}_U = \frac{\sum_{i \in U} \mathrm{SD}\,(X_i)}{\#U}, \tag{6}$$

$$\mathrm{PCC}_U = \frac{\sum_{i,j \in U, i \neq j} \left|\mathrm{PCC}\big(X_i, X_j\big)\right|}{\#U(\#U - 1)}, \tag{7}$$

$$\mathrm{PCC}_{\overline{U}} = \frac{\sum_{i\in U, j\in\overline{U}} \left|\mathrm{PCC}(X_i, X_j)\right|}{\#U\#\overline{U}}, \tag{8}$$

$$D_U = \frac{\mathrm{SD}_U \cdot \mathrm{PCC}_U}{\mathrm{PCC}_{\overline{U}}}. \tag{9}$$

ここで、$\mathrm{SD}(X_i)$はX_iの標準偏差、$\mathrm{PCC}(X_i, X_j)$はX_iとX_jのピアソン相関係数、$|\cdot|$はその絶対値、$\#A$は集合Aの要素数をそれぞれ表す。理論的には、もしUが DNM 集合である場合、臨界的状態遷移が近づくにつれてSD_Uが発散し、PCC_Uは1に、$\mathrm{PCC}_{\overline{U}}$は0に収束する。その結果、$D_U$も発散する。したがって、DNM 集合$I$は、過去の多変量時系列データにおいて、系が不安定化する直前にD_Uが非常に大きくなる、つまり最大となるような集合Uとして定まる。以降、SD_I、PCC_I、$\mathrm{PCC}_{\overline{I}}$、$D_I$を総称して「DNM 指標」と呼ぶ。補足として、DNM 指標のうちD_Iは多くの実証研究で使用される一方で、不安定性の予兆は特にSD_Iに安定して反映されることが先行研究で示唆されている(Masuda, Aihara, and MacLaren 2024; 中川・奥・合原 2016)。そして、DNM 集合Iのもとで計算したD_Iの上昇を基に将来的な系の不安定性の予兆を捉えられると期待でき、その有効性はすでに一部の研究で評価されている。

本研究では、多数の市場参加者の取引態様を表す多変量時系列に対して DNM 理論を適用し、市場不安定性に関する予兆検知の可能性を検討する。具体的には、上述の DNM 理論における「因子」を一市場参加者に対応づけ、各市場参加者の発注取引態様を定量化した時系列$x_i(t)$に着目する。市場におけるハーディング行動や「取引が取引を呼ぶ」[1]効果等を考慮すると、各市場参加者の発注取引態様$x_i(t)$は他者の発注取引$x_j(t)$（$i \neq j$）の影響を受けて変化すると考えるのが自然である。したがって、市場参加者間の複雑な相互作用を背景に、各市場参加者の発注取引態様$x_i(t)$が何らかの関数fを介して式(4)のように変化する高次元力学系を仮定することができる。このような仮定の下で、多変量時系列$\boldsymbol{x}(t) = (x_1(t), \ldots, x_N(t))$に DNM 理論を適用し、市場参加者の発注取引における不安定性の予測可能性について検討する。本節で理論的背景を述べた上で、次節からは実証分析の手法について説明する。

2.2. 分析対象データの概要

本研究では、日本取引所グループ提供の東京証券取引所の板再現データを分析対象とした。分析対象期間は、東証 arrowhead のリプレースに伴い ServerID の振り直しが行われた 2019 年 11 月 5 日から、2023 年 3 月 31 日までである。このうち、特に 2019 年 11 月 5 日から 2020 年 12 月 31 日までのデータ（延べ 20,496,855,295 のレコード）を詳細に分析した。この期間には、新型コロナウイルス感染症の流行を受けて金融市場が不安定化した、2020 年 3 月のコロナショ

[1] 発注や取引により板や価格が変化し、それに基づいてさらに発注取引が行われていく状況。特に、価格の上昇に伴い買いが増えてさらに価格の上昇トレンドが生まれる「買いが買いを呼ぶ」ような状況や、その逆の「売りが売りを呼ぶ」ような状況があり、これらの状況は投資家の焦りのような心理状態とも関連する。

ックが含まれている。銘柄については、通常の普通株、転換社債型新株予約権付社債(CB)、優先株やライツ・オファリングに伴う新株予約権のうち、通常の普通株のみを分析対象とした。

2.3. 市場参加者の定義

本節では、市場参加者の定義方法について説明する。先述のように、本研究では市場参加者（i）ごとに発注取引時系列$x_i(t)$を構成し、これらを集めた多変量時系列$\boldsymbol{x}(t) = (x_1(t), \ldots, x_N(t))$を分析対象とする。このとき、一市場参加者をどのように定めるかが重要となる。最も単純な方法としては、一つの仮想サーバーID（ServerID）を一つの市場参加者に対応づけることが考えられる。しかし実際には、単一の市場参加者（あるいは取引主体）が複数のServerID を使い分けており、一市場参加者の振る舞いを捉えるためには、複数の ServerID による注文をまとめて扱う必要がある。また、本分析で用いるデータには、ServerID の使用者や、その使い分けに関する情報が含まれていない。そこで本研究では、以下に述べる Trading desk の考え方と、発注取引の特徴ベクトルに基づく ServerID のクラスタリングに基づいて、複数のServerID からなる集合を一つの市場参加者として定義づける方法を検討した。

2.3.1. Trading desk

複数の ServerID をまとめて一市場参加者のものとみなす方法について、いくつかの先行研究ではTrading desk という考え方を取り入れている(Goshima, Tobe, and Uno 2019; Sato and Kanazawa 2023; 山田 2023)。この考え方では、新規発注から変更や取消等に至る個別注文のライフサイクルを把握するのに有用な、個別注文の識別番号（OrderID）に着目する。OrderID と ServerID について、実際にデータの各レコードの対応関係を調べると、同一 OrderID が付された新規、変更、取消注文等が異なる ServerID から発せられている様子をしばしば確認できる。先行研究では、同一 OrderID の発注を行ったことがある ServerID の集合を一つの取引主体である Trading desk とみなしている。

本研究においても、ServerID を Trading desk 単位へとグルーピングした。具体的には、2019 年 11 月 5 日から 2023 年 3 月 31 日までに稼働した6,780の ServerID による注文の OrderID を調べ、各 OrderID αについて、その OrderID が付された発注を行ったことがある ServerID の集合をA_αとした。このようにして構成された集合族$\{A_\alpha\}$について、「もし集合A_αと集合$A_{\alpha'}$に共通した ServerID が含まれる（$A_\alpha \cap A_{\alpha'} \neq \phi$）ならば、$A_\alpha$と$A_{\alpha'}$をマージして新たな ServerID 集合$A_\alpha \cup A_{\alpha'}$を作る」という操作を、これ以上 ServerID 集合同士をマージできなくなるまで（$A_\alpha \cap A_{\alpha'} \neq \phi$となる$(\alpha, \alpha')$が無くなるまで）繰り返した。この操作により得られた集合族について、各要素を一つの Trading desk とみなすこととした。したがって、一つの Trading desk は、2019 年 11 月から 2023 年 3 月までの間に「同一 OrderID の発注をしたことがある」という事実に基づいてできる限り ServerID を集めた結果特定できた集合となっている。ここで注意すべき点として、実際には同一取引主体に扱われている ServerID であっても同一 Trading desk に含まれない場合がある。一方で、一つの Trading desk に含まれる ServerID は、Trading desk の定義上、ほぼ確実

に同一取引主体により扱われているものだと考えられる。本研究で特定したTrading deskは2019年 11 月 5 日から 2023 年 3 月 31 日の期間において延べ2,941存在した。各月における Trading desk 数は、図 1 のように推移していた。図 1 では Trading desk 数が著しく減少するような様子等が見られるが、これは、ServerID が新規に参入したり使われなくなる等して常時入れ替わっていることと、先述のように、実際には同一取引主体に扱われている ServerID であっても同一 Trading desk として捉えられていない場合があるためである。

さらに、先行研究(山田 2023)を参考にし、Trading desk を「HFT」「証券会社自己」「一般投資家」「その他」の四つのタイプに分類した。山田 (2023)では、先行研究で提案された分類手法を取り入れ(大山・津田 2020; 保坂 2014)、以下のような発注取引態様に関する条件に基づいて Trading desk のタイプを判別しており、本研究でも同様の基準を用いる。まず、「HFT」の Trading desk は、次の条件に基づいて選定する。

1. 約定率 ≤ 25%、
ただし、約定率 = 約定件数/新規注文件数
2. 取消率 ≥ 20%、
ただし、取消率 = 取消注文件数/新規注文件数
3. 成行注文割合 1%未満
4. 手動注文割合 0.1%未満

上述の基準 1、2 をサーバー稼働日の40%以上、基準 3 を同60%以上満たすものを「HFT」とする。ここで、分析データには基準 4 のために必要な手動注文に関する情報が提供されていなかったため、山田 (2023)と同様に基準 1〜3 を用いた。次に、「HFT」以外の Trading desk の中から、自己委託区分が「自己」となっている Trading desk を「証券会社自己」と判別する。さらに、「HFT」でも「証券会社自己」でもない Trading desk のうち、次の条件をサーバー稼働日の40%以上で満たす Trading desk はリテール証券会社のものと推定される。これらの Trading desk を「一般投資家」とラベル付ける（山田 (2023)では「個人投資家」として言及している）。

5. 約定代金ベースの信用取引比率が0%より大きい。
6. 約定代金ベースの委託注文比率が99%より大きい。
7. 約定代金ベースの空売り注文の99.5%以上が信用取引による。
8. 新規注文から注文取消までの平均生存時間が5秒以上である。
9. 約定代金が　当日の総約定代金の0.1%以上である。

最後に、「HFT」、「証券会社自己」、「一般投資家」のいずれにも当てはまらない Trading desk は「その他」とラベル付けする。山田 (2023)では、「その他」として、海外投資家や市場参加者登録をしていない国内機関投資家などが想定されると指摘している。

本研究でも、2019 年 11 月 5 日から 2020 年 12 月 30 日における通常の普通株に関する発注取引データに対し山田 (2023)と同様の条件を適用し、当期間に稼働していた2,136の Trading desk を四種類に分類した。その結果、「HFT」、「証券会社自己」、「一般投資家」、「その他」の Trading desk を、それぞれ532、373、146、1,085ずつ特定することができた。なお、これらのラベル

は、各 Trading desk を「四タイプのうちどのタイプらしく振る舞っているか」という観点に基づいて特徴づけたものであり、実際の取引主体を確定的に識別するものではない点に注意が必要である。

2.3.2. 特徴ベクトルに基づく ServerID クラスタリング

本研究では、OrderID に基づく Trading desk の特定に加え、発注取引態様の類似性に基づいて ServerID をクラスタリングし、市場参加者を定義づける方法も検討した。大山・津田(2022)では、2010 年 1 月から 2015 年 9 月の全営業日における本研究と同様のデータを用いて、ServerID を階層クラスタリングによって250程度のクラスタに分類し、それぞれのクラスタに含まれる ServerID の発注取引の特徴を分析している。そこでは、「*変更注文を行わず下3桁まで取消件数が同じ（6 桁のうち上 3 桁が等しい）クラスター*」（大山・津田，2022）のように互いに著しく似通った ServerID で構成されるクラスタが見つかっている。このような発注取引態様の類似性に基づく ServerID クラスタリングで得られる各クラスタも、一つの市場参加者に対応するものと期待できる。

そこで本研究でも、大山・津田(2022)を参考に ServerID の階層クラスタリングを行い、クラスタ数が250となるようなクラスタ構造を得た。具体的には、各日（d）について、各 ServerID（s）の表 1 に示す32項目の件数と、分析対象銘柄のそれぞれに対する注文数を要素としてもつ特徴ベクトル$\mathbf{e}^{d,\,s} := (e_1^{d,s}, \ldots, e_k^{d,s}, \ldots, e_K^{d,s})$を構成した。ここで分析対象銘柄は、2019 年 11 月 5 日から 2020 年 12 月 30 日の間に発注取引があった通常の普通株4,164銘柄としている。したがって、各日の特徴ベクトルの次元 Kは$4{,}196 (= 4{,}164 + 32)$である。また、分析対象期間の最後の三ヶ月間に新たに稼働を始めた ServerID をクラスタリングの対象から除外し、2019 年 11 月 5 日から 2020 年 9 月 30 日までに稼働していた ServerID を分類対象とした。さらに、$\mathbf{e}^{d,s}$を分析対象期間の日数（$D = 282$日）分並べた$(K \times D)$次元ベクトルを考え、ServerID sと ServerID s'の距離を、それぞれの$(K \times D)$次元ベクトル間のユークリッド距離

$$\sqrt{\sum_{d=1}^{D}\sum_{k=1}^{K}(e_k^{d,s} - e_k^{d,s'})^2} \tag{10}$$

で与えた。この距離に基づき、ウォード法を用いて ServerID の階層クラスタリングを行った。よって、このクラスタリングで得られるクラスタは、各種注文数や発注銘柄が特に似通った ServerID の集合となる。ここで、特徴ベクトルを構成するにあたり、d日に ServerID sのレコードが存在しない場合には$\mathbf{e}^{d,s} = \mathbf{0}$とした。これにより、同日に稼働していない ServerID 間の距離が相対的に大きくなり、稼働期間が似ている ServerID が同一クラスタに入りやすくなっている。そして階層クラスタリングの結果に対し、クラスタ数が250になるように閾値を定め、クラスタ構造 $\tilde{C} = \{\tilde{C}_1, \ldots, \tilde{C}_j, \ldots, \tilde{C}_{250}\}$（$\tilde{C}_j$は一つのクラスタ）を得た（図 2）。

表 1　ServerID の階層クラスタリングに用いた項目。

項目の分類	項目
レコード種別	新規注文、約定、変更注文、取消注文、注文失効、取消新規処理、引け処理
業務ステータス	注文受付時間中、終値引け成立
信用区分	現金取引、信用新規、信用弁済
自己委託区分	委託、自己
成行注文	成行注文総数
売買単位	売買単位 100 の回数
約定までの時間（速さ）	0.0005秒以内、0.0005秒～0.005秒、0.005秒～0.5秒、0.5秒～1秒、1秒～1分、1分～10分、10分～1時間、1時間以内
取消までの時間（速さ）	0.0005秒以内、0.0005秒～0.005秒、0.005秒～0.01秒、0.01秒～0.1秒、0.1秒～0.5秒、0.5秒～1秒、1秒～1分、1分以内に取消

上述の、全日（D日）の発注取引態様を考慮したクラスタリング結果$\tilde{C}$の頑健性を確認するために、改めて各日の発注取引態様のみに基づいて ServerID クラスタリングを行い、その結果と$\tilde{C}$を比較した。各日（d日）の発注取引態様のみを考慮したクラスタリングでは、 K次元特徴ベクトル$\mathbf{e}^{d,s}$に基づいて ServerID の階層クラスタリングを行い、クラスタ構造$\hat{C}^d = \{\hat{C}_1^d, \ldots, \hat{C}_j^d, \ldots, \hat{C}_{250}^d\}$を得た。そして全日分に基づくクラスタ構造$\tilde{C}$の各クラスタ$(\tilde{C}_j)$について、各日のクラスタ構造$\hat{C}^d$の中に$\tilde{C}_j$と全く同じ SererID で構成されているクラスタ$\hat{C}_{j'}^d$が存在するか確認した。その結果、全日（282日）のどの日dについても、全く同じ ServerID で構成されたクラスタ$\hat{C}_{j'}^d$がそれぞれ見つかるような$\tilde{C}$のクラスタ$\tilde{C}_j$も見つかった。つまり、クラスタ$\tilde{C}_j$は、全日分の発注取引態様に基づくクラスタリングでも、いずれかの日の発注取引態様のみに基づくクラスタリングでも、ロバストに同じ ServerID の集合として取り出されるクラスタである。上述の議論を拡張し、$\tilde{C}$の各クラスタ$\tilde{C}_j$について、全く同じ ServerID で構成されるクラスタ$\hat{C}_{j'}^d$が何日分で見つけられるか、つまり$\#\{d; \tilde{C}_j = \hat{C}_{j'}^d$となる$j'$が存在$\}$を、クラスタ$\tilde{C}_j$の頑健性とおくことにする。全日数の発注取引態様に基づくクラスタリング結果$\tilde{C}$については、頑健性が200以上となるクラスタが39存在するなど、頑健性の高いクラスタが多々見受けられた。

さらに、全日数の発注取引態様に基づくクラスタリング結果$\tilde{C}$と Trading desk の関係を確認したところ、互いに一貫性の強い結果が得られた。具体的には、2,033の Trading desk のうち、同一 Trading desk に含まれる ServerID が異なるクラスタに分類されるという事象が起きた Trading desk 数は60であり、全体のごく一部であった。つまり、ほとんどの場合、同一 Trading desk に含まれる ServerID は同一クラスタに含まれていた。ServerID クラスタリングでは、Trading desk の特定に用いる OrderID の情報は考慮されていない。それにも関わらず、ServerID クラスタリングの結果と Trading desk の間に一定の対応が見られることは、発注取引態様に基づくクラス

タリングによって取引主体や市場参加者を定義づける手法の有効性を示唆していると考えられる。

上述のような、発注取引態様に基づくクラスタリング結果の頑健性や Trading desk との対応、そして二百程度のクラスタ数という扱いやすい数量を考慮し、本研究ではクラスタリング結果$\tilde{C}$をベースに市場参加者を定義づけることとする。ただし、一部 Trading desk との齟齬を解消するための調整を行った。具体的には、まず同一 Trading desk に含まれる ServerID が、クラスタ構造$\tilde{C}$において複数の異なるクラスタに含まれてしまった場合、それらのクラスタの中で最も高いロバスト性$\#\{d; \tilde{C}_j = \hat{C}_{j'}^d$となる$j'$が存在$\}$をもつクラスタにその Trading desk 内の全ての ServerID を移動する操作を行った。その結果、198のクラスタで構成されるクラスタ構造$C = \{C_1, \dots, C_i, \dots, C_{198}\}$が得られた。この操作により、各クラスタが複数の Trading desk から構成され、さらに各 Trading desk が複数の ServerID から構成されるという階層構造が形成される。次に、Cの各クラスタを構成する Trading desk の種類（「HFT」、「証券会社自己」、「一般投資家」、「その他」のいずれか）を確認した。その結果、Cの198クラスタのうち182クラスタが同一種の Trading desk で構成されており、ここでも市場参加者の定義づけをする上での発注取引態様に基づくクラスタリングの有用性が支持されている。最後に、複数種の Trading desk で構成された16クラスタに着目し、それらのクラスタに含まれる全ての Trading desk を、その種類に沿って、「HFT-残り」、「証券会社自己-残り」、「一般投資家-残り」、「その他-残り」の四グループに再分類した。これら四グループに含まれる ServerID による発注件数（新規注文、変更注文、取消注文）は、全 ServerID の発注件数の8.1%に抑えられた。最終的な市場参加者の定義づけとして、まずクラスタ構造Cのクラスタのうち同一種の Trading desk で構成されている各クラスタ（C_i）を一つの市場参加者（i）とした。加えて、「HFT-残り」、「証券会社自己-残り」、「一般投資家-残り」、「その他-残り」の一つ一つをそれぞれ市場参加者とみなすことにした。上述の操作により、全てのクラスタがそれぞれ同一種の Trading desk で構成されるようになり、各市場参加者に対して HFT、証券会社自己、一般投資家、その他のいずれか一つのタイプを対応づけられた。

最後に、これまでに説明した市場参加者の定義づけについてまとめ、本研究における市場参加者の解釈について述べる。本研究では、全日数の発注取引態様に基づく ServerID クラスタリングの結果について、Trading desk やその種類と齟齬が無いように調整を施した後、概ね一つのクラスタを一つの市場参加者とみなすこととした（例外として、「HFT-残り」、「証券会社自己-残り」、「一般投資家-残り」、「その他-残り」の四つの市場参加者も加えた）。このようにして特定された市場参加者の総数は186であり、その種類別の数としては、「HFT」が68、「証券会社自己」が25、「一般投資家」が3、「その他」が90である。重要な留意点として、本研究における「市場参加者」は、Trading desk のように明らかに取引主体に対応するものではない。本分析の「市場参加者」の中には、実際には取引主体が異なる Trading desk で構成されているものも多々あると考えられる。加えて、「一般投資家」に分類された Trading desk に属する ServerID からの発注取引は、リテール証券会社などを通じて行われた多数の投資家による取引を集約した

ものである。したがって、本研究における「市場参加者」は、あくまで分析対象期間において発注取引態様が類似した ServerID を含む Trading desk をまとめたものである。以降の議論においても、「ある市場参加者の発注取引時系列」は「特定の発注取引態様の特徴を示す ServerID 集合の発注取引時系列」を意味することに留意されたい。

2.4. DNM 解析のタイムスケール

本節では、次節で市場参加者ごとの発注取引時系列を構成するに先立ち、DNM 解析におけるタイムスケールについて説明する。本研究では、日単位で DNM 指標を算出し、市場の不安定化についても日単位で特定した上で、これらを比較することで日単位の不安定性の予兆検知の可能性を検討する。複雑系の観点から市場の不安定性を議論する先行研究では、時間、日、年単位など様々なタイムスケールで予兆検知が試みられている(Battiston et al. 2016; Oya, Aihara, and Hirata 2014; Saracco et al. 2016; Song and Li 2024)。その中でも、例えば Song and Li (2024)では、日単位の定量的解析に基づいて不安定化の予測可能性が示唆されている。一方、分析対象期間における東証の取引時間は前場（9:00～11:30）と後場（12:30～15:00）に分かれており、各場において取引開始直後や終了直前に注文が集中するなど、時間帯ごとのトレンドが存在する。また、場を跨いで発注取引の様子が不連続になる。特に、後場から翌営業日の前場にかけては、海外市場の情報流入により、発注取引態様が大きく変化し得る。以上のような場を跨ぐ際の不連続性を踏まえて、まず各営業日の場毎に DNM 指標を計算することとした。さらに、市場参加者ごとの発注取引数や指標の値を確認したところ、その大小が前場か後場かに依存する様子も確認された。そこで、各日について前場・後場における指標の値を平均して平滑化し、最終的には、日単位で DNM 指標を定めることとした。

上述のタイムスケールで DNM 指標を算出するにあたり、各市場参加者について日・場ごとの発注取引時系列を構成する必要があるが、この時系列の時間の単位としては分単位を採用した。具体的には、ある日・場における市場参加者iの発注取引時系列$x_i(t)\ (t = 0,1, \dots, T)$の構成に際し、時間$t$の単位を1分とした。各場は150分であるため、時系列$x_i(t)$の長さは開始・終了時刻も含め$150\ (T = 150)$である。時間単位を1分とした理由は以下の通りである。まず、時間単位が1秒など非常に短い場合、$x_i(t)$の値が小さくなり、多くの時点tにおいて$x_i(t) = 0$となるため、統計的解析に適さないと判断した。一方、時間単位が1分よりも長い場合には、時系列の長さが短くなり、DNM 指標を算出する際のデータサイズが不十分になる（例えば、SD_Uの計算には$x_i(t)\ (t = 0,1, \dots, T)$の標準偏差を用いる）ことから、これも適切ではないと判断した。

2.5. 発注取引多変量時系列の構成

本節では、市場参加者の発注取引態様を表した多変量時系列の構成の詳細と時系列の前処理について述べる。2.1 で説明したように、本研究では、まず市場参加者（i）ごとの発注取引態様を表した時系列$x_i(t)$を構成する。ここで、2.4 の検討をふまえ、時系列$x_i(t)$は各日・場に対して構成し、この時系列の時間の単位は1分とする。

時系列$x_i(t)$の構成に際しては、市場参加者の発注取引態様を様々な視点から反映するために、総計36種類の時系列を考えることとした（表 2–4）。本研究で DNM 解析への適用を検討した時系列は、大別すると(1)発注取引数量に着目したもの（表 2）、(2)市場参加者間の発注取引銘柄の共有に着目したもの（表 3）、(3)発注取引点過程に着目したもの（表 4）の三通りである。それぞれの時系列については、例えば(1)の場合、「買いの指値注文の数量」のみをカウントするなどして、発注取引の種類別に時系列を構成した。以下、(1)–(3)の時系列の詳細を説明する。

2.5.1. 発注取引数量に着目した時系列

まず(1)発注取引数量に着目した時系列については、各市場参加者（i）について、単位時間tあたりの発注取引数量の総数を表すものとした。ここで、数量については、表 2 のような発注取引の種類別に足し上げ、それらの種類に従い、vol1からvol9の9種類の時系列$x_i(t)$を構成した。

表 2　発注取引数量に着目した時系列の種類。発注取引に関し、「全注文」は新規・変更・取消注文を合わせたものを指す。図における略称では、V が数量（volume）、O が発注（order placement）、E が約定（execution）、MO が成行注文（market order）、LO が指値注文（limit order）、b が買い（buy）、s が売り（sell）を示す。

記号	図における略称	発注取引	成行/指値	買/売
vol1	V_O_MO_b	新規注文	成行	買
vol2	V_O_MO_s	新規注文	成行	売
vol3	V_O_LO_b	新規注文	指値	買
vol4	V_O_LO_s	新規注文	指値	売
vol5	V_E_MO_b	約定	成行	買
vol6	V_E_MO_s	約定	成行	売
vol7	V_E_LO_b	約定	指値	買
vol8	V_E_LO_s	約定	指値	売
vol9	V_all_order	全注文	成行・指値	買・売

表 3　市場参加者間の発注取引銘柄の共有に着目した時系列の種類。図における略称では、C が銘柄共有（数量による重み付けを考慮しない）、CW が銘柄共有（数量による重みを考慮）を表し、その他は表 2 と同様の記号を用いる。

記号	図における略称	発注取引	成行/指値	重み	買/売
co1	C_O_MO_b	新規注文	成行	0, 1	買
co2	C_O_MO_s	新規注文	成行	0, 1	売
co3	C_O_LO_b	新規注文	指値	0, 1	買

記号	図における略称	発注取引	成行/指値	重み	買/売
co4	C_O_LO_s	新規注文	指値	0, 1	売
co5	C_E_MO_b	約定	成行	0, 1	買
co6	C_E_MO_s	約定	成行	0, 1	売
co7	C_E_LO_b	約定	指値	0, 1	買
co8	C_E_LO_s	約定	指値	0, 1	売
co9	C_all_order	全注文	成行・指値	0, 1	買・売
co1’	CW_O_MO_b	新規注文	成行	数量	買
co2’	CW_O_MO_s	新規注文	成行	数量	売
co3’	CW_O_LO_b	新規注文	指値	数量	買
co4’	CW_O_LO_s	新規注文	指値	数量	売
co5’	CW_E_MO_b	約定	成行	数量	買
co6’	CW_E_MO_s	約定	成行	数量	売
co7’	CW_E_LO_b	約定	指値	数量	買
co8’	CW_E_LO_s	約定	指値	数量	売
co9’	CW_all_order	全注文	成行・指値	数量	買・売

表 4　発注取引点過程に着目した時系列の種類。図における略称では、P が点過程時系列を表し、その他は表 2 と同様の記号を用いる。

記号	図における略称	発注取引	成行/指値	買/売
pp1	P_O_MO_b	新規注文	成行	買
pp2	P_O_MO_s	新規注文	成行	売
pp3	P_O_LO_b	新規注文	指値	買
pp4	P_O_LO_s	新規注文	指値	売
pp5	P_E_MO_b	約定	成行	買
pp6	P_E_MO_s	約定	成行	売
pp7	P_E_LO_b	約定	指値	買
pp8	P_E_LO_s	約定	指値	売
pp9	P_all_order	全注文	成行・指値	買・売

2.5.2.　市場参加者間の発注取引銘柄の共有に着目した時系列

次に、(2)市場参加者間の発注取引銘柄の共有に着目した時系列については、市場の内生的な不安定性（Systemic risk）と金融時系列の相関構造に関する先行研究(Bonanno, Lillo, and Mantegna 2001; Kwapień and Drożdż 2012; Podobnik et al. 2010; Sandoval and Franca 2012; Zheng et al. 2012)を参考に、同時刻に同銘柄に対して発注取引を行った市場参加者ペアの振る舞いを反映させた時系列を構成した。市場の不安定性と取引の全体像の関係を調べた先行研究では、市場が外生要

因によってではなく特に内生的に不安定化する際に、個々の銘柄やインデックスの価格時系列等の間に強い相関関係が生まれることが示されている。この事象については広範な分析が行われており、その一例として、銘柄（インデックス）間相関の全体像をネットワーク表現する手法やネットワーク解析に基づいて市場の状態を定量化する手法も検討されてきた(Bonanno, Lillo, and Mantegna 2001; Kwapień and Drożdż 2012; Song et al. 2011)。本研究では、板再現データを用いた分析から、銘柄間相関を生み出す素過程に対応する市場参加者間の発注取引銘柄の共有に着目して時系列を構成することとした。具体的な時系列の構成としては、まず表 3 のco1からco9で示したような発注取引種のそれぞれについて、秒単位で各時点（$\tilde{t}$）における市場参加者iから銘柄σへの各種発注取引の有無を1，0で示した$y_{i,\sigma}(\tilde{t})$を構成した。ここでは、常に十分な取引が行われている銘柄のみを対象とするため、データにおいて分析対象期間を通して各日におけるレコード数が10,000件以上となる547銘柄を選定し、分析に用いた。これらの時系列を用いて計算した

$$z_{i,j}(\tilde{t}) = \sum_{\sigma} y_{i,\sigma}(\tilde{t}) y_{j,\sigma}(\tilde{t}) \tag{11}$$

は、時刻$\tilde{t}$において、市場参加者iとjがいくつの銘柄に対して同時に各種の発注取引を行っていたかを表す。さらに、発注取引銘柄の共有関係における各市場参加者（i）の中心性$\sum_j z_{i,j}(\tilde{t})$を算出し、それを分単位（$t$）で足し上げた時系列を

$$x_i(t) = \sum_{\tilde{t}=1}^{60} \sum_{j} z_{i,j}(\tilde{t}) \tag{12}$$

のように構成し、(2)市場参加者間の発注取引銘柄の共有に着目した9種類（co1～co9）の時系列$x_i(t)$を定めた。加えて、銘柄共有関係について、市場参加者同士の発注取引数量で重み付けをした時系列も構成した。具体的には、表 3 のco1′からco9′で示したような発注取引種について、秒単位$\tilde{t}$で市場参加者iから銘柄σへの各種発注取引数量を示した$y_{i,\sigma}'(\tilde{t})$を構成し、co1からco9の時系列と同様の手順で9種類の時系列co1′からco9′も構成した。これらの時系列種に関する結果は 6 章補論で示す。

2.5.3.　発注取引点過程に着目した時系列

(3)発注取引点過程に着目した時系列に関しては、時々刻々と発注取引が起きていく様子を定量化して時系列を構成することを検討した。ここで、一般的に、点過程時系列はイベントが起きた時刻の系列を指す。本研究では、発注・取引をイベントとみなし、これらの発生時刻（発注・取引レコードのタイムスタンプ）によって構成される点過程時系列に着目した。発注取引点過程では、発生時刻は時間的に非一様に分布しており、ある短時間に多くの発注や取引が集中したり、長期間何も起こらない場合もある。このように、点過程時系列は一般的な時系列と異なり単位時間あたりの数量を示すものではないことから、DNM 解析にそのまま適用することはできない。そこで、単位時間あたりの部分点過程の特徴を定量化することで一般的な時系

列を構成し DNM 解析に適用することとした。部分点過程の定量化に関し、先行研究では点過程における不均一なイベントの起こり方を数値化する様々な手法が提案されている(Bacry, Mastromatteo, and Muzy 2015; Hawkes 2018; Hirata and Aihara 2015; Karsai, Jo, and Kaski 2018)。それらの中でも、Hawkes 過程モデルのもとで発注取引発生の背景を解析することや、点過程の非一様性を測る指標を用いることを検討した。前者の Hawkes 過程モデルを用いる方法に関しては、6.1. 補論 1 に示すように、当モデルのもとで発注取引を引き起こす内生・外生要因の強さに対応するパラメータを推定し、これらの強さの時間変化を反映させて時系列を構成することを試みた。ここで、Hawkes 過程は、イベントがさらにイベントを誘発することを仮定した点過程モデルであり、多くの金融点過程時系列解析で用いられている。しかし、本分析における発注取引点過程については、特に「HFT」や「その他」タイプの市場参加者の点過程時系列において Hawkes 過程とは合わないような強い周期性がしばしば見られた。そのことから、(3)の時系列として、Hawkes 過程に基づく構成はし難いと判断し、後者の点過程の非一様性の指標を反映して構成することとした。

上述のような検討を経て本分析で構成した(3)発注取引点過程を考慮した時系列について、詳細を以下に説明する。まず各市場参加者（i）に対し、表 4 に示す発注取引の種類ごとに、点過程時系列$\{t_j^i\}$を構成した。ここでt_j^iは、市場参加者iによるj番目の当該種の発注取引が行われた時刻を表す。そして、単位時間tに対し、点過程$\{t_j^i\}$についてtから$t+1$の間に入る部分点過程$\{t_j^i;\ j=j_1,\dots,j_m,\ t\le t_{j_1}^i\le\cdots\le t_{j_m}^i<t+1\}$を考える。この部分点過程の不均一性を表す指標の値を$x_i(t)$として、9 種類の時系列pp1～pp9（表 4）を構成した。

部分点過程の不均一性指標の具体的な算出においては、部分点過程のイベント間隔$\Delta_j^i:=t_j^i-t_{j-1}^i$の不均一性に着目する。このイベント間隔の変動係数 CV（標準偏差を平均で除した値）

$$\mathrm{CV}=\frac{\sqrt{\mathrm{Var}\left(\Delta_j^i\right)}}{\langle\Delta_j^i\rangle} \tag{13}$$

（$\langle\cdot\rangle$は平均を表す）は、点過程の不均一さを表す指標として広く用いられている(Karsai, Jo, and Kaski 2018; Hirata and Aihara 2012)。しかし、CV の値は統計的な要因により点過程サイズにも依存してしまうことが指摘されており(Kim and Jo 2016)、実際に構成した単位時間あたりの部分点過程サイズも、市場参加者（i）や時点（t）、発注取引種類に依存して著しく異なる値を取ることが確認された。これらの理由から、CV そのものを用いて DNM 解析に用いる時系列を構成することは不適切であると判断した（同様の理由により、点過程の別の指標である LV についても、時系列の構成に取り入れることは難しいと考えた（6.1. 補論 1））。そこで、CV を反映しつつ点過程サイズ（m）の依存性を調整した指標B

$$B=\frac{\sqrt{m+2}\,\mathrm{CV}-\sqrt{m}}{\left(\sqrt{m+2}-2\right)\mathrm{CV}+\sqrt{m}} \tag{14}$$

を用いることとした(Karsai, Jo, and Kaski 2018; Kim and Jo 2016)。指標Bについては、「イベントが短時間に多数起きる一方で長期間起きないこともある」といったようなイベントの起き方の

不均一性が強くなるにつれ値が大きくなり、完全にランダムに起きる（定常ポアソン過程に従う）ときに0を取り、周期的に起きる傾向が強くなると負の値を取るようになり-1に近づく。

以上をまとめると、各種の発注取引について（表 4）、時刻tから$t+1$の間に入る部分点過程$\{t_j^i;\ j=j_1,\dots,j_m,\ t\le t_{j_1}^i\le\cdots\le t_{j_m}^i<t+1\}$についてイベント間隔$\Delta_j^i:=t_j^i-t_{j-1}^i$を計算し、$\Delta_j^i$の変動係数 CVに対して $x_i(t)=B$ とすることで、(3) 発注取引点過程に着目した時系列$x_i(t)$を構成した。ここで、部分点過程サイズが20以下となった場合には、その時点tにおける$x_i(t)$は欠損値として扱うこととした。

2.5.4.　発注取引時系列の前処理

最後に、DNM 解析への適用に先立ち、発注取引時系列に対して行った前処理について述べる。後述のように、構築した市場参加者毎の発注取引時系列には、市場参加者間の著しい不均一性や、時系列そのものの非定常性が見られた。そのため、2.5.1 から 2.5.3 で示した時系列をそのまま DNM 解析に適用することが難しく、時系列の前処理が必要となった。以下ではその前処理の内容について詳細を示す。

まず、各日の各場における各市場参加者（i）の発注取引時系列$x_i(t)$については、値の規模が市場参加者によって大きく異なるため（図 3）、時系列の規格化を行った。具体的には、発注取引時系列$x_i(t)\ (t=0,1,\dots,T)$の値を平均 $\langle x_i(t)\rangle:=\sum_{t=0}^{T}x_i\,(t)/T$ で割った値$\tilde{x}_i(t):=x_i(t)/\langle x_i(t)\rangle$を考え、新たに時系列$\{\tilde{x}_i(t)\}$を構成した。

次に、時系列$\tilde{x}_i(t)$については、取引開始や終了時刻近辺で発注取引量が他の時刻に比べて多くなるといったような非定常性や、時折$\tilde{x}_i(t)$が著しく大きな値を取る等の強い不均一性が見られることから（図 3）、$\tilde{x}_i(t)$の対数差分を取ることで新たに時系列を構成することとした。具体的には、 $\tilde{\tilde{x}}_i(t):=\log\tilde{x}_i(t)-\log\tilde{x}_i(t-1)$ とおいて、先述のような発注取引量に関する日内季節性を極力除去し、$\tilde{x}_i(t)$の値に関する強い不均一性を抑えた時系列$\tilde{\tilde{x}}_i(t)$を考えることとした(青山ら 2008)。以降では、記号の見やすさを考慮して、前処理を施した発注取引時系列$\tilde{\tilde{x}}_i(t)$を$x_i(t)$と置き直すこととする。ただし、点過程に関する時系列種 pp1~pp9 については、$x_i(t)$は概ね-1と1の間の値を取ることから、上述の前処理を適用させなかった。

2.6.　DNM 解析

ここからは、DNM 解析の流れについて説明する。まず市場参加者毎の発注取引時系列から DNM 指標、特にSD_Iを算出する。一方で、本分析にて予測対象とする市場の不安定化についても定義し特定する。そして日単位のタイムスケールで市場の不安定化のタイミングと DNM 指標推移の関係を調べ、DNM 集合の特定を試みる。最後に市場不安定化の予兆検知の可能性について検討する。

2.6.1.　DNM 指標の算出

まず、DNM 指標に関しては、2.1 で提示したSD_I、PCC_I、$\mathrm{PCC}_{\bar{I}}$、D_Iの四種類のうち、特にSD_I

に着目することとした。その理由は、SD_I以外の指標に反映される市場参加者間の発注取引時系列の相関関係について、その強さがノイズの影響を極めて強く受けているように見受けられたためである。これは、発注取引時系列には常に外部ニュースなどの外生要因が反映されるために、2.5.4 で示したような前処理を行っても個々の時系列にそれぞれ非定常性やノイズが残ってしまうためだと考えられる。したがって、様々な市場参加者ペアにわたって時系列間相関を平均することで計算されるPCC_I、$\mathrm{PCC}_{\bar{I}}$については、本分析では頑健性が乏しくなってしまうことから使用を見送ることとした。さらに、DNM 理論を包括的に反映した指標であるD_Iについても、絶対値が小さい値を取る$\mathrm{PCC}_{\bar{I}}(\in [-1,1])$が分母にあることから、$\mathrm{PCC}_{\bar{I}}$のノイズの影響を強く受けると考えられ、本分析では用いないこととした。一方で、SD_Iはその頑健性から、DNM 理論と関連する先行研究でしばしば優先して使用されている(Chen et al. 2012; Masuda et al. 2024; 中川ら 2016)。そこで本分析でも、特にSD_Iの考え方に基づいて DNM 指標を定め、議論を進める。すなわち、「不安定化の直前に状態が大きく振動し、時系列の標準偏差が上昇する」という現象に着目して、予兆検知の可能性を探る。

次に、DNM 集合Iを定めるための方針を説明する。2.1 で示したように、市場が不安定化する直前に DNM 指標を最大化させるような市場参加者集合Uが DNM 集合Iである。本研究で参考にする DNM 指標SD_Iは、集合Iに属する市場参加者の時系列の標準偏差を平均したものであることから、分析ではまず各市場参加者の時系列について標準偏差を計算する。既存のデータの上で、市場不安定化の直前に上述の標準偏差が著しく大きくなり不安定化後に小さくなるような市場参加者の集合を見つけ出して DNM 集合を定め、新たな不安定性の予測に有用となる DNM 指標を構築する。

ここで、上述の、各市場参加者の時系列の標準偏差について、具体的な計算方法をまとめる。2.4 で言及したように、まず、各日・場における各市場参加者（i）の発注取引時系列の標準偏差を求め、各場の値の平均を取ることで日毎の標準偏差を算出する。つまり、d日の前場（am）における市場参加者iの発注取引時系列$\{x_i(t)\}$の標準偏差

$$\mathrm{SD}_{i,\mathrm{am}}(d) \coloneqq \sqrt{\frac{1}{T}\sum_{t=0}^{T}(x_i(t) - \langle x_i(t)\rangle)^2} \tag{15}$$

を計算し、同様に後場（pm）についても標準偏差$\mathrm{SD}_{i,\ \mathrm{pm}}(d)$を計算し、それらの平均$(\mathrm{SD}_{i,\mathrm{am}}(d) + \mathrm{SD}_{i,\mathrm{pm}}(d))/2$を$\mathrm{SD}_i(d)$とおいて、$\mathrm{SD}_i(d)$を DNM 解析で用いる。ここで、時系列において$x_i(t)$が0もしくは欠損値となる時点が50点以上存在する場合には、当該場における$\mathrm{SD}_{i,\mathrm{am}}(d)$（もしくは$\mathrm{SD}_{i,\mathrm{pm}}(d)$）は欠損値として扱うこととした。その際には、計算ができた場の標準偏差$\mathrm{SD}_{i,\mathrm{pm}}(d)$（もしくは$\mathrm{SD}_{i,\mathrm{am}}(d)$）を用いて日にち$d$の$\mathrm{SD}_i(d)$を定め、共に$\mathrm{SD}_{i,\mathrm{am}}(d)$、$\mathrm{SD}_{i,\mathrm{pm}}(d)$が欠損値となった場合は$\mathrm{SD}_i(d)$も欠損値とした。図 4 では、例として vol3（V_O_LO_b）の時系列について、$\mathrm{SD}_{i,\mathrm{am}}(d)$および$\mathrm{SD}_{i,\mathrm{pm}}(d)$の推移と分布を示した。$\mathrm{SD}_{i,\mathrm{am}}(d)$と$\mathrm{SD}_{i,\mathrm{pm}}(d)$の値は概ね一定の範囲内で日・場ごとにゆらいでいるが、時折大きく振動する様子が見られた（図 4(a)）。実際に、全ての時系列種について市場参加者タイプごとに$\mathrm{SD}_{i,\mathrm{am}}(d)$と$\mathrm{SD}_{i,\mathrm{pm}}(d)$の分布を調べ

たところ、ほとんどの場合これらの値が小さく抑えられている一方で著しく大きな値も取る様子が見られ、時折$\mathrm{SD}_{i,\mathrm{am}}(d)$と$\mathrm{SD}_{i,\mathrm{pm}}(d)$が非常に大きくなるような市場参加者の存在も示唆された（図 4(b, c)、6.3. 補論 3）。

さらに分析では、移動平均により$\mathrm{SD}_i(d)$を平滑化した値$\overline{\mathrm{SD}_i}(d)$の前週比を考慮する。発注取引時系列の振る舞いには、元々式(4)の力学系に織り込まれていないような多くの外生要因が影響を与え、そのため$\mathrm{SD}_i(d)$も日毎に大きくゆらぐ。また、この$\mathrm{SD}_i(d)$を様々な市場参加者にわたって平均し従来のSD_Iに対応する値を計算したところ、この値も日毎に大きくゆらいでいることが確認された。このようなノイズの影響を抑えるために、本分析では約一週間にあたる5営業日の幅のもとで$\mathrm{SD}_i(d)$の移動平均をとった。具体的には、$\mathrm{SD}_i(d-4),\ \mathrm{SD}_i(d-3),\ldots,\ \mathrm{SD}_i(d)$の平均を$\overline{\mathrm{SD}_i}(d)$とおいた。また$\overline{\mathrm{SD}_i}(d)$については、市場参加者間で値の規模が異なる（例えば市場参加者によっては一貫して高い値を示す等）。加えて、DNM 指標の値そのものが高いということよりも、値が上昇するということが、不安定性の予兆に対応すると考えられることから(Song and Li 2024)、実用性も考慮して、本分析では$\overline{\mathrm{SD}_i}(d)$と$\overline{\mathrm{SD}_i}(d-5)$の比 $R_i(d) := \overline{\mathrm{SD}_i}(d)/\overline{\mathrm{SD}_i}(d-5)$ に特に着目することとした。ここで、先述のように5営業日はほぼ一週間に対応するので、$R_i(d)$を$\overline{\mathrm{SD}_i}(d)$の前週比と呼ぶことにする。

最後に、本 DNM 分析で用いる指標と記号を整理する。本分析では、従来のSD_Iの計算のように単に各日の発注取引時系列$x_i(t)$の標準偏差を用いるのではなく、この標準偏差の5営業日にわたる移動平均の前週比$R_i(d)$に着目する。本分析では、様々な時系列種について、各市場参加者の$R_i(d)$の推移と市場不安定化の時期を比較し、その結果に基づいてSD_Iに代わる DNM 指標を検討する。さらに、その DNM 指標に基づく市場不安定性の予測可能性について評価する。

2.6.2.　市場不安定化の特定

本分析では、DNM 解析の予測対象とする「市場の不安定性」を東証株価指数 TOPIX に基づいて決定した。複雑系の観点から臨界減速や DNM 理論を用いて金融市場の不安定化予測を試みる先行研究では様々なイベントを予測対象としており、例えばリーマンショック等の金融危機を対象として年単位で予兆検知を試みるものがある(Battiston et al. 2016; Jackson and Pernoud 2021; Saracco et al. 2016)。その他にも、複数の金融時系列の中でいずれかが著しく変動する状況や、金融市場の主要インデックスが大きく変動する状況を不安定性とみなし、より短いタイムスケールでこれらを予測する試みもなされている(Oya, Aihara, and Hirata 2014; Sandoval and Franca 2012; Song et al. 2011; Song and Li 2024)。本研究では、東証の代表的なインデックスである TOPIX の変動幅に基づいて市場の不安定性を定義することとした。タイムスケールに関しては、2.4 で検討したように、日単位の市場の不安定さと日毎に計算した DNM 指標の推移を比較する。よって本分析では、日のタイムスケールで、発注取引態様の質的な変化（臨界的状態遷移）の予兆を DNM 理論に基づき捉え、TOPIX に基づいて特定した市場の不安定性と対応し得るか評価する。

TOPIX の推移については、JPX データクラウド（https://db-ec.jpx.co.jp/）の「TOPIX 歩み値（テ

ィック）」を分析した。使用したデータの期間は 2019 年 11 月分から 2020 年 12 月分であり、本データには毎秒の TOPIX の値が記録されている。

市場の不安定性、つまり TOPIX の変動幅については、TOPIX の秒足データについて対数差分を取りその標準偏差を用いて定義した。具体的には、先行研究で用いられるボラティリティの定義を取り入れて(青山ら 2008)、まず日にちdの時刻$\tilde{t}$（秒）における TOPIX の数値$\tilde{V}_d(\tilde{t})$に対してその対数差分 $\tilde{\tilde{V}}_d(\tilde{t}) := \log\tilde{V}_d(\tilde{t}) - \log\tilde{V}_d(\tilde{t}-1)$ の時系列を考える。そして、$\tilde{\tilde{V}}_d(\tilde{t})$の標準偏差 $V(d) := \mathrm{Std}[\tilde{\tilde{V}}_d(\tilde{t})]$ を、d日の TOPIX の変動の大きさ（ボラティリティ）として定義した。図 5 に、TOPIX の数値と、$V(d)$、$V(d)$の前日比$V(d)/V(d-1)$についてそれらの推移を示す。ここで、本研究では不安定状態そのものではなく不安定状態への切り替わり（不安定化）の検知を目指すことから、$V(d)$よりむしろ$V(d)/V(d-1)$が高くなる日に着目する。

さらに、著しい市場不安定化の予測可能性について検討するために、TOPIX のボラティリティ前日比 $V(d)/V(d-1)$が分析期間において最も高くなった5日を選定した。ただし、前日から連続して$V(d)/V(d-1)$が高い日については、不安定化日の候補から除外した。この条件のもとで、2営業日以上の間隔を開けた日$d =$ 2020 年 1 月 8 日、2 月 25 日、3 月 9 日、3 月 13 日、8 月 28 日を、著しく市場が不安定化した日として設定し、DNM 理論に基づく不安定性の予測可能性を検討する分析（結果 3.2）に用いた。補足として、上記のボラティリティ以外にも、$\tilde{\tilde{V}}_d(\tilde{t})$の絶対値の平均E[$|\tilde{\tilde{V}}_d(\tilde{t})|$]により定義されるボラティリティについての前日比、$d-1$日の後場終値とd日の前場始値の比、$d-1$日の後場終値とd日の後場終値の比、d日の前場終値とd日の後場終値の比など、様々な TOPIX 指標の変動を表す数値の比較を行った。上述の5日においては、いずれの比も著しく大きな値を示していた。

3. 結果

3.1. DNM 指標と TOPIX ボラティリティの大小関係の比較

まず、解析対象期間を通して$V(d)/V(d-1)$と$R_i(d)$の大小関係を比較する。具体的には、各時系列種と各市場参加者iに対し、様々なタイムラグτのもとで、指標$R_i(d-\tau)$と TOPIX ボラティリティ$V(d)/V(d-1)$の値の大小を比べ、分析対象期間全体における「τ日前（$\tau > 0$）の指標$R_i(d-\tau)$が大きいこと」と「$V(d)/V(d-1)$が大きいこと」の関係性を調べる（図 6 (a)）。この関係性については、クロス集計に基づきフィッシャーの正確確率検定における p 値を計算することで評価する。ここでは、「指標$R_i(d)$が大きいこと」を、$R_i(d)$の値の高さが分析対象期間中の上位20%に入ることとし、同様に「$V(d)/V(d-1)$が大きいこと」も上位20%の条件で決定する。そして、「$R_i(d-\tau)$も$V(d)/V(d-1)$も大きい」、「$R_i(d-\tau)$が大きく$V(d)/V(d-1)$は大きくない」、「$R_i(d-\tau)$は大きくないが$V(d)/V(d-1)$は大きい」、「$R_i(d-\tau)$も$V(d)/V(d-1)$も大きくない」の四つの状態に入る日数（dの数）をそれぞれ計算する。各τに対して上述の集計に基づきフィッシャーの正確確率検定における p 値を計算し、「上述の関係性が無い」という帰無仮説を棄却できるか、つまり$R_i(d-\tau)$と$V(d)/V(d-1)$の間の関係性が示唆されるかについて評価する。

それぞれの時系列種について、市場参加者ごとにタイムラグτと p 値の関係を調べたところ、限定的ながら、1~5日程度のタイムラグのもとで p 値が徐々に低下し両者の間に連続的な対応関係が確認された。図 7 では、各パネルが時系列種（ここでは例として時系列種vol3、co3、pp3を示す）に対応し、縦軸と横軸がそれぞれ p 値とタイムラグを表しており、横軸の値（$-\tau$）が負の時には TOPIX ボラティリティとτ日前の$R_i(d)$の関係を、正の時には TOPIX ボラティリティとτ日後の$R_i(d)$の関係を示している（6.4. 補論 4 に、全ての時系列種について図 7 と同様の結果を示した）。各プロットは各市場参加者に対応するが、この図では、DNM 集合に含まれ得る市場参加者、つまり TOPIX ボラティリティの高まりの前にボラティリティと$R_i(d)$の関係性が強まり、ボラティリティが高まったあとにはこの関係性が無くなるような市場参加者を選定して、プロットした。すなわち、ここでは$-5 \leq -\tau < 0$の範囲で p 値が0.05を下回り、$-5 \leq -\tau < 0$の範囲におけるp 値の平均が$0 \leq -\tau < 5$の範囲におけるp 値の平均よりも低くなるような市場参加者を選び、図のプロットに反映させた。図 7 と 6.4. 補論 4 の図について全体を通して見ると、多くの DNM 候補の市場参加者のプロットは乱雑に振動しているように見受けられ、TOPIX ボラティリティと$R_i(d)$の関係性に明確なパターンが現れにくい傾向が確認された。また、図 7 と 6.4. 補論 4 においては$-10 \leq -\tau < -5$の範囲でも p 値が著しく低下する場合があり、これについては着目している TOPIX ボラティリティの高まりとは別のタイミングのボラティリティ上昇の影響を受けてしまっている可能性が考えられる。このような点も、TOPIX ボラティリティと$R_i(d)$を分析対象期間全体について一度に比較することの難しさに影響を与えていると予想する。一方で、一部の市場参加者については、タイムラグ$-\tau$の変化に応じて連続的に p 値が変化し、$-5 \leq -\tau < 0$の範囲で小さな値を示す様子が確認された（図 7・影をつけた箇所）。これらの市場参加者については、分析対象期間を通して、TOPIX ボラティリティが高まる数日前に、一貫して$R_i(d)$が高い（あるいは低い）値を示している可能性が示唆される。

ただし、p 値がタイムラグ$-\tau$に対して連続的に変化している場合でも、そのピークを取るタイムラグの値は市場参加者によって異なっていた。このことから、時系列の種類や市場参加者によって、TOPIX ボラティリティの高まりと$R_i(d)$の値との関係性が現れるタイミングは、日単位のタイムスケールにおいてばらつきがあると考えられる。

3.2. 市場不安定化前の DNM 指標の振る舞い

次に、時系列種毎に、市場が不安定化した数日前に指標$R_i(d)$が大きくなっていた市場参加者iの集合を暫定的に DNM 集合と定め、この DNM 集合のもとで新たな市場不安定化を予測できるか評価する。この検討には、以下に説明するように、クロスバリデーションの考え方を取り入れた（図 6 (b)）。具体的には、まず 2.6.2 で提示した 2020 年 1 月 8 日、2 月 25 日、3 月 9 日、3 月 13 日、8 月 28 日の各日を不安定化の予測対象日d_{focal}として、d_{focal}以外の4日の不安定化日（d）について、それぞれ1~5日前の$R_i(d)$の平均 $\overline{R_i(d)} = (R_i(d-1) + R_i(d-2) + R_i(d -$

$3) + R_i(d-4))/4$ を計算する[2]。そして、d_{focal}以外の4日の不安定化日にわたる$\overline{R_i(d)}$（$d \neq d_{focal}$）の幾何平均

$$\left(\prod_{d \neq d_{focal}} \overline{R_i(d)} \right)^{\frac{1}{4}} \tag{16}$$

を取る。式(16)の幾何平均の大小により、各市場参加者の$R_i(d)$が市場の不安定化（d_{focal}以外の不安定化）の数日前にどの程度高まるか評価する[3]。この幾何平均が最も大きかった10の市場参加者のうち、幾何平均の値が1よりも大きいものを選び[4]、このような市場参加者の集合を暫定的に DNM 集合$I_{d_{\text{focal}}}$とおくこととした。そして、DNM 集合$I_{d_{\text{focal}}}$に含まれる市場参加者らの$R_i(d)$がd_{focal}直前にも上昇するか確認し、$I_{d_{\text{focal}}}$が実際に DNM 集合として機能するか検討する。言い換えると、各時系列種について、d_{focal}以外の市場不安定化日の数日前における$R_i(d)$の振る舞いに基づいて DNM 集合$I_{d_{\text{focal}}}$を定め、$I_{d_{\text{focal}}}$に含まれる市場参加者の$R_i(d)$がd_{focal}前にも高まるか確認する。この評価を全てのd_{focal}について行う。以下では、それぞれの時系列種についての、$I_{d_{\text{focal}}}$内の市場参加者の$R_i(d)$と TOPIX ボラティリティの推移を示す。

まず、$I_{d_{\text{focal}}}$に含まれる各市場参加者を対象として$R_i(d)$の振る舞いを確認したところ、様々な時系列種とd_{focal}の組み合わせについて、比較的明確な市場参加者間の連動が見られた。図 8 では、例としてd_{focal}=2 月 25 日、時系列種vol4、co3、pp7について、$I_{d_{\text{focal}}}$に含まれる各市場参加者の$R_i(d)$を示している。これらの図では、多くの場合において市場参加者同士で$R_i(d)$の推移が連動している様子が見受けられる。さらに、$d_{\text{focal}} = 2$ 月 25 日前の$R_i(d)$の明確な上昇は時系列種 pp7 に限られるものの、他の市場不安定化日である 1 月 8 日、8 月 28 日前には、図 8 を通して多くの市場参加者について$R_i(d)$が連続的に上昇しピークを取る様子が見られた。

次に、従来の DNM 指標SD_Iに対応する指標として、$I_{d_{\text{focal}}}$に含まれる市場参加者iについて$R_i(d)$を平均した指標$\text{SD}_{I,d_{\text{focal}}}$を構成し、その振る舞いを調べた。図 9 から図 17 では、全ての時系列種について、時系列種の特徴に従って色分けした上で$\text{SD}_{I,d_{\text{focal}}}$を重ねてプロットした（6.5.補論 5 では、各時系列種とd_{focal}に対する$\text{SD}_{I,d_{\text{focal}}}$の推移を個別に示す）。具体的には、図 9、12、15 では新規注文と約定で、図 10、13、16 では買いと売りで、図 11、14、17 では成行注文と指値注文でプロットの色を分けて、$\text{SD}_{I,d_{\text{focal}}}$の推移を示した。また、図 9、 10、 11 は発注取引数量に関する時系列、図 12、 13、 14 は銘柄の共有に関する時系列、図 15、 16、 17 は点過程に関する時系列についての$\text{SD}_{I,d_{\text{focal}}}$の結果をまとめた。ここで、特に成行注文や銘柄共有を考慮した co1（C_O_MO_b）等の時系列種については、単位時間あたりのデータサイズが不足したため$\text{SD}_{I,d_{\text{focal}}}$を計算対象とすることができず、結果への反映は行っていない（6.5.補論 5 でこ

[2] 1~5日前の$R_i(d)$の平均を考慮する理由は、市場の不安定化に先立つ$R_i(d)$の上昇タイミングには時系列種や市場参加者によってばらつきがあることが示唆されたためである（結果 3.1）。

[3] 幾何平均の値は、算術平均と異なり、4日について$\overline{R_i(d)}$の値が軒並み高くなければ大きな値を取ることができない。

[4] 指標$R_i(d)$は、過去一週間の標準偏差の平均がその前の一週間の標準偏差の平均に比べてどの程度上昇したかを表し、$R_i(d) > 1$ならば上昇したことを示す（2.6.1）。

れらの時系列種について言及する）。

図 9—17 に示すように、多くの時系列種について複数の予測対象日d_{focal}の直前に$\text{SD}_{I,d_{\text{focal}}}$が上昇する様子を確認できた。一方で、上昇のパターンについては時系列種による顕著な特徴は認められなかった。図 9—17 を通じて、特にd_{focal} = 1 月 8 日、8 月 28 日に対して、様々な時系列種に関して$\text{SD}_{I,d_{\text{focal}}}$が$d_{\text{focal}}$直前にピークを取っている様子が見て取れる。また、コロナショックの強い影響を受けた 3 月 9 日以前の 2 月に、絶対値自体は高くないものの、$\text{SD}_{I,d_{\text{focal}}}$の上昇傾向が見られた。コロナショックの最中であったd_{focal} = 3 月 9 日、3 月 13 日については、これらの期間中に$\text{SD}_{I,d_{\text{focal}}}$の変動はあるものの、互いに日にちが近いことと$\text{SD}_{I,d_{\text{focal}}}$の変動のタイムスケールが比較的緩やかなことから、それぞれのd_{focal}に対する精細な反応は見られなかった。その他に、発注取引数量に関する時系列種について$\text{SD}_{I,d_{\text{focal}}}$を示した図 11 では、$d_{\text{focal}}$ = 2020/01/08に対して、先に指値注文の時系列の$\text{SD}_{I,d_{\text{focal}}}$が反応し、成行注文の反応が引き続く傾向が見られた。しかし、時系列種全体の比較を通して、特にd_{focal}前に反応しやすい時系列の種類や反応タイミングの時系列種間の差異に関しては、一貫性のある傾向は見られなかった。まとめると、多くの時系列種についてd_{focal}前に$\text{SD}_{I,d_{\text{focal}}}$が上昇する傾向がしばしば確認されたことから、$\text{SD}_{I,d_{\text{focal}}}$が DNM 指標として機能する可能性が示唆された一方、DNM 指標に用いる時系列種間の相対的な適切さについては、さらなる検討が必要である。

留意すべき点として、本分析で対象とした発注取引は、様々な制度的要因の影響も受けていると考えられる。そのため、DNM 指標の上昇はこのような要因も反映したものとなっている可能性がある。例えば、d_{focal}の一つである 1 月 8 日は、10 日 SQ（特別清算指数）算出日の直前にあたり、それを見越した発注取引態様の変化を、d_{focal}前の DNM 指標の上昇が捉えていた可能性が考えられる。このように、本分析は制度的要因や外生ショックを明示的に取り込まずに、あくまで発注取引データのみに基づいて、発注取引の状況が変化する前触れを定量化したものである。

3.3. DNM 集合を構成する市場参加者の特徴

本節では、DNM 集合$I_{d_{\text{focal}}}$を構成する市場参加者の特徴について考察する。これまでの分析では、様々な種類の発注取引時系列のもとで、市場が不安定した5日分のそれぞれの日（d_{focal}）を対象に、d_{focal}以外の不安定化日の直前の時系列を解析して DNM 集合$I_{d_{\text{focal}}}$を構成した。そして$I_{d_{\text{focal}}}$に基づいて計算した DNM 指標$\text{SD}_{I,d_{\text{focal}}}$が$d_{\text{focal}}$直前にも反応を示すか検証し、DNM 集合としての有効性について示唆を得た。本節では、時系列種とd_{focal}をまたいで$I_{d_{\text{focal}}}$を構成する市場参加者に一貫性が見られるか評価し、それらの特徴を調べることにより、DNM 集合の実体について考察する。

まず、それぞれの時系列種について、異なるd_{focal}に対する$I_{d_{\text{focal}}}$内の市場参加者を比べたところ、それらが比較的共通していることを確認できた。図 18 では、発注取引数量に着目した様々な時系列種（vol1～vol9）について、d_{focal}別に$I_{d_{\text{focal}}}$を構成する市場参加者を整理した。ここで図 18 の横軸では、市場参加者を、その種類（HFT、証券会社自己、一般投資家、その他）

別に、発注数に関して降順になるように並べた。縦軸では、同じ時系列種についてd_{focal}を隣接させて並べている。本プロットを俯瞰すると、縦方向に連続する線分が多々見られ、これは、当該市場参加者が複数のd_{focal}を通して一貫して$I_{d_{\mathrm{focal}}}$を構成していることを表す。このような一貫性は、市場参加者間の発注取引銘柄の共有に着目した時系列種（co1～co9）や発注取引点過程に着目した時系列種（pp1～pp9）のもとで図 18 と同様にプロットした図 19、20 においても見られた。以上の結果から、本分析対象期間における DNM 集合の頑健性が示唆された。また、過去の不安定化事象に基づいて DNM 集合および DNM 指標を構築し、それを用いて将来の市場不安定化を予測することの実現可能性についても示唆が得られた。

次に、全時系列種に渡って$I_{d_{\mathrm{focal}}}$を構成する市場参加者を列挙することにより、時系列種と$I_{d_{\mathrm{focal}}}$の構成要素の関係についていくつかの傾向を見つけた。図 21 は図 18 から図 20 を結合したものであり、縦軸方向に全ての時系列種とd_{focal}が並んでおり、横軸方向には図 18 と同順で市場参加者が並んでいる。ここでは、買い注文・売り注文を反映した時系列や数量・銘柄の共有・点過程に基づく時系列など、様々な時系列種を通じて$I_{d_{\mathrm{focal}}}$に含まれる市場参加者が見られた。また、「その他」タイプの市場参加者の中には、発注取引点過程に着目した時系列（略称が P_から始まる時系列）に基づく$I_{d_{\mathrm{focal}}}$に特異的に属するようなものも存在した（図 21・赤枠内）。つまり、これらの市場参加者については、単位時間あたりの発注取引ではなく、発注取引タイミングの不均一性といった点過程の特徴に注目することで初めて、DNM 集合としての有用性が顕在化すると考えられる。その他に、市場参加者の発注件数の多さと$I_{d_{\mathrm{focal}}}$に入るか否かの関係性は単調ではないことも見て取れる。先述のように、図 21 の横軸では市場参加者を発注件数について降順に並べている。この図において、 $I_{d_{\mathrm{focal}}}$に含まれることを示すマーカーが横軸方向の様々な位置に分布していることから、例えば「発注件数が多い市場参加者ほど$I_{d_{\mathrm{focal}}}$に含まれやすい」といったような単調な傾向はほとんど確認されない。その他の傾向としては、指値注文の時系列に関する$I_{d_{\mathrm{focal}}}$には HFT とその他の市場参加者が主に含まれ、成行注文の時系列に関する$I_{d_{\mathrm{focal}}}$には証券会社自己や一般投資家の市場参加者が主に含まれた。しかしこの傾向は、各市場参加者タイプの定義や既に知られている各タイプの発注取引態様を反映した結果に過ぎず、ほぼ自明なものである。

さらに、多数の時系列種およびd_{focal}に渡って$I_{d_{\mathrm{focal}}}$に含まれるような主要な市場参加者に着目してその発注取引態様を調べたところ、それらの各種発注取引件数には特異的な性質が見られなかったものの、銘柄の共有関係において重要な位置に存在するものが見つかった。上述のような、多数の時系列種およびd_{focal}において$I_{d_{\mathrm{focal}}}$に含まれる市場参加者は、様々な発注取引の側面において、DNM 理論の観点から重要な構成要素になっているとみなせる。そこで、全ての時系列種およびd_{focal}にわたり最も頻繁に$I_{d_{\mathrm{focal}}}$に含まれた上位10の市場参加者（以下、「主要市場参加者」と呼ぶ）を特定した。加えて、点過程に関する時系列種pp1～pp9に限定した場合の主要市場参加者も上述の主要市場参加者と同様に選定した。そして、これらの主要市場参加者についてレコード種別（表 1）の発注取引件数を調べた結果を図 22 に示す。図 22 では、特に$\mathrm{SD}_{I,d_{\mathrm{focal}}}$の反応が著しかった$d_{\mathrm{focal}} =$ 1 月 8 日を含む 2020 年 1 月を対象に、横軸方向に図

18—21 と同じ順番で市場参加者を並べ、縦軸方向に発注取引のレコード種別を列挙し、当該月における発注取引件数をヒートマップで示した（2020 年 1 月以外の同結果については 6.6. 補論 6 に示す）。ここでは主要市場参加者を赤枠で囲って示したが、それらのレコード種別の件数には、隣り合う非主要市場参加者のものと比べて顕著な差は確認されなかった。次に、時系列種co1～co9を構成する際に考慮したような市場参加者間の発注取引銘柄の共有関係をネットワーク表現し、その共有構造における主要市場参加者の位置付けを確認した（図 23）。具体的には、2020 年 1 月の各日（d）について、市場参加者iとjが共に発注を行った銘柄数を$z_{i,j}(d)$とし，1 月の全ての営業日について$z_{i,j}(d)$の和を取った値を$w_{i,j}$とする（$w_{i,j} = \sum_d z_{i,j}(d)$）。ここで、市場参加者を頂点とし、$w_{i,j} \neq 0$であれば頂点$i$と頂点$j$の間に重み$w_{i,j}$のリンクが張られるような重み付きネットワークを考える。重み付きネットワークについては、$w_{i,j}$が有意に大きいリンクのみを残してネットワーク・バックボーンを捉える刈り込み手法が多く提案されているが、その中でも次のような条件により、リンクの刈り込みを行った。すなわち、

$$\left(1-\frac{w_{i,j}}{s_i}\right)^{k_i-1} < 0.01 \quad \text{もしくは} \quad \left(1-\frac{w_{i,j}}{s_j}\right)^{k_j-1} < 0.01 \tag{17}$$

のとき、頂点iと頂点jを結ぶリンクを残し、それ以外のリンクを取り除いた[5] (Menczer, Fortunato, and Davis 2020)。ここで、k_iは頂点iの次数（頂点iに接続するリンク数）、s_iは頂点iの強度（頂点iに接続するリンクの重みの総和）とする。このような銘柄共有ネットワークの解釈として、ある市場参加者の発注取引が他の市場参加者の発注に影響を与える場合、自然と市場参加者間の発注銘柄の共有関係が生じると考えられることから、この銘柄共有ネットワークは DNM 理論における因子間の関係性を示したネットワークの構造を反映している可能性がある。図 23 のように銘柄共有ネットワークを可視化したところ、特定の「証券会社自己」タイプの主要市場参加者が著しく高い次数を持ち、このネットワークにおいて重要な位置に存在する様子が見られた。

4. 考察

本研究では、金融市場における市場参加者の発注取引間の複雑な関係性を背景として、不安定性の予兆検知手法である DNM 理論を応用することで、市場不安定化の予兆検知の可能性について一定の示唆を得た。DNM 理論は、複雑に相互作用する多数の因子から、不安定性の予兆と関連する因子集合を抽出する手法を提案する。本研究では、市場参加者ごとに発注取引の様子を表す時系列を構成し、それらを合わせて市場全体の状態を表す多変量時系列を構築したうえで、DNM 理論を適用した。特に、発注取引態様を表す多数の種類の時系列を考慮し、それぞれの予兆検知の可能性について比較した。その結果、著しい市場不安定化については、日単位

[5] ここでは、各頂点の次数と強度が解析対象のネットワークと等しいという条件のもとで各リンクの重みがランダムに決まるようなヌルモデルを仮定する。$\left(1-w_{i,j}/s_i\right)^{k_i-1}$は、ヌルモデルにおいて頂点$i$に接続するあるリンクの重みが$w_{i,j}$以上になる確率である。式(17)の条件は、$w_{i,j}$がヌルモデルではほとんど起こらないくらい大きいことを表す。

のタイムスケールで前兆を捉え得ることを示せた。これは、市場参加者ごとの発注取引時系列を用いて市場全体の状態を表現し、DNM 理論を適用したことで得られた成果である。さらに、本分析は市場構造の変化を把握する新たな視点を提供しており、市場安定性の評価やリスク管理への応用可能性を示唆している。

本研究の市場不安定性予測の特徴は、市場全体の発注取引の構造に着目し、その質的変化自体ではなく、変化の予兆を検知する点にある。金融危機の予測を試みた多くの先行研究では、銀行間取引や銘柄間相関など金融経済に関わる因子間相互作用の構造変化を検知し、近い将来の市場不安定化を予測する手法が採られてきた(Zheng et al. 2012; Saracco et al. 2016; Battiston et al. 2016; Jackson and Pernoud 2021) 。これに対し、本研究では市場における発注取引関係（因子間相互作用）の質的変化に先行する兆候を捉えることを目的としている。したがって、本手法が実用化されれば、発注取引の関係性の構造が変化する前、つまりより早い段階で、警戒を発することが可能になると期待できる。

一方で、DNM 指標をより実務的な市場不安定性予測に活用するためには、市場における外部情報の影響を踏まえた整理が必要である。本研究で明らかになったのは、不安定化した日（d_{focal}）の数日前に$\mathrm{SD}_{I,d_{\mathrm{focal}}}$が上昇していたという事実である。この点は予兆検知の有効性を裏付けるが、$\mathrm{SD}_{I,d_{\mathrm{focal}}}$が$d_{\mathrm{focal}}$に対して何日前に上昇するのか、あるいはピークを迎えるのか、どの程度の上昇が予兆とみなせるのか、といった定量的な一貫基準については今後の検討課題となる。もっとも、こうした課題は本研究に特有のものではなく、市場状態を定量化し警戒指標を構築した先行研究においても同様である。例えば、市場の状態を定量化し警戒指標を構築している研究の中にも、「不安定化の直前に指標の値が著しく上昇していた」といったような目視による質的な評価にとどまっているものが散見される。さらに、警戒指標の値そのものの高さではなく、値が上昇しピークを取ることが不安定性の予兆に対応すると考える先行研究も多く、そのような考えのもとでは、警戒のシグナルを出すタイミングの調整も一つの難しい課題となる。このように不安定化の予兆を高精度に捕捉することが困難な要因の一つとして、市場状態に含まれるノイズの大きさが考えられる。DNM 理論の場合、2.1 で示したように市場参加者内で閉じた関係性と小さくランダムなノイズを考慮するが、実際の金融市場では外部ニュースが絶え間なく入り、市場はそれらに対して大きく反応する(Ito et al. 2024)。こうした外生要因が DNM 指標や他の警戒指標に変動を与えることは避けられず、これらを踏まえた分析の工夫が、予兆検知の安定性向上に向けた重要な方向性となる。

上述の外生要因を分析から除去するために、タイムスケールの調整が有用であると考えられ、今後の課題の一つとしてより多様なタイムスケールの検討が挙げられる。例えば本分析においては、DNM 指標を日単位で算出しつつ、さらに週単位（5営業日）の幅で移動平均を取ることにより、突発的な外生要因の影響を抑制した。一方で、分単位などのより短いタイムスケールで、分析対象期間のスコープを狭めて解析することも、外生要因の影響を除外することにつながり得る。例えば、本研究で分析した東証における取引の場合、後場終了から翌日の前場開始までに、時差がある海外の市場では取引が行われており、その情報が翌日前場の取引開始時に

外生要因として東証の市場に影響を与える。このような日を跨ぐことによる外生要因の影響は、分析対象を一日の内で閉じられるくらい短いタイムスケールを選定することにより除外し得る。さらに、昨今の高速取引の現状を考慮すると、分・秒といったタイムスケールで DNM 解析を行うことは、今後の重要な研究方向となる。関連して、市場参加者のタイプによって発注戦略や取引速度が異なる点を考慮すると、特定の市場参加者タイプに焦点を当てた DNM 解析も有用であると期待される。

さらに、もう一つの今後の課題として、複数の時系列種を適切に集約した DNM 指標の構築が挙げられる。本分析で、様々な時系列種に関して$\mathrm{SD}_{I,d_{\mathrm{focal}}}$を計算し不安定性の予兆検知に対する有効性を比較したところ、時系列種間で一貫した著しい差異は見られなかったものの、$\mathrm{SD}_{I,d_{\mathrm{focal}}}$の上昇タイミングに僅かなばらつきが見られた。この結果は、様々な時系列種がそれぞれ市場の不安定化に関する情報を有していることと、それらの情報の間に細かなばらつきがあることを示唆している。一般的に、機械学習分野のアンサンブル学習のように、複数の情報源を集約することで統計的要因により精度の向上が期待できる（集合知の効果）。この考え方を取り入れて、多数の時系列種の振る舞いを集約した DNM 指標を構築することで、ロバストな不安定性予測が可能になると期待できる。

最後に、DNM 集合に含まれる市場参加者（主要市場参加者）の特徴と、市場安定性の制御可能性について議論する。DNM 集合は、互いに複雑に影響し合う因子の関係性の中で、不安定化の前兆である臨界減速に寄与する因子集合である。したがって、ある市場参加者が DNM 集合に含まれることは、その市場参加者単独の振る舞いが特異的であるというよりも、互いに影響し合う発注取引の関係性の中での位置付けが特異的であることを示唆している。例えば、この関係性の構造の中で、外生要因の影響を吸収してショックの市場全体への伝播を抑制するような位置 (Jackson and Pernoud 2021; Klinčić et al. 2023) や、市場参加者全体の発注取引の状態を制御し得る位置(Liu, Slotine and Barabási 2011)に存在する市場参加者も考えられ、それらが DNM 集合に含まれている可能性もある。市場参加者間の具体的な関係性を明確に捉えることは容易ではないが、本分析ではその一端として、市場参加者間の発注銘柄の共有関係をネットワーク表現し、このネットワーク構造における主要市場参加者の位置付けを確認した。その結果、主要市場参加者の一つが、この銘柄共有ネットワークにおいて中心的な位置に存在していることが示された。もちろん、銘柄共有ネットワークは市場構造の一部を反映したものであり、すべてを包括するわけではないが、今後の展望として、この市場全体の構造をより包括的かつ精緻に捉え、DNM 集合の位置付けを評価することにより、市場の不安定性の制御につなげられる可能性が期待される。

5. 結論

本研究では、金融市場における市場参加者間の発注取引の複雑な関係性を踏まえ、東京証券取引所の板再現データを用いて DNM 理論を適用し、市場不安定化の予兆検知の可能性を検討した。その結果、日単位のタイムスケールで市場不安定化の前兆を把握できる可能性が示され、

市場参加者ベースの時系列解析によって市場構造の変化を事前に捉えられる新たな視点を提示することができた。

この成果は、従来の価格時系列中心の分析では得られにくい市場構造の内部変化を定量的に抽出した点で新規性を有する。特に、市場参加者レベルの時系列を統合して解析する枠組みは、市場安定性評価やリスク管理への応用に向けた有望なアプローチと考えられる。

今後は、外部情報や多様なタイムスケールを考慮した指標設計、複数時系列種の統合によるロバストな DNM 指標構築、およびネットワーク構造に基づく主要市場参加者の位置付け評価などを進めることで、予兆検知の安定性と汎用性の向上が期待される。これにより、本研究で示した枠組みが市場不安定性の早期検知および安定性の制御につながる実務的なツールとして発展していくことが期待される。

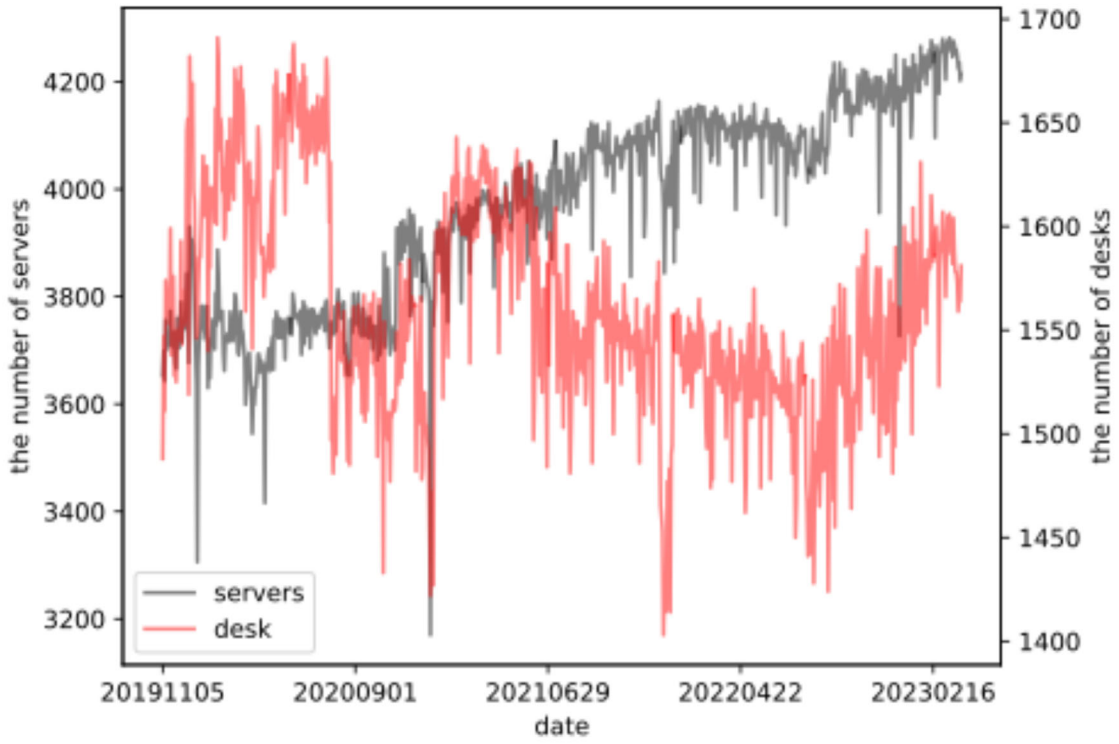

図 1　2019 年 11 月 5 日から 2023 年 3 月 31 日における、各日に稼働していた ServerID 数（黒、左軸）と Trading desk 数（赤、右軸）。

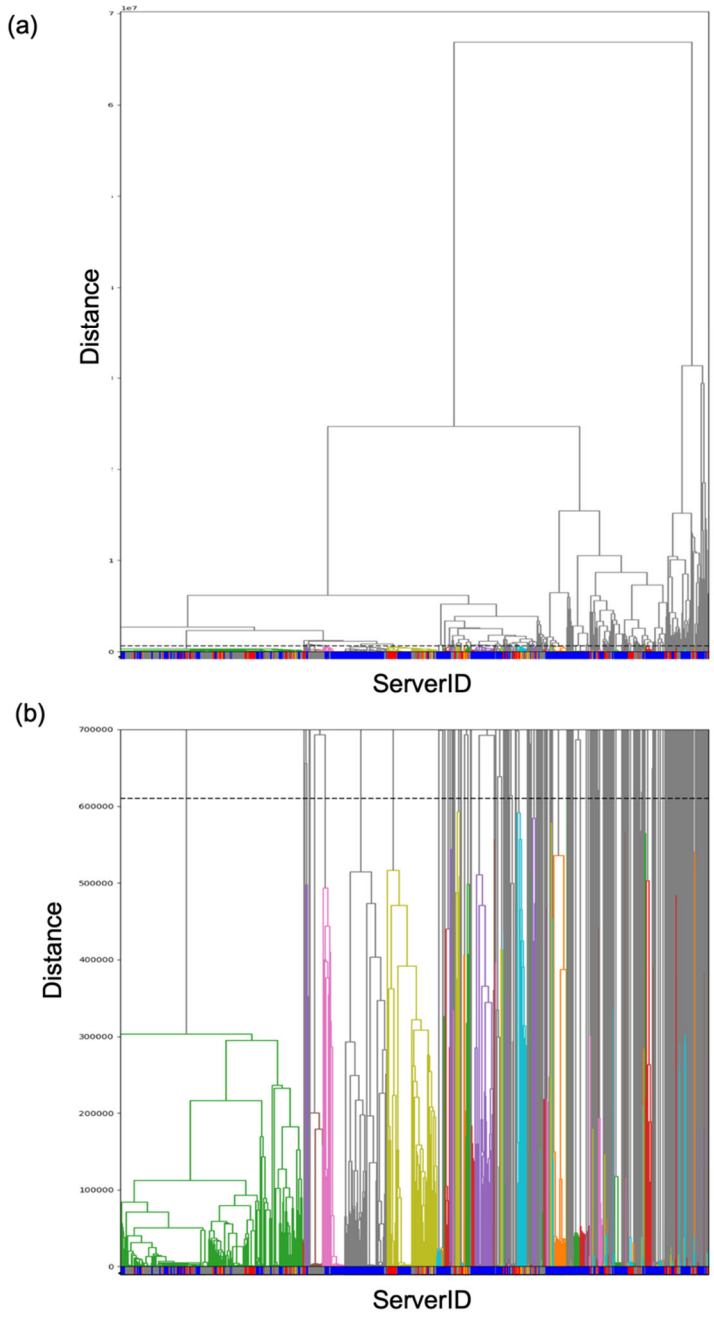

図 2　ServerID の階層クラスタリング結果のデンドログラム。(a)ではデンドログラム全体を示し、(b)では(a)の下部分を拡大したものを表示した。デンドログラム下には ServerID が並んでおり、それらの色は、各 ServerID を含む Trading desk のタイプを表す（青：HFT、赤：証券会社自己、オレンジ：一般投資家、灰色：その他）。(b)では、クラスタ数を 250 とするための閾値を黒の水平線（破線）で示しており、デンドログラムの枝の色はクラスタ分割に対応している。

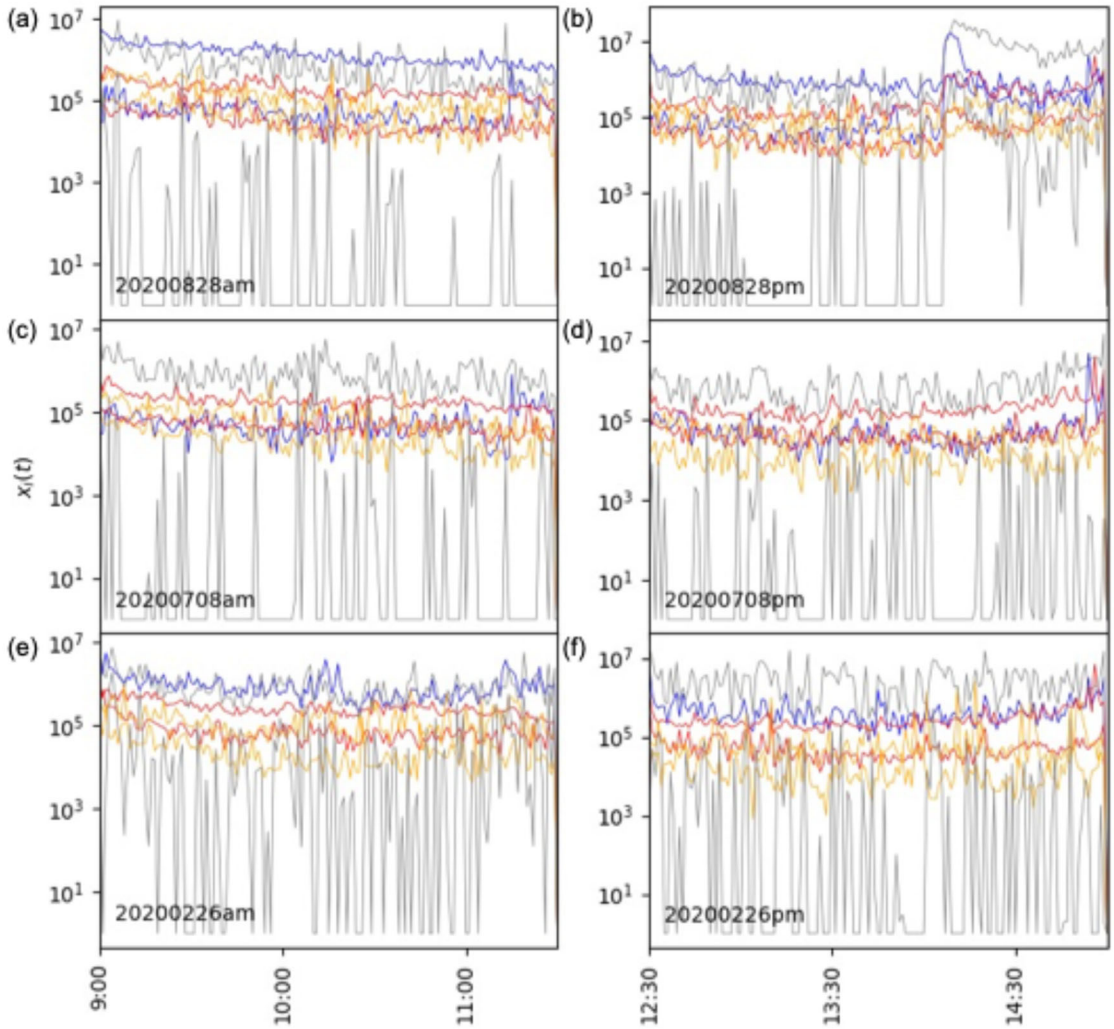

図 3　各市場参加者（i）の時系列$x_i(t)$（時系列種は vol4 の V_O_LO_s）。(a,b)は TOPIX ボラティリティの前日比$V(d)/V(d-1)$が最も大きかった 2020 年 8 月 28 日、(c,d)は$V(d)/V(d-1)$が中程度だった 2020 年 7 月 8 日、(e,f)は$V(d)/V(d-1)$が最も小さかった 2020 年 2 月 26 日に対応する。(a,c,e)は前場、(b,d,f)は後場の結果を示す。各プロットは市場参加者に対応する。例として、HFT タイプの市場参加者（青）、証券会社自己タイプの市場参加者（赤）、一般投資家タイプの市場参加者（オレンジ）、その他タイプの市場参加者（灰色）を二つずつ示した。ここでは、各タイプについて、最も発注件数が多い市場参加者と中程度の市場参加者を選定しており、当日に稼働している場合のみプロットした。縦軸では$x_i\ (t)+1$の値を対数スケールで示し、横軸は時刻を示す。

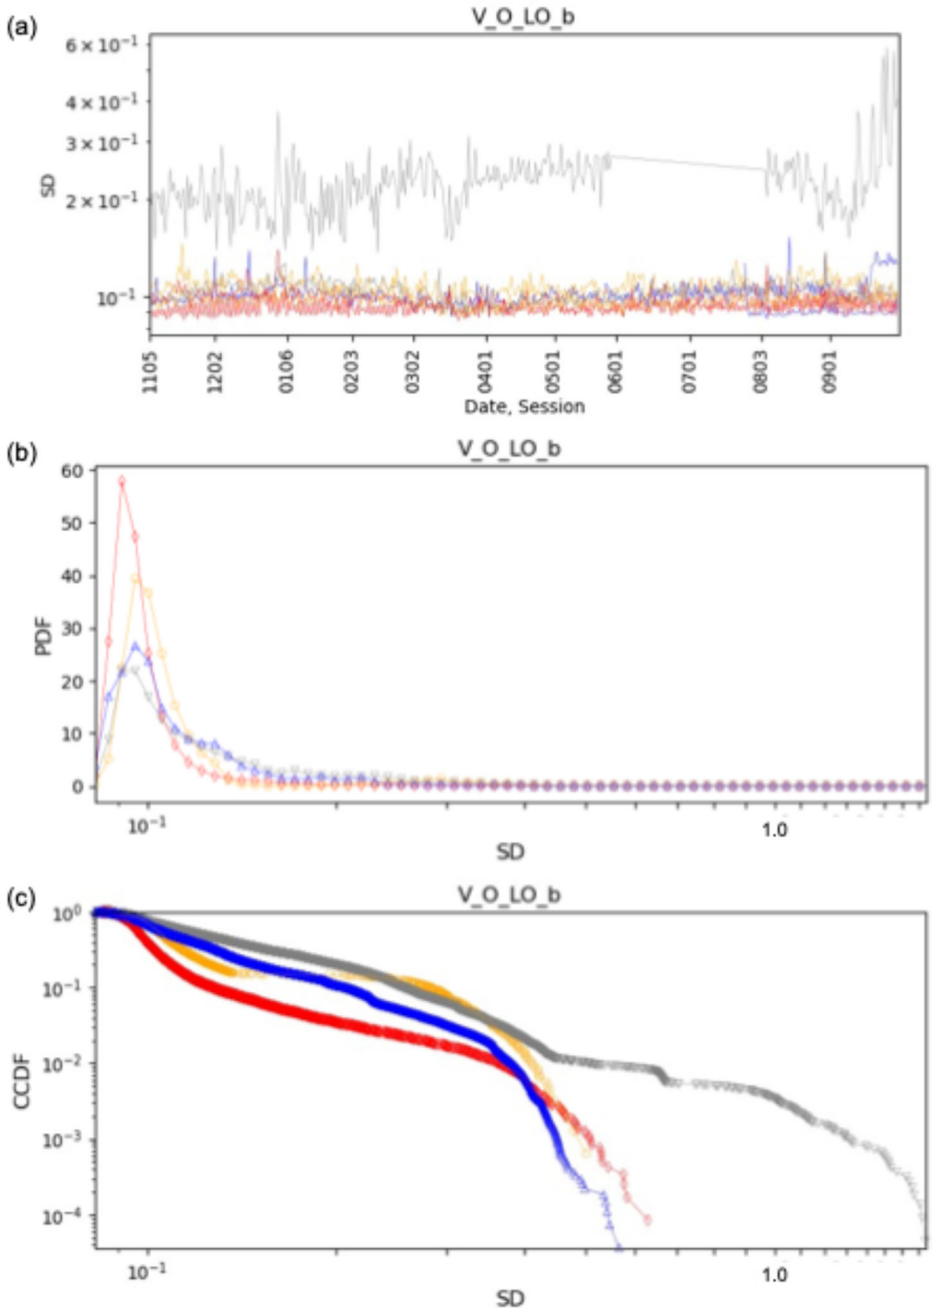

図 4　$SD_{i,am}(d)$および$SD_{i,pm}(d)$が取る値。例として vol3（V_O_LO_b）の時系列種について、(a)は図 3 と同じ市場参加者の$SD_{i,am}(d)$および$SD_{i,pm}()$の推移を示す。各プロットは市場参加者に対応する。(b)は各市場参加者タイプの$SD_{i,am}(d)$および$SD_{i,pm}(d)$の確率密度関数（PDF）を示し、(c)はその相補累積分布関数（CCDF）を示す。(b, c)では各プロットが市場参加者タイプに対応し、「HFT」を青、「証券会社自己」を赤、「一般投資家」をオレンジ、「その他」を灰色で示した。

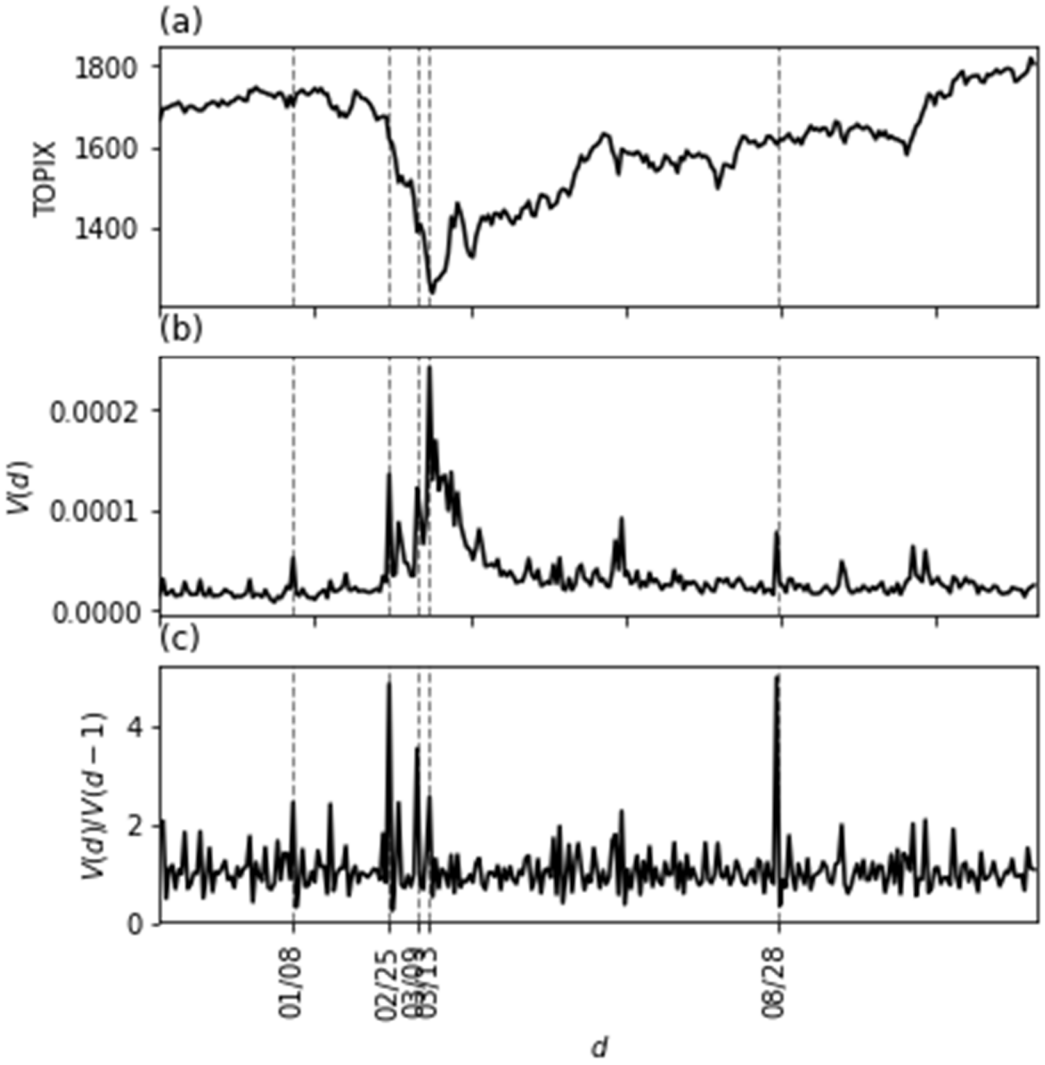

図 5　TOPIX と TOPIX ボラティリティの推移。(a)は各日の TOPIX の終値を、(b)は TOPIX ボラティリティ$V(d)$を、(c)は TOPIX ボラティリティの前日比$V(d)/V(d-1)$を示す。破線は、特に$V(d)/V(d-1)$が大きかった5日（2020 年 1 月 8 日、2 月 25 日、3 月 9 日、3 月 13 日、8 月 28 日）を示す。

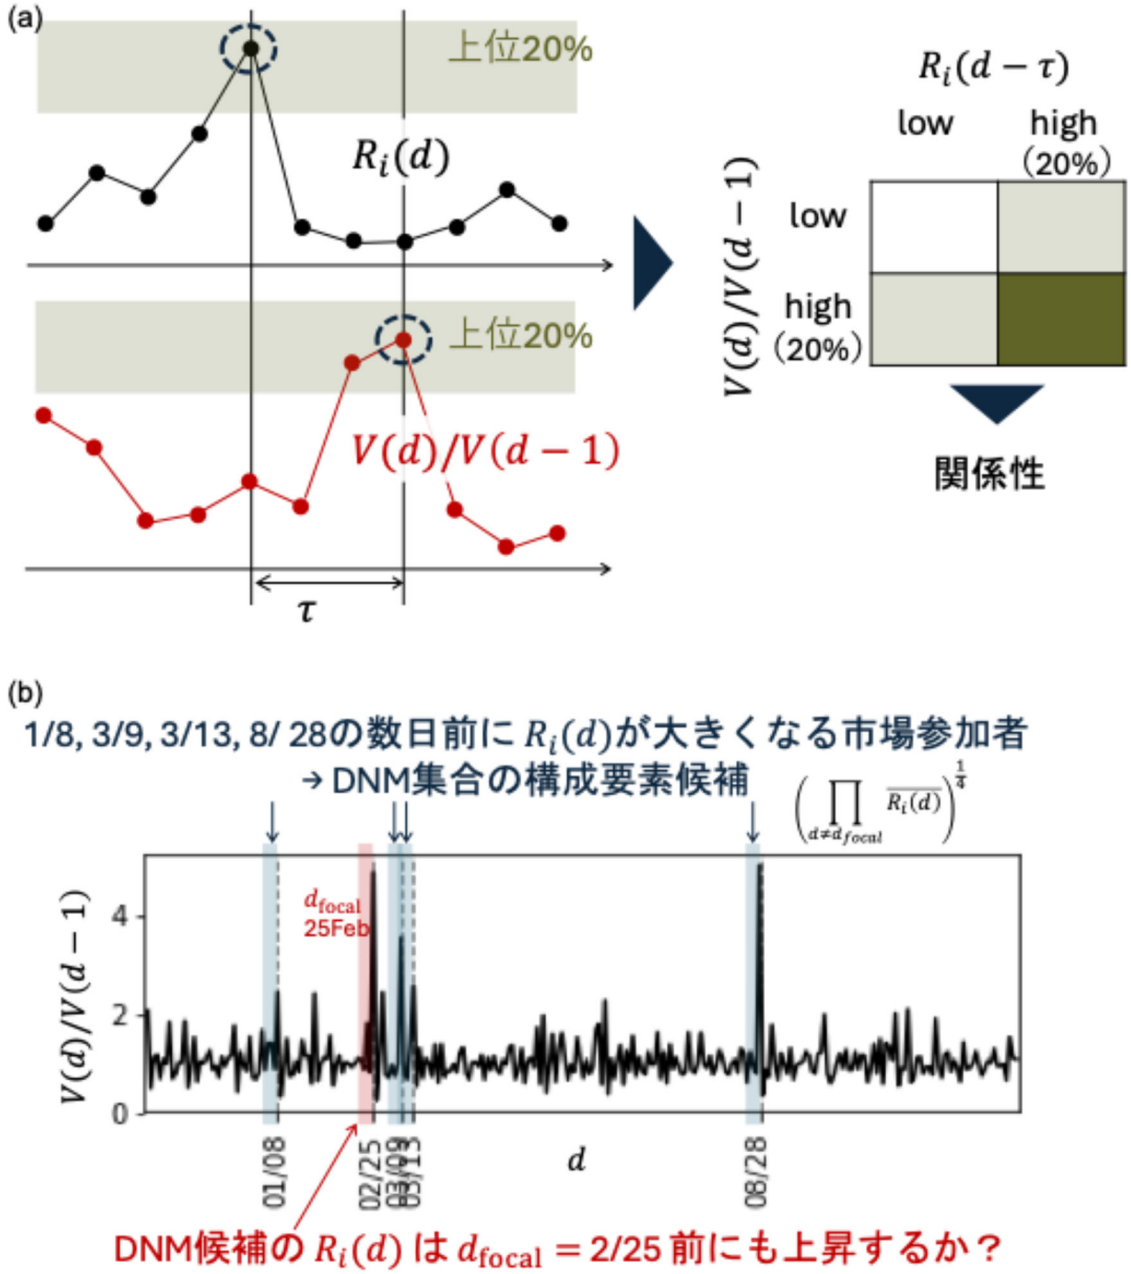

図 6　(a) DNM 指標と TOPIX ボラティリティの大小関係の比較の流れ。(b)市場不安定化前の DNM 指標の振る舞いを評価する手順。

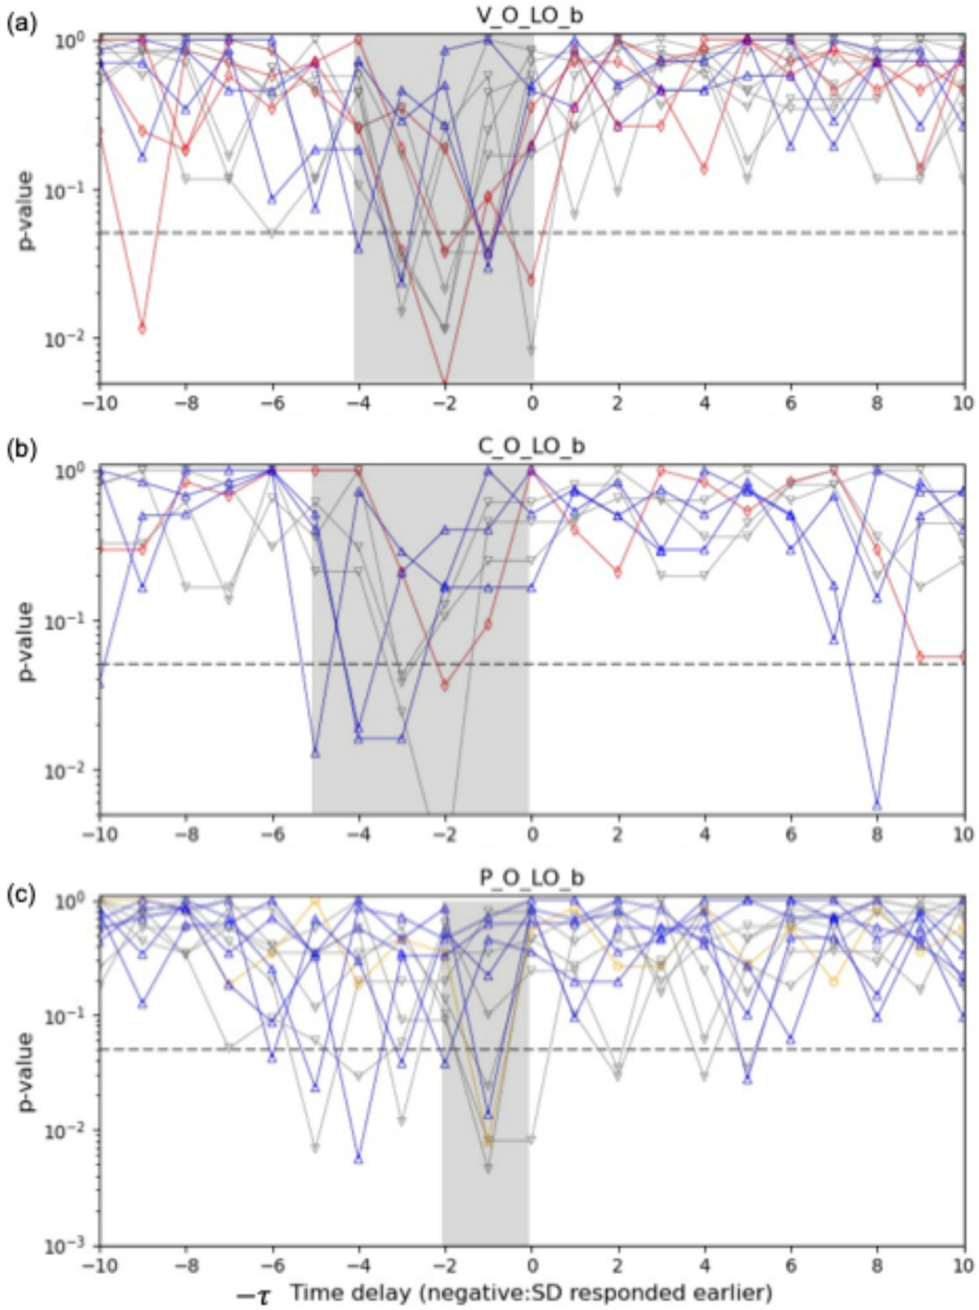

図 7 $R_i(d-\tau)$と$V(d)/V(d-1)$の関係性。縦軸はこの関係性に関するフィッシャーの正確確率検定の p 値を対数スケールで表し、横軸はタイムラグ$-\tau$を表す。パネル(a,b,c)は、それぞれ時系列種 vol3（V_O_LO_b）、co3（C_O_LO_b）、pp3（P_O_LO_b）に対応する。各プロットが市場参加者に対応しており、ここでは「DNM 集合に含まれ得る市場参加者」として、$-5 \leq -\tau < 0$の範囲で p 値が 0.05（破線）を下回り、$-5 \leq -\tau < 0$の範囲における p 値の平均が$0 \leq -\tau < 5$の範囲における p 値の平均よりも低くなるような市場参加者についてのみプロットした。HFT の市場参加者は青、証券会社自己は赤、一般投資家はオレンジ、その他は灰色で示した。6.4 補論 4 に、全ての時系列種について本図と同様の結果を示す。

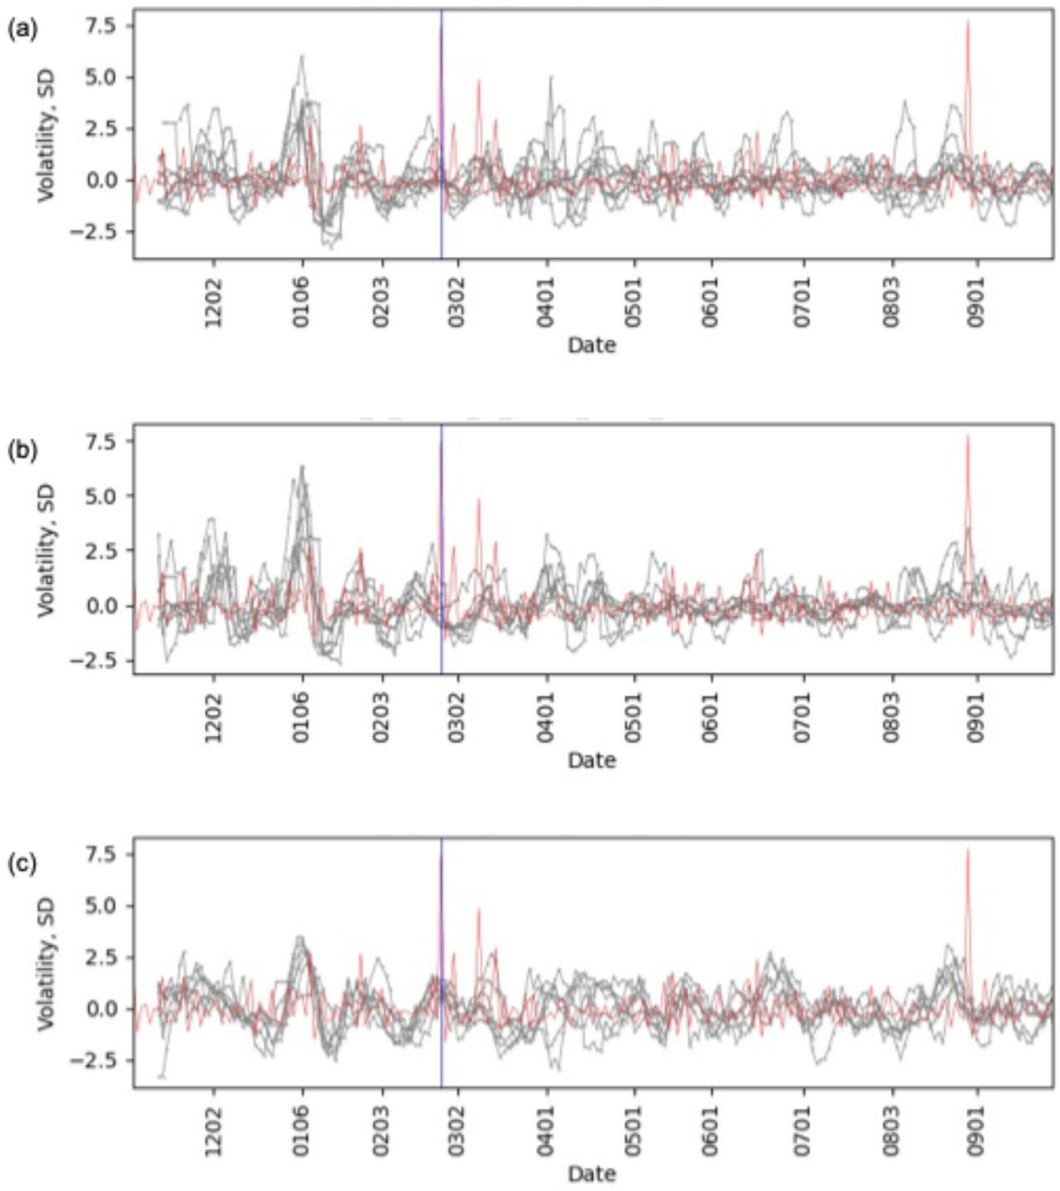

図 8 $I_{d_{focal}}$に含まれる各市場参加者の$R_i(d)$と TOPIX ボラティリティ前日比$V(d)/V(d-1)$の推移（d_{focal} =2 月 25 日。d_{focal}は青色の垂線で示した）。パネル(a,b,c)は、それぞれ時系列種 vol4（V_O_LO_s）、co3（C_O_LO_b）、pp7（P_E_LO_b）に対応する。各市場参加者の$R_i(d)$の Z 値を黒色のプロットで、$V(d)/V(d-1)$の Z 値を赤色のプロットで示した。

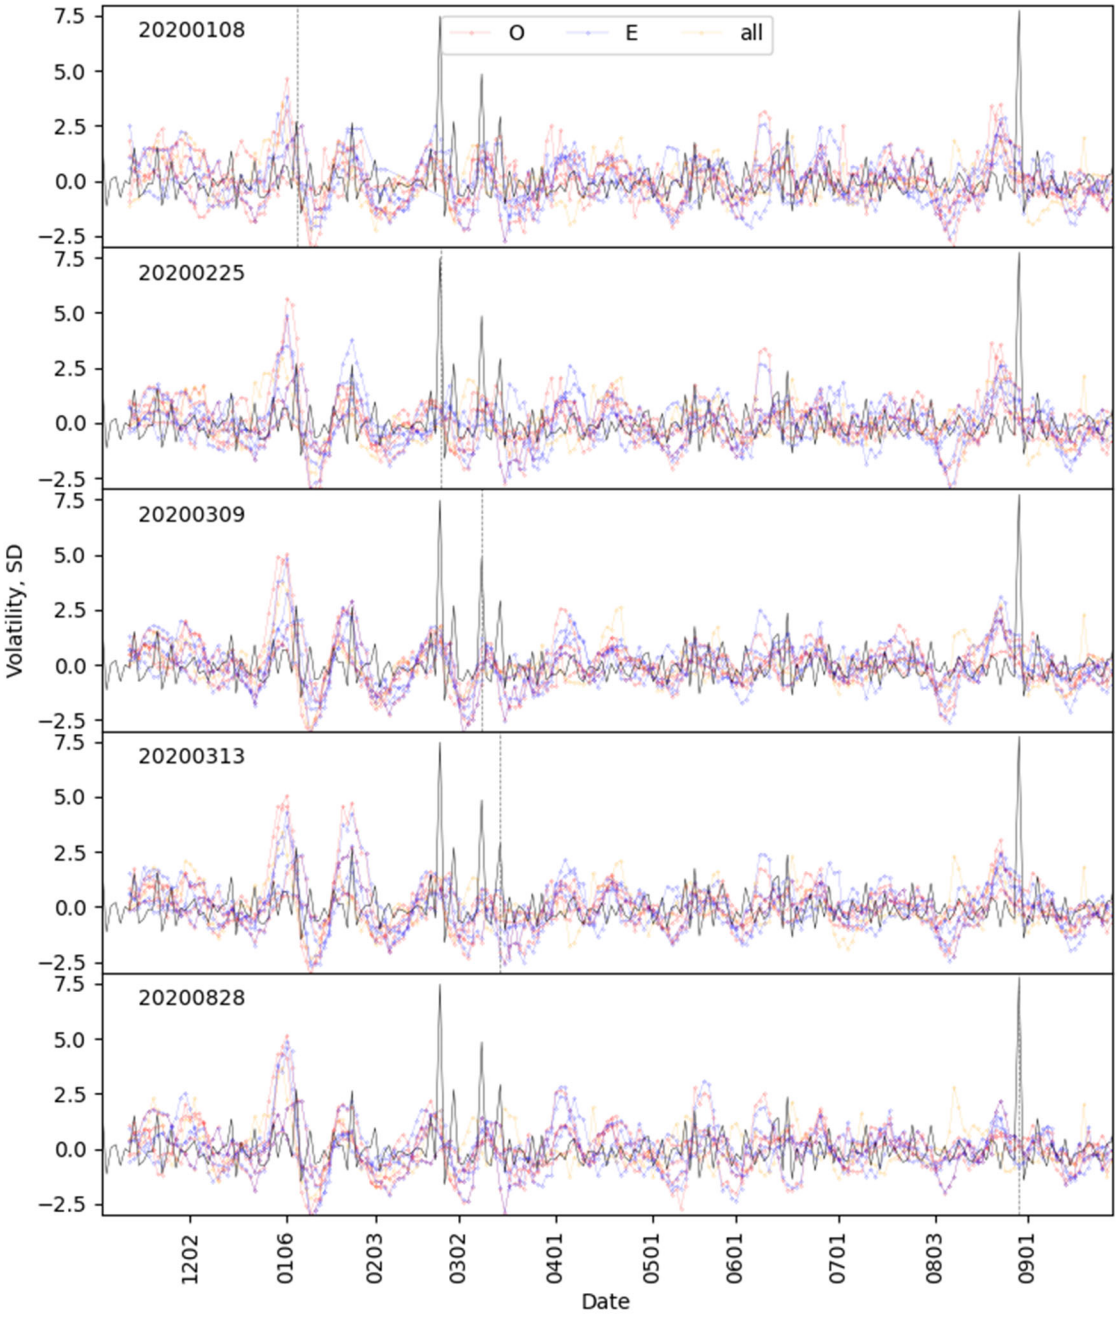

図 9　発注取引数量に関する時系列種（vol1～vol9）についての$SD_{I,d_{focal}}$の推移。各パネルがd_{focal}に対応する（パネル左上にd_{focal}を示した）。$SD_{I,d_{focal}}$の Z 値について、新規注文に関する時系列種は赤色で、約定に関する時系列種は青色で、全ての発注に関する時系列種はオレンジ色でプロットした。$V(d)/V(d-1)$の Z 値は、黒色のプロットで示した。

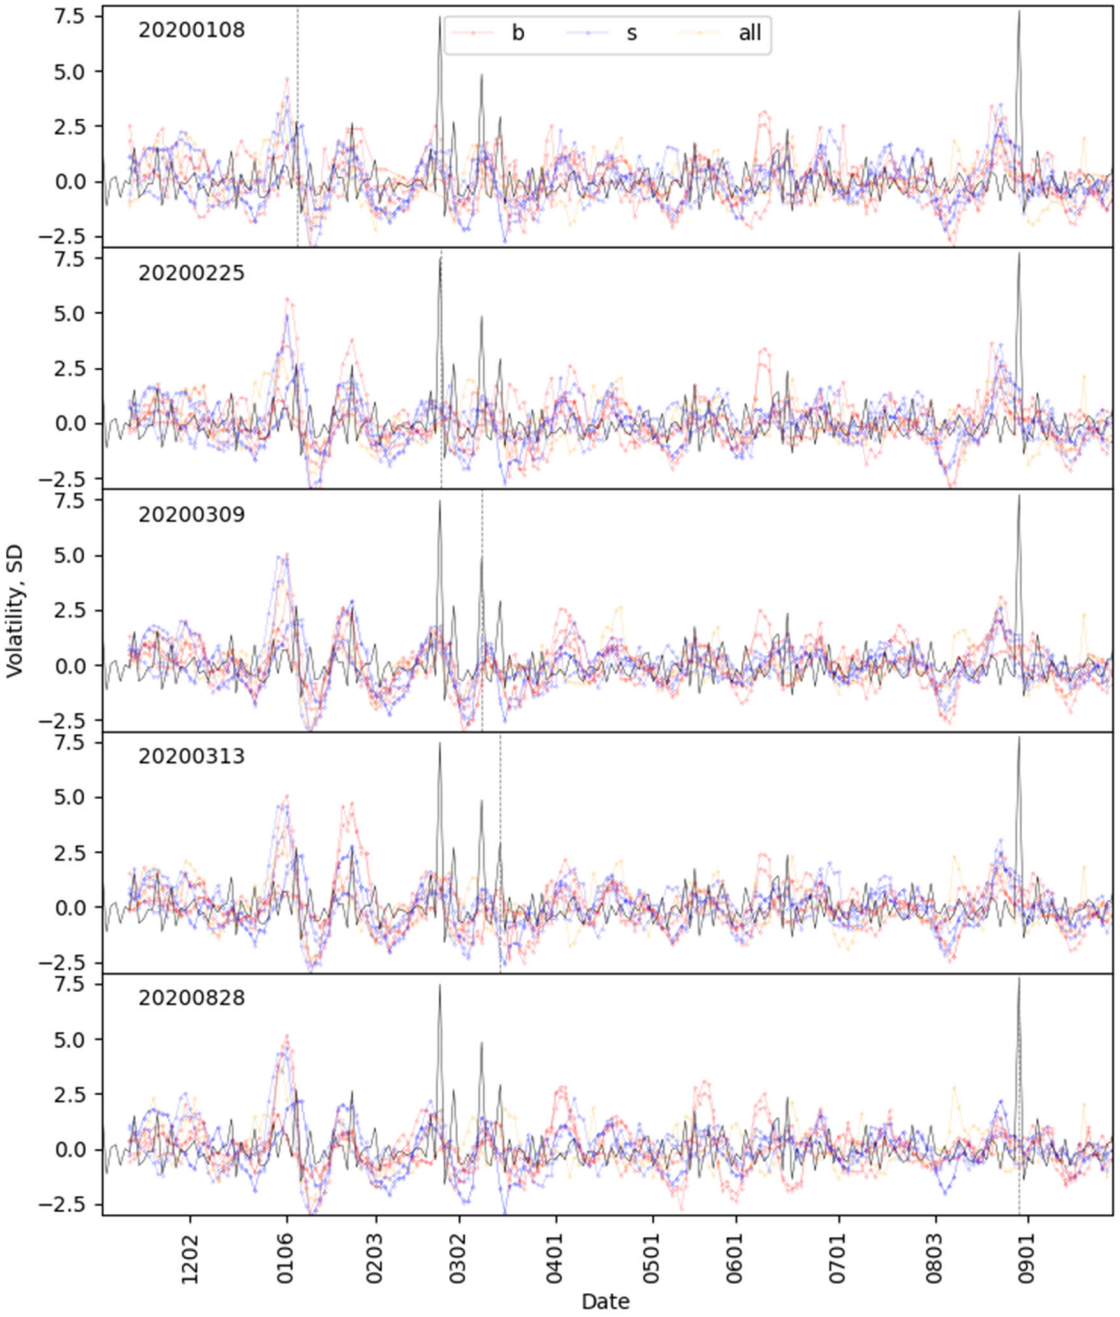

図 10　発注取引数量に関する時系列種（vol1～vol9）についての$SD_{I,d_{focal}}$の推移。各パネルがd_{focal}に対応する（パネル左上に示した）。$SD_{I,d_{focal}}$の Z 値について、買いに関する時系列種は赤色で、売りに関する時系列種は青色で、全ての発注に関する時系列種はオレンジ色でプロットした。$V(d)/V(d-1)$の Z 値は、黒色のプロットで示した。

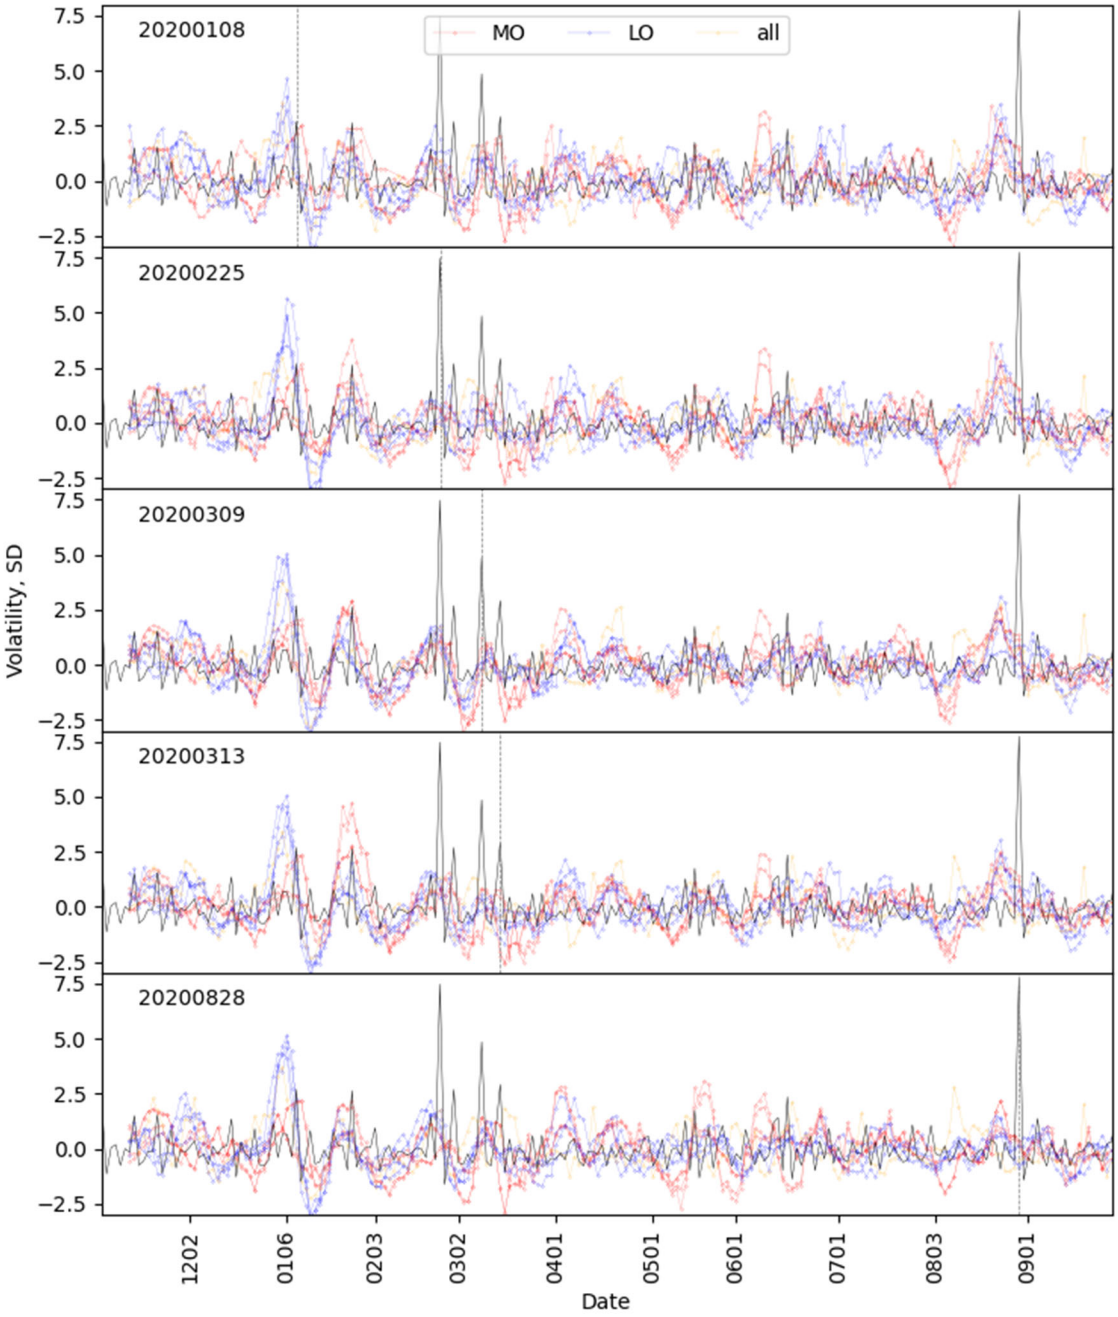

図 11　発注取引数量に関する時系列種（vol1～vol9）についての$SD_{I,d_{focal}}$の推移。各パネルがd_{focal}に対応する（パネル左上に示した）。$SD_{I,d_{focal}}$の Z 値について、成行注文に関する時系列種は赤色で、指値注文に関する時系列種は青色で、全ての発注に関する時系列種はオレンジ色でプロットした。$V(d)/V(d-1)$の Z 値は、黒色のプロットで示した。

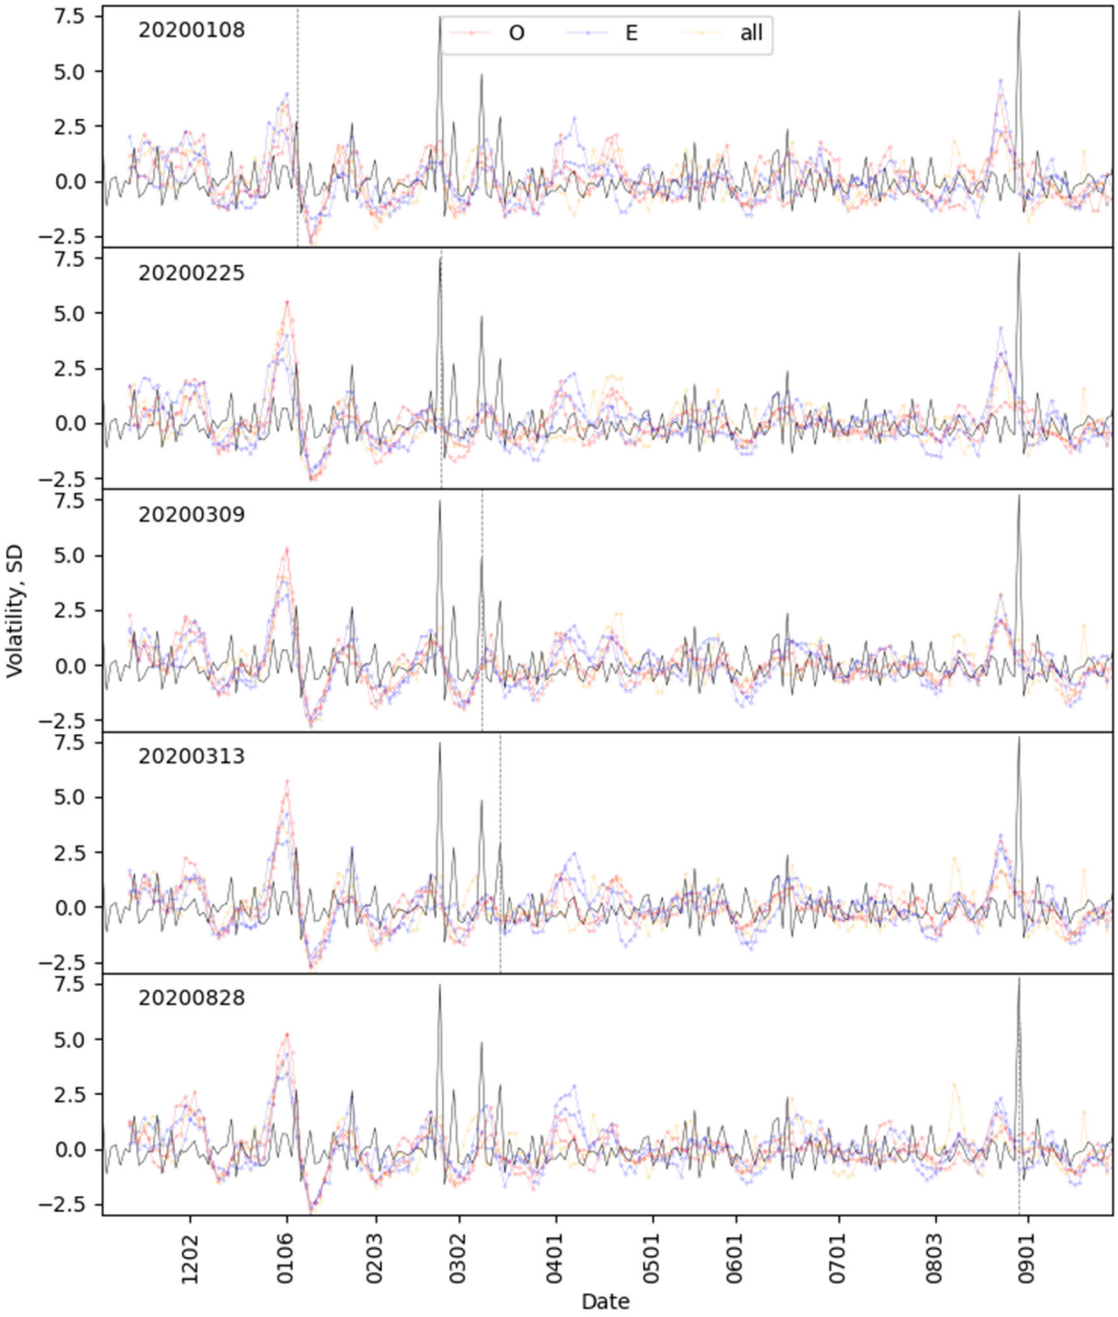

図 12　銘柄の共有に関する時系列種 (co1～co9) についての$SD_{I,d_{focal}}$の推移。各パネルがd_{focal}に対応する（パネル左上に示した）。$SD_{I,d_{focal}}$の Z 値について、新規注文に関する時系列種は赤色で、約定に関する時系列種は青色で、全ての発注に関する時系列種はオレンジ色でプロットした。$V(d)/V(d-1)$の Z 値は、黒色のプロットで示した。

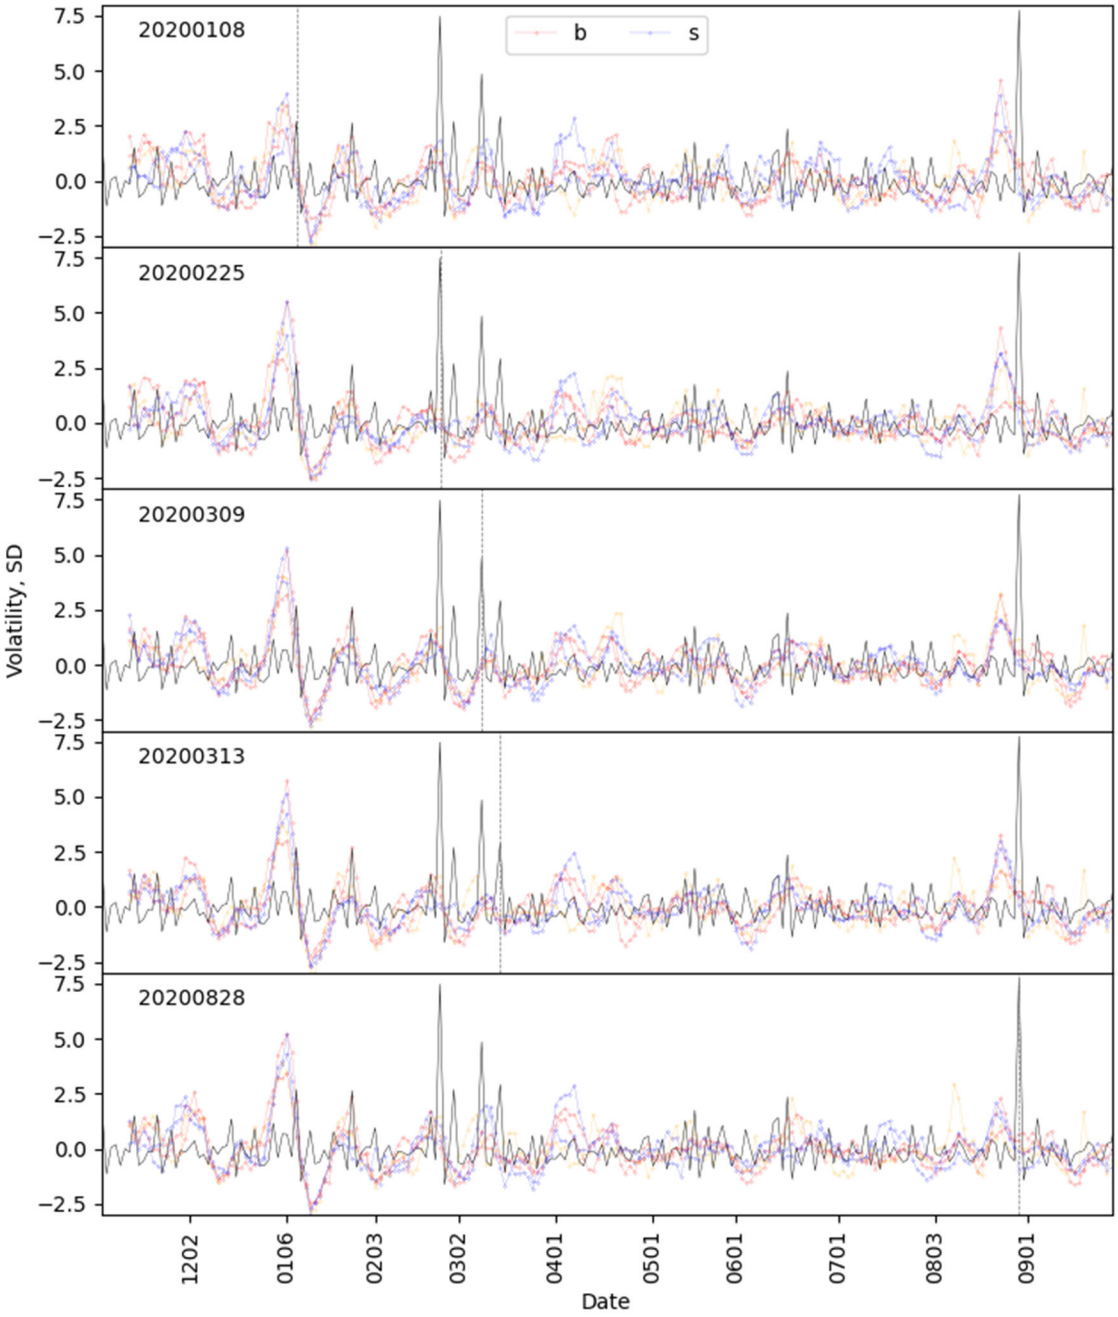

図 13　銘柄の共有に関する時系列種（co1～co 9）についての$SD_{I,d_{focal}}$の推移。各パネルがd_{focal}に対応する（パネル左上に示した）。$SD_{I,d_{focal}}$の Z 値について、買いに関する時系列種は赤色で、売りに関する時系列種は青色で、全ての発注に関する時系列種はオレンジ色でプロットした。$V(d)/V(d-1)$の Z 値は、黒色のプロットで示した。

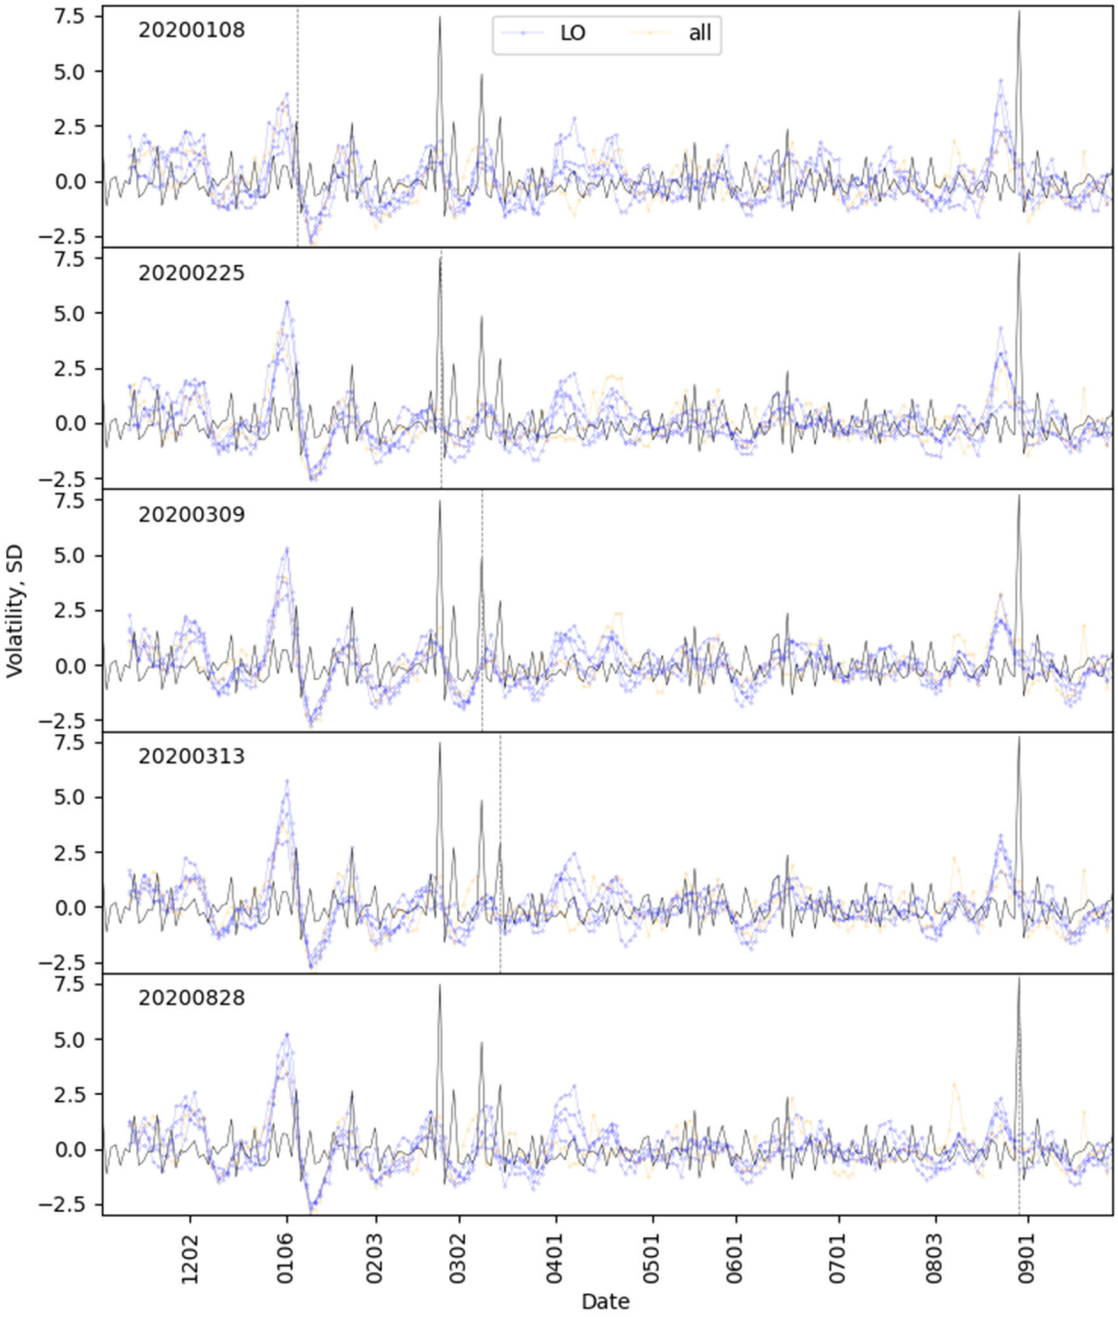

図 14　銘柄の共有に関する時系列種（co1～co 9）についての$SD_{I,d_{focal}}$の推移。各パネルがd_{focal}に対応する（パネル左上に示した）。$SD_{I,d_{focal}}$の Z 値について、成行注文に関する時系列種は赤色で、指値注文に関する時系列種は青色で、全ての発注に関する時系列種はオレンジ色でプロットした。$V(d)/V(d-1)$の Z 値は、黒色のプロットで示した。

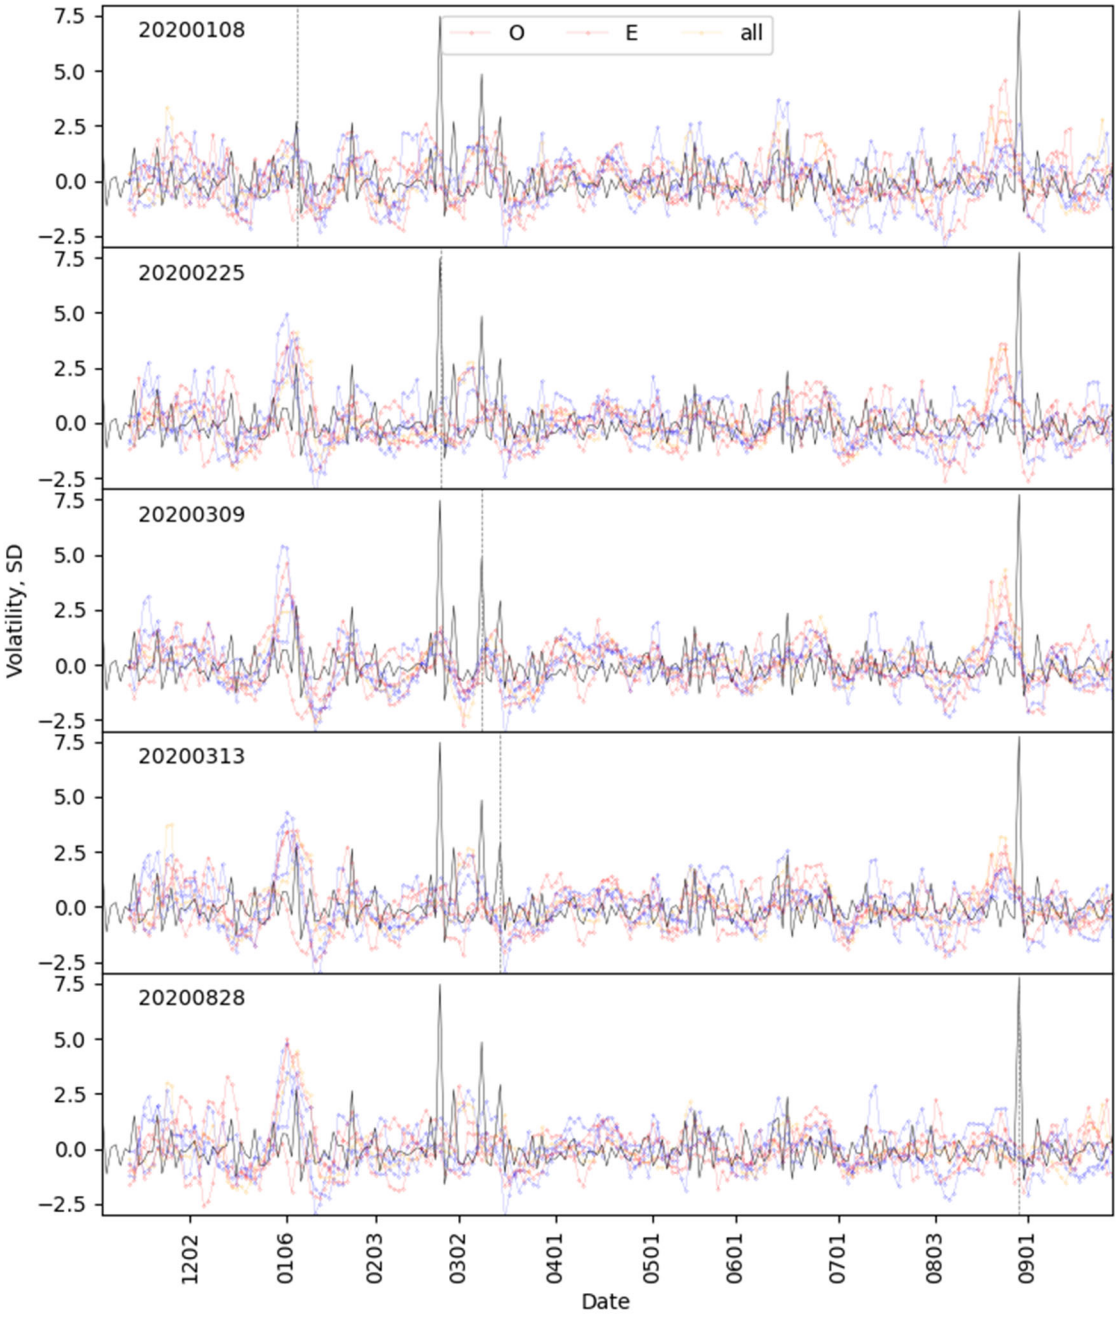

図 15　点過程に関する時系列種（pp1～pp9）についての$SD_{I,d_{focal}}$の推移。各パネルがd_{focal}に対応する（パネル左上に示した）。$SD_{I,d_{focal}}$の Z 値について、新規注文に関する時系列種は赤色で、約定に関する時系列種は青色で、全ての発注に関する時系列種はオレンジ色でプロットした。$V(d)/V(d-1)$の Z 値は、黒色のプロットで示した。

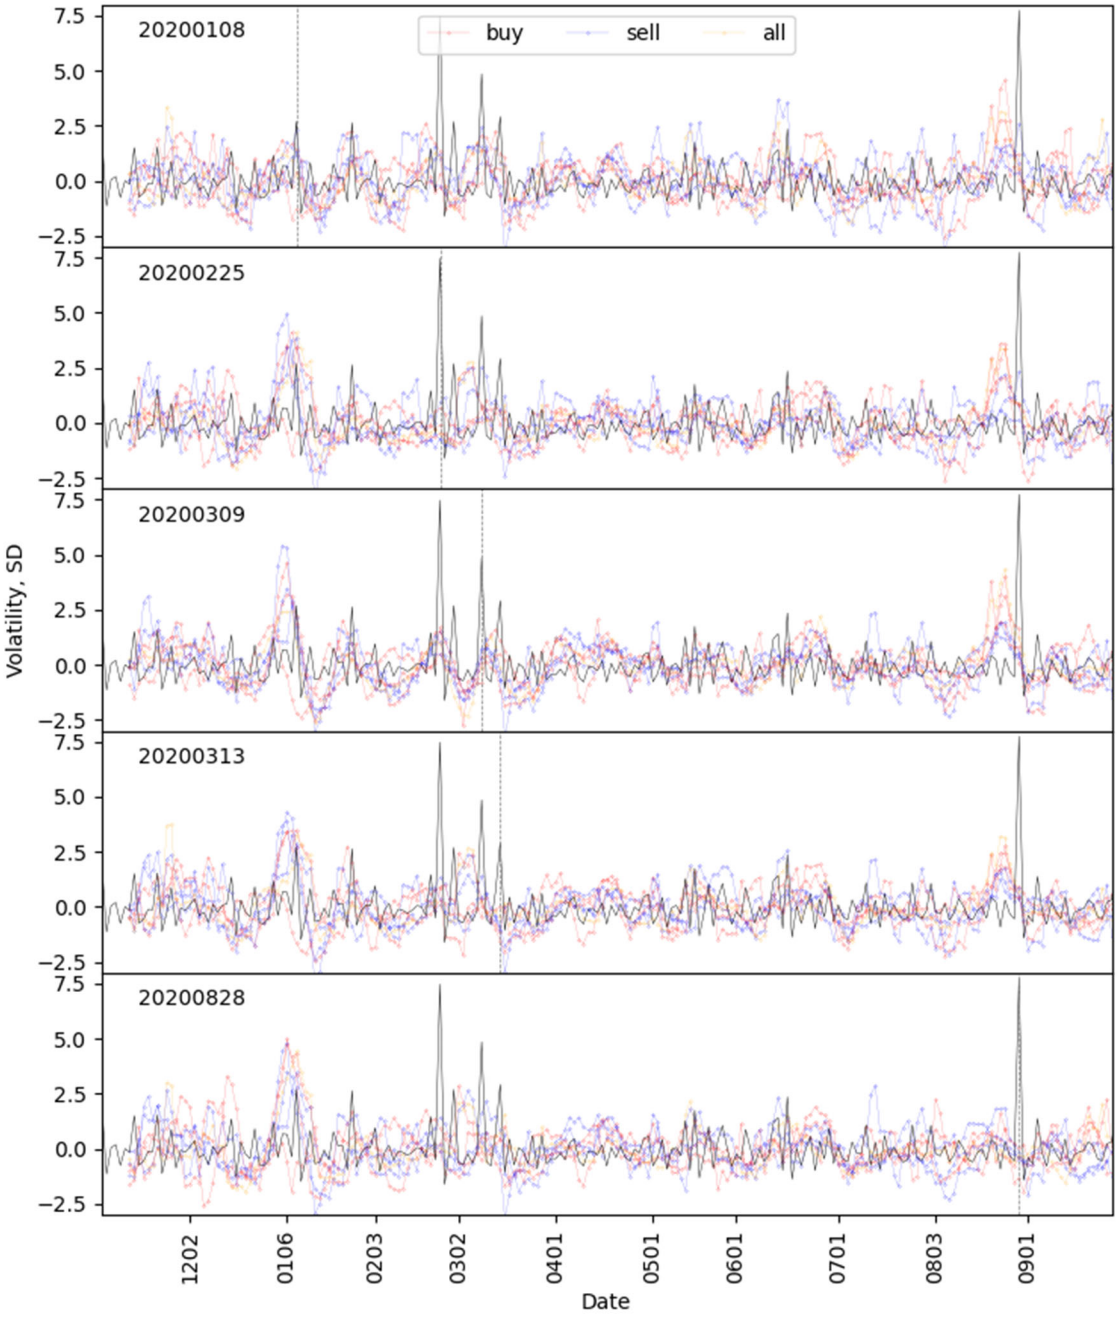

図 16　点過程に関する時系列種（pp1～pp 9）についての$SD_{I,d_{focal}}$の推移。各パネルがd_{focal}に対応する（パネル左上に示した）。$SD_{I,d_{focal}}$の Z 値について、買いに関する時系列種は赤色で、売りに関する時系列種は青色で、全ての発注に関する時系列種はオレンジ色でプロットした。$V(d)/V(d-1)$の Z 値は、黒色のプロットで示した。

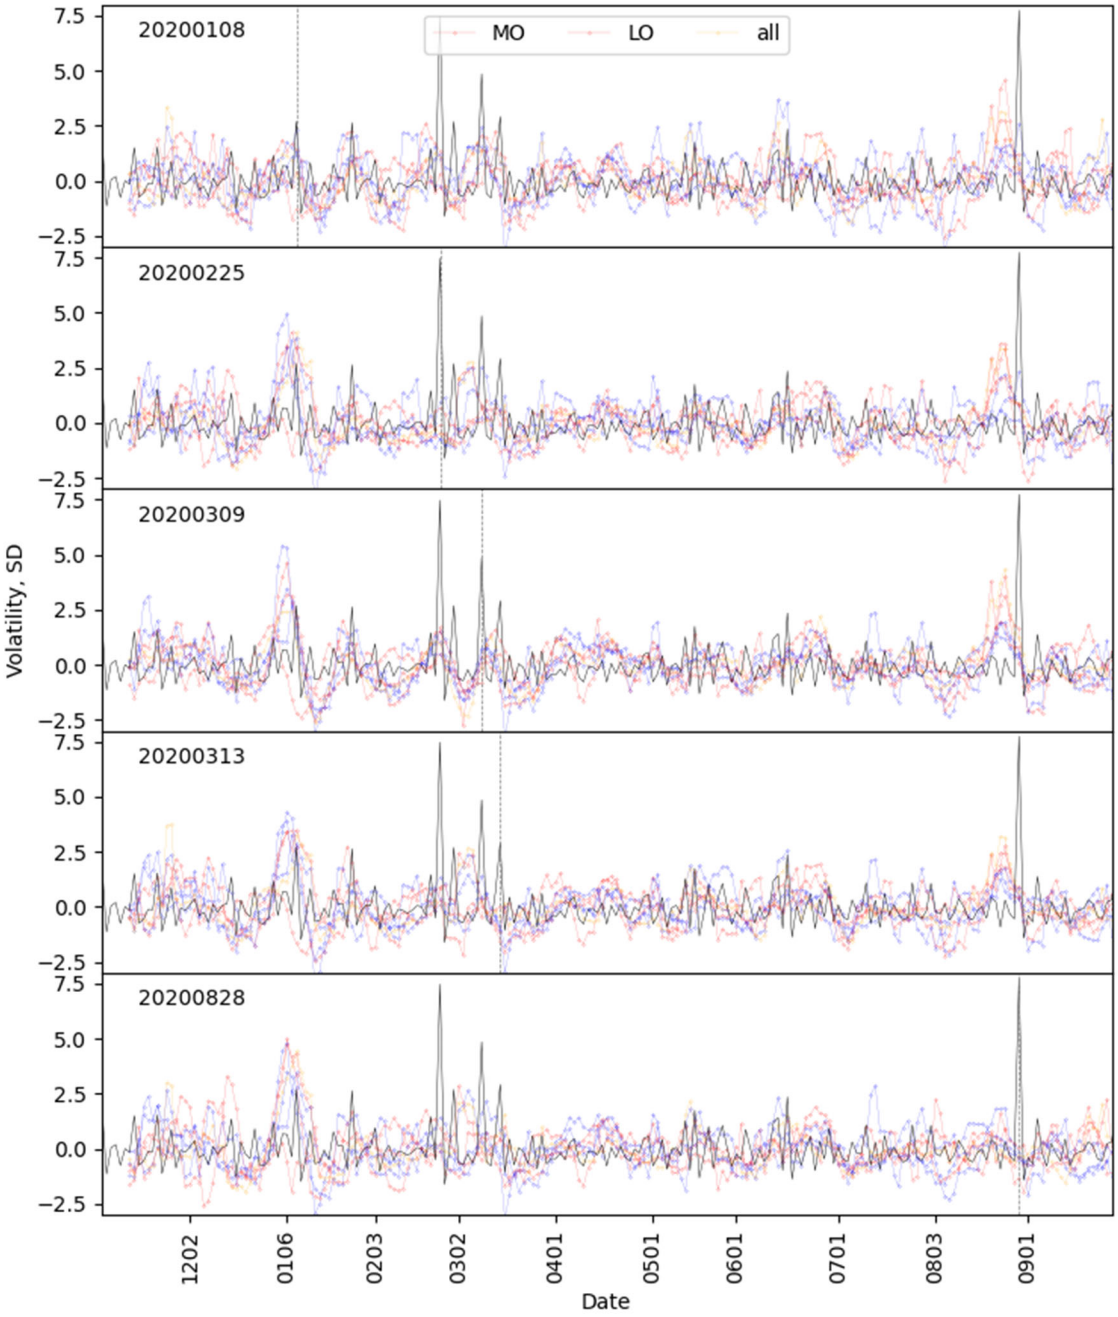

図 17 点過程に関する時系列種（pp1～pp 9）についての$SD_{I,d_{focal}}$の推移。各パネルがd_{focal}に対応する（パネル左上に示した）。$SD_{I,d_{fcal}}$の Z 値について、成行注文に関する時系列種は赤色で、指値注文に関する時系列種は青色で、全ての発注に関する時系列種はオレンジ色でプロットした。$V(d)/V(d-1)$の Z 値は、黒色のプロットで示した。

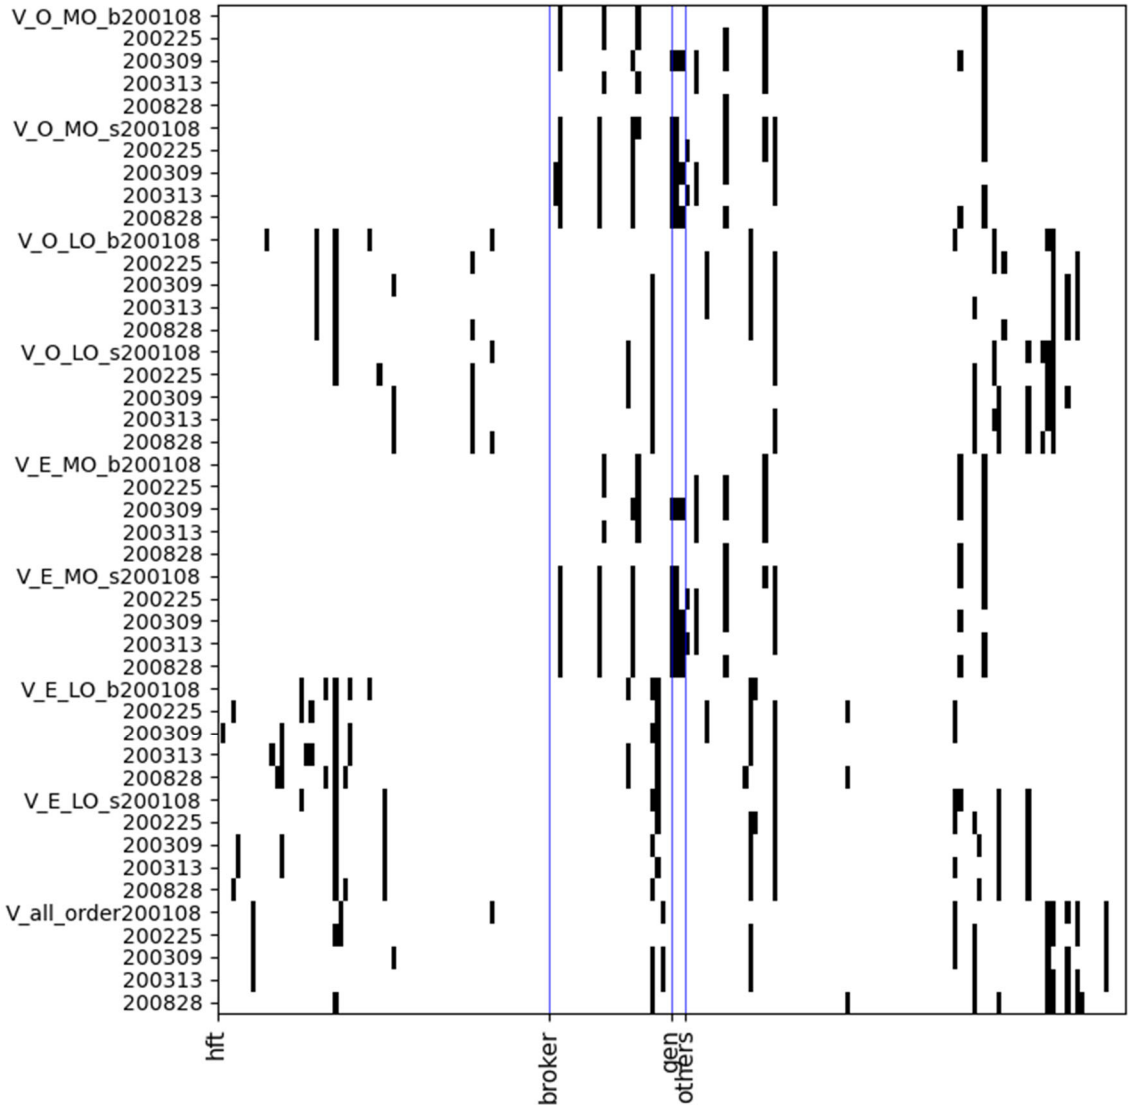

図 18 発注取引数量に着目した時系列種（$vol1$～$vol9$）に関する、d_{focal}別の、$I_{d_{focal}}$を構成する市場参加者。横軸では、市場参加者を、その種類別に、HFT（横軸 hft ラベルの右側）、証券会社自己（横軸 broker ラベルの右側）、一般投資家（横軸 gen ラベルの右側）、その他（横軸 others ラベルの右側）の順で、さらに発注数に関して降順になるように並べた。縦軸では、同じ時系列種についてd_{focal}を隣接させて並べている。黒いプロットは、その市場参加者が当該$I_{d_{focal}}$に含まれていることを表す。

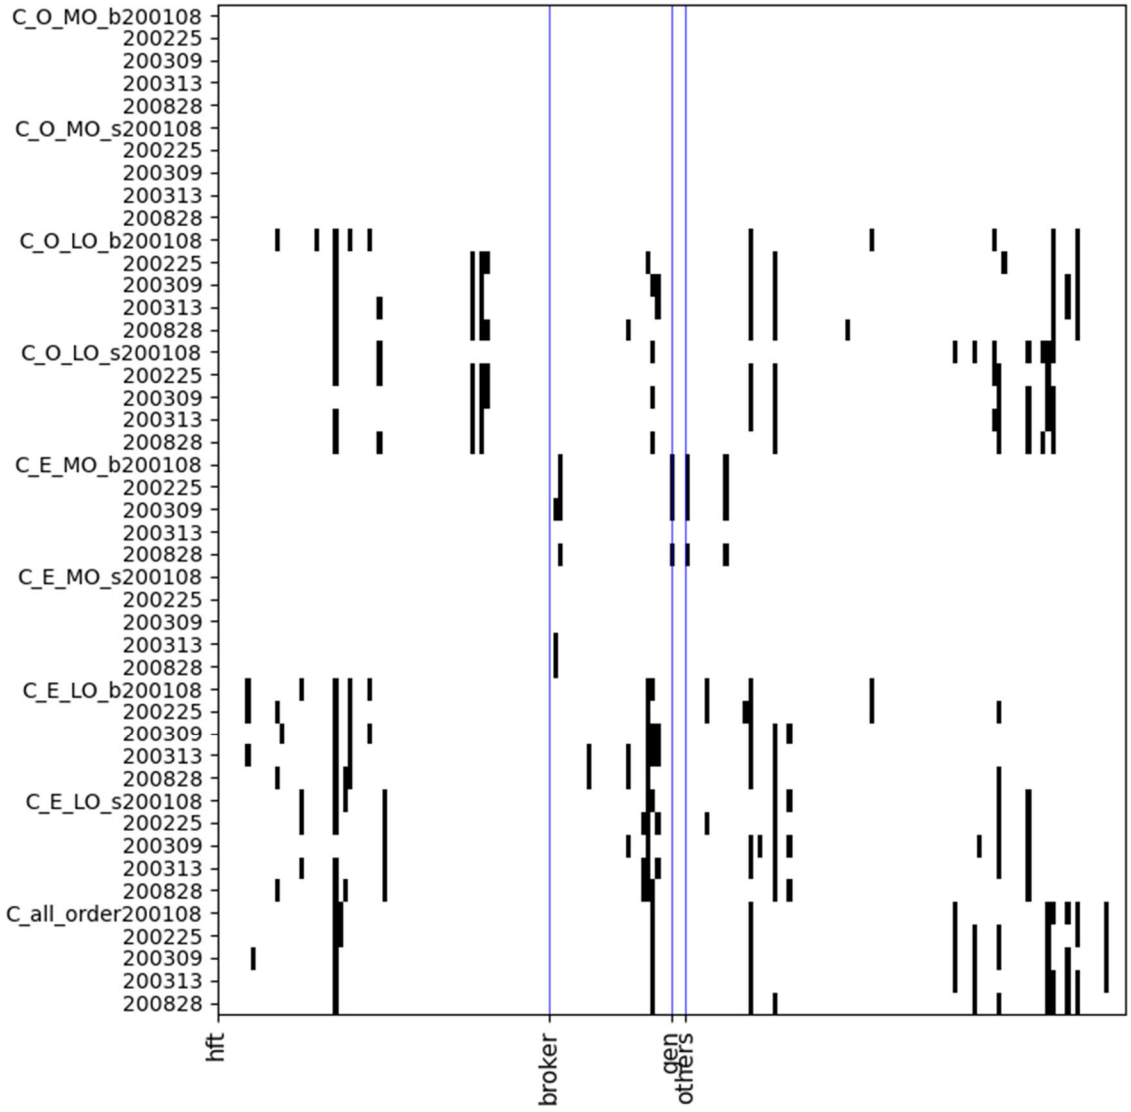

図 19　銘柄の共有に着目した時系列種（$co1$～$co9$）に関する、d_{focal}別の、$I_{d_{focal}}$を構成する市場参加者。横軸では、市場参加者を、その種類（HFT、証券会社自己、一般投資家、その他）別に、発注数に関して降順になるように並べた。縦軸では、同じ時系列種についてd_{focal}を隣接させて並べている。黒いプロットは、その市場参加者が当該$I_{d_{focal}}$に含まれていることを表す。

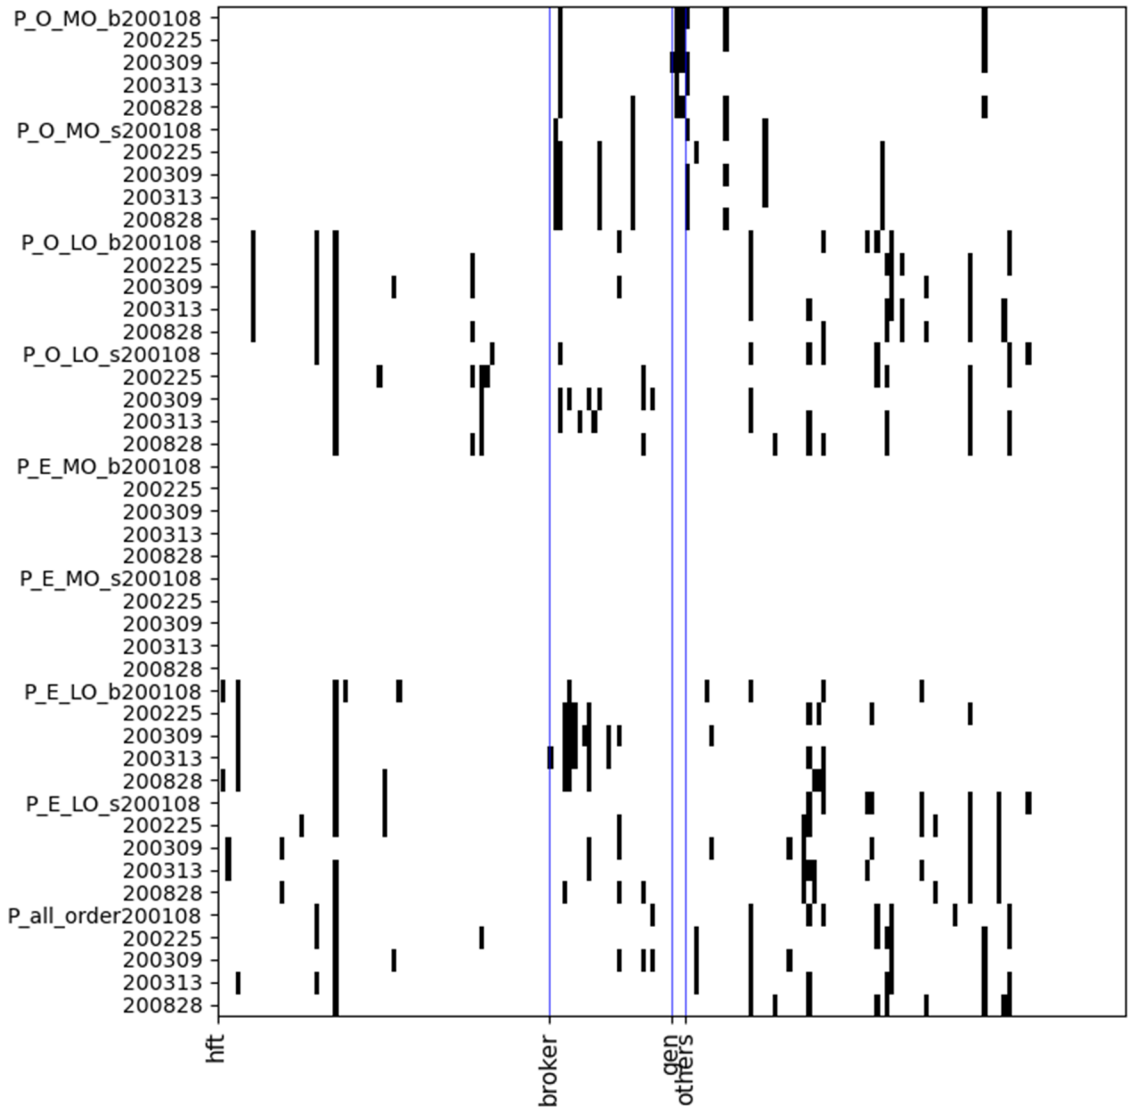

図 20　点過程に着目した時系列種（$pp1$～$pp9$）に関する、d_{focal}別の、$I_{d_{focal}}$を構成する市場参加者。横軸では、市場参加者を、その種類（HFT、証券会社自己、一般投資家、その他）別に、発注数に関して降順になるように並べた。縦軸では、同じ時系列種についてd_{focal}を隣接させて並べている。黒いプロットは、その市場参加者が当該$I_{d_{focal}}$に含まれていることを表す。

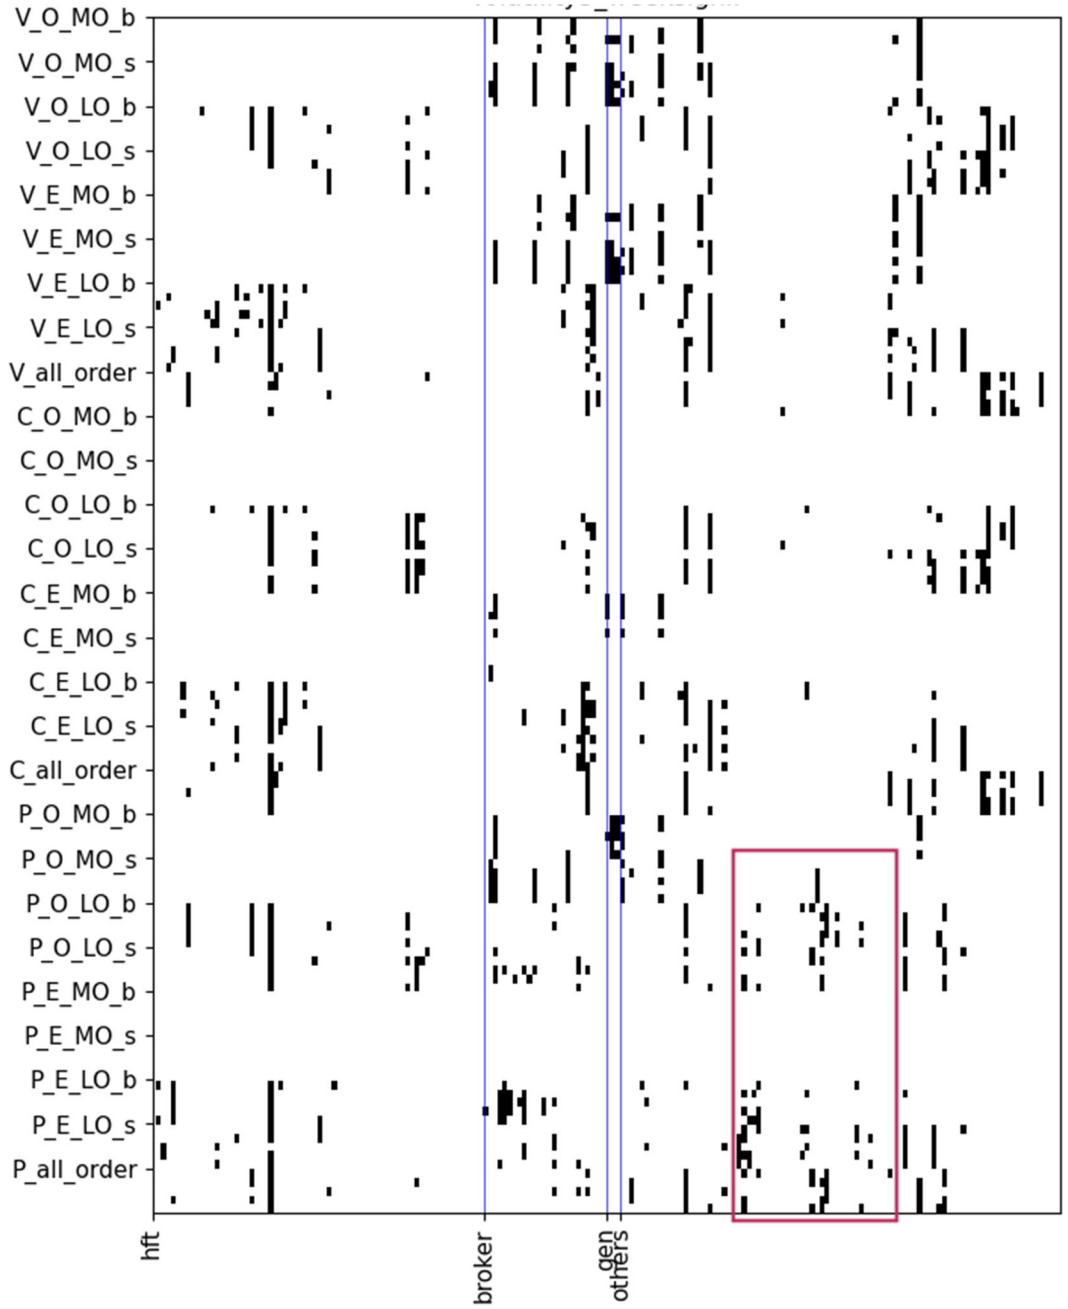

図 21　全時系列種に関する、d_{focal}別の、$I_{d_{focal}}$を構成する市場参加者。この図では、図 18 から 20 を縦に並べて示している。赤枠内では、「発注取引点過程に着目した時系列」（略称が P_ から始まる時系列）に基づく$I_{d_{focal}}$に特異的に属するような市場参加者が見られる。

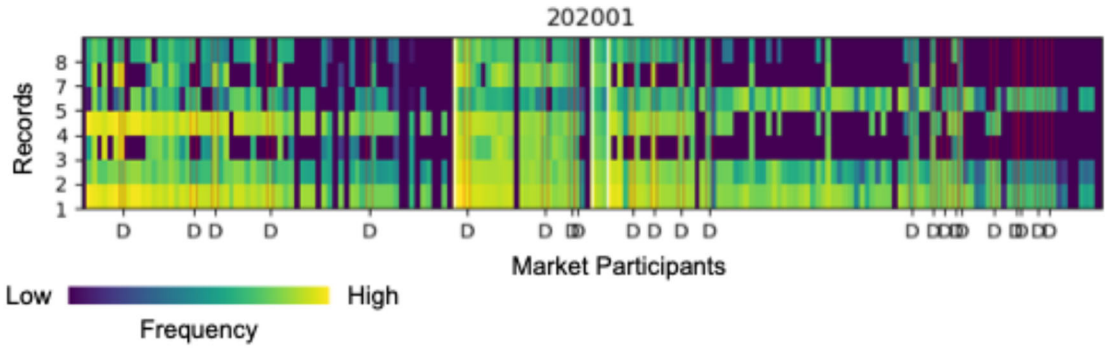

図 22　主要市場参加者のレコード種別発注取引件数。2020 年 1 月を対象に、横軸方向に図 18—21 と同じ順番（HFT、証券会社自己、一般投資家、その他の順。さらに、それぞれの市場参加者タイプの中では発注件数についての降順）で全市場参加者を並べ、縦軸方向にレコード種別を列挙し、当該月における発注取引件数を対数スケールでヒートマップにより示した。縦軸のレコード種は、1：新規注文、2：約定、3：変更注文、4：取消注文、5：注文失効、7：取消新規処理、8：引け処理を示す。ここでは主要市場参加者を赤枠で囲って示した。また、市場参加者タイプが切り替わる箇所を白の垂線で示した。

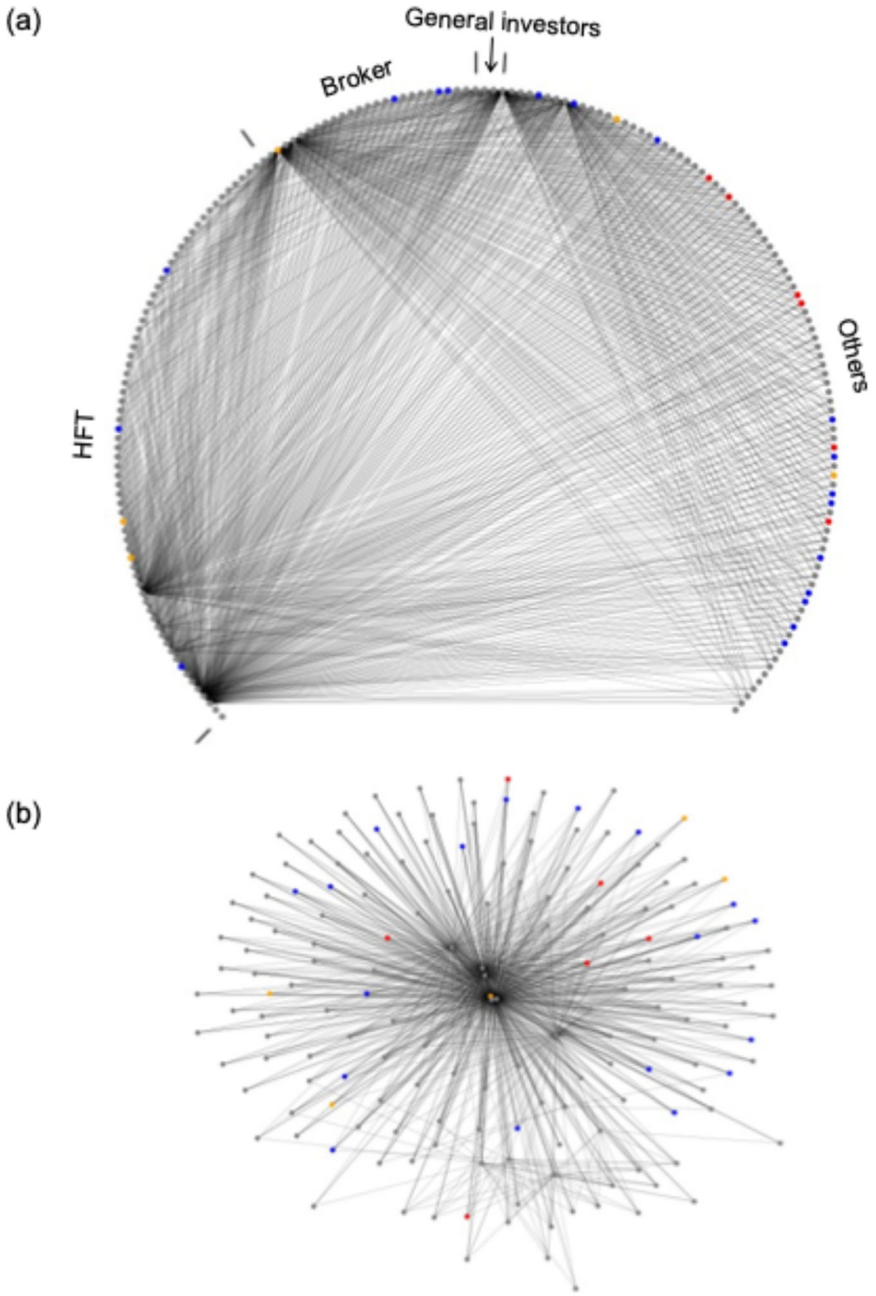

図 23　(a,b) 2020 年 1 月における発注取引銘柄の共有関係のネットワーク表現。頂点は市場参加者を表し、リンクは銘柄共有に関する強い関係性を表す。全ての時系列種のもとで定めた主要市場参加者を DNM1、点過程に関する時系列種のみ考慮して定めた主要市場参加者を DNM2 としたとき、 DNM1 のみに属する主要市場参加者を青、DNM2 のみに属する主要市場参加者を赤で示し、DNM1 と DNM2 の双方に属する主要市場参加者をオレンジで示した。(a)では、市場参加者を、反時計回りに図 18—22 と同じ順番で並べた。(b)では、より密につながった頂点同士が近づくように頂点を配置した。

6. 補論

6.1. 補論 1. 点過程に基づく時系列の構成に関する検討

6.1.1. Hawkes 過程を考慮した時系列の構成

本研究では、発注取引点過程に着目した時系列の構成に Hawkes 過程解析を取り入れることを検討したが、実際の発注取引態様と Hawkes 過程モデルを比較し、Hawkes 過程の本分析への適用を見送った。ここでは、参考として、当初検討していた Hawkes 過程解析に基づく発注取引時系列の構成について説明する。

Hawkes 過程は、イベントがイベントをさらに引き起こすことを仮定した点過程モデルである。大地震が発生した後には地震（余震）が発生しやすくなることから地震学で用いられてきたが、金融市場において短時間に取引が多く発生するような現象などの分析にも応用されている。特に先行研究では、市場参加者の取引が起こる確率の時間変化を外生的な変動と内生的な変動に分解する手法が提案されている。ここで外生的変動は、ニュース、日銀の介入、政策の発表、地震・テロなどのイベントに起因する取引発生確率の変動や、取引開始・終了時刻近辺で取引が増えるというような一般的なトレンドを反映したベースラインの変動を指す。また、内生的変動は、過去の取引がさらに取引を引き起こす強さ（自己励起）の変動を表す。

本研究では、内生的変動に着目して発注取引時系列を構成することを考えた。金融市場における複雑な発注取引の様子の変動は、外生的変動と内生的変動の総和だと考えられるが、このうち、外生的変動は予測ができないノイズと見なすことができる。そこで、内生的変動のみを取り出して発注取引時系列を構成し DNM 理論を適用することを考えた。 また、本計画の準備として、EM アルゴリズムを用いて取引点過程から外生的変動と内生的変動を推定する手法を改良し、東証における銘柄ごとの約定時刻で構成された点過程時系列データに適用して、外生・内生要因に基づく市場状態の定量化を行った(Ito et al. 2024)。

しかしながら、銘柄ごとではなく市場参加者単位の点過程時系列の特徴を調べた結果、上述のような Hawkes 過程を仮定した解析が難しいと判断した。Hawkes 過程モデルでは、その自己励起性により、一度発注取引が行われると多数の発注取引がさらに引き続くような時間的に不均一な点過程が得られるはずである。一方で、特に HFT タイプの市場参加者の発注取引点過程では、しばしば周期性や規則性を示すものがあり、Hawkes 過程モデルの仮定が合わないものが少なからず見られた。さらに、他の市場参加者タイプにおいても、点過程の不均一性や発注取引数の少なさに起因して、発注取引が時間的に非常に疎になる場合があり、その結果、外生的・内生的変動の推定が困難となるケースが多く確認された。これらの理由により、本研究では、Hawkes 過程モデルを用いて DNM 解析用の発注取引時系列を構成することは見送ることとした。

6.1.2. LV 指標を考慮した時系列の構成

発注取引点過程に着目した時系列を構成するにあたり、前節の Hawkes 過程解析に加え、点過程指標LVの使用も検討した。しかしながら、本研究ではこの手法の採用も見送っており、そ

の理由と点過程時系列の扱いの難しさについて本節で詳述する。

LVは、連続するイベント間隔同士の類似性を評価するものであり、例えば「短い間隔でイベントが発生した後に、再び短い間隔で次のイベントが発生する傾向があるか」といった、局所的なイベント発生の傾向を定量化する指標である。点過程$\{t_i\}$に対して、イベント間隔の時系列$\{\Delta_i\}$（$\Delta_i := t_i - t_{i-1}$）を考慮したとき、LVは

$$\mathrm{LV} = \left\langle \frac{3(\Delta_i - \Delta_{i+1})^2}{(\Delta_i + \Delta_{i+1})^2} \right\rangle (\geq 0)$$

と定義される。イベントが等間隔に起きている場合は、$\Delta_i - \Delta_{i+1} = 0$であるため、$\mathrm{LV} = 0$となる。連続する間隔同士の長さが類似していればLVは小さくなり、間隔の変動が大きい場合LVは大きな値をとる。

本文ではCVを改良した指標Bを用いて時系列pp1～pp9を構成しているが、本研究においては指標Bの他にLVを使用することも検討した。具体的には、発注取引点過程の単位時間（t）あたりの部分点過程についてLVを計算し、$x_i(t) = \mathrm{LV}$として、時系列を構成することを考えた。

しかしながら、部分点過程のサイズがLVの値に著しく影響を与え得ることを考慮し、本研究ではLVの使用を見送ることとした。具体的には、LVを計算する際には、全てのイベント間隔にわたって$3(\Delta_i - \Delta_{i+1})^2/(\Delta_i + \Delta_{i+1})^2$を平均する必要があるが、このように平均した値の分散は、大数の法則によりイベント間隔数、つまり部分点過程のサイズの影響を受ける。実際に、Nを部分点過程のサイズとしたとき、

$$\mathrm{Var}[\mathrm{LV}] = \mathrm{Var}\left[\left\langle \frac{3(\Delta_i - \Delta_{i+1})^2}{(\Delta_i + \Delta_{i+1})^2} \right\rangle\right] = \mathrm{Var}\left[\frac{1}{(N-2)} \sum_{i=1}^{N-2} \frac{3(\Delta_i - \Delta_{i+1})^2}{(\Delta_i + \Delta_{i+1})^2}\right]$$

$$= \frac{1}{(N-2)} \mathrm{Var}\left[\frac{3(\Delta_i - \Delta_{i+1})^2}{(\Delta_i + \Delta_{i+1})^2}\right].$$

ここで、本研究で仮に指標 LV を用いて時系列$x_i(t)$を構成した場合、DNM 指標の計算に取り入れる標準偏差は$\sqrt{\mathrm{Var}[\mathrm{LV}]}$である。よって、DNM 指標は発注取引時系列の振動の強さの他にも、部分点過程サイズ、つまり単位時間あたりに発生した発注取引数の影響も受けてしまう。分析において実際に構築した発注取引点過程時系列を確認したところ、同一市場参加者であっても、その発注取引数は単位時間毎にも日毎にも変動している。したがって、市場参加者iのd日における指標$R_i(d)$が高かった場合に、それが発注取引数が少なかったためなのか、不安定性の前兆として大きく振動しているためなのか、詳細に区別することができないと考えられる。このことから、LVを用いた DNM 解析用の時系列構成を見送ることとした。上記の議論は、本文で示したようなCVを用いた時系列構成の際にも留意すべき点であり、このことを踏まえて、CVの代わりにBの指標を用いることとした。

6.2. 補論 2. 記号表

記号	説明

α	OrderID
s	ServerID
d	時間（日にち）
t	時間（分）
$\tilde{t}$	時間（秒）
i	市場参加者
N	市場参加者数
C_i	市場参加者iに対応する ServerID クラスタ
$x_i(t)$	市場参加者iの発注取引時系列
σ	銘柄
$y_{i,\sigma}(t)$	市場参加者iから銘柄σへの発注取引
$\{t_j^i\}$	市場参加者iの発注取引点過程
$V(d)$	TOPIX のd日のボラティリティ
I	DNM 集合

6.3. 補論 3. 各時系列種の SD の分布

ここでは、2.6. 図 4 で示した$\mathrm{SD}_{i,\mathrm{am}}(d)$および$\mathrm{SD}_{i,\mathrm{pm}}(d)$の分布に関し、全時系列種に関する結果を個別に示す。ここで、点過程を考慮した時系列である pp5（P_E_MO_b）と pp6（P_E_MO_s）については、単位時間あたりのデータサイズが不足し、各市場参加者の SD を計算することができなかったため、結果に反映させていない。

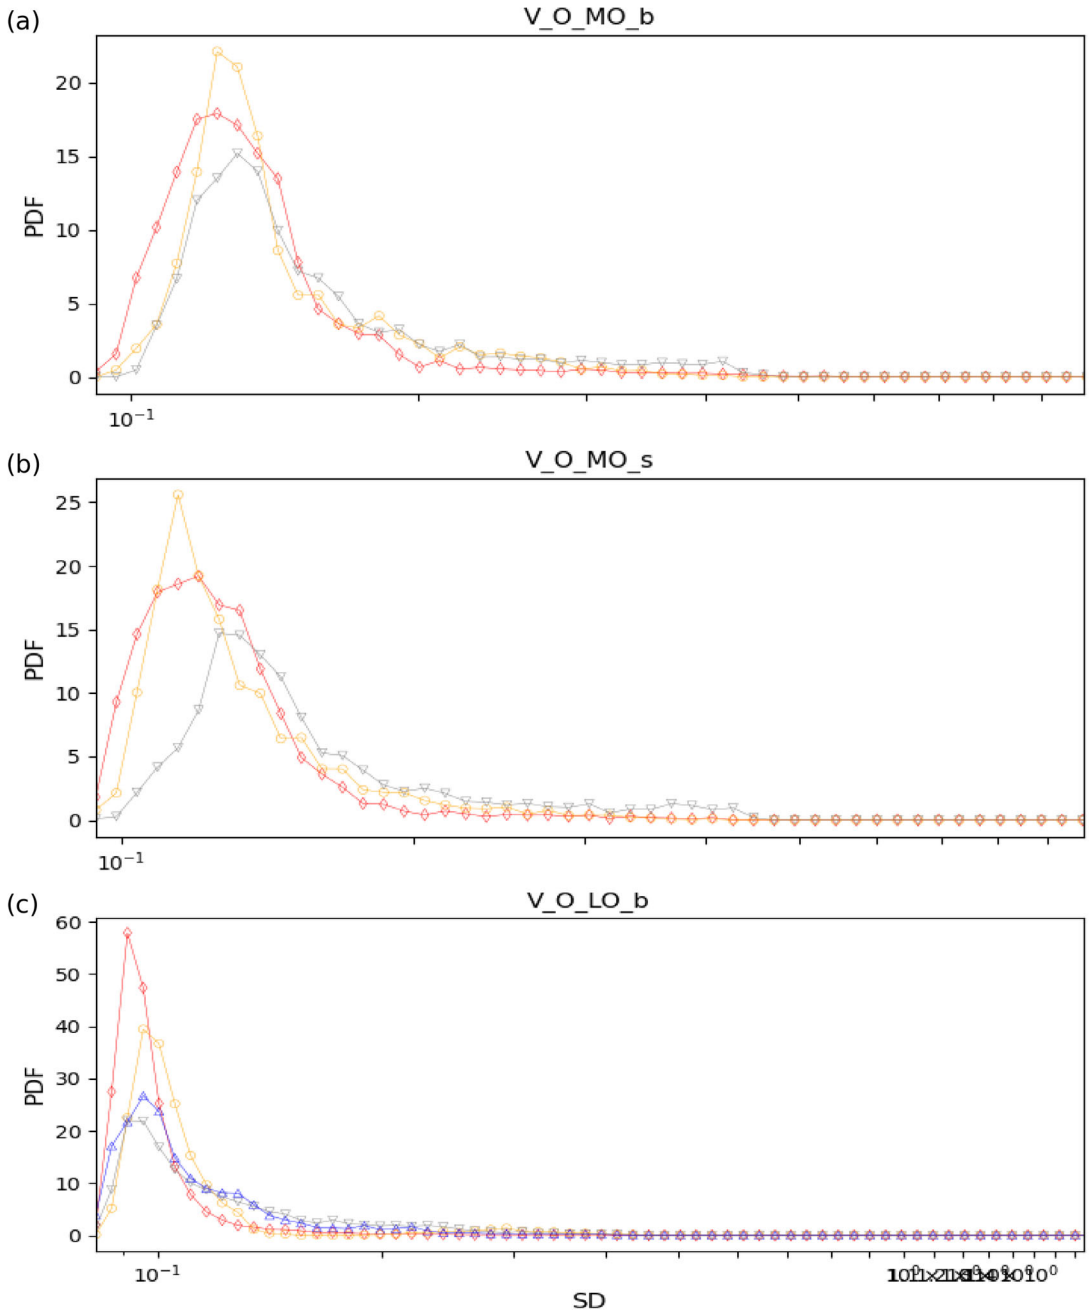

図 24　$SD_{i,am}(d)$および$SD_{i,pm}(d)$が取る値の確率密度関数（PDF）。(a) vol1（V_O_MO_b）、(b) vol2（V_O_MO_s）、(c) vol3（V_O_LO_b）の時系列種の結果を示す。市場参加者タイプ毎に PDF をプロットし、「HFT」は青、「証券会社自己」は赤、「一般投資家」はオレンジ、「その他」は灰色で示す)。

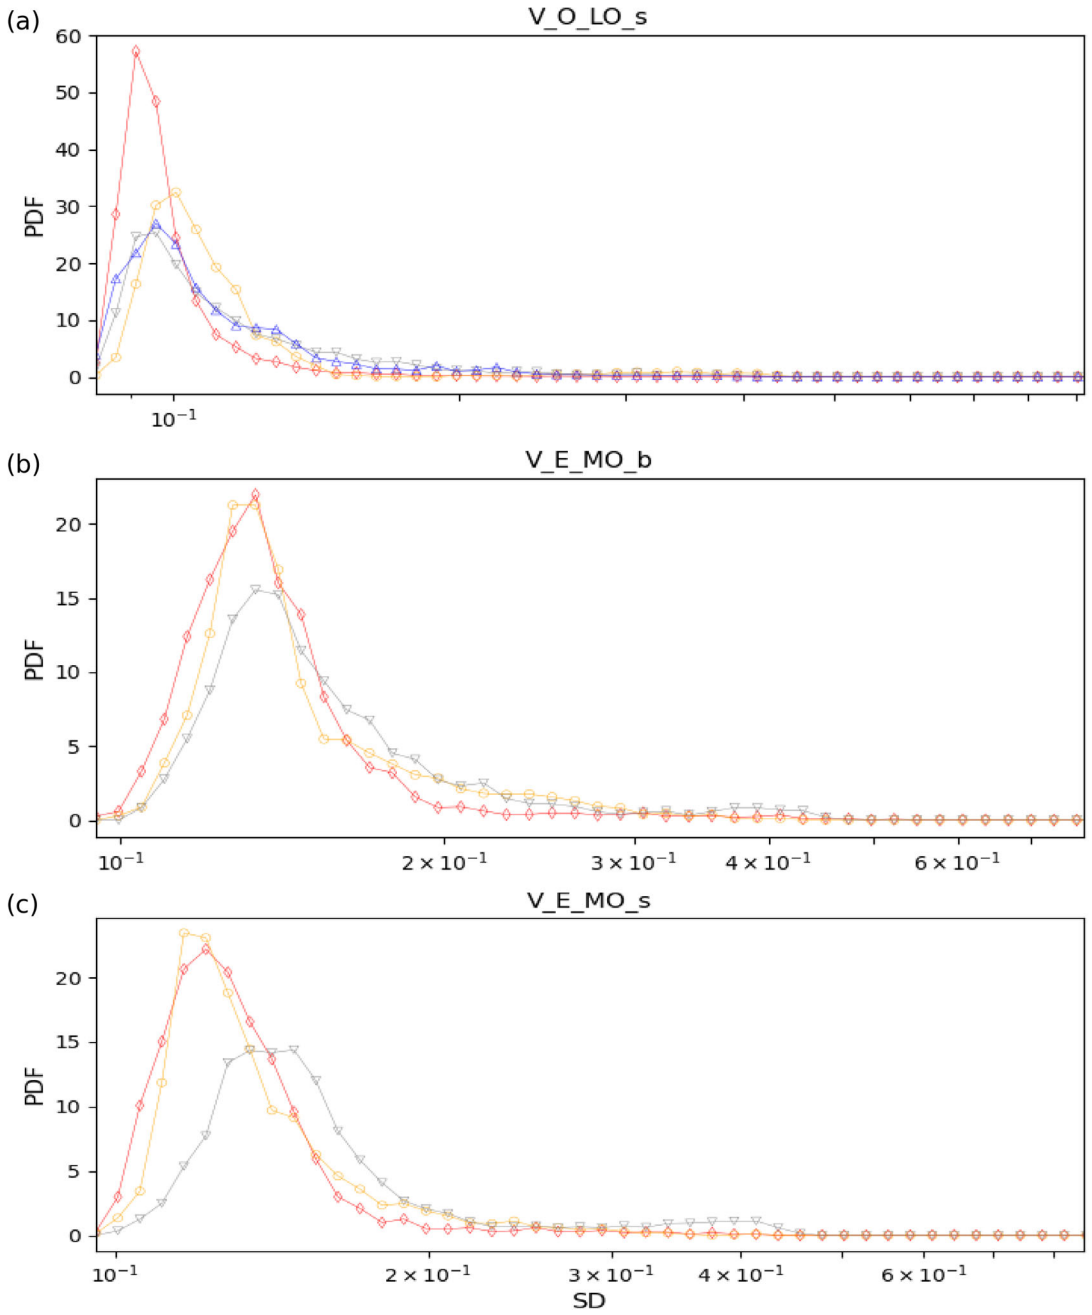

図 25 $SD_{i,am}(d)$および$SD_{i,pm}(d)$が取る値の確率密度関数（PDF）。(a) vol4（V_O_LO_s）、(b) vol5（V_E_MO_b）、(c) vol6（V_E_MO_s）の時系列種の結果を示す。市場参加者タイプ毎に PDF をプロットし、「HFT」は青、「証券会社自己」は赤、「一般投資家」はオレンジ、「その他」は灰色で示す）。

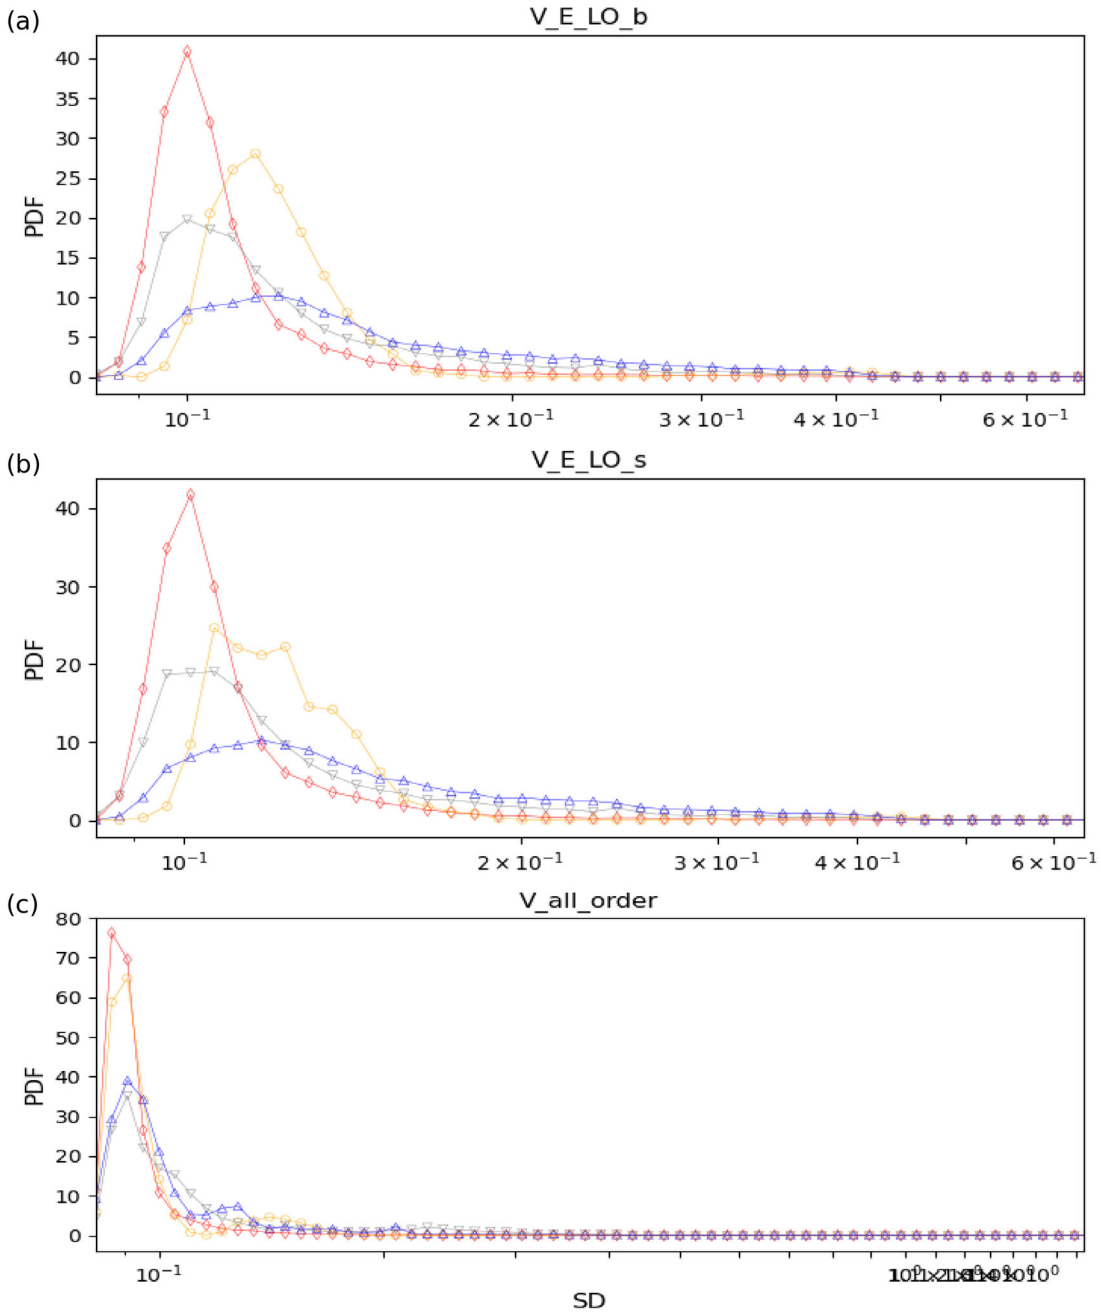

図 26 $SD_{i,am}(d)$および$SD_{i,pm}(d)$が取る値の確率密度関数（PDF）。(a) vol7（V_E_LO_b）、(b) vol8（V_E_LO_s）、(c) vol9（V_all_order）の時系列種の結果を示す。市場参加者タイプ毎に PDF をプロットし、「HFT」は青、「証券会社自己」は赤、「一般投資家」はオレンジ、「その他」は灰色で示す）。

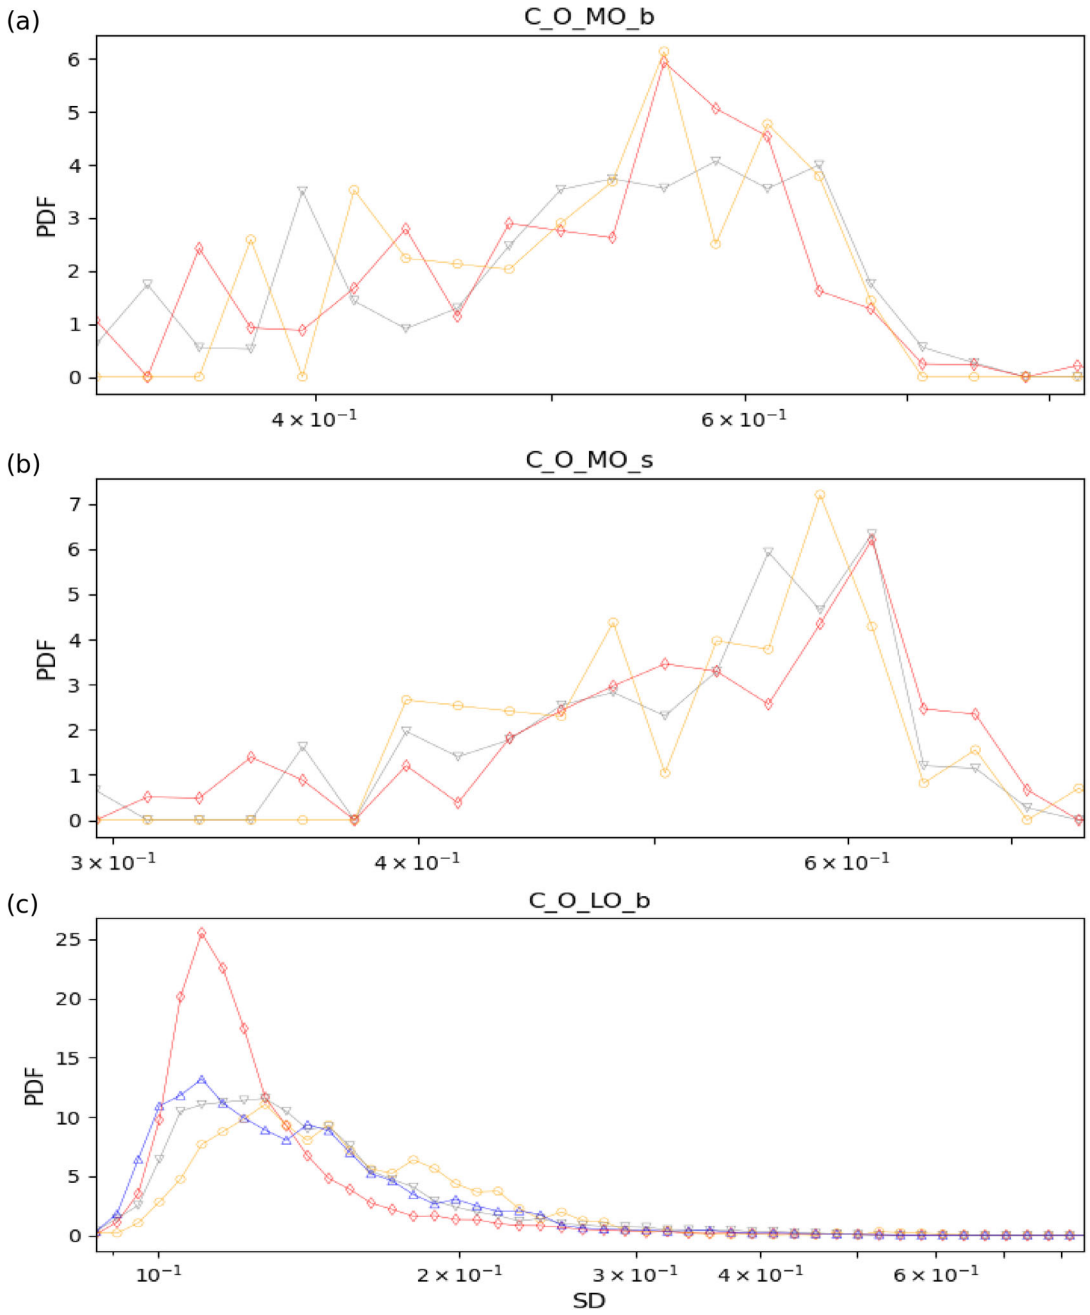

図 27 $SD_{i,am}(d)$および$SD_{i,pm}(d)$が取る値の確率密度関数（PDF）。(a) co1（C_O_MO_b）、(b) co2（C_O_MO_s）、(c) co3（C_O_LO_b）の時系列種の結果を示す。市場参加者タイプ毎に PDF をプロットし、「HFT」は青、「証券会社自己」は赤、「一般投資家」はオレンジ、「その他」は灰色で示す）。

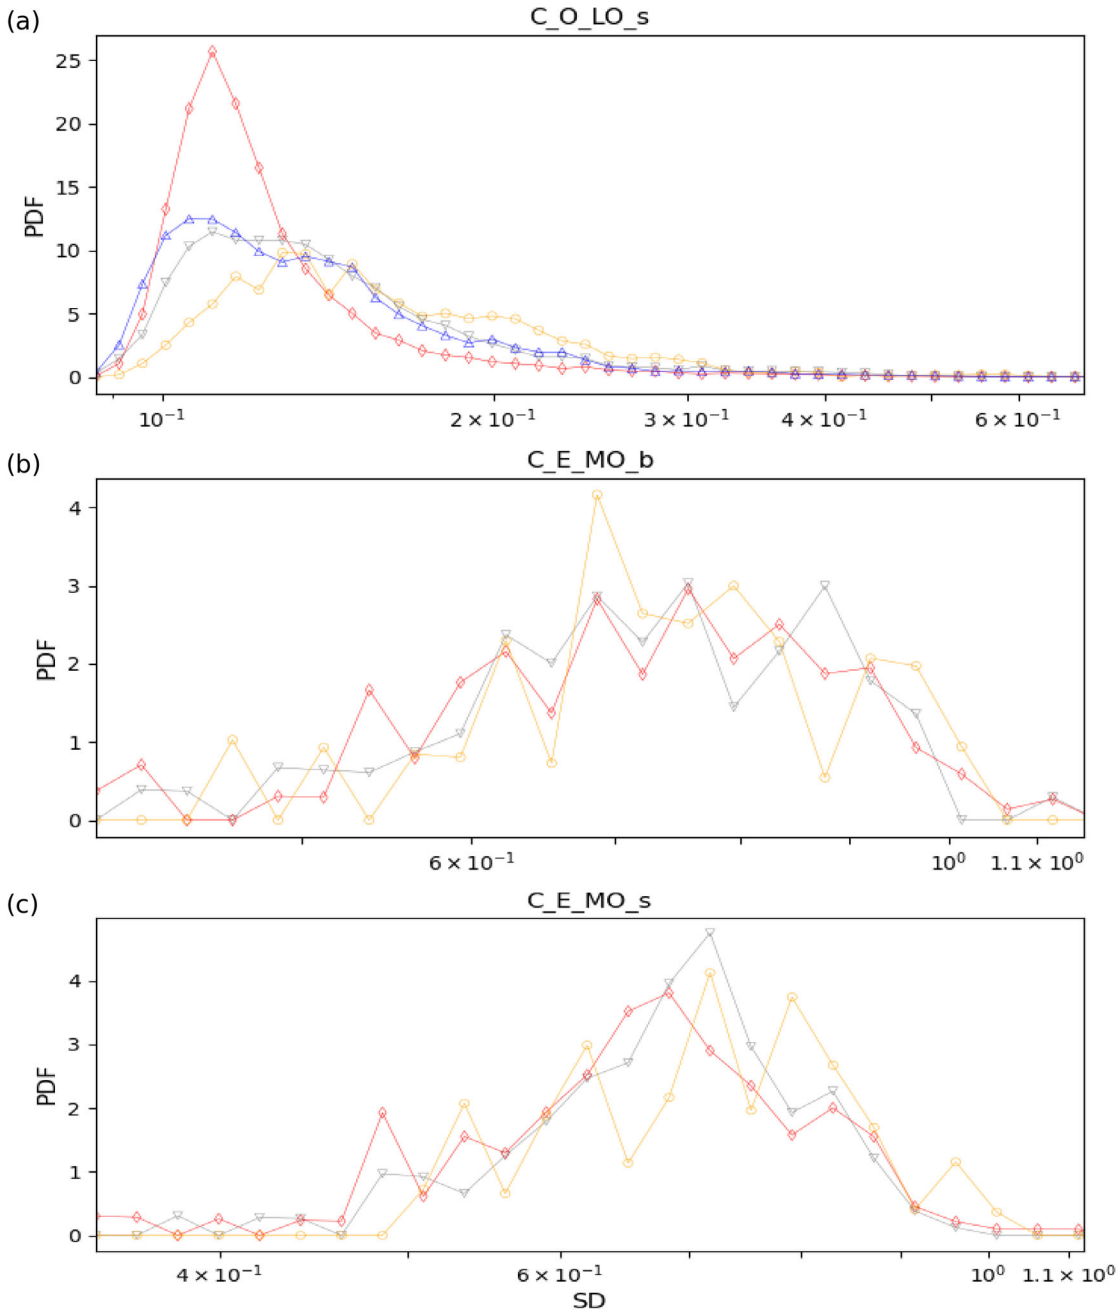

図 28 $SD_{i,am}(d)$および$SD_{i,pm}(d)$が取る値の確率密度関数（PDF）。(a) co4（C_O_LO_s）、(b) co5（C_E_MO_b）、(c) co6（C_E_MO_s）の時系列種の結果を示す。市場参加者タイプ毎に PDF をプロットし、「HFT」は青、「証券会社自己」は赤、「一般投資家」はオレンジ、「その他」は灰色で示す）。

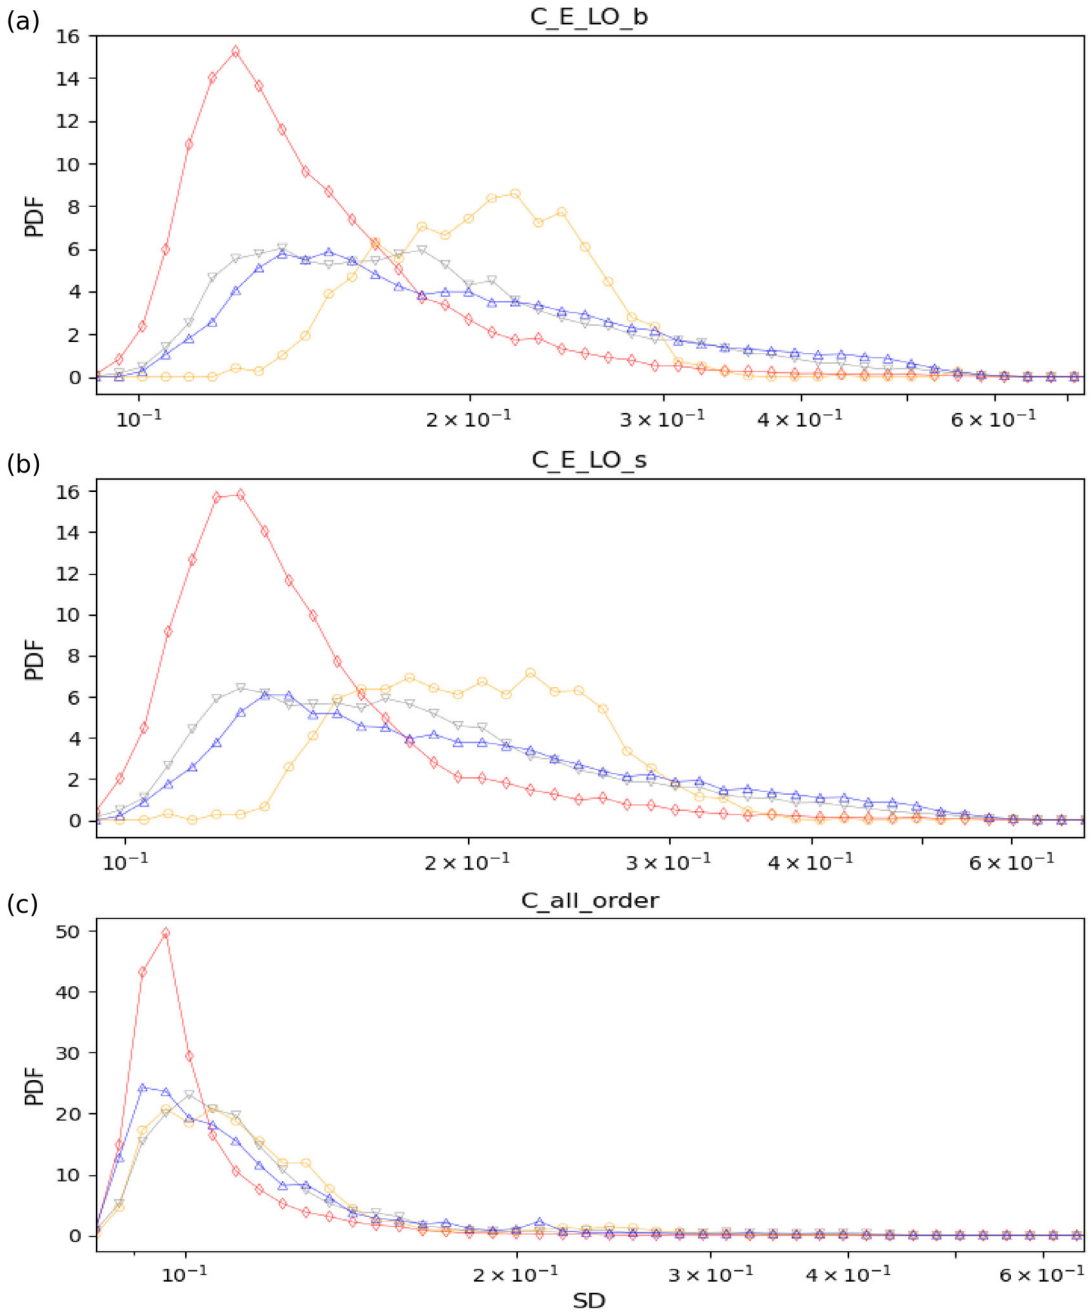

図 29 $SD_{i,am}(d)$および$SD_{i,pm}(d)$が取る値の確率密度関数（PDF）。(a) co7（C_E_LO_b）、(b) co8（C_E_LO_s）、(c) co9（C_all_order）の時系列種の結果を示す。市場参加者タイプ毎に PDF をプロットし、「HFT」は青、「証券会社自己」は赤、「一般投資家」はオレンジ、「その他」は灰色で示す）。

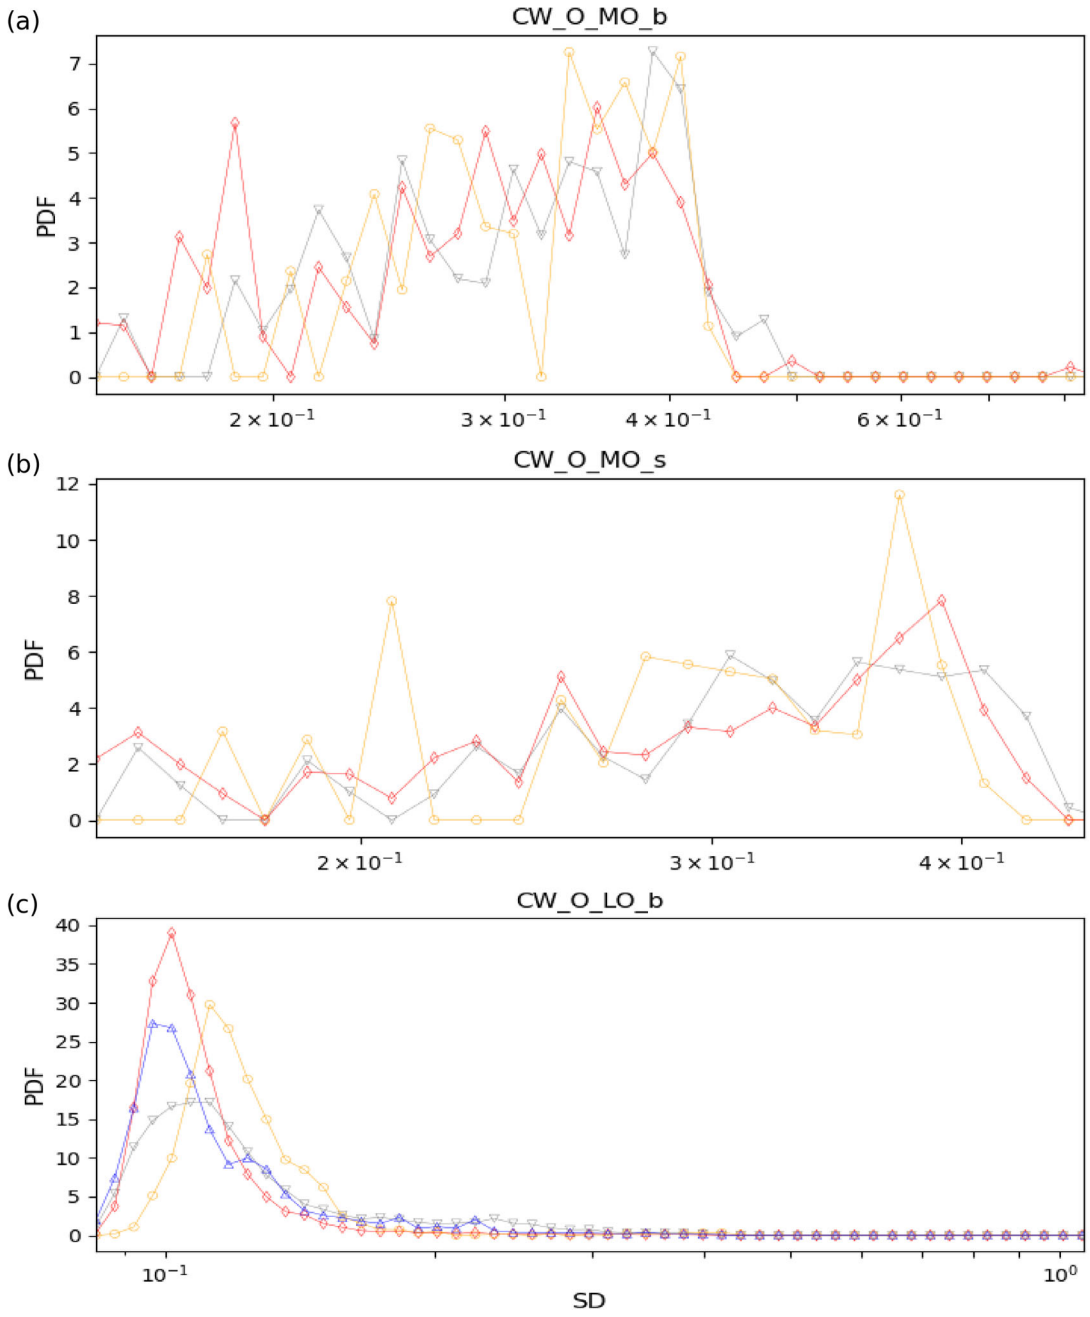

図 30 $SD_{i,am}(d)$および$SD_{i,pm}(d)$が取る値の確率密度関数（PDF）。(a) co1’（CW_O_MO_b）、(b) co2’（CW_O_MO_s）、(c) co3’（CW_O_LO_b）の時系列種の結果を示す。市場参加者タイプ毎に PDF をプロットし、「HFT」は青、「証券会社自己」は赤、「一般投資家」はオレンジ、「その他」は灰色で示す）。

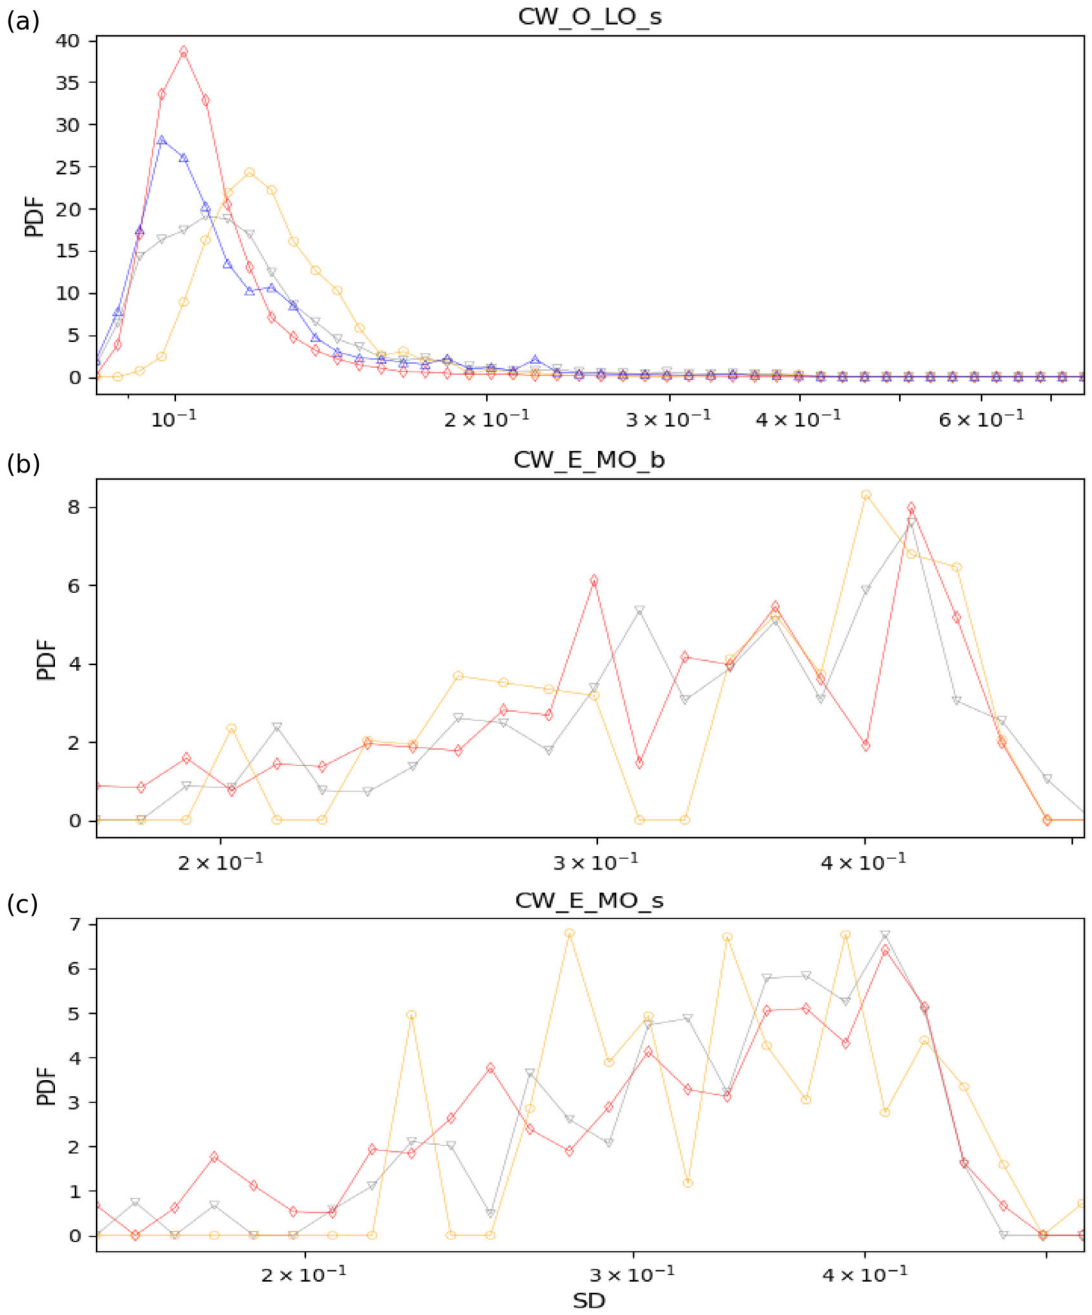

図 31 $SD_{i,am}(d)$および$SD_{i,pm}(d)$が取る値の確率密度関数（PDF）。(a) co4’（CW_O_LO_s）、(b) co5’（CW_E_MO_b）、(c) co6’（CW_E_MO_s）の時系列種の結果を示す。市場参加者タイプ毎に PDF をプロットし、「HFT」は青、「証券会社自己」は赤、「一般投資家」はオレンジ、「その他」は灰色で示す）。

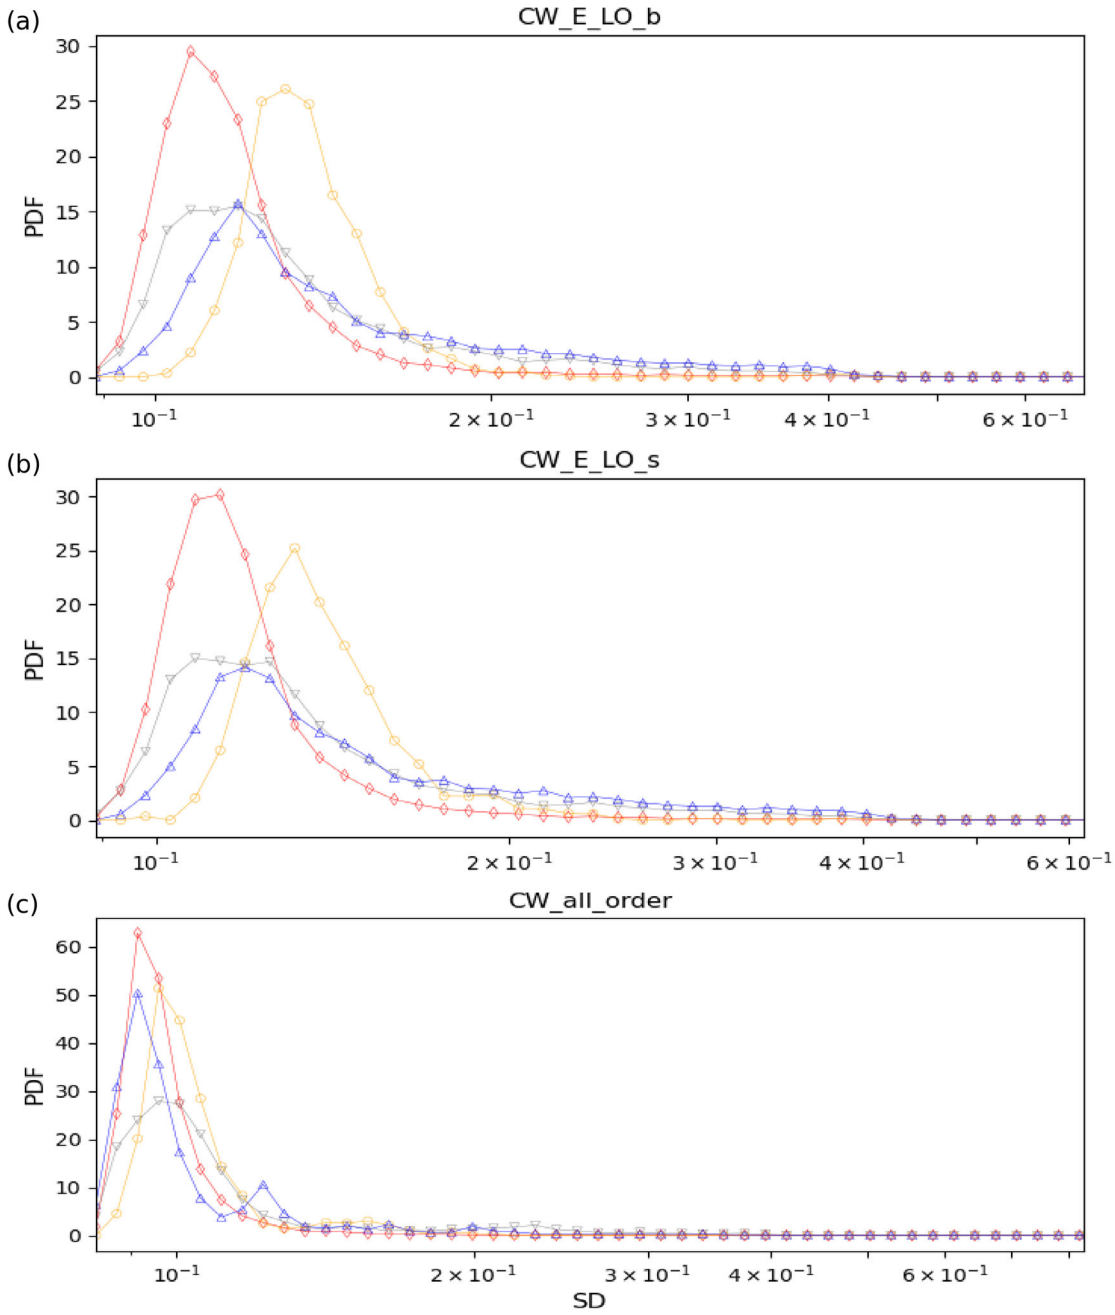

図 32 $SD_{i,am}(d)$および$SD_{i,pm}(d)$が取る値の確率密度関数（PDF）。(a) co7’（CW_E_LO_b）、(b) co8’（CW_E_LO_s）、(c) co9’（CW_all_order）の時系列種の結果を示す。市場参加者タイプ毎に PDF をプロットし、「HFT」は青、「証券会社自己」は赤、「一般投資家」はオレンジ、「その他」は灰色で示す）。

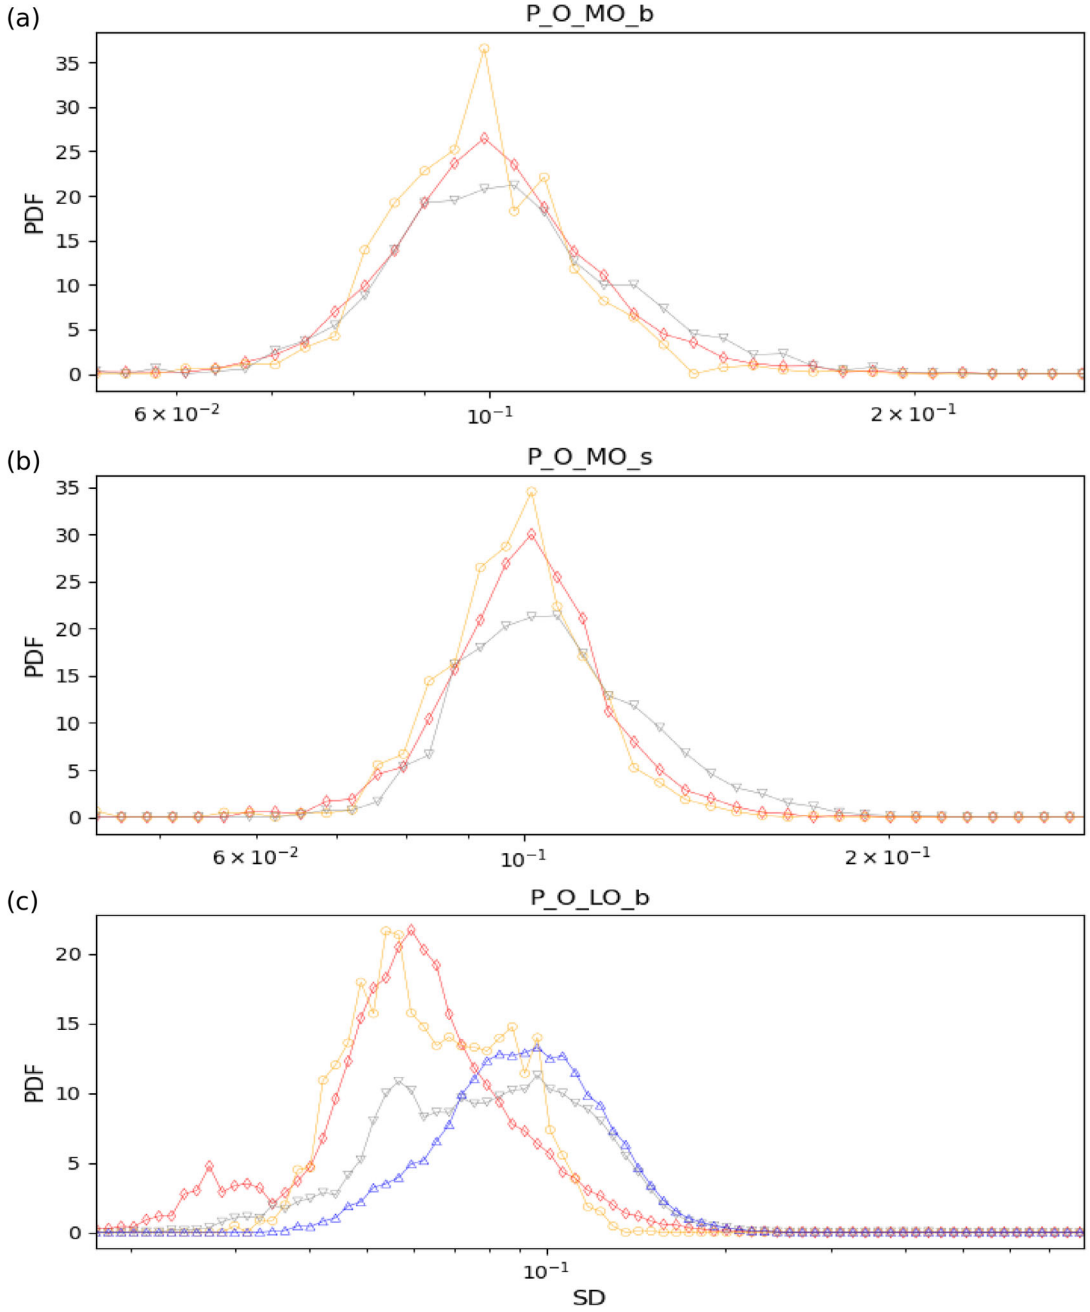

図 33 $SD_{i,am}(d)$および$SD_{i,pm}(d)$が取る値の確率密度関数（PDF）。(a) pp1（P_O_MO_b）、(b) pp2（P_O_MO_s）、(c) pp3（P_O_LO_b）の時系列種の結果を示す。市場参加者タイプ毎に PDF をプロットし、「HFT」は青、「証券会社自己」は赤、「一般投資家」はオレンジ、「その他」は灰色で示す）。

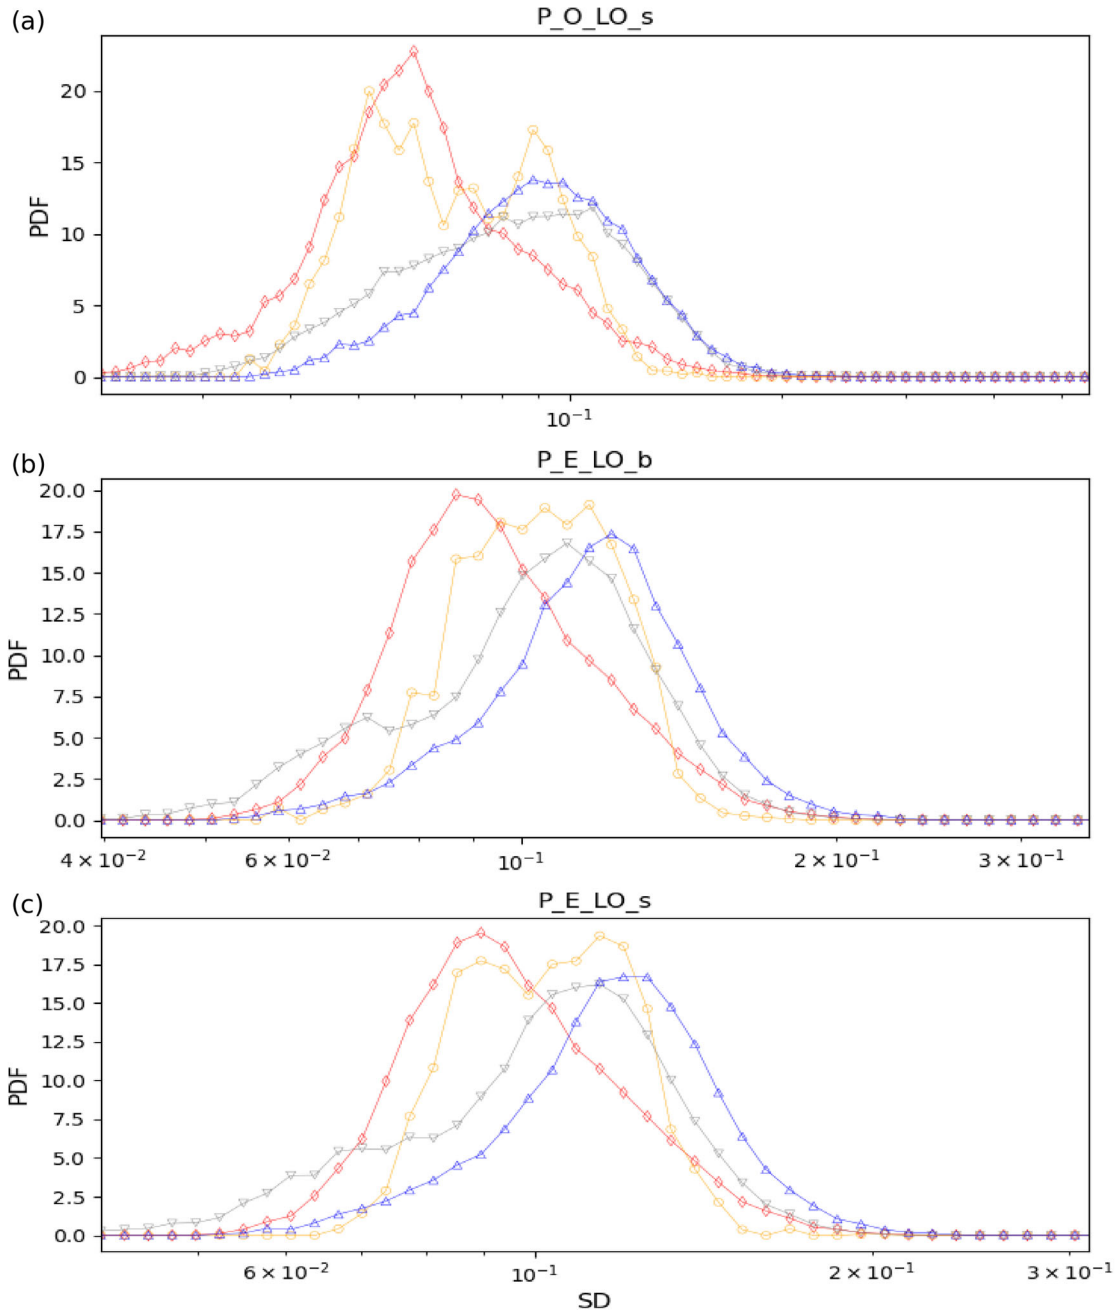

図 34 $SD_{i,am}(d)$および$SD_{i,pm}(d)$が取る値の確率密度関数（PDF）。(a) pp4（P_O_LO_s）、(b) pp7（P_E_LO_b）、(c) pp8（P_E_LO_s）の時系列種の結果を示す。市場参加者タイプ毎に PDF をプロットし、「HFT」は青、「証券会社自己」は赤、「一般投資家」はオレンジ、「その他」は灰色で示す)。

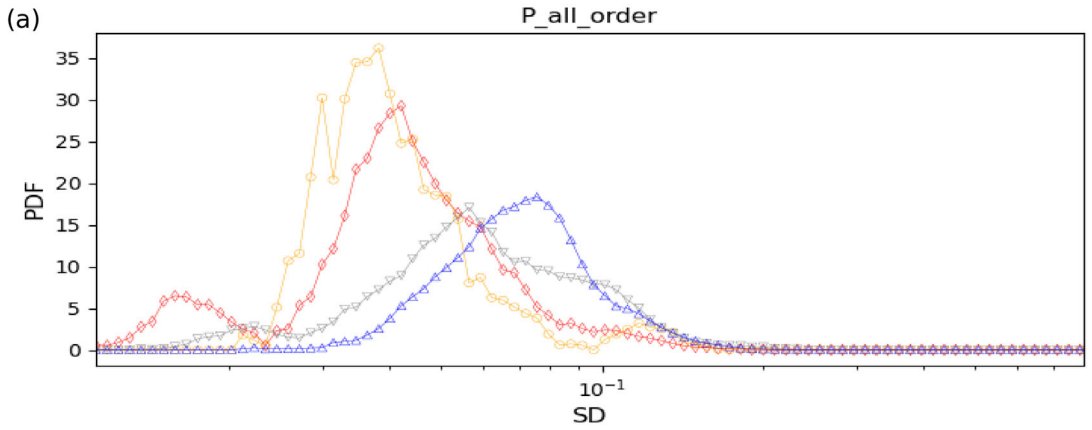

図 35 $SD_{i,am}(d)$および$SD_{i,pm}(d)$が取る値の確率密度関数（PDF）。(a) pp9（P_all_order）の時系列種の結果を示す。市場参加者タイプ毎に PDF をプロットし、「HFT」は青、「証券会社自己」は赤、「一般投資家」はオレンジ、「その他」は灰色で示す)。

6.4. 補論 4. DNM 指標と TOPIX ボラティリティの大小関係比較の詳細

ここでは、3.1 で示した$V(d)/V(d-1)$と$R_i(d)$の大小関係の比較（図 7）に関し、全時系列種に関する結果を個別に示す。ここで、成行注文や銘柄共有を考慮した vol5（V_E_MO_b）、co1（C_O_MO_b）、co2（C_O_MO_s）、co5（C_E_MO_b）、co6（C_E_MO_s）、co1’（CW_O_MO_b）、co5’（CW_E_MO_b）、pp1（P_O_MO_b）、pp5（P_E_MO_b）、pp6（P_E_MO_s）の時系列種については、単位時間あたりのデータサイズが不足し$V(d)/V(d-1)$と$R_i(d)$の大小比較ができなかったため、もしくは、「DNM 集合に含まれ得る市場参加者」を特定できなかったため、結果に反映させていない。

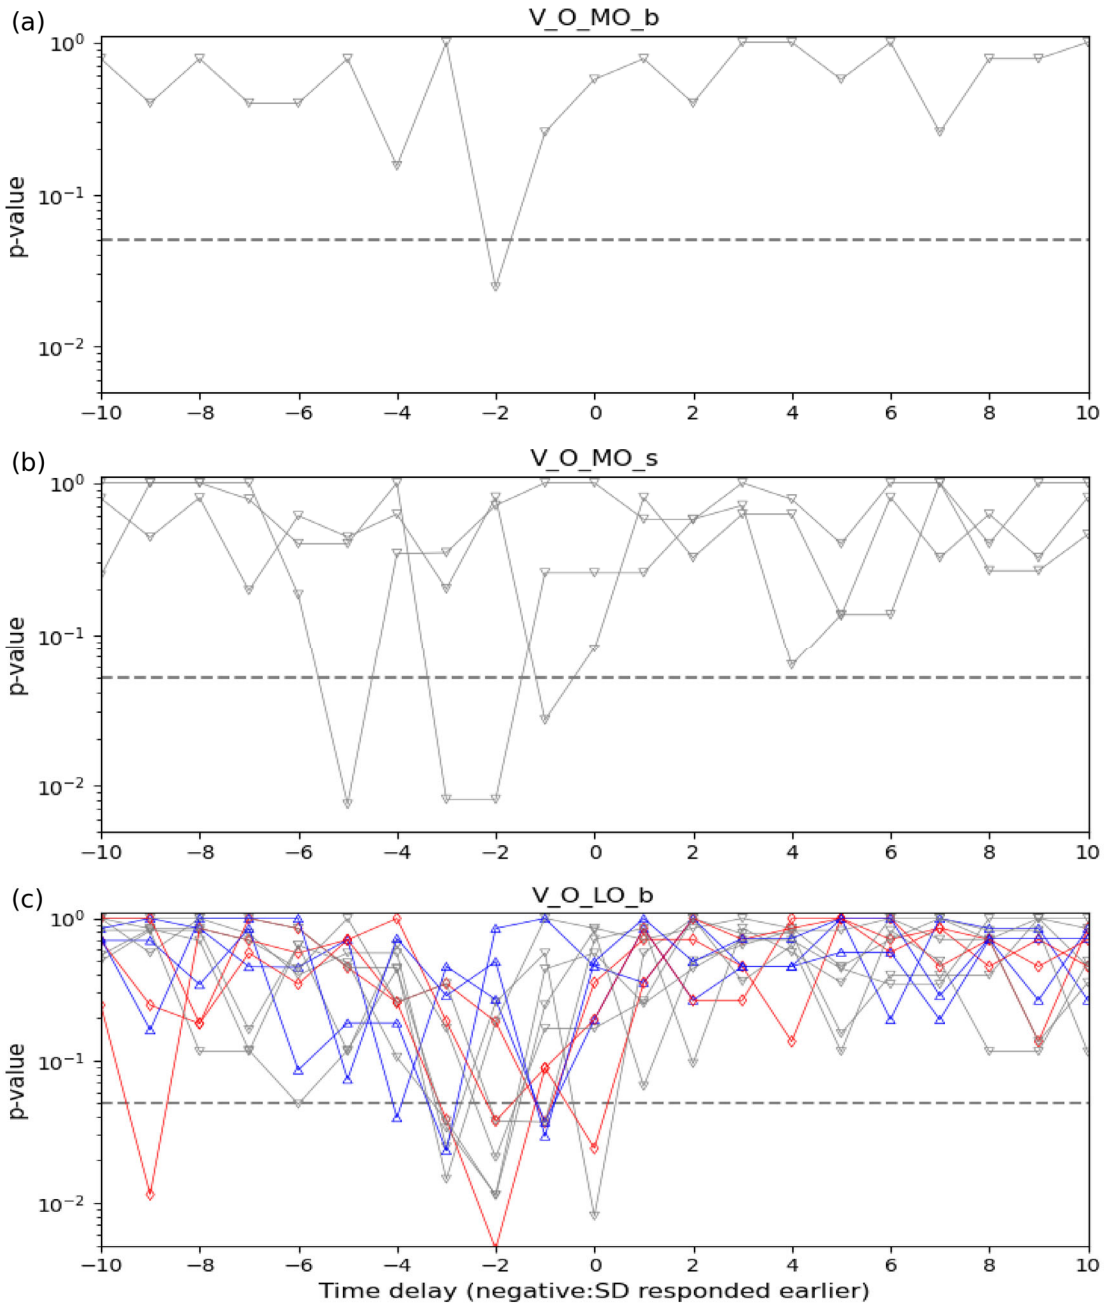

図 36 $R_i(d-\tau)$と$V(d)/V(d-1)$の関係性。縦軸はこの関係性に関するフィッシャーの正確確率検定の p 値を表し、横軸はタイムラグ$-\tau$を表す。パネル(a,b,c)は、それぞれ時系列種 vol1（V_O_MO_b）、vol2（V_O_MO_s）、vol3（V_O_LO_b）に対応する。各プロットが市場参加者に対応しており、ここでは「DNM 集合に含まれ得る市場参加者」として、$-5 \leq -\tau < 0$の範囲で p 値が0.05を下回り、$-5 \leq -\tau < 0$の範囲におけるp*値*の平均が$0 \leq -\tau < 5$の範囲におけるp*値*の平均よりも低くなるような市場参加者についてのみプロットした。HFT の市場参加者は青、証券会社自己は赤、一般投資家はオレンジ、その他は灰色で示した。

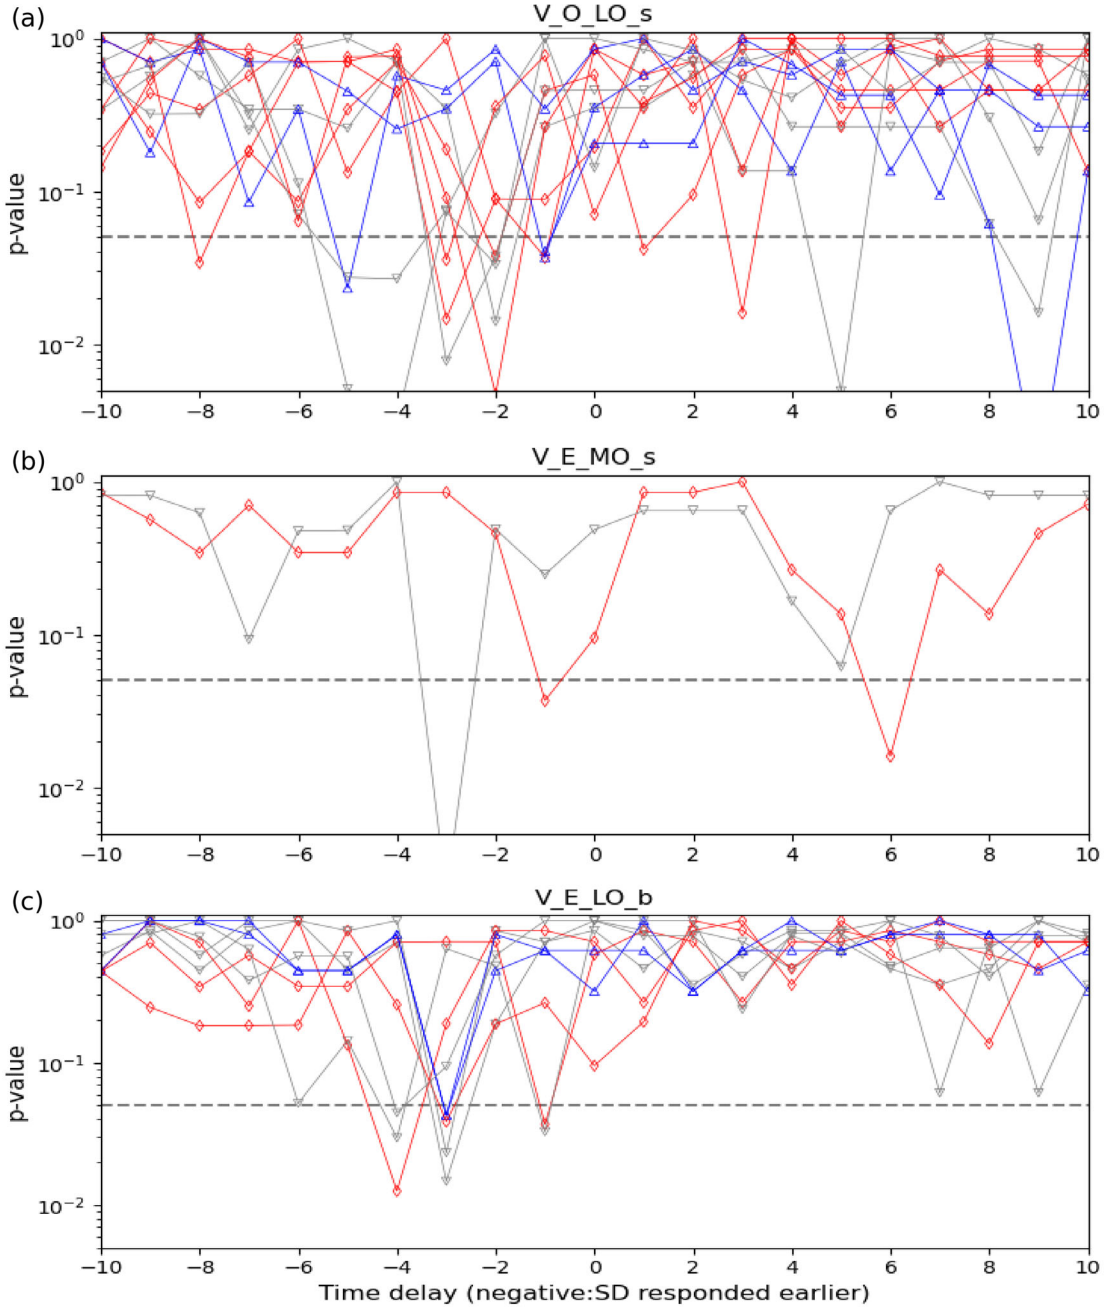

図 37 $R_i(d-\tau)$と$V(d)/V(d-1)$の関係性。縦軸はこの関係性に関するフィッシャーの正確確率検定の p 値を表し、横軸はタイムラグ$-\tau$を表す。パネル(a,b,c,d)は、それぞれ時系列種 vol4（V_O_LO_s）、vol6（V_E_MO_s）、vol7（V_E_LO_b）に対応する。図 36 と同様に「DNM 集合に含まれ得る市場参加者」を定め、市場参加者ごとにプロットした。

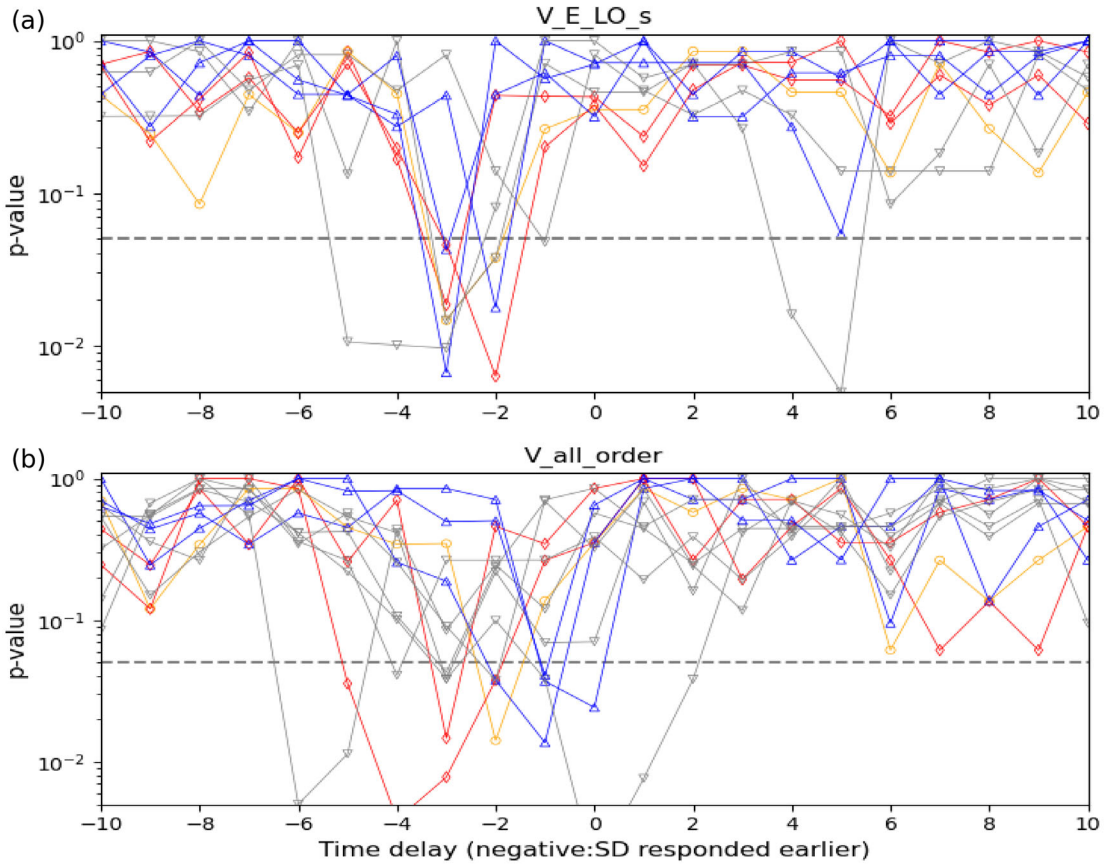

図 38 $R_i(d-\tau)$と$V(d)/V(d-1)$の関係性。縦軸はこの関係性に関するフィッシャーの正確確率検定の p 値を表し、横軸はタイムラグ$-\tau$を表す。パネル(a,b,c)は、それぞれ時系列種 vol8（V_E_LO_s）、vol9（V_all_order）に対応する。図 36 と同様に「DNM 集合に含まれ得る市場参加者」を定め、市場参加者ごとにプロットした。

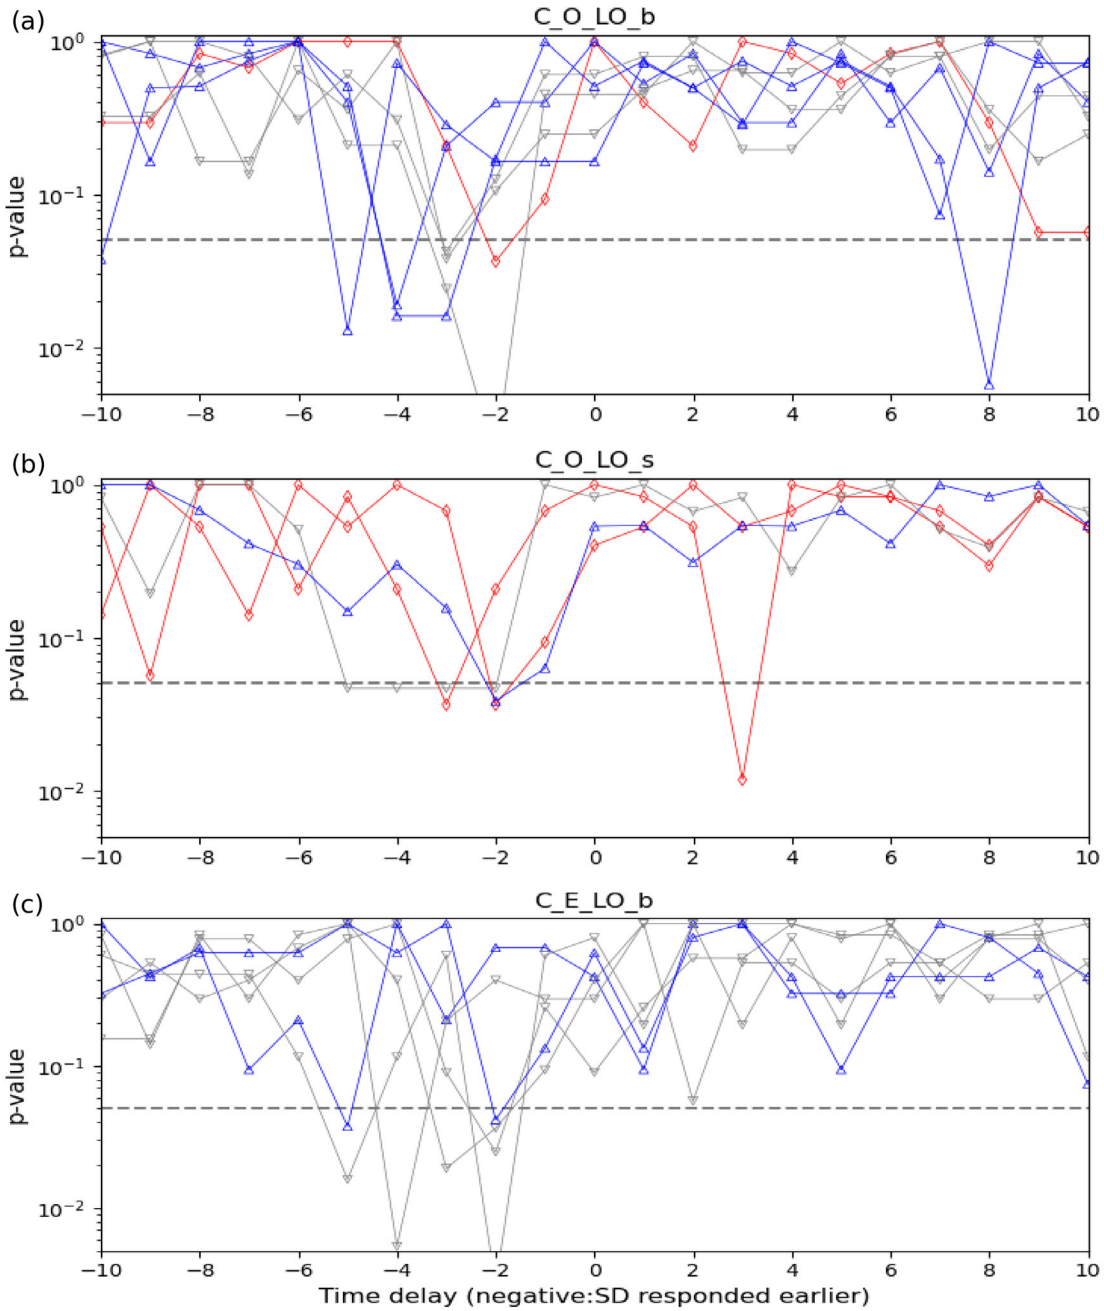

図 39　$R_i(d-\tau)$と$V(d)/V(d-1)$の関係性。縦軸はこの関係性に関するフィッシャーの正確確率検定の p 値を表し、横軸はタイムラグ$-\tau$を表す。パネル(a,b,c)は、それぞれ時系列種 co3（C_O_LO_b）、co4（C_O_LO_s）、co7（C_E_LO_b）に対応する。図 36 と同様に「DNM 集合に含まれ得る市場参加者」を定め、市場参加者ごとにプロットした。

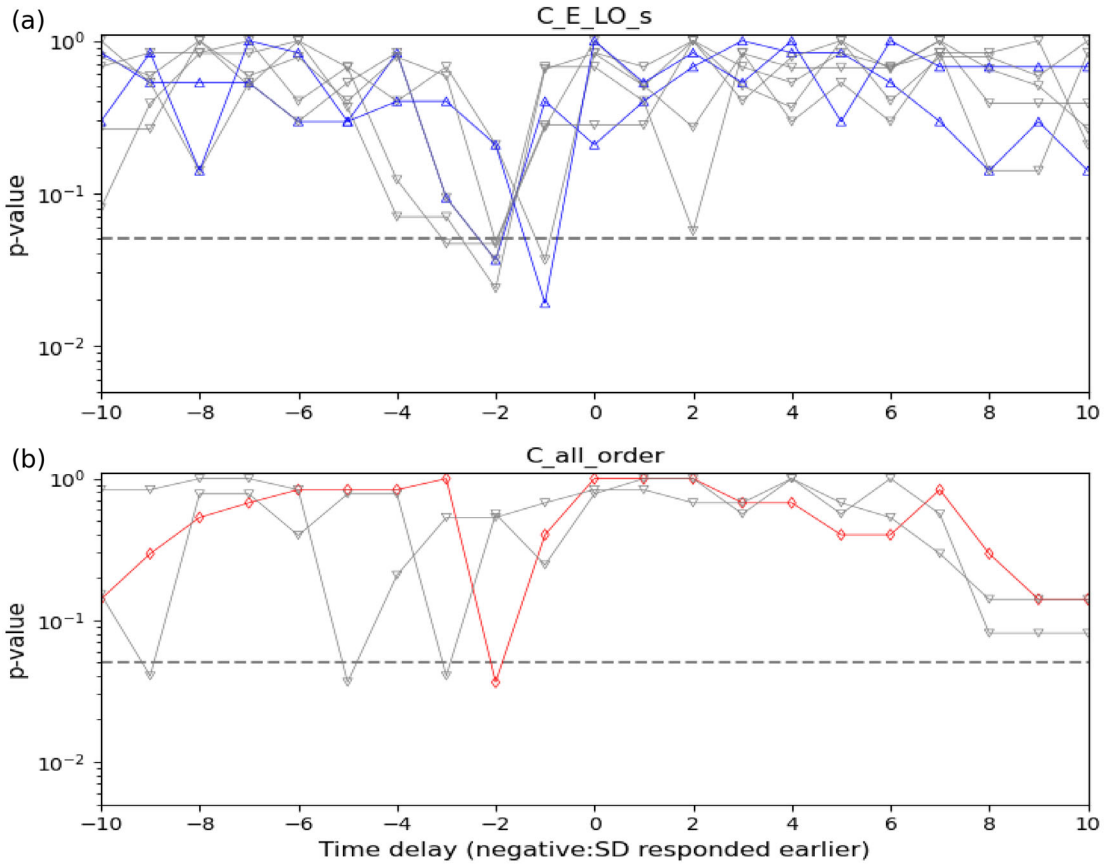

図 40 $R_i(d-\tau)$と$V(d)/V(d-1)$の関係性。縦軸はこの関係性に関するフィッシャーの正確確率検定の p 値を表し、横軸はタイムラグ$-\tau$を表す。パネル(a,b)は、それぞれ時系列種 co8（C_E_LO_s）、co9（C_all_order）に対応する。図 36 と同様に「DNM 集合に含まれ得る市場参加者」を定め、市場参加者ごとにプロットした。

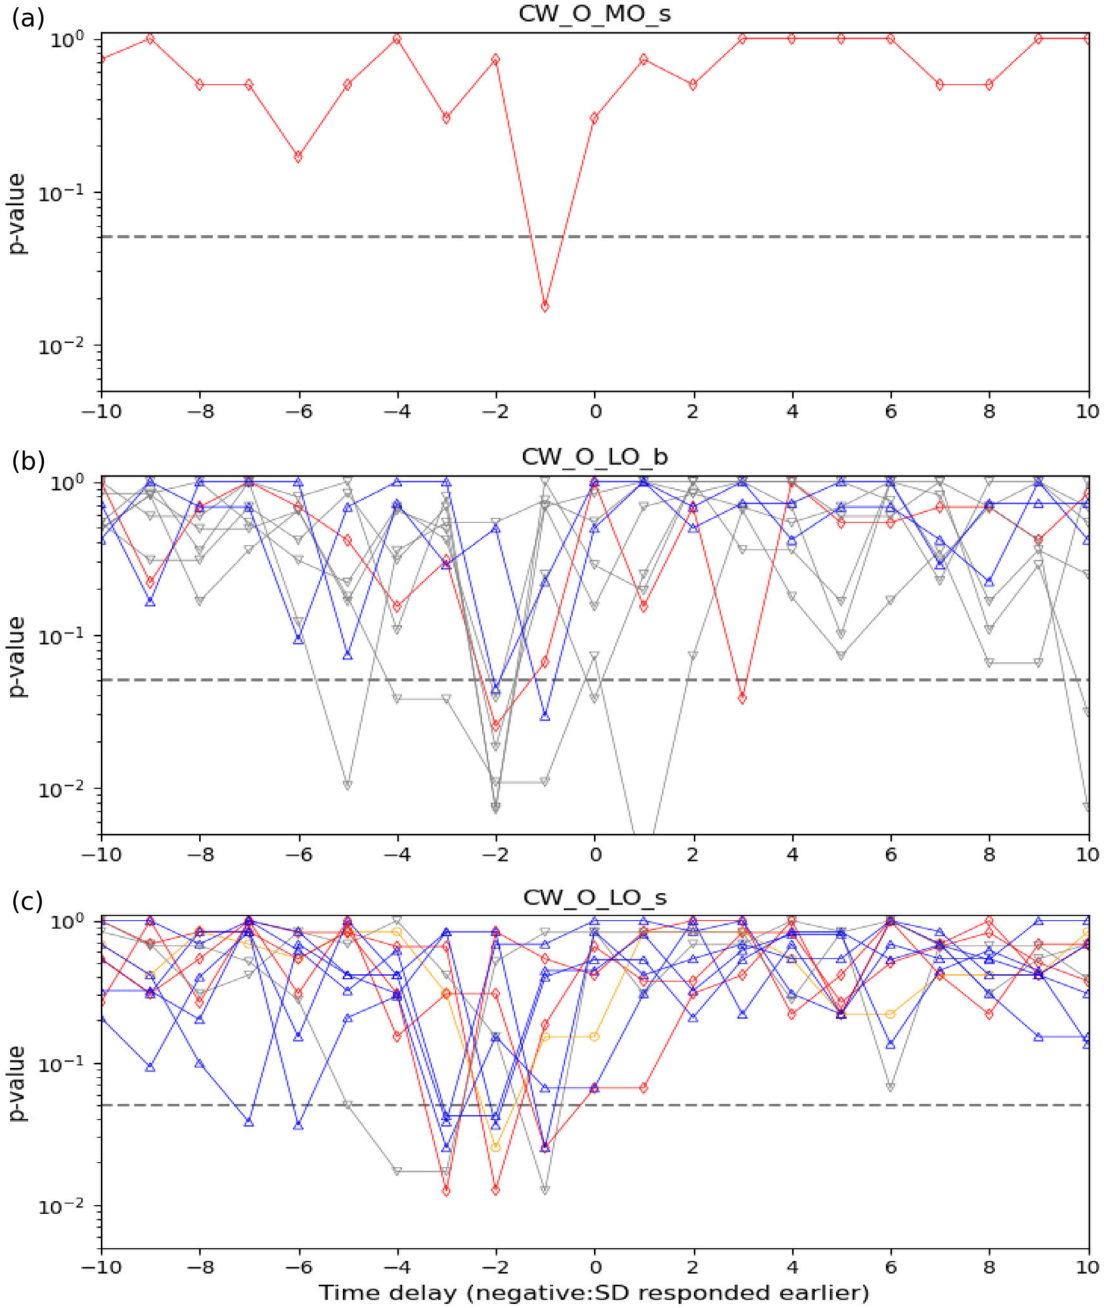

図 41 $R_i(d-\tau)$と$V(d)/V(d-1)$の関係性。縦軸はこの関係性に関するフィッシャーの正確確率検定の p 値を表し、横軸はタイムラグ$-\tau$を表す。パネル(a,b,c)は、それぞれ時系列種 co2’（CW_O_MO_s）、co3’（CW_O_LO_b）、co4’（CW_O_LO_s）に対応する。図 36 と同様に「DNM 集合に含まれ得る市場参加者」を定め、市場参加者ごとにプロットした。

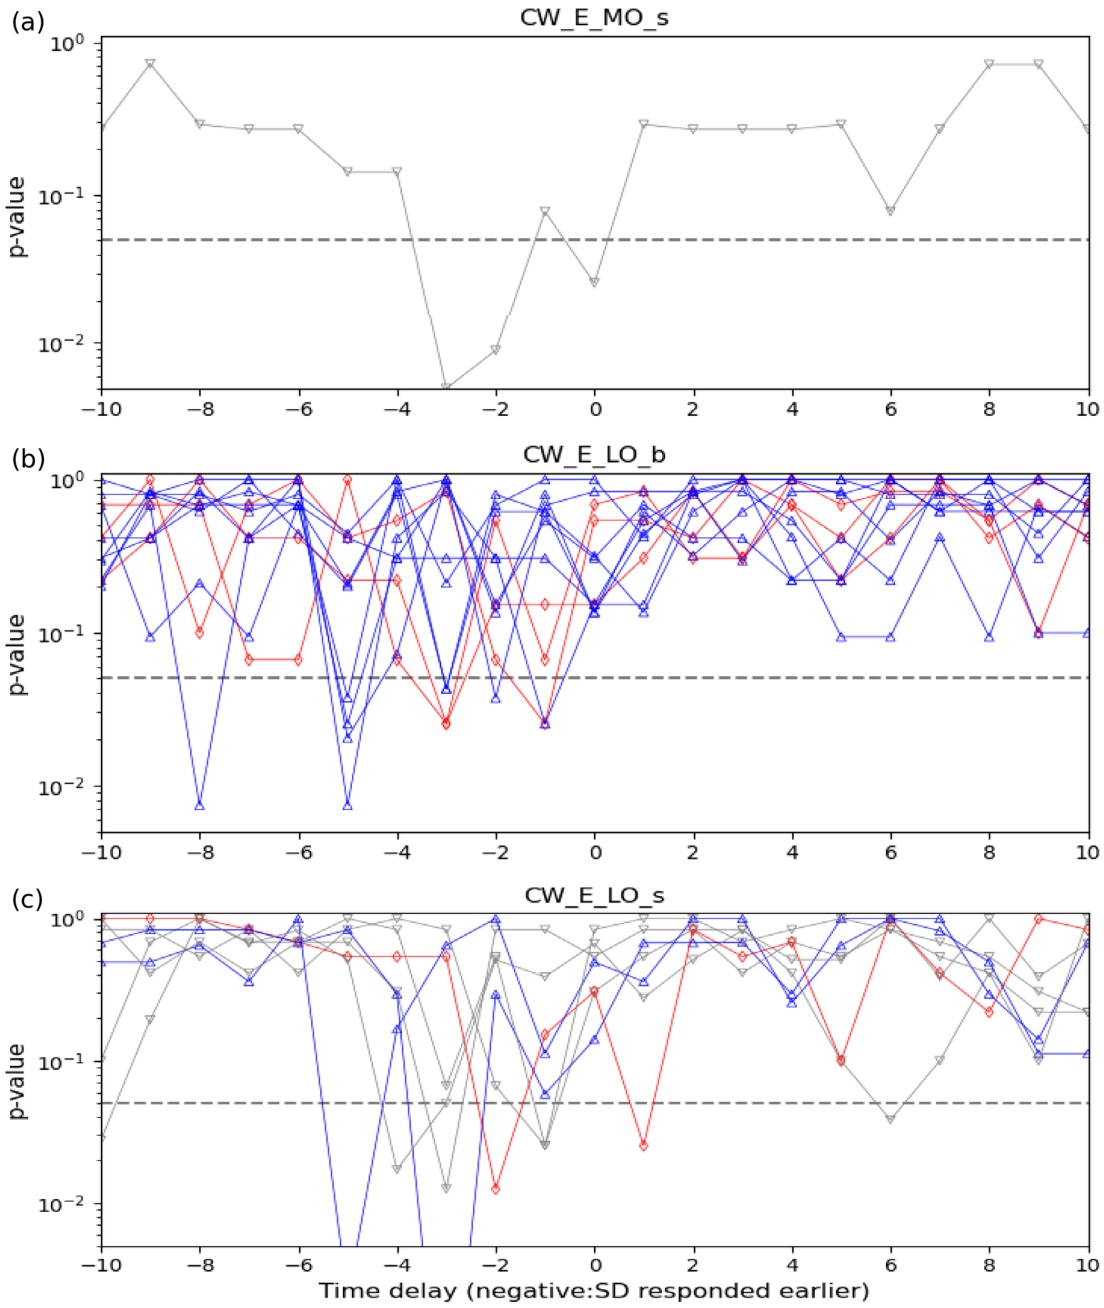

図 42 $R_i(d-\tau)$と$V(d)/V(d-1)$の関係性。縦軸はこの関係性に関するフィッシャーの正確確率検定の p 値を表し、横軸はタイムラグ$-\tau$を表す。パネル(a,b,c)は、それぞれ時系列種 co6’（CW_E_MO_s）、co7’（CW_E_LO_b）、co8’（CW_E_LO_s）に対応する。図 36 と同様に「DNM 集合に含まれ得る市場参加者」を定め、市場参加者ごとにプロットした。

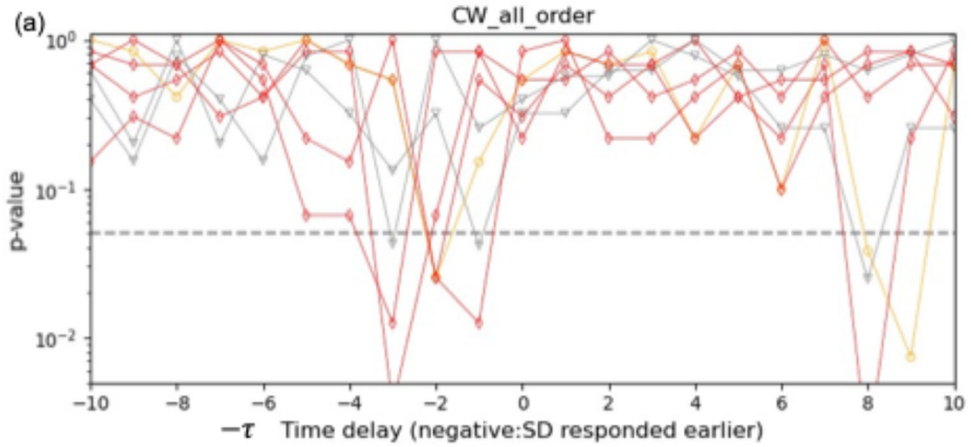

図 43 $R_i(d-\tau)$と$V(d)/V(d-1)$の関係性。縦軸はこの関係性に関するフィッシャーの正確確率検定の p 値を表し、横軸はタイムラグ$-\tau$を表す。パネル(a)は、それぞれ時系列種 co9’（CW_all_order）に対応する。図 36 と同様に「DNM 集合に含まれ得る市場参加者」を定め、市場参加者ごとにプロットした。

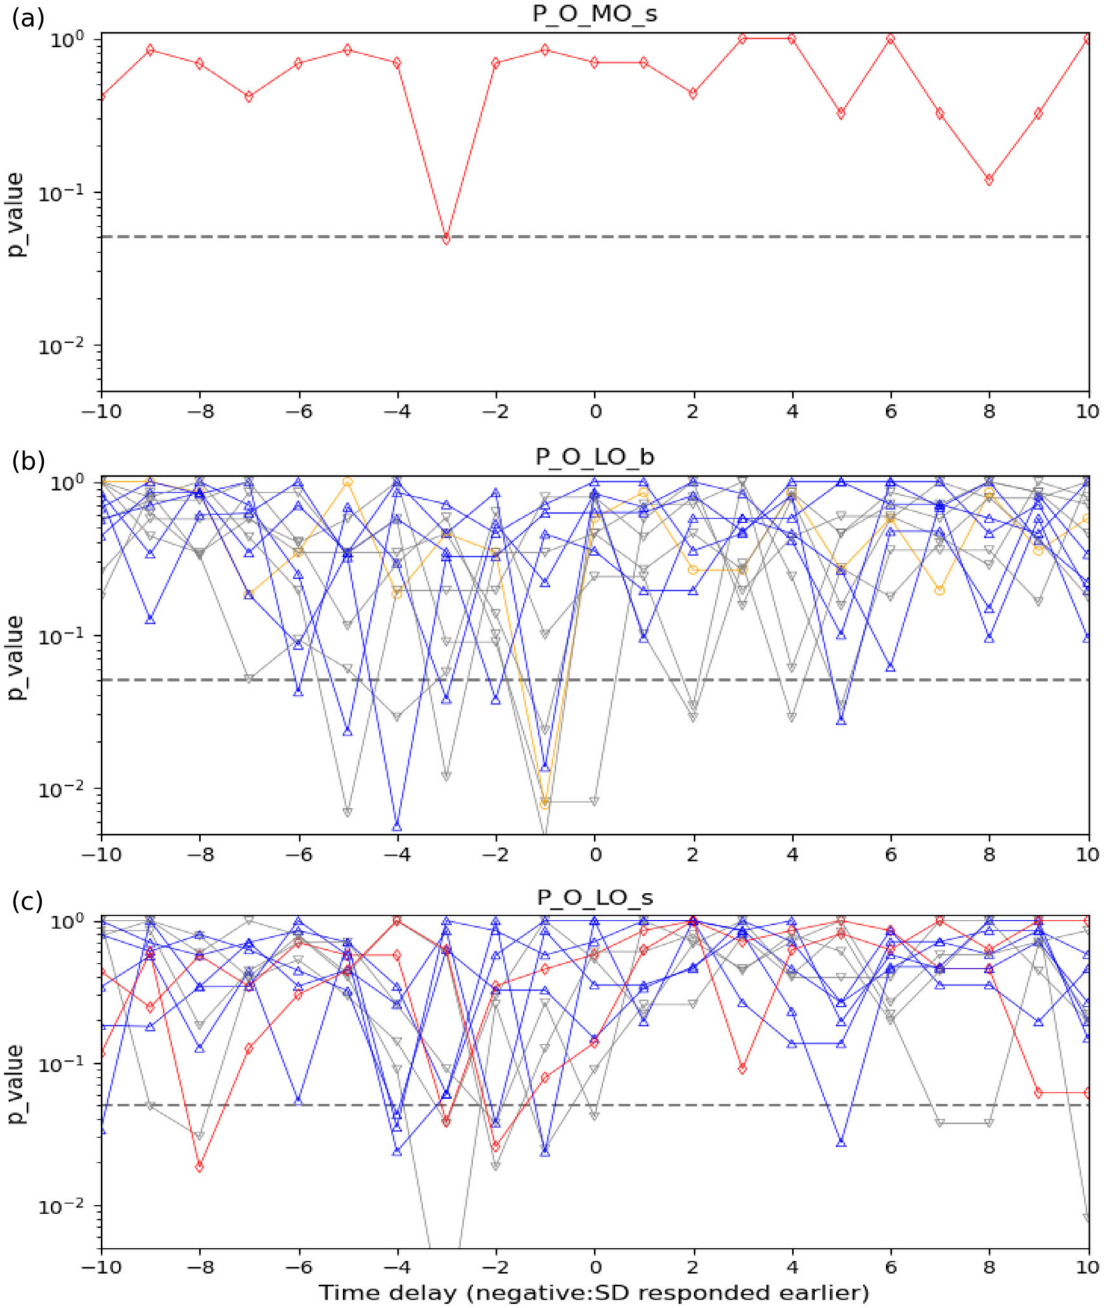

図 44 $R_i(d-\tau)$と$V(d)/V(d-1)$の関係性。縦軸はこの関係性に関するフィッシャーの正確確率検定の p 値を表し、横軸はタイムラグ$-\tau$を表す。パネル(a,b,c)は、それぞれ時系列種 pp2（P_O_MO_s）、pp3（P_O_LO_b）、pp4（P_O_LO_s）に対応する。図 36 と同様に「DNM 集合に含まれ得る市場参加者」を定め、市場参加者ごとにプロットした。

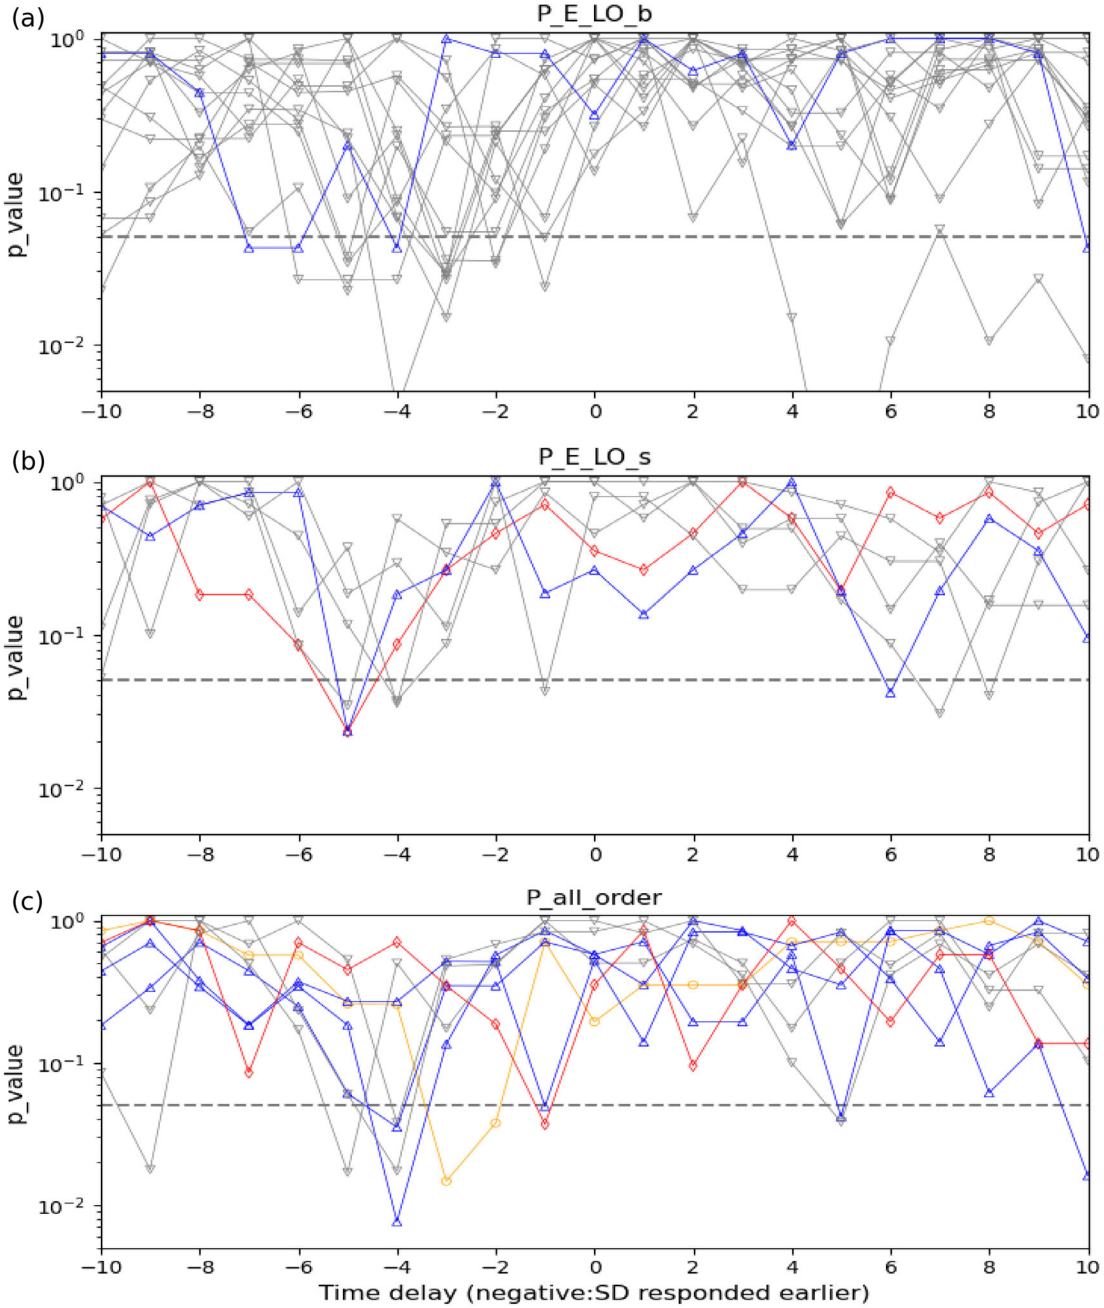

図 45 $(d-\tau)$と$V(d)/V(d-1)$の関係性。縦軸はこの関係性に関するフィッシャーの正確確率検定の p 値を表し、横軸はタイムラグ$-\tau$を表す。パネル(a,b,c)は、それぞれ時系列種 pp7（P_E_LO_b）、pp8（P_E_LO_s）、pp9（P_all_order）に対応する。図 36 と同様に「DNM 集合に含まれ得る市場参加者」を定め、市場参加者ごとにプロットした。

6.5. 補論 5. 市場不安定化前の DNM 指標の振る舞いの詳細

ここでは、3.2 で示した$\mathrm{SD}_{I,d_{\mathrm{focal}}}$の推移（図 9—17）に関し、各時系列種と$d_{\mathrm{focal}}$に対する$\mathrm{SD}_{I,d_{\mathrm{focal}}}$を個別に示す。ここで、成行注文や銘柄共有を考慮した co1（C_O_MO_b）、co2（C_O_MO_s）、co7（C_O_LO_b）、co8（C_O_LO_s）、co1’（CW_O_MO_b）、co2’（CW_O_MO_s）、co7’（CW_O_LO_b）、co8’（CW_O_LO_s）、pp5（P_E_MO_b）、pp6（P_E_MO_s）の時系列種については、単位時間あたりのデータサイズが不足したため$\mathrm{SD}_{I,d_{\mathrm{focal}}}$を計算対象とすることができず、結果への反映は行っていない。

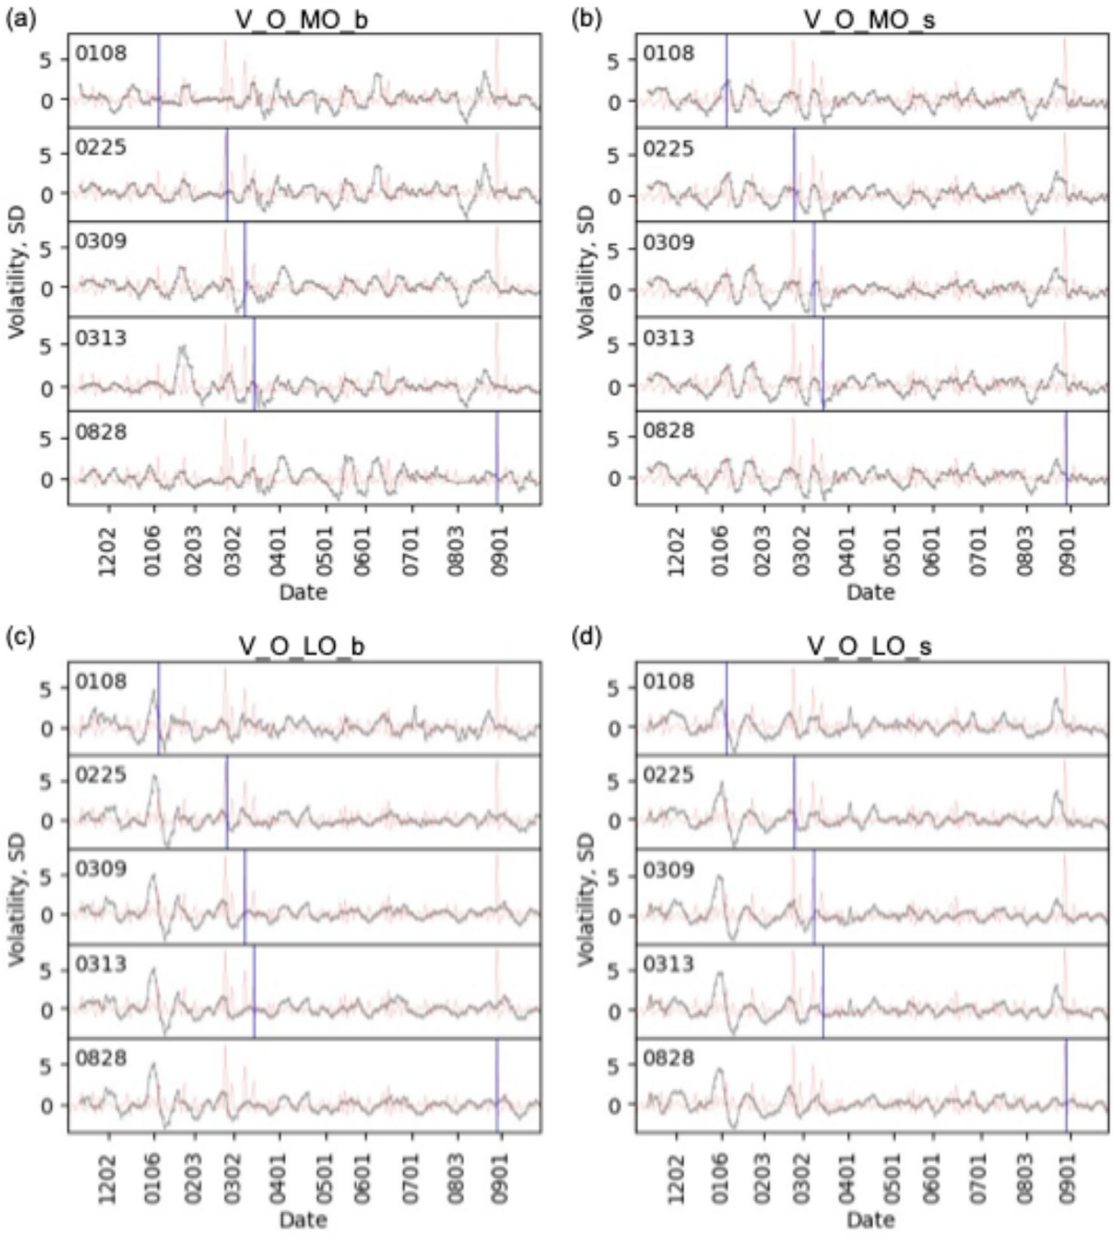

図 46　時系列種(a)vol1（V_O_MO_b）、(b)vol2（V_O_MO_s）、(c)vol3（V_O_LO_b）、(d)vol4（V_O_LO_s）についての、全てのd_{focal}（各パネル左上に示した）に対する$SD_{I,d_{focal}}$の推移。$SD_{I,d_{focal}}$の Z 値を黒色のプロットで、$V(d)/V(d-1)$の Z 値を赤色のプロットで示した。

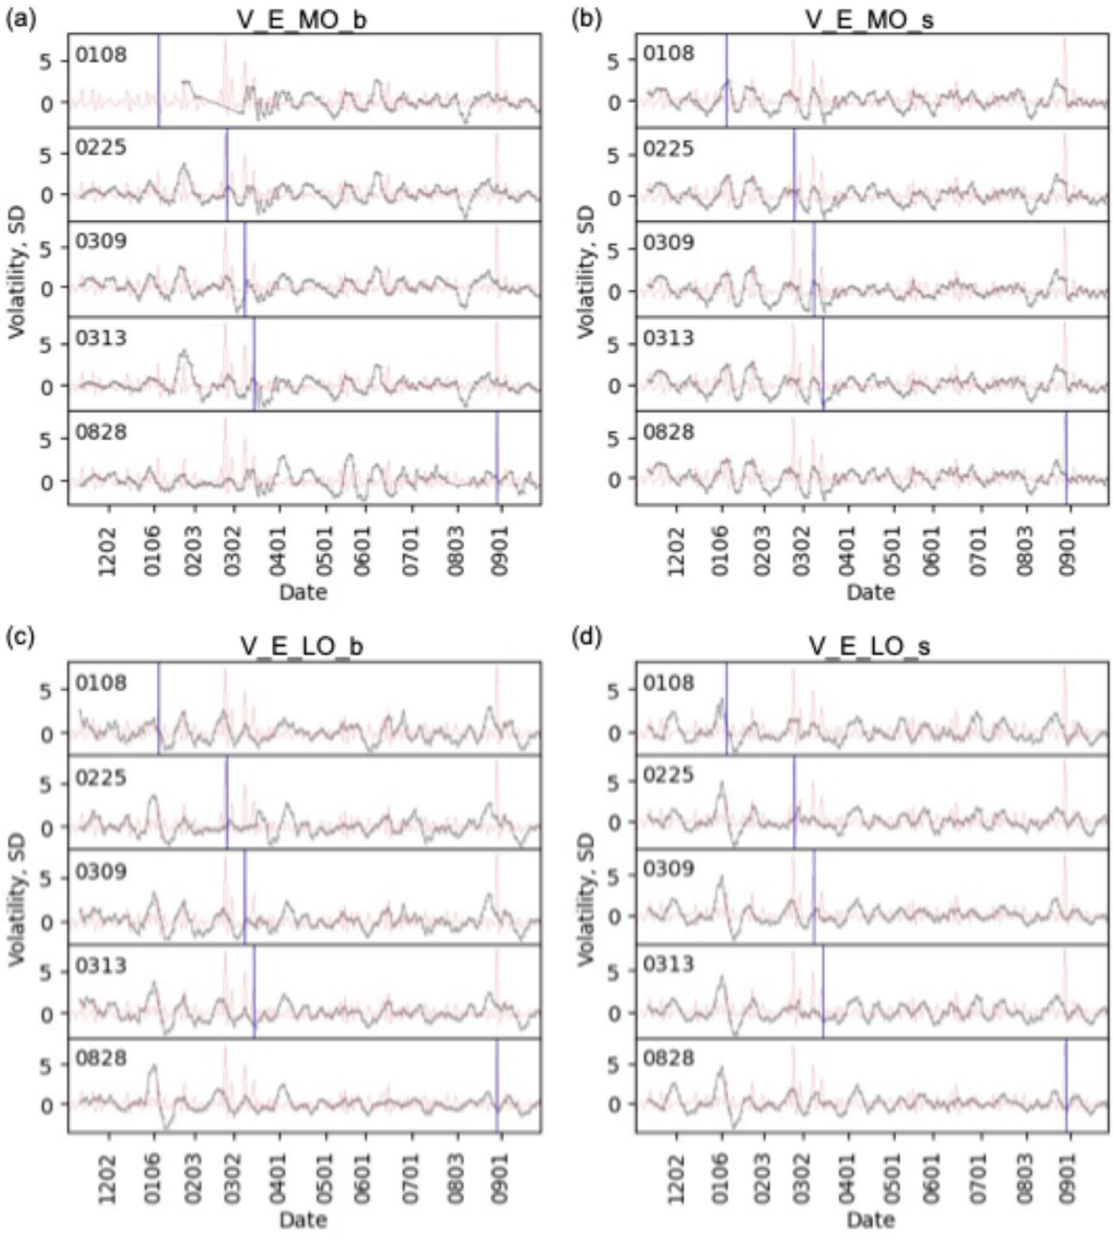

図 47　時系列種(a)vol5（V_E_MO_b）、(b)vol6（V_O_MO_s）、(c)vol7（V_E_LO_b）、(d)vol8（V_E_LO_s）についての、全てのd_{fcal}（各パネル左上に示した）に対する$SD_{I,d_{focal}}$の推移。$SD_{I,d_{focal}}$のＺ値を黒色のプロットで、$V(d)/V(d-1)$のＺ値を赤色のプロットで示した。

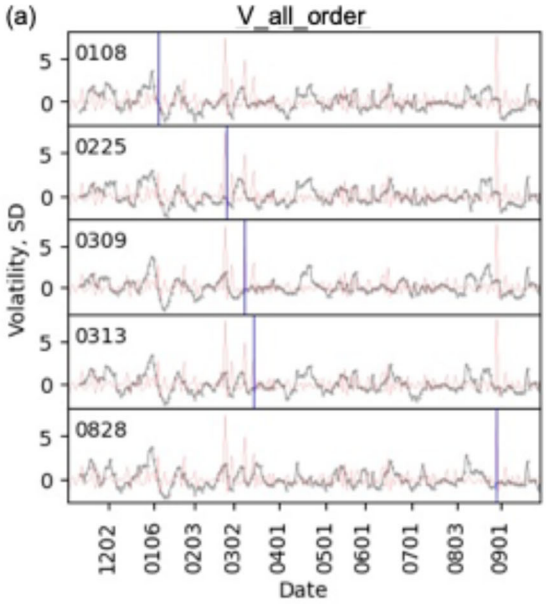

図 48　時系列種(a)vol9（V_all_order）についての、全てのd_{focal}（各パネル左上に示した）に対する$SD_{I,d_{focal}}$の推移。$SD_{I,d_{focal}}$の Z 値を黒色のプロットで、$V(d)/V(d-1)$の Z 値を赤色のプロットで示した。

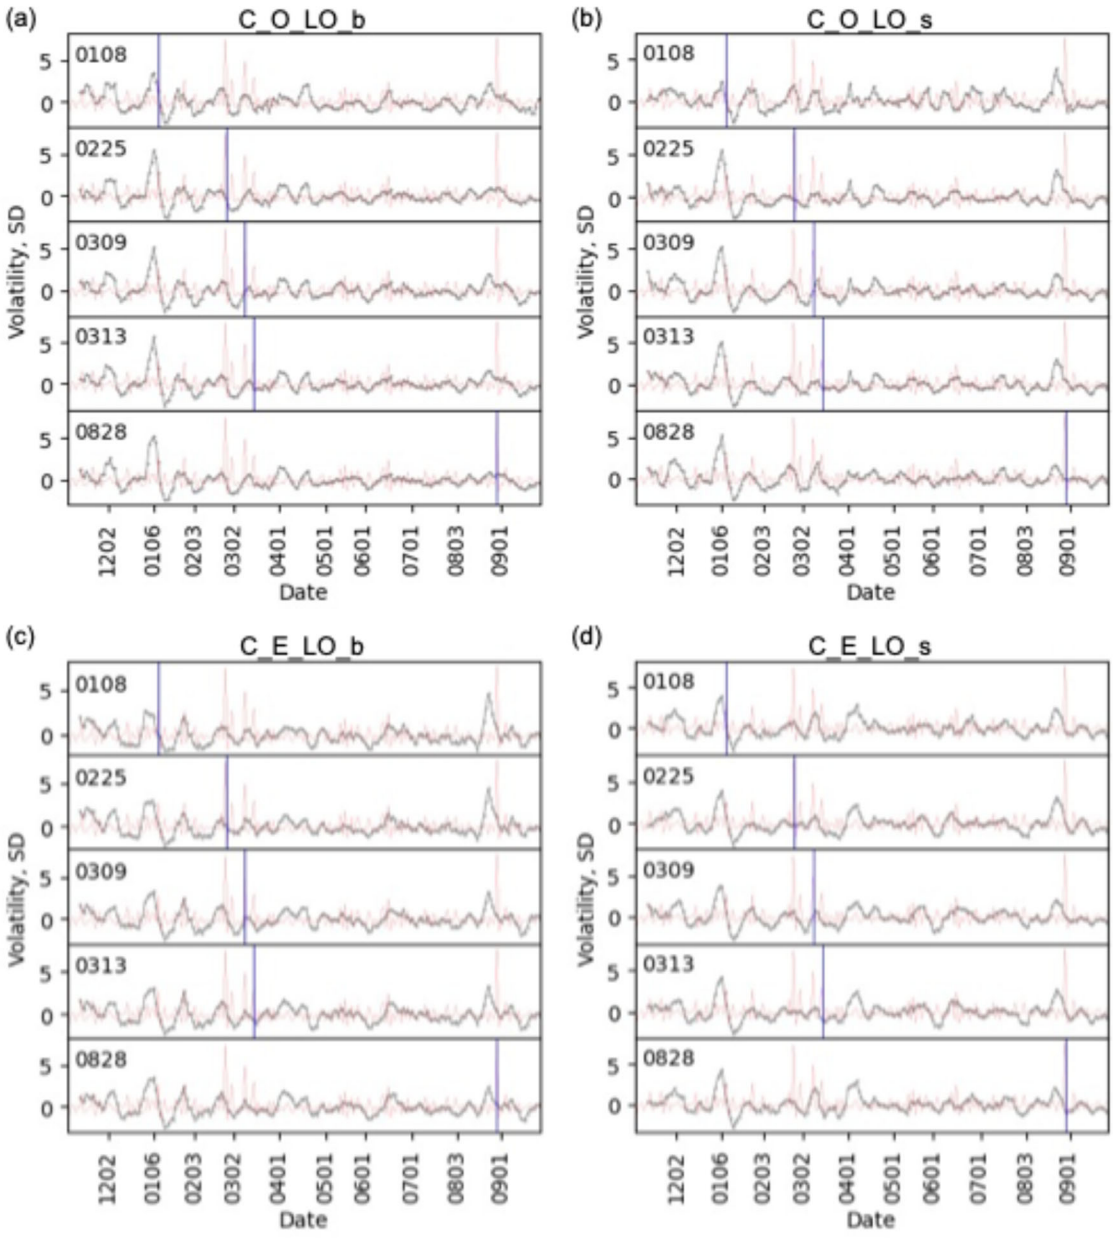

図 49　時系列種(a)co3（C_O_LO_b）、(b)co4（C_O_LO_s）、(c)co7（C_E_LO_b）、(d)co8（C_O_LO_s）についての、全てのd_{focal}（各パネル左上に示した）に対する$SD_{I,d_{focal}}$の推移。$SD_{I,d_{focal}}$のＺ値を黒色のプロットで、$V(d)/V(d-1)$のＺ値を赤色のプロットで示した。

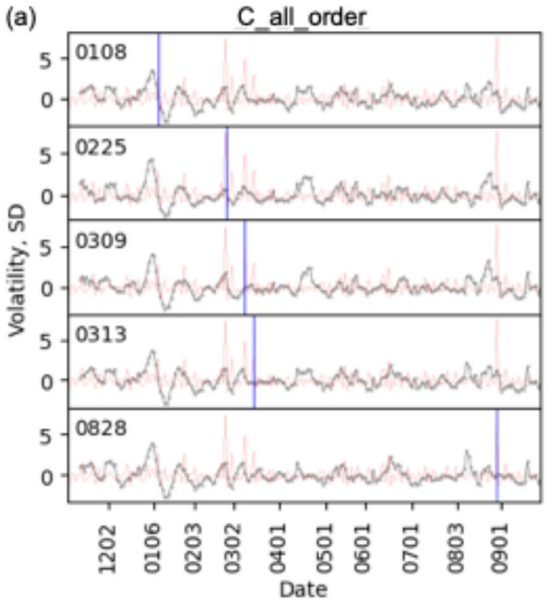

図 50　時系列種(a)co9（C_all_order）についての、全てのd_{focal}（各パネル左上に示した）に対する$SD_{I,d_{focal}}$の推移。$SD_{I,d_{focal}}$の Z 値を黒色のプロットで、$(d)/V(d-1)$の Z 値を赤色のプロットで示した。

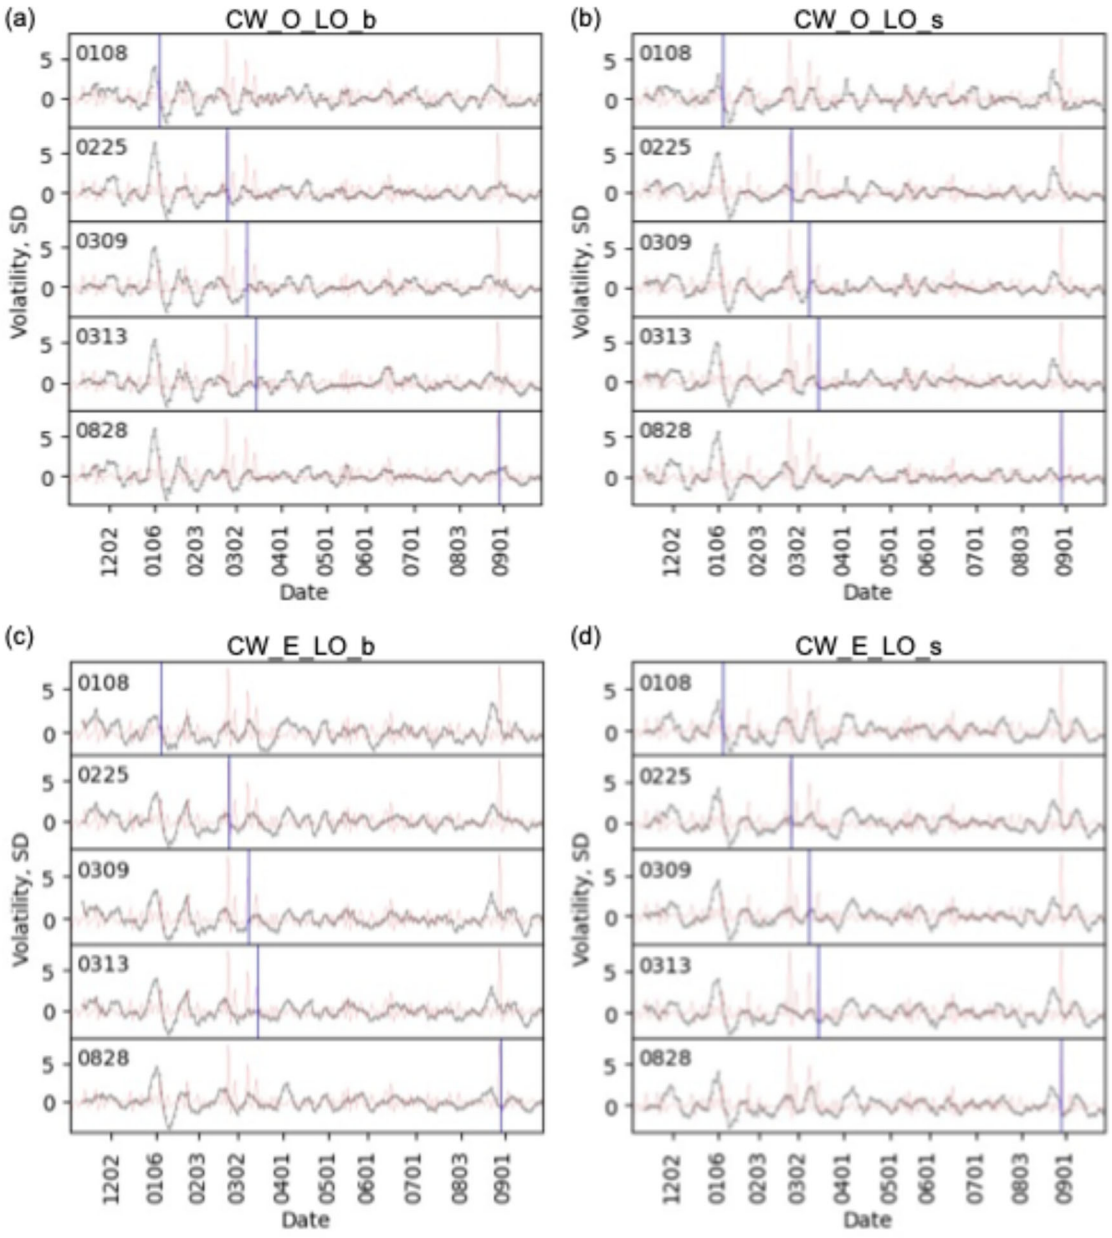

図 51　時系列種(a)co3’（CW_O_LO_b）、(b)co4’（CW_O_LO_s）、(c)co7’（CW_E_LO_b）、(d)co8’（CW_E_LO_s）についての、全てのd_{focal}（各パネル左上に示した）に対する$SD_{I,d_{focal}}$の推移。$SD_{I,d_{focal}}$のＺ値を黒色のプロットで、$V(d)/V(d-1)$のＺ値を赤色のプロットで示した。

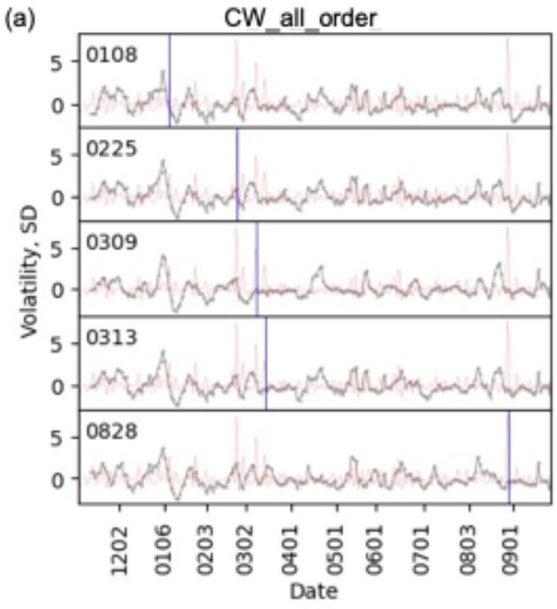

図 52　時系列種(a)co9’（CW_all_order）についての、全てのd_{focal}（各パネル左上に示した）に対する$SD_{I,d_{focal}}$の推移。$SD_{I,d_{focal}}$の Z 値を黒色のプロットで、$V(d)/V(d-1)$の Z 値を赤色のプロットで示した。

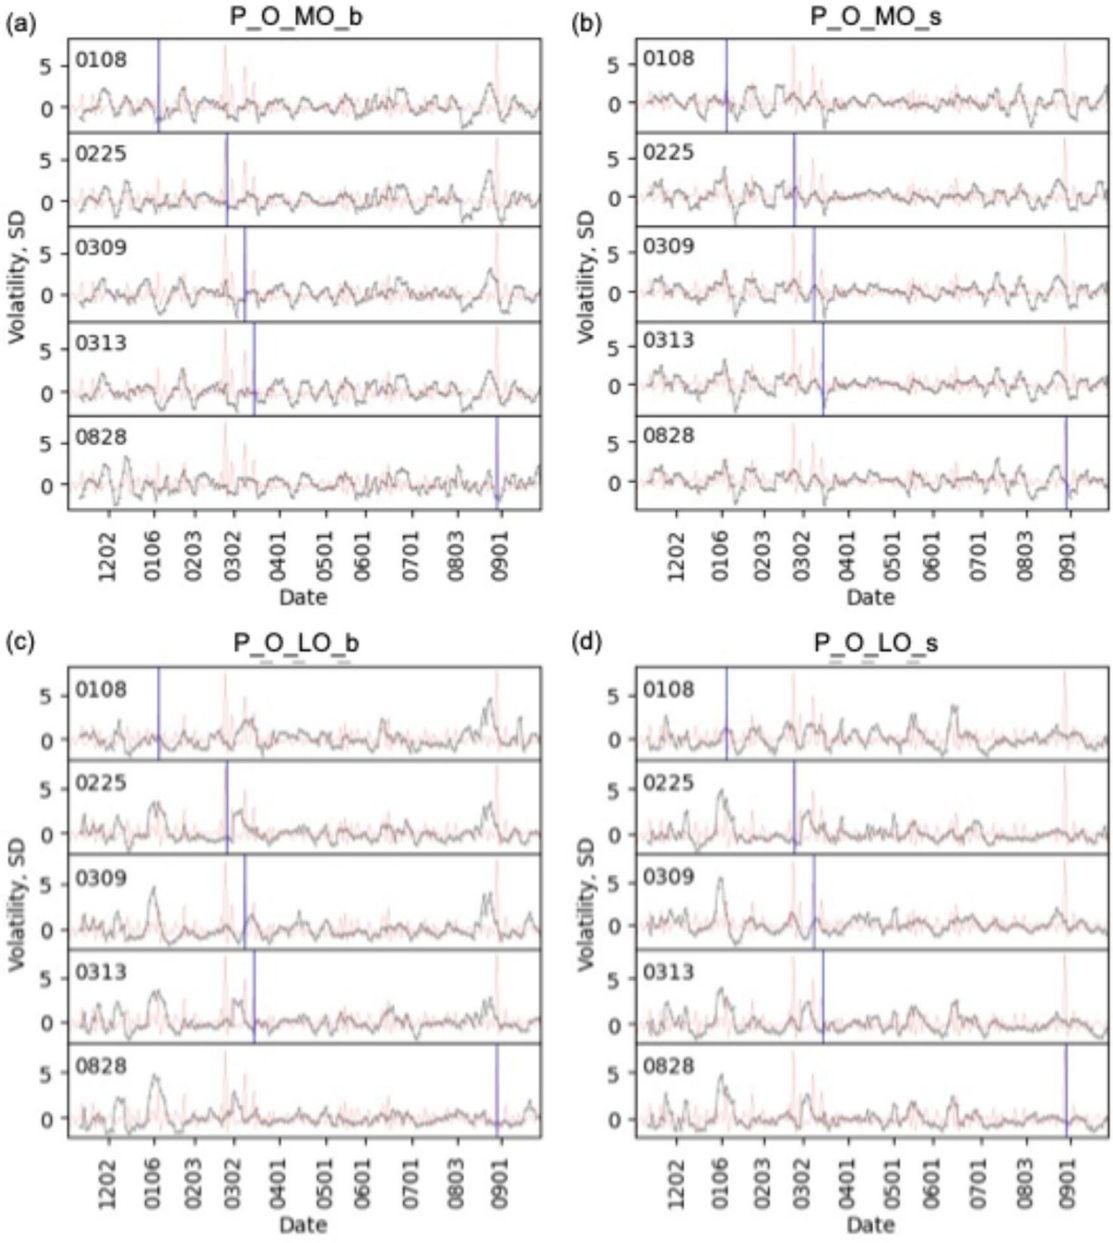

図 53　時系列種(a)pp1（P_O_MO_b）、(b)pp2（P_O_MO_s）、(c)pp3（P_O_LO_b）、(d)pp4（P_O_LO_s）についての、全てのd_{focl}（各パネル左上に示した）に対する$SD_{I,d_{focal}}$の推移。$SD_{I,d_{focal}}$のＺ値を黒色のプロットで、$V(d)/V(d-1)$のＺ値を赤色のプロットで示した。

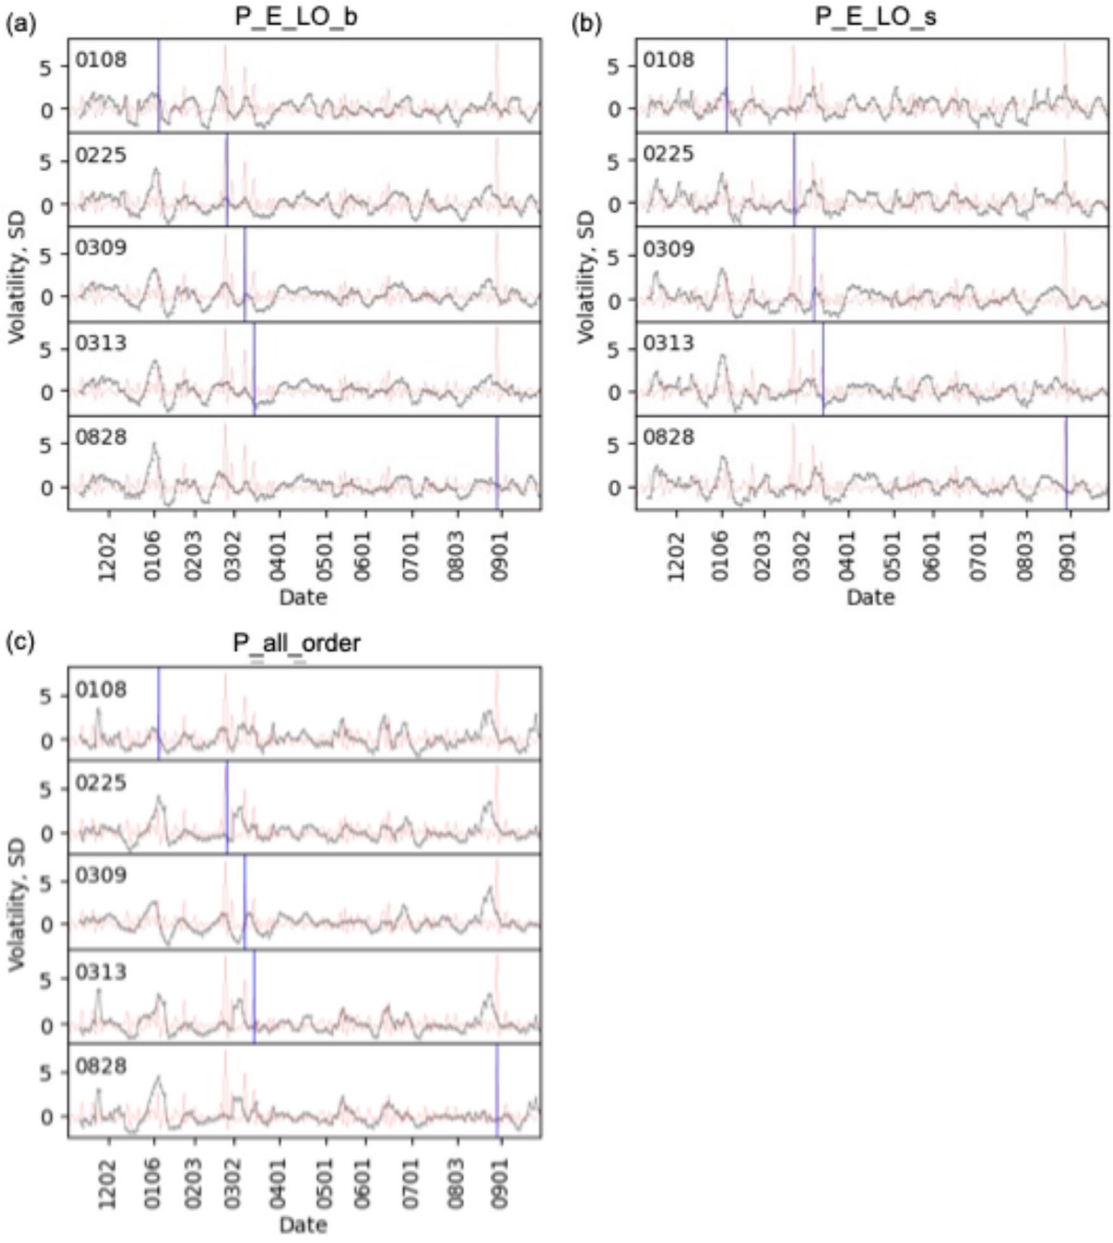

図 54 時系列種(a)pp7（P_E_LO_b）、(b)pp8（P_E_LO_s）、(c)pp9（P_all_order）についての、全てのd_{focal}（各パネル左上に示した）に対する$SD_{I,d_{focal}}$の推移。$SD_{I,d_{focal}}$の Z 値を黒色のプロットで、$V(d)/V(d-1)$の Z 値を赤色のプロットで示した。

6.6. 補論 6. DNM 集合を構成する市場参加者のレコード種別発注取引件数の詳細

ここでは、3.3 で示した DNM 集合を構成する市場参加者（主要市場参加者）のレコード種別発注取引件数について、詳細を示す。具体的には、3.3 の図 22 では 2020 年 1 月分の結果についてのみ示したが、本補論では 2019 年 11 月から 2020 年 9 月までのそれぞれの月における結果を示す。

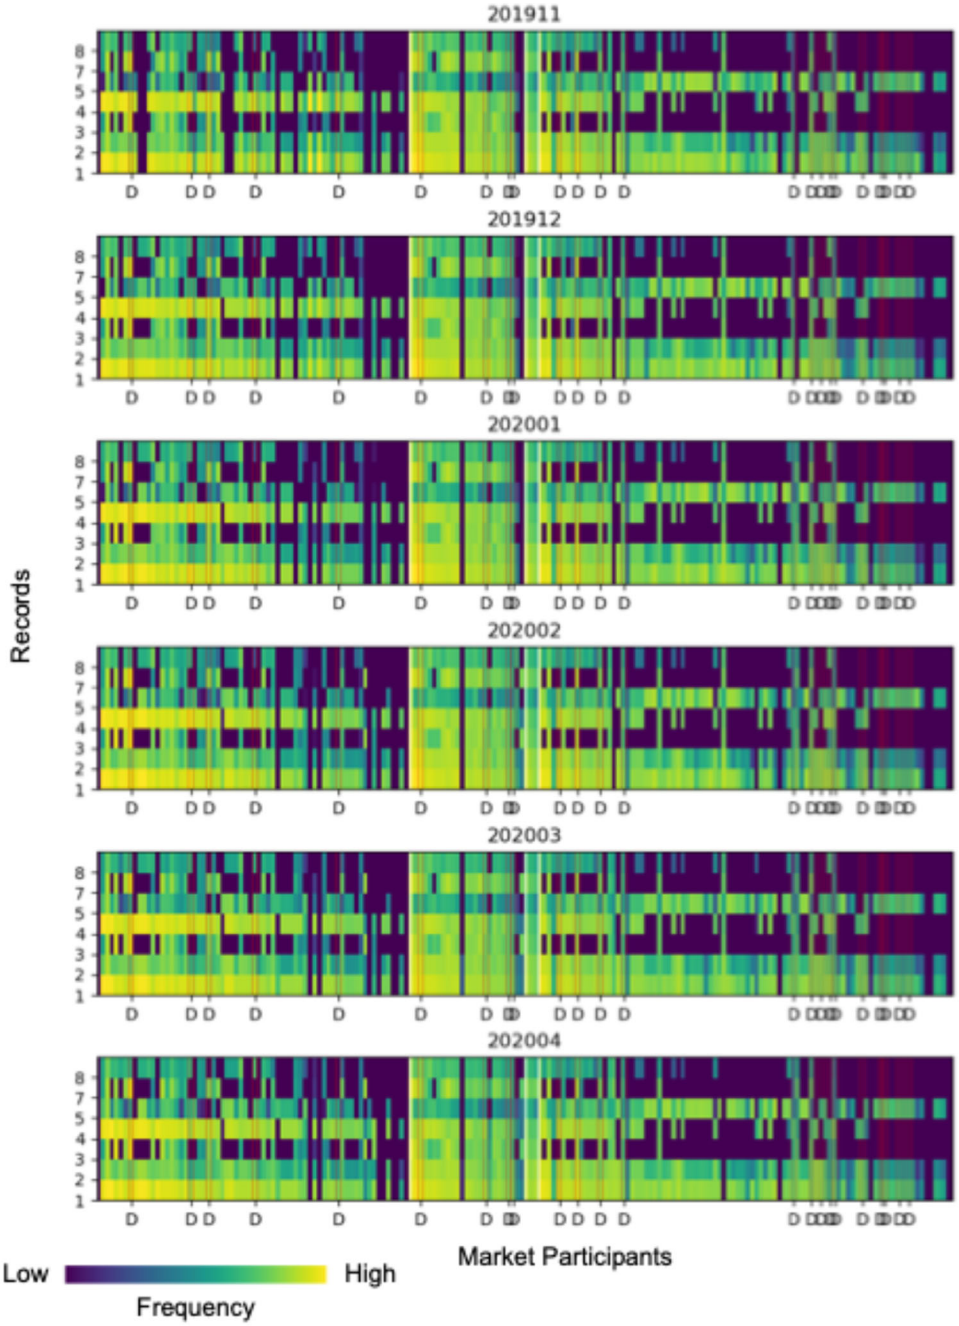

図 55 主要市場参加者のレコード種別発注取引件数。パネル上部に示した各月（2019 年 11 月～2020 年 4 月）を対象に、横軸方向に図 18—21 と同じ順番（HFT、証券会社自己、一般投資家、その他の順。さらに、それぞれの市場参加者タイプの中では発注件数についての降順）で全市場参加者を並べ、縦軸方向にレコード種別を列挙し、当該月における発注取引件数を対数スケールでヒートマップにより示した。縦軸のレコード種は、1：新規注文、2：約定、3：変更注文、4：取消注文、5：注文失効、7：取消新規処理、8：引け処理を示す。ここでは主要市場参加者を赤枠で囲って示した。また、市場参加者タイプが切り替わる箇所を白の垂線で示した。

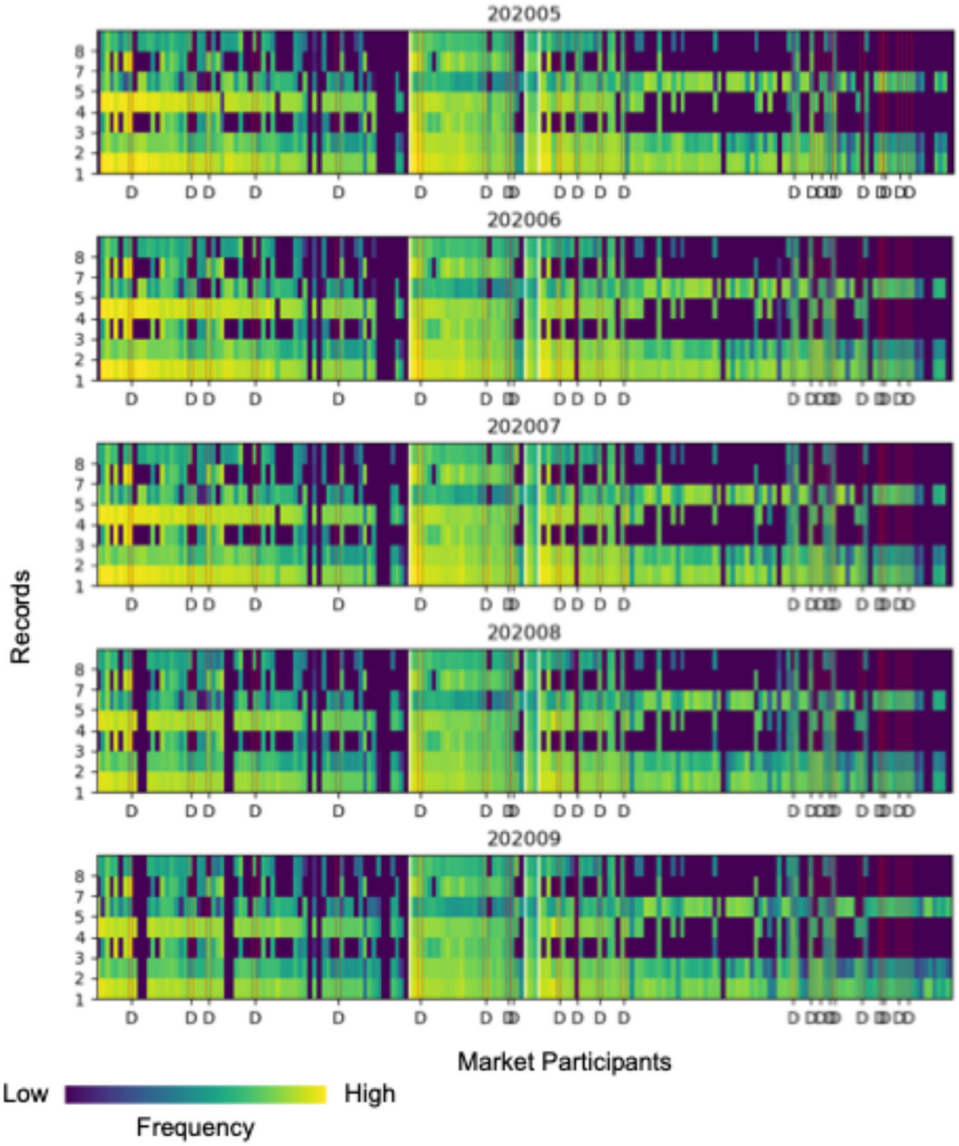

図 56 主要市場参加者のレコード種別発注取引件数。パネル上部に示した各月（2020 年 5 月～2020 年 9 月）を対象に、図 55 と同様にヒートマップでレコード種別発注取引件数を示す。

6.7. 補論 7. 発注取引銘柄の共有関係のネットワーク表現

ここでは、3.3 で示した発注取引銘柄の共有関係のネットワーク表現について、詳細を示す。具体的には、3.3 の図 23 では 2020 年 1 月分の結果についてのみ示したが、本補論では 2019 年 11 月から 2020 年 9 月までのそれぞれの月における結果を示す。

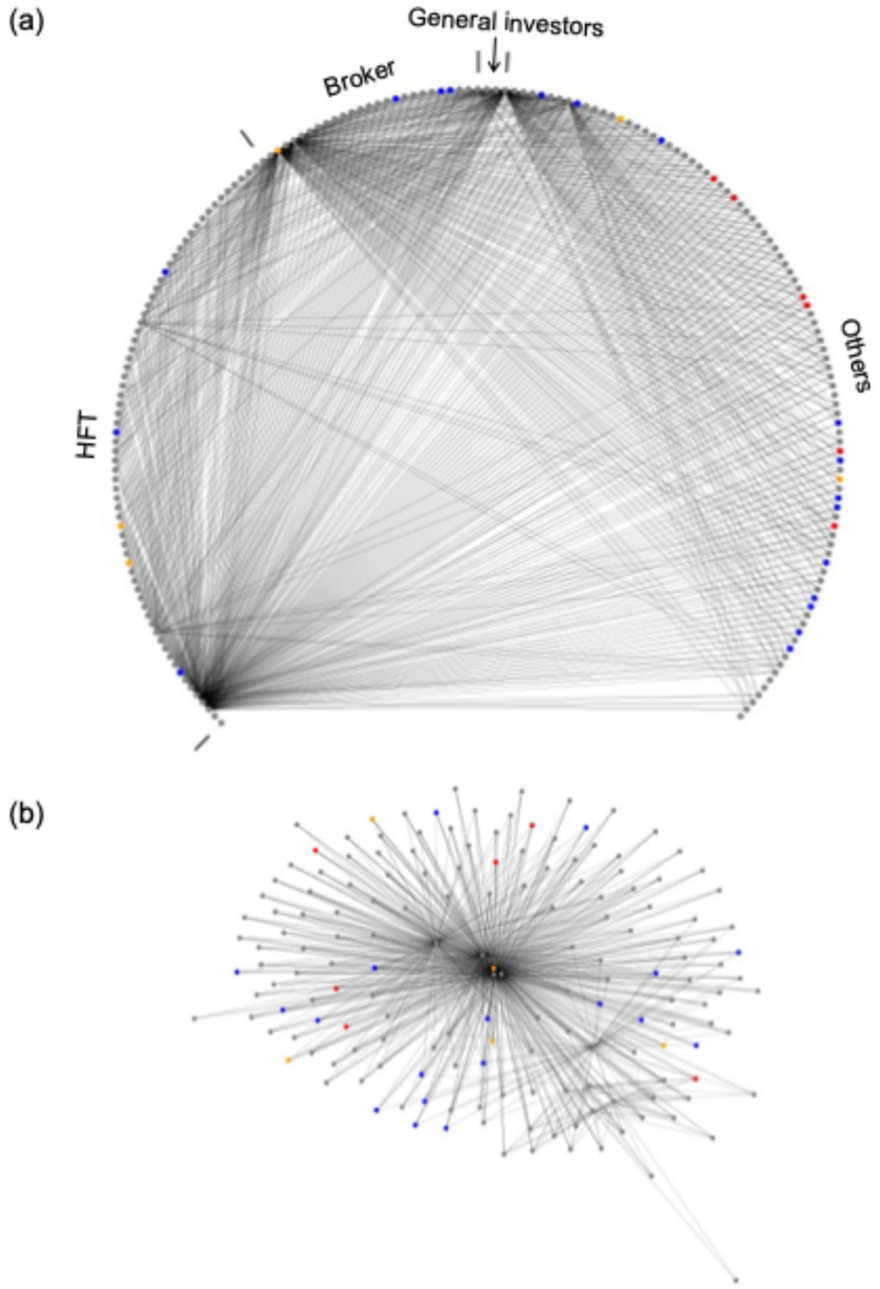

図 57 (a,b) 2019 年 11 月における発注取引銘柄の共有関係のネットワーク表現。頂点は市場参加者を表し、リンクは銘柄共有に関する強い関係性を表す。全ての時系列種のもとで定めた主要市場参加者を DNM1、点過程に関する時系列種のみ考慮して定めた主要市場参加者を DNM2 としたとき、 DNM1 のみに属する主要市場参加者を青、DNM2 のみに属する主要市場参加者を赤で示し、DNM1 と DNM2 の双方に属する主要市場参加者をオレンジで示した。(a)では、市場参加者を、反時計回りに図 18—22 と同じ順番で並べた。(b)では、より密につながった頂点同士が近づくように頂点を配置した。

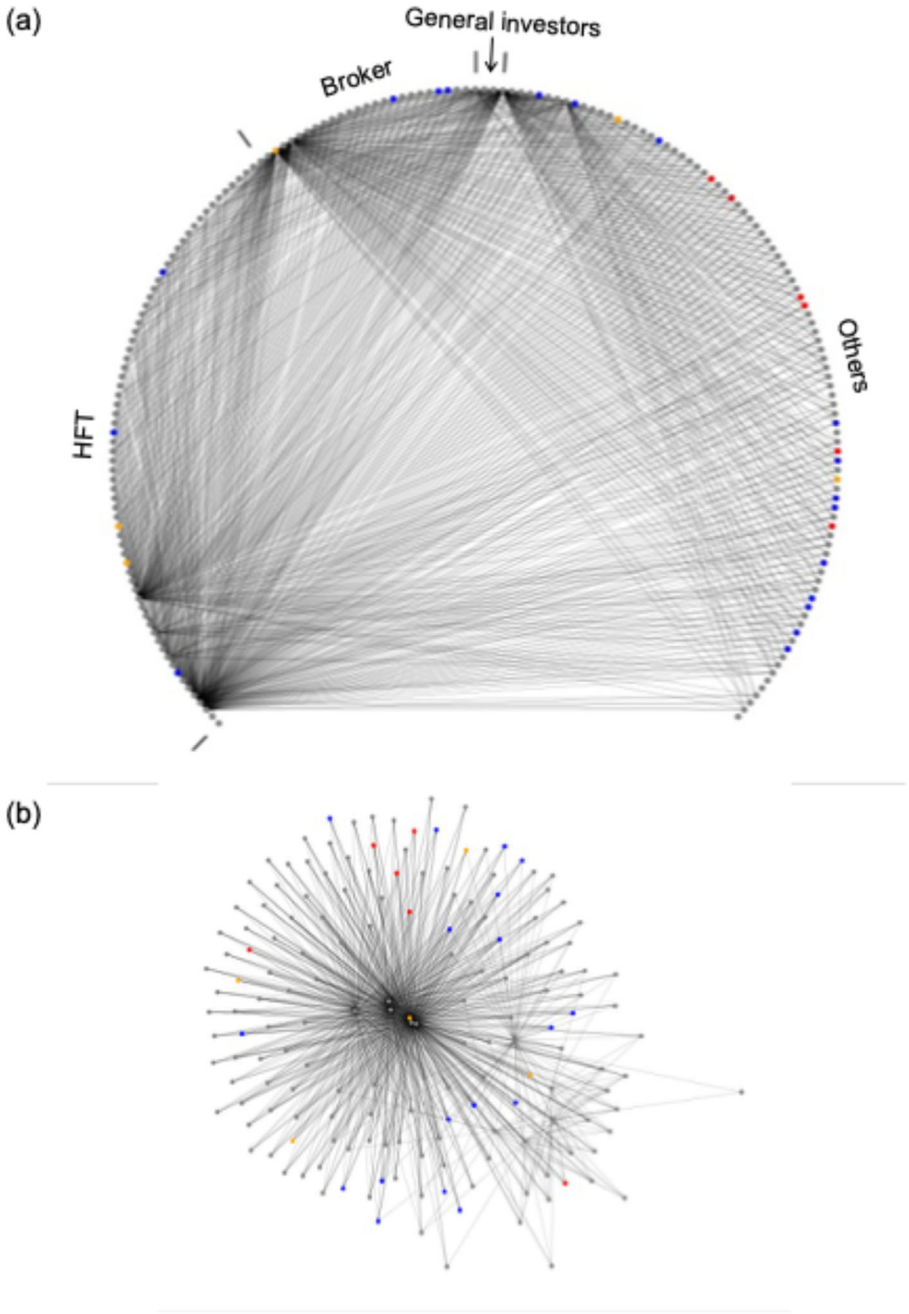

図 58 (a,b) 2019 年 12 月における発注取引銘柄の共有関係のネットワーク表現を図 57 と同様に示す。

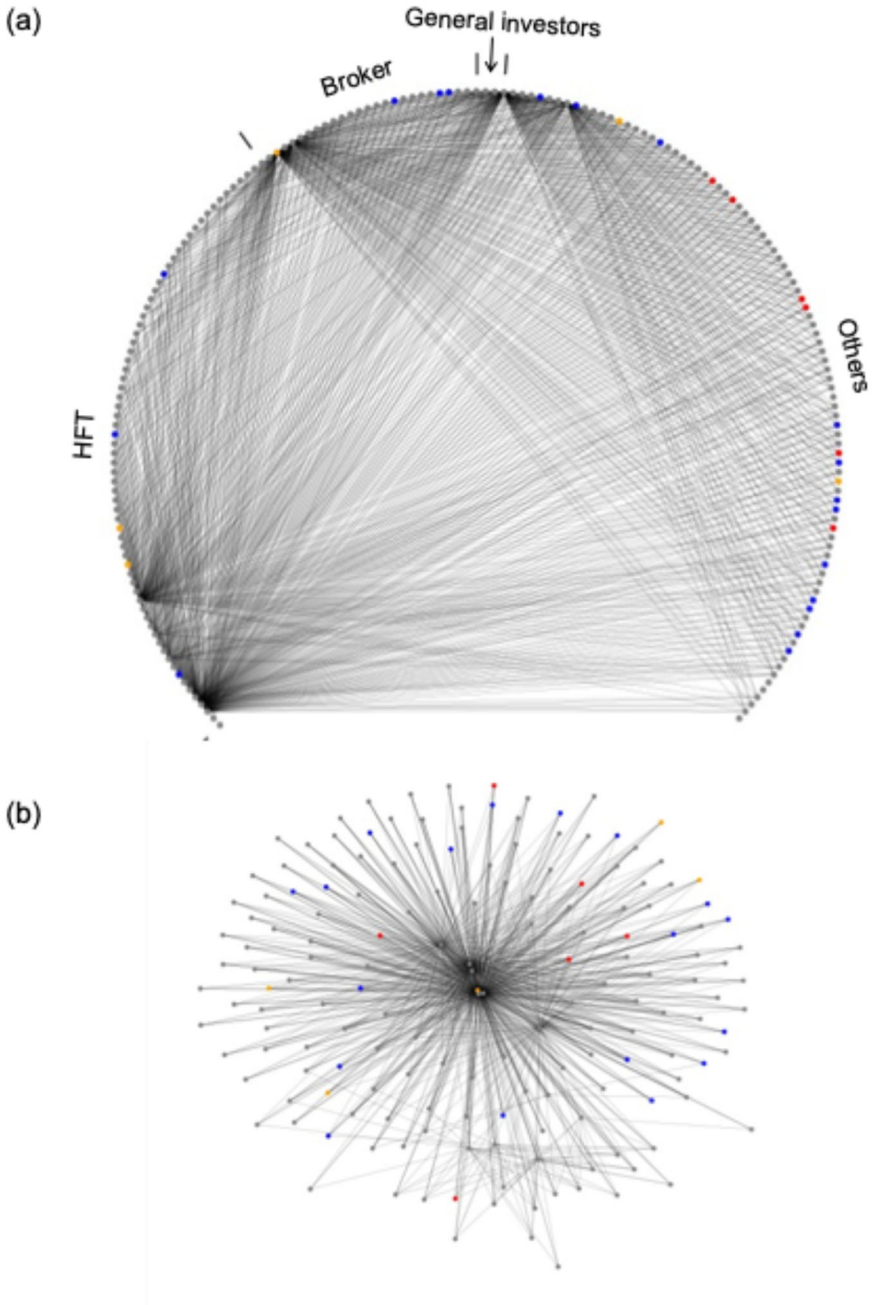

図 59 (a,b) 2020 年 1 月における発注取引銘柄の共有関係のネットワーク表現を図 57 と同様に示す（図 23 の再掲）。

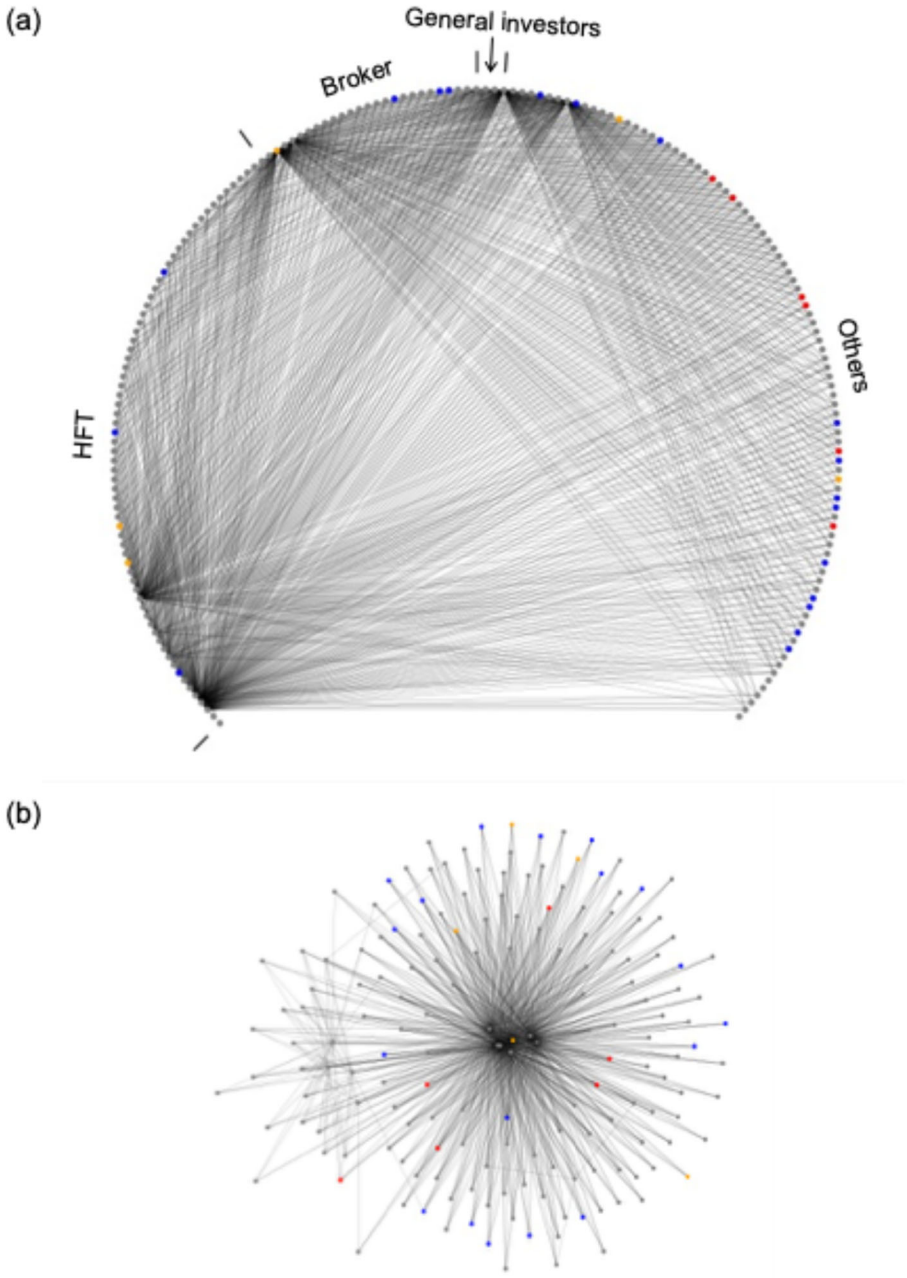

図 60 (a,b) 2020 年 2 月における発注取引銘柄の共有関係のネットワーク表現を図 57 と同様に示す。

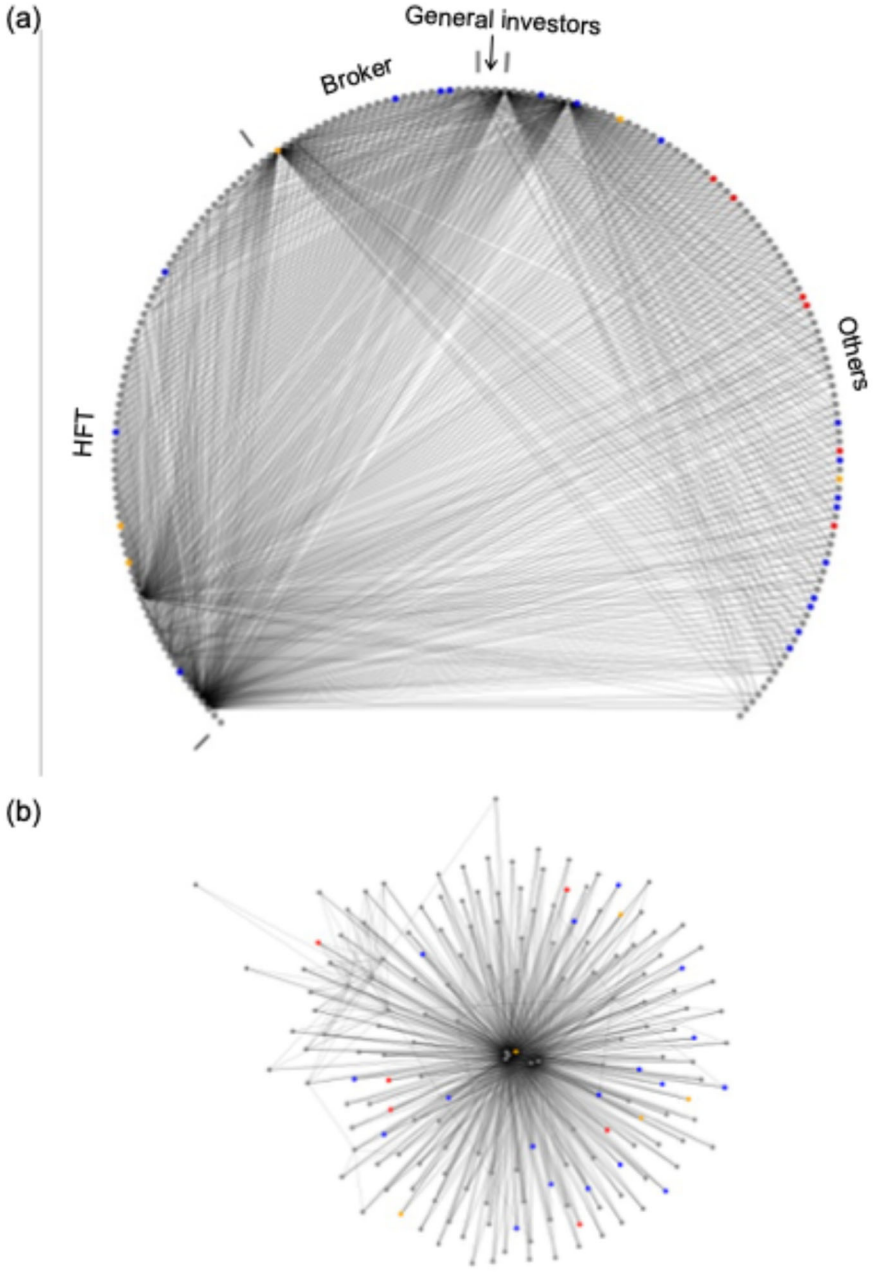

図 61 (a,b) 2020 年 3 月における発注取引銘柄の共有関係のネットワーク表現を図 57 と同様に示す。

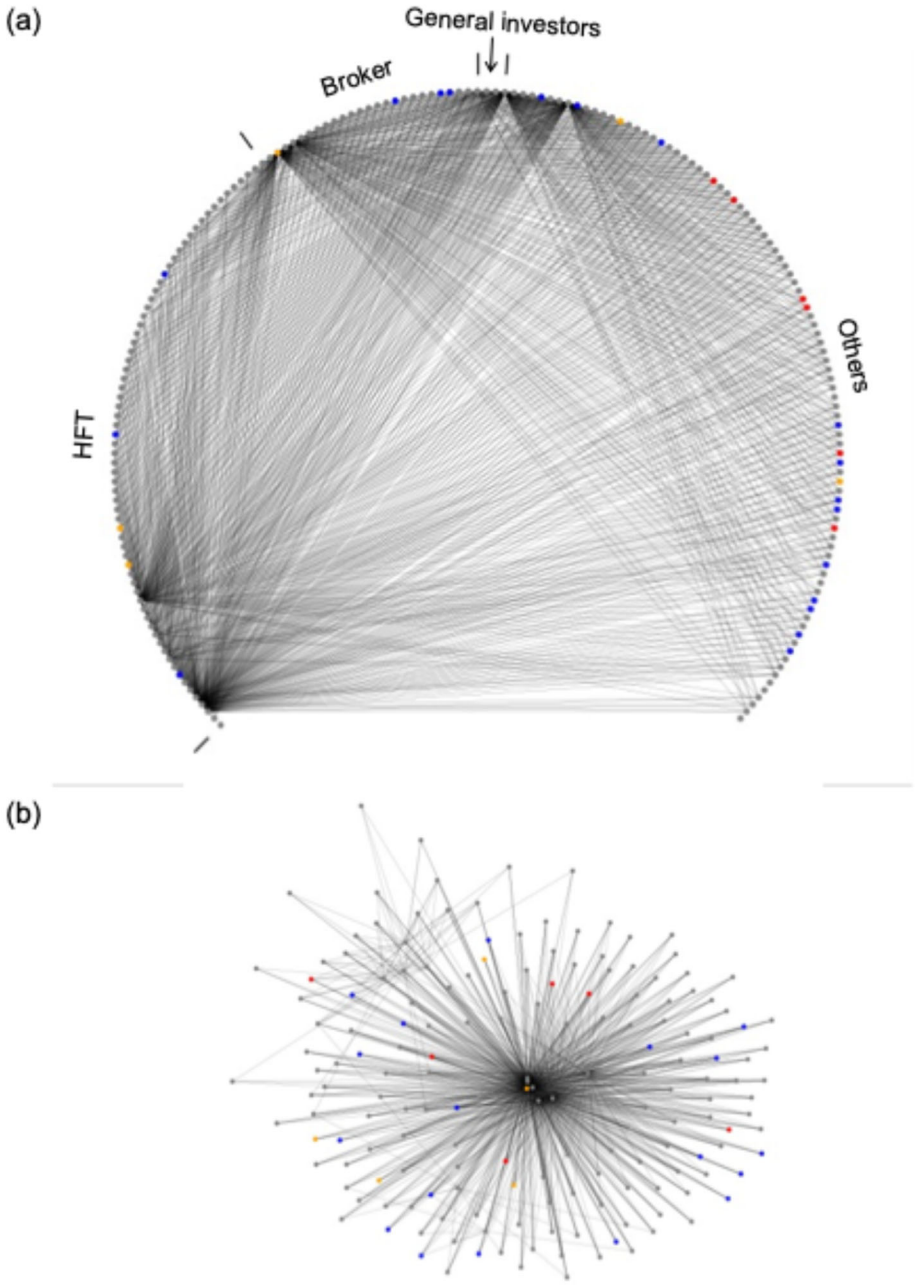

図 62 (a,b) 2020 年 4 月における発注取引銘柄の共有関係のネットワーク表現を図 57 と同様に示す。

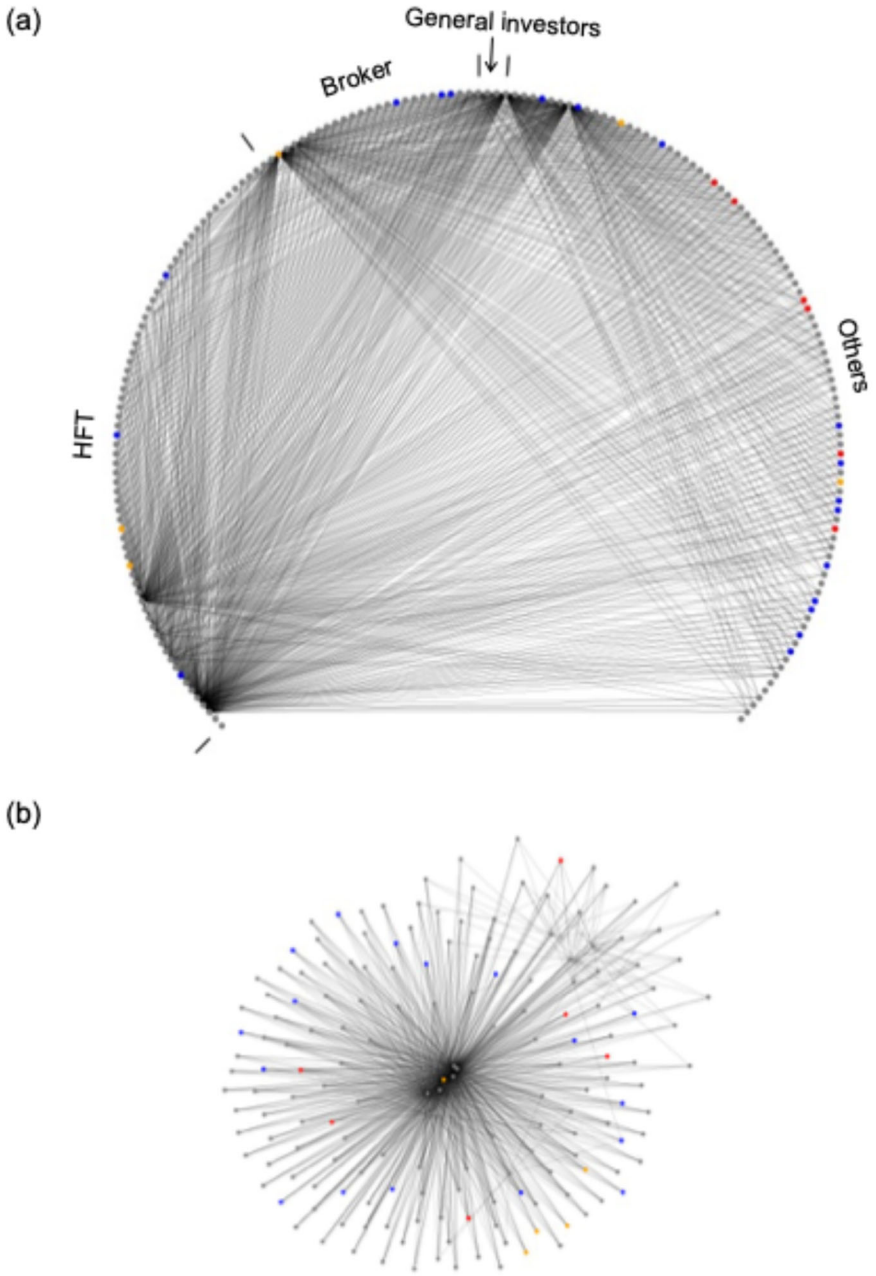

図 63 (a,b) 2020 年 5 月における発注取引銘柄の共有関係のネットワーク表現を図 57 と同様に示す。

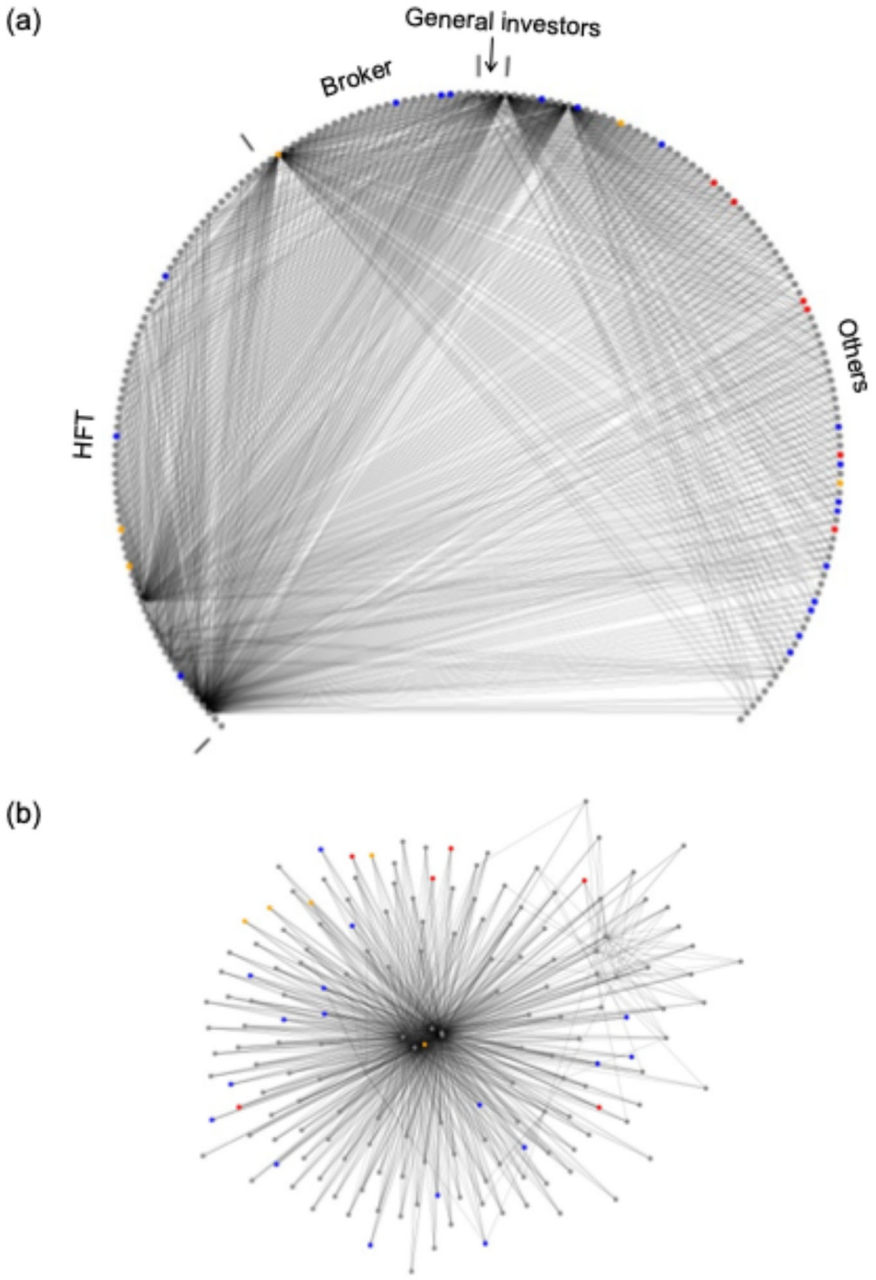

図 64 (a,b) 2020 年 6 月における発注取引銘柄の共有関係のネットワーク表現を図 57 と同様に示す。

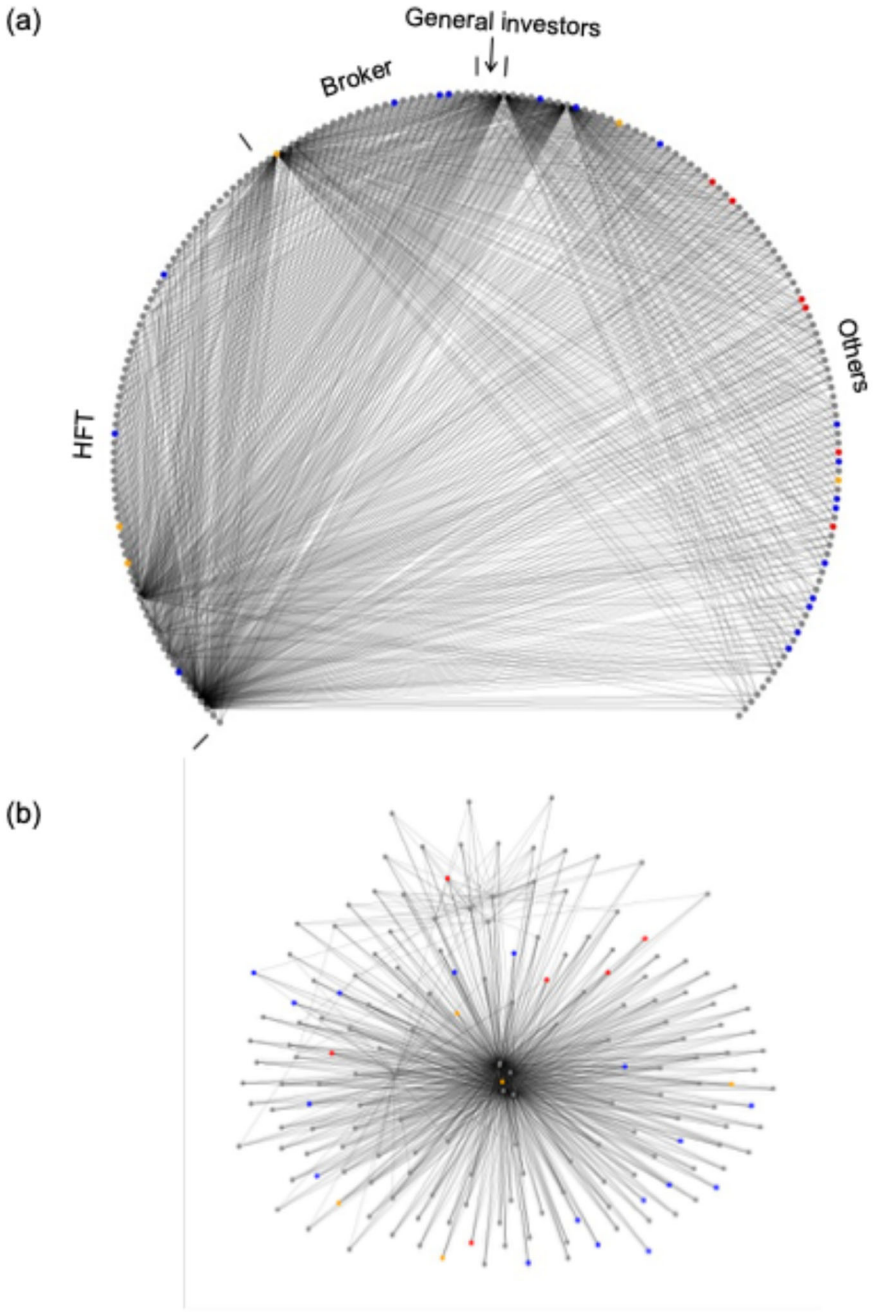

図 65 (a,b) 2020 年 7 月における発注取引銘柄の共有関係のネットワーク表現を図 57 と同様に示す。

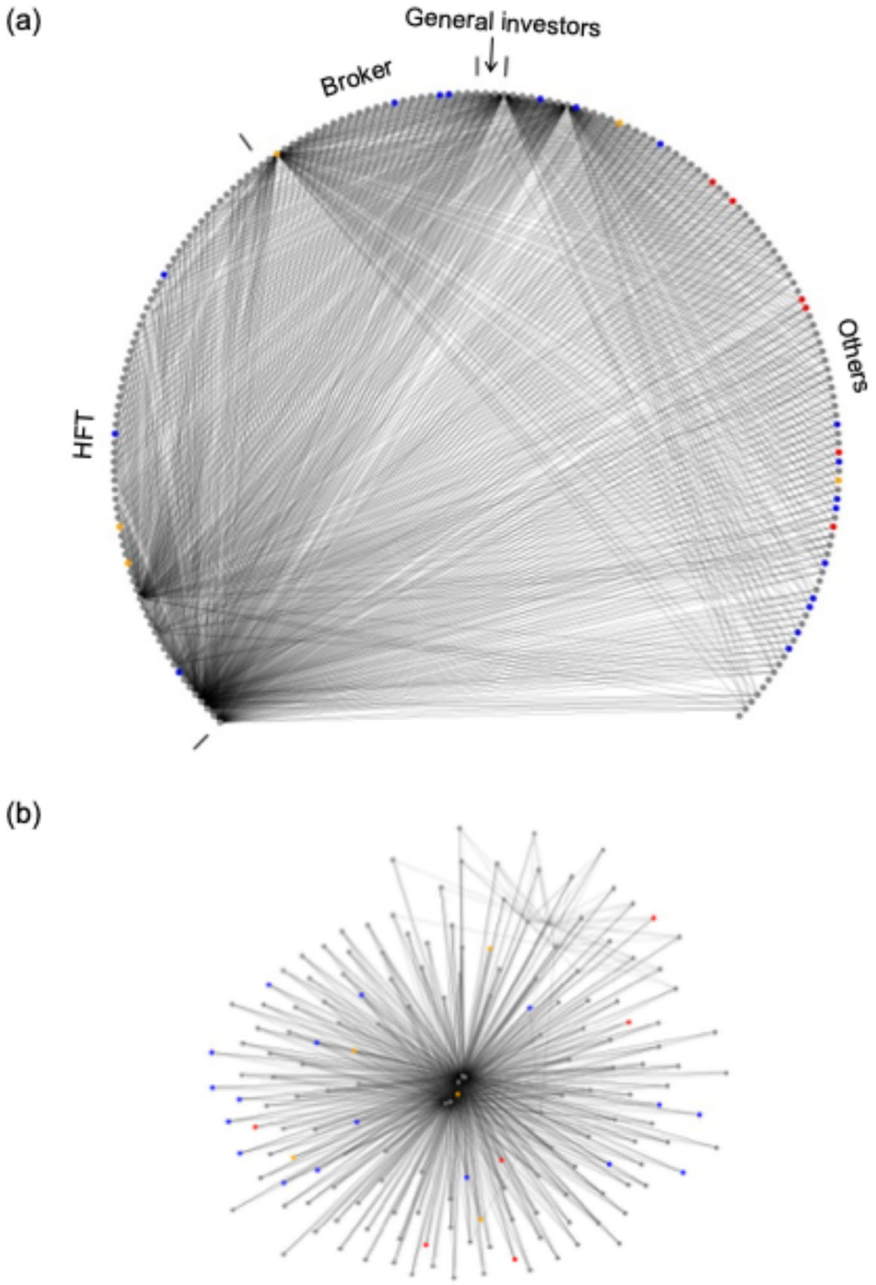

図 66 (a,b) 2020 年 8 月における発注取引銘柄の共有関係のネットワーク表現を図 57 と同様に示す。

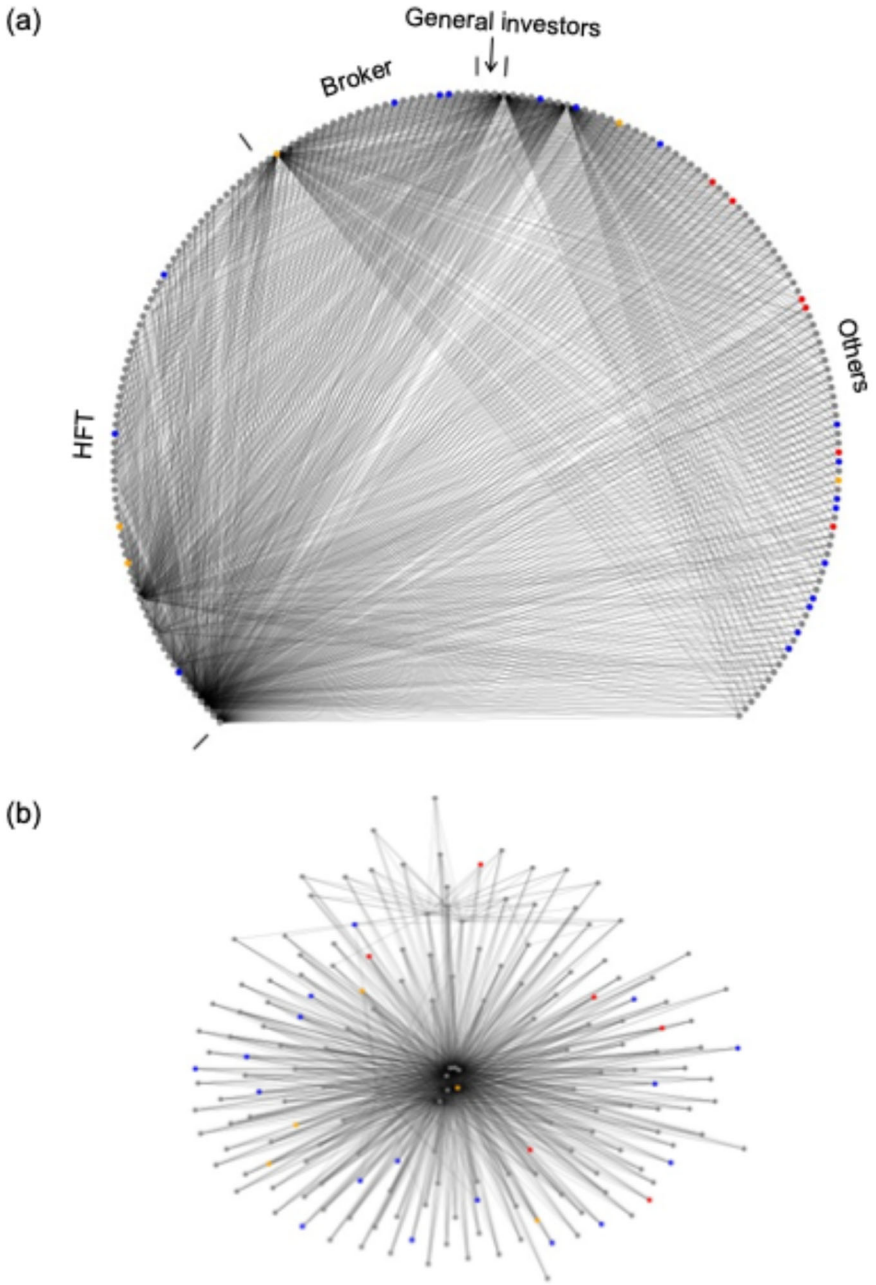

図 67 (a,b) 2020 年 9 月における発注取引銘柄の共有関係のネットワーク表現を図 57 と同様に示す。

参考文献

Aihara, K., Liu, R., Koizumi, K., Liu, X., and Chen, L. (2022), "Dynamical Network Biomarkers: Theory and Applications." *Gene*, Vol. 808, p.145997.

Bacry, E., Mastromatteo, I., and Muzy, J-F. (2015), "Hawkes Processes in Finance." *Market Microstructure and Liquidity*, Vol. 1, No. 1, p.1550005.

Bardoscia, M., Barucca, P., Battiston, S., Caccioli, F., Cimini, G., Garlaschelli, D., Saracco, F., Squartini, T., and Caldarelli, G. (2021), "The Physics of Financial Networks." *Nature Reviews Physics*, Vol. 3, No. 7, pp. 490–507.

Battiston, S., Farmer, J. D., Flache, A, Garlaschelli, D, Haldane, A. G., Heesterbeek, H., Hommes, C., Jaeger, C., May, R., and Scheffer, M. (2016), "Complexity Theory and Financial Regulation." *Science*, No. 351, Vol. 6275, pp. 818–819.

Bonanno, G., Lillo, F., and Mantegna, R.N. (2001), "High-Frequency Cross-Correlation in a Set of Stocks." *Quantitative Finance*, Vol. 1, No. 1, pp. 96–104.

Chen, L., Liu, R., Liu, Z-P., Li, M., and Aihara, K. (2012), "Detecting Early-Warning Signals for Sudden Deterioration of Complex Diseases by Dynamical Network Biomarkers." *Scientific Reports*, Vol. 2, No. 1, pp. 1–8.

Drake, J. M., and Griffen, B. D. (2010), "Early Warning Signals of Extinction in Deteriorating Environments." *Nature*, Vol. 467, No. 7314, pp. 456–459.

Goshima, K., Tobe, R., and Uno, J. (2019), "Trader Classification by Cluster Analysis: Interaction between HFTs and Other Traders." *Waseda University Institute for Buisiness and Finance Working Paper Series*.

Hawkes, A. G. (2018), "Hawkes Processes and Their Applications to Finance: A Review." *Quantitative Finance*, Vol. 18, No. 2, pp.193–198.

Hirata, Y., and Aihara, K. (2015), "Edit Distance for Marked Point Processes Revisited: An Implementation by Binary Integer Programming." *Chaos: An Interdisciplinary Journal of Nonlinear Science*, Vol. 25, No. 12, p. 123117.

Hirata, Y., and Aihara, K. (2012), "Timing Matters in Foreign Exchange Markets." *Physica A: Statistical Mechanics and Its Applications*, Vol. 391, No. 3, pp. 760–766.

Ito, M. I., Honma, Y., Ohnishi, T., Watanabe, T., and Aihara, T. (2024), "Exogenous and Endogenous Factors Affecting Stock Market Transactions: A Hawkes Process Analysis of the Tokyo Stock Exchange during the COVID-19 Pandemic." *PLOS ONE* 19 (4): e0301462.

Jackson, M. O., and Pernoud, A. (2021), "Systemic Risk in Financial Networks: A Survey." *Annual Review of Economics* Vol. 13, No. 1, pp. 171–202.

Jorge, A., Aldasoro, I., Aymanns, C., D'Errico, M., Rousová, L. F., Hoffmann, P, Langfield, S., Neychev, M., and Roukny, T. (2016), "Shedding Light on Dark Markets: First Insights from the New EU-

Wide OTC Derivatives Dataset." *ESRB: Occasional Paper Series*, No 11/September 2016.

Karsai, M., Jo, H. H., and Kaski, K. (2018), *Bursty Human Dynamics*. Springer.

Kim, E-K., and Jo, H-H. (2016). "Measuring Burstiness for Finite Event Sequences." *Physical Review E* Vol. 94, No. 3, p. 032311.

Klinčić, L., Zlatić, V., Caldarelli, G., and Štefančić, H. (2023), "Systemic risk measured by the resiliency of the system to initial shocks." *Physical Review E* Vol. 108, No. 4, p.044303.

Koizumi, K., Oku, M., Hayashi, S., Inujima, A., Shibahara, N., Chen, L., Igarashi, Y., et al. (2019), "Identifying Pre-Disease Signals before Metabolic Syndrome in Mice by Dynamical Network Biomarkers." *Scientific Reports* Vol. 9, No. 1, p. 8767.

Kwapień, J., and Drożdż, S. (2012), "Physical Approach to Complex Systems." *Physics Reports* Vol. 515, No. 3–4, pp. 115–226.

Liu, Y-Y., Slotine J-J., and Barabási A-L. (2011), "Controllability of complex networks." *Nature* Vol. 473, No. 7346, pp. 167–173.

Masuda, N., Aihara, K., and MacLaren, N. G. (2024), "Anticipating Regime Shifts by Mixing Early Warning Signals from Different Nodes." *Nature Communications* Vol. 15, No. 1, p. 1086.

May, R. M., Levin, S. A., and Sugihara, G. (2008). "Ecology for Bankers." *Nature* Vol. 451, No. 7181, pp. 893–894.

Menczer, F., Fortunato, S., and Davis, C. A. (2020). *A First Course in Network Science*. Cambridge University Press.

Musciotto, F., Piilo, J., and Mantegna, R. N. (2021). "High-Frequency Trading and Networked Markets." *Proceedings of the National Academy of Sciences* Vol. 118, No. 26, p.　e2015573118.

Oya, S., Aihara, K., and Hirata, Y. (2014). "Forecasting Abrupt Changes in Foreign Exchange Markets: Method Using Dynamical Network Marker." *New Journal of Physics* Vol. 16, No. 11, p. 115015.

Podobnik, B., Wang, D., Horvatic, D., Grosse, I., and Stanley, H. E. (2010). "Time-Lag Cross-Correlations in Collective Phenomena." *EPL (Europhysics Letters)* Vol. 90, No. 6, p. 68001.

Sandoval, L., and Franca, I. D. P. (2012). "Correlation of Financial Markets in Times of Crisis." *Physica A: Statistical Mechanics and Its Applications* Vol. 391, No. 1–2, pp. 187–208.

Saracco, F., Clemente, R. D., Gabrielli, A., and Squartini, T. (2016). "Detecting Early Signs of the 2007–2008 Crisis in the World Trade." *Scientific Reports* No. 6, Vol. 1, p. 30286.

Sato, Y., and Kanazawa, K. (2023). "Inferring Microscopic Financial Information from the Long Memory in Market-Order Flow: A Quantitative Test of the Lillo-Mike-Farmer Model." *Physical Review Letters* Vol. 131, No. 19, p. 197401.

Scheffer, M., Bascompte, J., Brock, W. A., Brovkin, V., Carpenter, S. R., Dakos, V., Held, H., van Nes, E. H., Rietkerk, M., and Sugihara, G. (2009). "Early-Warning Signals for Critical Transitions." *Nature* Vol. 461, No. 7260, pp. 53–59.

Song, D-M., Tumminello, M., Zhou, W-X., and Mantegna, R. N. (2011). "Evolution of Worldwide Stock

Markets, Correlation Structure, and Correlation-Based Graphs". *Physical Review E* Vol. 84, No. 2, p. 026108.

Song, S., and Li, H. (2024). "Early Warning Signals for Stock Market Crashes: Empirical and Analytical Insights Utilizing Nonlinear Methods." *EPJ Data Science* No. 13, Vol. 1, p.16.

Strogatz, S. H. (2000). *Nonlinear Dynamics and Chaos: With Applications to Physics, Biology, Chemistry and Engineering*. Studies in Nonlinearity. Westview.

Wheatley, S., Wehrli, A., and Sornette, D. (2019). "The Endo–Exo Problem in High Frequency Financial Price Fluctuations and Rejecting Criticality." *Quantitative Finance* Vol. 19, No. 7, pp. 1165–1178.

Yellen, J. L. (2013), "Interconnectedness and Systemic Risk: Lessons from the Financial Crisis and Policy Implications. " *Speech by Ms Janet L Yellen, Vice Chair of the Board of Governments of the Federal Reserve System, at the American Economic Association/American Finance Association Joint Luncheon, San Diego, California*. (https://www.federalreserve.gov/newsevents/speech/yellen20130104a.htm).

Zheng, Z., Podobnik, B., Feng, L., and Li, B. (2012). "Changes in Cross-Correlations as an Indicator for Systemic Risk." *Scientific Reports* Vol. 2, No. 1, p. 888.

青山秀明・家富洋・池田裕一・相馬亘・藤原義久(2008). 『経済物理学』共立出版.

大山篤之・津田博史 (2022) 「アルゴリズム化基準による高頻度取引 (HFT) の特性分析」『ジャフィー・ジャーナル』第 20 号，pp. 55–69.

中川拓麻 ・奥牧人・合原一幸 (2016) 「動的ネットワークマーカーによるシステムの転移の予兆検出」『生産研究』第 68 巻第 3 号，pp. 271–274.

保坂豪 (2014),「東京証券取引所における High-Frequency Trading の分析」,『証券アナリストジャーナル』 第 52 巻第 6 号，pp. 73–82.

山田昌弘 (2023)「日本の株式市場における高頻度取引について」『TCER Working Paper Series』pp. 1–23.

金融庁金融研究センター

〒100-8967　東京都千代田区霞ヶ関 3-2-1
中央合同庁舎 7 号館　金融庁

TEL：03-3506-6000
URL：https://www.fsa.go.jp/frtc/index.html