

高速取引行為が市場流動性や市場変動の大きさに与える影響に関する分析

(要旨)

本稿では、高速取引行為（HFT）が市場流動性及び市場変動の大きさに与える影響について、2023 年 12 月の株価指数先物取引の注文明細データを用いて詳細な分析を試みた。HFT による流動性供給動向を取消注文も考慮して確認すると、時期や最良気配の変化によって HFT の取引行動に変化があるものの、総じて一定の流動性供給が確認された。また、市場変動の大きさに与える影響の分析では、取引戦略の違いにより、HFT が市場変動を抑制する方向に寄与する場合がある一方、拡大する方向に寄与する場合もある可能性が示唆された。引き続き分析手法の改善や分析対象の拡大等を通じて、HFT の実態把握を進めていく。

1. はじめに

市場における高速取引行為（以下「HFT」という）¹の取引シェアは大きく、例えば市場デリバティブ取引を扱う大阪取引所では売買代金ベースで 35~55%程度、新規・変更・取消を合わせた注文件数ベースで 93~97%程度と非常に高い²。市場のメカニズムを理解するうえで、HFT が市場に与える影響について分析することは重要である。

金融庁では、株式取引等の注文明細データを用いて HFT の実態把握を進めてきた。他方、HFT の取引行動の全容を詳細に解明することは困難であり、HFT が市場に与える影響について、市場関係者等からはこれまで様々な評価がなされている。HFT は高頻度で指値注文等を発注して市場に流動性を供給し、スプレッド³の低下に貢献していると肯定的に捉える評価⁴もあるものの、他方では、取消注文を多用しており市場流動性の向上に貢献してはいない、HFT の高速性が市場の市場変動の大きさを上昇させ、相場を攪乱する要因となっている等の懸念も指摘されている⁵。

このため、本稿では、「HFT が市場流動性に与える影響」及び「HFT の注文行動が市場変動の大き

¹ 2018 年 4 月の金融商品取引法改正により、高速取引行為者の登録制が導入され、同法第 2 条第 42 項に規定される高速取引行為者の数は足元 50 社程度で推移している。本稿では、当該者を「HFT 業者」、当該者による高速取引行為を「HFT」とする。

² 金融庁「高速取引行為の動向について」<https://www.fsa.go.jp/news/r2/sonota/20210630/20210630.html>

³ 最も低い売り注文価格（売り最良気配）と最も高い買い注文価格（買い最良気配）との価格差を指す。

⁴ 金融庁金融研究センター「高速取引行為の特性分析」

https://www.fsa.go.jp/frtc/report/honbun/2021/20210707_SR_HFT_Article.pdf

⁵ 金融庁「金融審議会『市場ワーキング・グループ』報告書の公表について」

https://www.fsa.go.jp/singi/singi_kinyu/tosin/20161222-1.html

さに与える影響」に絞って詳細な分析を試みた。

本稿の分析は、日本株市場の動きを代表する株価指数先物である「日経 225 先物」及び「日経 225mini」の 2023 年 12 月の中心限月の注文明細データ⁶を用いて行った⁷。

II. HFT が市場流動性に与える影響

本章では、取引参加者が取引板⁸における売買双方向の最良気配⁹から 5 ティック¹⁰以内に注文を発注したとき、「流動性を供給」したと定義する。もっとも、HFT 業者は取消注文を多く行っている先も多く、注文発注後すぐに取消行為が行われた場合、取消前の注文も流動性を供給したとみなせるかは疑問である。そこで、本分析では、各注文が流動性を供給している時間の概念を加えることで、取消注文も考慮した市場流動性の指標を定義し、HFT による流動性供給動向を確認した。

1. 定義

「最良気配から 5 ティック以内にある注文数量の時間加重平均」を市場流動性の指標とする。このとき、時間区間 t_s 以上から t_e 未満における HFT による流動性供給割合 $R_{j,[t_s,t_e]}$ の算出式を以下の通り定義する。 j は買い板 (buy) または売り板 (sell) である。

$$R_{j,[t_s,t_e]} := \frac{\text{最良気配から 5 ティック以内にある HFT の注文数量の時間加重平均}}{\text{最良気配から 5 ティック以内にある全注文数量の時間加重平均}}$$

定義式のとおり、 $R_{j,[t_s,t_e]}$ は 0 以上 1 以下の値となり、HFT の流動性供給割合が大きいほど 1 に近くなる。計算例として図表 1 を示す。この場合は、売り板を対象とした時間区間 $t=0$ 以上 $t=6$ 未満における HFT による流動性供給割合 $R_{sell,[0,6]}$ は 0.57 と算出される。

⁶ 注文明細データには、新規注文、変更注文、取消注文、成約のレコード区分のほか、売買区分、価格、注文枚数、注文数量、注文条件、発注者 (HFT 業者の場合は戦略含む)、タイムスタンプなどが記録されている。


⁷ 先物・オプション取引では、取引できる期限毎に商品が分かれており、取引できる期限の月を「限月」という。先物・オプション取引では複数の限月が上場され取引が行われるが、中心限月とはその中で最も出来高が多い限月を指す。2023 年 12 月限の「日経 225 先物」、「日経 225mini」の最終取引日が 12 月 7 日であるため、それ以降は次の中心限月である 2024 年 3 月限のデータを利用した。

⁸ 取引参加者からの売買注文を記録する、銘柄別の注文控えのことを「板」という。

⁹ 最も低い売り注文価格を「売り最良気配」、最も高い買い注文価格を「買い最良気配」という。

¹⁰ 値段の刻みの単位をティック (呼び値) という。

図表 1 流動性供給割合 $R_{j,[t_s,t_e]}$ 計算例



$$R_{sell,[0,6)} = \frac{\text{最良気配から5ティック以内にあるHFTの注文数量の時間平均}}{\text{最良気配から5ティック以内にある全注文数量の時間平均}}$$

$$= \frac{\frac{16 \times 1 + 18 \times 2 + 15 \times 3}{1 + 2 + 3}}{\frac{27 \times 1 + 33 \times 2 + 26 \times 3}{1 + 2 + 3}}$$

$$= 0.57$$

$t=0,1,3$ で売り板の更新が行われた際の時間区間 $[0,6)$ の計算

2. HFT による流動性供給割合

本節では、2023 年 12 月の 1 ヶ月の期間における HFT による流動性供給割合 $R_{j,[t_s,t_e]}$ ¹¹を 1 時間毎に算出し、その推移を確認した。


図表 2 は、左図に日経 225 先物、右図に日経 225mini を対象とする HFT による流動性供給割合を示したものである。日経 225 先物では 0.6~0.9、日経 225mini では 0.6~0.8 で推移していることから、いずれも HFT は一定の流動性を供給していると解釈できる¹²。

¹¹ 時間区間 $[t_s, t_e) \in \{[t_i, t_i + 1 \text{ hour}) \mid t_i \text{ は } 8:00 \sim 翌5:00 \text{ までの一時間刻み}\}$ における $R_{j,[t_s,t_e]}$ とする。

¹² 日経 225 先物、日経 225mini の双方とも 25 日から 26 日未明にかけて流動性供給割合が減少しているが、この時間帯は欧米市場が休場で取引参加者が限られ、取引が低調だったことが背景にあると考えられる。

図表 2 HFT による流動性供給割合 (2023 年 12 月)

(左図:日経 225 先物 右図:日経 225mini)



3. 最良気配の変化に対する HFT の反応

本節では、最良気配の変化に対する HFT の反応を分析するため、最良気配の変化の方向と HFT の流動性供給割合の変化の関係性を確認した。

具体的には、図表 3 のように最良気配 P_j がある時刻 t に $\Delta P_{j,t}$ 変化したとき、当該時刻に最も近い丸め処理の基準時点 T_i から 200 マイクロ秒間における HFT による流動性供給割合と、その次の 200 マイクロ秒間の HFT による流動性供給割合との差分 $\Delta R_{j,T_i}$ を算出する。これら算出されたデータに基づき、一日毎に「 $\Delta P_{j,T_i}$ の符号に対する $\Delta R_{j,T_i}$ の符号の条件付確率¹³⁾」を求める。


図 4 で示す通り、HFT はスプレッドが拡大する方向に進んだときに流動性の供給を抑制すると仮定する¹⁴⁾。つまり、売り板（買い板）における HFT の流動性供給割合は、最良売り（買い）気配が上昇したときは低下（上昇）し、最良売り（買い）気配が下落したときは上昇（低下）すると想定される。当該仮説を検証するため、最良売り（買い）気配が上昇または下落したときの、売り板（買い

¹³⁾ 売買それぞれにおいて、最良気配が上昇した場合の HFT による流動性供給割合が上昇するか低下するか、最良気配が下落した場合の HFT による流動性供給割合が上昇するか低下するかを数え、条件付確率で求めた。ただし、最良気配と流動性供給割合の板 (j) が同じ場合のみ対象とした。

¹⁴⁾ Avellaneda and Stoikov[2008]は自身らのモデルにて、HFT は在庫を抱えると、その在庫リスクを削減するために、流動性供給における指値位置をずらして、約定確率をコントロールすると主張している。例えば買いポジションの在庫が溜まっている場合、買い板の指値価格を下げることで買い指値注文の約定確率を低下させることにより在庫を増えないようにし、売り板の指値価格を下げることで売り指値の約定確率を上昇させて在庫を処分しようとするとして仮定している。


板)における HFT の流動性供給割合の動向(流動性供給割合が低下あるいは上昇いずれの確率が高いか)を調査した。

図表 3 本節における $\Delta R_{j,T_i}$ の算出方法




図表 4 価格変化に対する流動性供給変化の例

【売り板の最良気配が上昇する変化】



【売り板の最良気配が下落する変化】



結果をまとめたものが図表 5 であり、図表 6 は日経 225 先物、図表 7 は日経 225mini の結果である¹⁵。

日経 225 先物と日経 225mini 双方において、最良気配上昇時の売り板や最良気配下落時の買い板では HFT による流動性供給割合は低下する確率が高かった（図表 5 の青地部分）。この結果は、前述の想定と概ね整合的である。

一方で、最良気配上昇時の買い板や最良気配下落時の売り板では、日経 225 先物では、12 月限月取引終了日直後の二営業日以外は HFT による流動性供給割合の増減に顕著な傾向は見られなかったが、日経 225mini では、12 月限月取引終了日の翌日以降は HFT による流動性供給割合が上昇する確率が高かった（図表 5 の白地部分）。この結果は、一部を除き前述の想定とは違う結果を示した。これは、日経 225 先物の呼値¹⁶（10 円）が日経 225mini（5 円）の呼値より大きいことや、一般に日経 225 先物の方が日経 225mini より機関投資家の割合が多く、個人投資家の割合が少ないこと等が背景にあると考えられる。

また、下記の結果とは別に、HFT の反応速度を調べるために図表 3 における τ を 50 マイクロ秒から 400 マイクロ秒の間で変更しながら計算を行ったところ（ τ の設定については BOX 1 を参照）、興味深い示唆が得られた。例えば日経 225mini の最良気配下落時の売り板のようにスプレッドが狭まる変化に対しては、HFT は即座に反応し、流動性供給割合を上昇させる動きが見られた。一方、日経 225mini の最良気配下降時の買い板のようにスプレッドが広がる変化に対しては、狭まる変化の時ほど早く反応せずに、比較的時間をかけて HFT による流動性供給割合が低下する結果が示された。この要因として、HFT はスプレッドが広がる変化に対しては次の注文行動決定までに比較的長い計算を行うアルゴリズムを有している可能性や、HFT 以外の注文が間に入り、それに反応するため注文行動が遅れるといった可能性が考えられるが、今後の研究課題である。


¹⁵ ただし、HFT による流動性供給割合が変化しなかった場合に関してはプロットしていない。

¹⁶ 売買可能な価格の刻み幅のこと。


図表 5 結果まとめ

	日経225先物		日経225mini	
	売り板	買い板	売り板	買い板
最良気配 上昇時	HFTによる流動性供給割合の低下確率が優勢	12月限月取引終了日直後の二営業日はHFTによる流動性供給割合の上昇確率が優勢だが、それ以外はほぼ変わらず	HFTによる流動性供給割合の低下確率が優勢	12月限月取引終了日の翌日以降、HFTによる流動性供給割合の上昇確率が優勢
最良気配 下落時	12月限月取引終了日直後の二営業日はHFTによる流動性供給割合の上昇確率が優勢だが、それ以外はほぼ変わらず	HFTによる流動性供給割合の低下確率が優勢	12月限月取引終了日の翌日以降、HFTによる流動性供給割合の上昇確率が優勢	HFTによる流動性供給割合の低下確率が優勢

図表 6 流動性供給割合が上昇する確率及び低下する確率の推移（日経 225 先物）



図表 7 流動性供給割合が上昇する確率及び低下する確率の推移（日経 225mini）




BOX 1: 注文明細データに対する注文処理レイテンシ¹⁷


注文明細データのタイムスタンプはデータ処理層到達時に記録されるものであり、市場参加者の注文の発注時刻や大阪取引所の売買システムの玄関口たるゲートウェイ到達時刻ではないことに注意する必要がある。これは、ゲートウェイでの処理を挟むことから、注文がほぼ同時に売買システムに到着した場合、到達順序は担保されるがその間隔は担保されないことを意味する。また、大阪取引所の売買システムの注文処理レイテンシ（50%タイル）¹⁸は40マイクロ秒となっている。これはとある注文処理の結果（板情報の更新）を確認し、それを反映してHFT業者が行う次の注文にタイムスタンプが付されるまでには少なくとも40マイクロ秒程度は経っていることを示す。このことから、第3節における τ は最良価格を変化させた注文の結果を確認し、それを反映した注文を観測する必要があることから、少なくとも40マイクロ秒は必要であると考えられる。

図表8 注文処理の概要と注文処理レイテンシ

【取引システム概要】



【注文処理タイムライン】



¹⁷ 注文取引を受信してから板登録が完了しその応答を返すまでの内部処理時間を計測したもの。

¹⁸ <https://www.jpx.co.jp/systems/derivatives-trading/01.html>

III. HFT が市場変動の大きさに与える影響の分析

第 I 章で記載したとおり、HFT の高速性が市場変動を増大させ、相場を攪乱する要因となっているのではないか等の懸念が指摘されていることから、本章では HFT による注文行動と市場変動の大きさとの関係性に着目した分析を行う。

1. 分析の概要

HFT の注文行動の特徴は、新規注文以外にも変更・取消注文も高速かつ大量に行っていることである。そのため、HFT が市場に与えている影響を評価するためには、実際に約定した価格等の情報だけでなく、新規・変更・取消、それぞれの注文行動が市場に与えている影響も考慮のうえ評価する必要がある。

そこで、今回の分析においては新規・変更・取消、それぞれの注文行動の連なりが市場を変動させていると仮定したうえでモデルを構築し、当該モデルにより約定状況を予測することによって HFT が市場変動の大きさに与えている影響の評価を試みた。

なお、それぞれの注文が市場に与える影響は、市場の状況によって異なり、非常に複雑な関係にあることが想定されるため、変数同士の複雑な関係性を表現できるモデルであるニューラルネットワーク¹⁹を分析に利用した。

具体的には、日経 225mini（中心限月）の 2023 年 12 月の注文データ（日中立合）を対象に、当該期間中のザラバ²⁰における注文行動の順序関係と、市場変動の大きさの関係性をニューラルネットワークでモデル化する。次に、当該モデルで全注文データを入力した場合と、HFT に係る注文データを除去したデータを入力した場合とで、市場変動の大きさの予測値の分布がどのように変わるか比較することにより、HFT が市場変動の大きさに与えている影響についての評価を行った。

2. 分析方法

まず、注文データから「直前に市場に到着した注文の種類 $CurrentOrder_{j,k,l}$ 」で条件付けした次の注

¹⁹ 人の脳内にある神経細胞であるニューロンを模した構造を有する、機械学習のモデルの一種。変数間の複雑な非線形の関係性を学習することができる。

²⁰ 寄り付きから引けまでの間の取引時間。本章においては、板寄せの時間を分析対象外としている。

文種類 $NextOrder_{j,k,l}$ の発生確率^{21,22}」(例えば、新規で買いのメイク注文²³が市場に到着した場合に次に新規での売りのメイク注文が到着する確率)を以下のように定義した。

$$\left\{ P(NextOrder_{jkl} | CurrentOrder_{jkl})_{[t_s, t_{s+1})} \mid j \in \{buy, sell\}, k \in \{Enter, Amend, Delete\}, l \in \{take, make\} \right\}$$

これを1分間隔で設定した各区間 $[t_s, t_{s+1})$ について、添え字 j, k, l についてすべての注文の組み合わせを計算し、行列化²⁴する。

次に、当該行列を特徴量とし、当該1分間の約定価格のエントロピーを目的変数とするニューラルネットワークを学習する²⁵。ここで、約定価格のエントロピーとは、市場変動の大きさを表現する指標²⁶として、以下のとおり定義する。なお、 $P(ContractPrice_i)_{[t_s, t_{s+1})}$ は区間 $[t_s, t_{s+1})$ (ここでは1分間)において、価格 $ContractPrice_i$ で約定した確率であり、文字 $D_{[t_s, t_{s+1})}$ は区間 $[t_s, t_{s+1})$ 中に約定があった価格 $ContractPrice_i$ を識別するインデックス i の集合である。

$ContractPriceEntropy_{[t_s, t_{s+1})}$:

$$= - \sum_{i \in D_{[t_s, t_{s+1})}} P(ContractPrice_i)_{[t_s, t_{s+1})} \times \log_2 P(ContractPrice_i)_{[t_s, t_{s+1})}$$

約定価格のエントロピーは、集計期間中の約定価格の散らばりを評価する指標であり、様々な価格で約定している(つまり、市場に動きがある)場合は、約定価格のエントロピーは高くなり、同じ

²¹ つまり、ある1分間において、直前にある種類の注文が来ていた時に、次にくる注文の種類別の確率をそれぞれ計算した値。例えば、直前の注文が新規での買いのメイク注文である場合、直後に来る注文が新規での売りのメイク注文である確率は $x\%$ 、といった確率を、それぞれの組み合わせ及び全ての1分間について計算した。

²² ただし、FAK(一部約定後に未執行数量が残る場合には、当該残数量を失効させる条件)・FOK(全数量が直ちに約定しない場合には、当該全数量を失効させる条件)注文の失効は板や約定記録に影響を与えず、さらに他市場参加者から観測もできないことから影響は軽微と判断し、FAK・FOK注文は約定した注文のみを集計した。

²³ 成行又は即時約定価格での指値により、板にある買い指値に売り向かう(又は売り指値に買い向かう)注文をメイク注文、即時約定しない価格での指値注文をメイク注文とした。


²⁴ 全ての注文データを時系列で並べた場合、例えば、新規での買いのメイク注文、新規での売りのメイク注文、買い注文の取消、等の形で注文行動の列ができる。注文は、売りか買いか、新規か変更か取消か、新規・変更についてはメイクかメイクか、の計10種類($2 \times 2 \times 2 + 2 \times 1 \times 1$)ある。本分析では、このように時系列で注文を並べた場合、特定の注文の次にはどの種類の注文が来るのか、に注目しており、「直前に市場に到着した注文の種類 $CurrentOrder_{j,k,l}$ 」10種類でそれぞれ条件付けた「次の注文種類 $NextOrder_{j,k,l}$ 」10種類の発生確率、つまり 10×10 の行列を計算し、特徴量とした。

²⁵ なお、8割を学習データとし、2割を検証データとして利用。3層のニューラルネットワークを設定し、中間層のノード数は252、optimizerはAdamとし、学習率は0.0001、エポック数は50、バッチサイズは50、損失関数はMeanSquaredErrorで学習を行った。

²⁶ 高頻度金融データにおいてボラティリティの推定を行う場合、注文データのタイムスタンプが不規則な間隔で並んでいることや、最良売り気配と最良買い気配両方の側で約定することで両者のスプレッドがノイズとなること等から、標準的な方法では有効なボラティリティの推定値がうまく得られないことが知られている。そのため、本分析ではボラティリティの代替指標として、情報理論等で不確かさ(乱雑さ)を表す量として定義されるエントロピーという概念を約定価格の散らばりを表す指標として応用した「約定価格のエントロピー」を定義して分析を行った。エントロピーの金融市場モデリングへの応用については、Marcos López de Prado."Advances in Financial Machine Learning" John Wiley & Sons, Inc. (2018) (マルコス・ロペス・デ・ブラド、長尾慎太郎・鹿子木亨紀(監訳)、大和アセットマネジメント(訳)『ファイナンス機械学習』金融財政事情研究会,2019)参照。

金額ばかりで約定している（つまり、市場の動きが乏しい）場合は、約定価格のエントロピーは低くなる。下限は0であり、集計期間中、平均 1.34、分散 0.51 であった。

このように学習したニューラルネットワークのモデルを用いることで、特定の注文確率行列に対する約定価格のエントロピーの予測値を求めることができる。そして、全注文データで計算した注文確率行列と、HFT による注文データを除去したデータで計算し直した注文確率行列²⁷について、各々を用いて推定した約定価格のエントロピーの予測値の分布を比較することで、HFT が市場変動の大きさに与えている影響を分析する（図表 9）。



3. 推計結果

図表 10 は、上記にて設定したモデルの検証用データに対する約定価格のエントロピーの予測値と原データをプロットした図である。予測値と原データとの間には一定の比例関係が見られ、学習したニューラルネットワークのモデルは今回のタスクに対して一定の予測力があると評価できる（検証データに対して、相関係数 0.77²⁸）。

図表 11 は、全データをモデルに入力した場合の約定価格のエントロピーの予測値と、原データの分布をプロットしたものである。データの特性上多峰に分布している²⁹等、やや分布に異なる特徴が


²⁷ 注文データから HFT による注文データを全て除去し、非 HFT による注文データのみで、本文中定義した「直前に市場に到着した注文の種類 $CurrentOrder_{j,k,l}$ で条件付けした次の注文種類 $NextOrder_{j,k,l}$ の発生確率」を同様の手順で再計算した。

²⁸ また、平均二乗誤差 (MSE) は 0.225。


²⁹ 約定価格がティックの間隔に沿って分布しているというデータの性質上、当該データから計算される約定価格のエントロピーは、特定の値の周辺に分布が偏りやすい性質を持つため。

あるものの、今回の目的は入力データを差替えた際のモデルの予測値の分布の変化を評価することであることに鑑みると、十分に分布の特徴を捉えていると評価できる。

図表 10 検証データに対する約定価格のエントロピーの予測値（縦軸）と原データ（横軸）の比較



図表 11 全データに対する約定価格のエントロピーの予測値と原データの分布の比較




図表 12 は、全注文データから求めた約定価格のエントロピーの予測値と、HFT による注文を除去したデータから求めた約定価格のエントロピーの予測値の分布をプロットしたものである。それぞれの分布を比較すると、HFT による注文を除去したデータから求めた分布の方が、約定価格のエントロピーの予測値が高い方向（すなわち、市場の変動を大きくする方向）へ遷移しており、全体としては HFT が市場に流動性を供給することで、急激な市場変動を抑制していると示唆される。

図表 13 は、同様の手法で、HFT による注文データを戦略³⁰ごとに除去した場合の約定価格のエントロピーの予測値の分布を示したものである。マーケットメイク戦略を除去したデータを入力した場合では、約定価格のエントロピーの予測値の分布が高い方向へ遷移している一方、その他の戦略を除去した場合は、約定価格のエントロピーの予測値の分布が低い方に遷移していることが分かる。すなわち、マーケットメイク戦略は市場の変動を抑制する方向に寄与する傾向がある一方、その他の戦略は市場の変動を大きくする方向に寄与する傾向があると示唆される。


ただし、今回の分析は、①HFT による注文が存在しない場合も、その他の投資家は HFT による注文が存在する場合と同じように行動する、②HFT による注文データを除去したデータを入力した場合も、全データで学習したニューラルネットワークのモデルが有効な推定を行う、という二つの仮定に基づくものであり、解釈の際には留意が必要である。

³⁰ 高速取引行為者向けの監督指針Ⅲ－３－１－１（２）①に記載された、マーケットメイク戦略、アービトラージ戦略、ディレクショナル戦略、その他の戦略の４つ。

図表 12 全データを入力した場合と HFT による注文データを除去した場合の
約定価格のエントロピーの予測値の分布の比較



図表 13 全データを入力した場合と HFT による注文データを戦略ごとに除去した場合の
約定価格のエントロピーの予測値の分布の比較




BOX 2: 2023 年 12 月における直近限月のデータを用いた分析


本章では 2023 年 12 月の日経 225mini について中心限月のデータを用いて分析を行ったが、直近限月のデータを対象に、本章と同様の分析手法を適用した結果が以下の図表 14、15 である。2023 年 12 月 8 日以降の分析対象が、中心限月である 2024 年 3 月限ではなく直近限月である 2024 年 1 月限となっている点で異なる。なお、一般的に、直近限月よりも中心限月の方が活発に取引される傾向があり、2024 年 1 月限は 2024 年 3 月限に比べて取引高が少ない。

図表 14 で、HFT による注文データを除去したデータから求めた約定価格のエントロピーの予測値の分布を確認すると、全データを入力した場合に比べて、分布の峰が潰れ、左右の裾部分が厚くなっている。この結果から、取引高が少ない市場においては、HFT が市場変動の大きさの分散を低下させている可能性が示唆された。なお、HFT による注文データを戦略ごとに除去した場合の予測値の分布の傾向（図表 15）は、本文中の中心限月のデータを対象として分析した場合と同様である。

図表 14 全データを入力した場合と HFT による注文データを除去した場合の約定価格のエントロピーの予測値の分布の比較



図表 15 全データを入力した場合と HFT による注文データを戦略ごとに除去した場合の
約定価格のエントロピーの予測値の分布の比較



IV. 総括

本稿では、大阪取引所より提供を受けた 2023 年 12 月の 1 ヶ月分の先物取引の注文データを用いて、HFT が市場の流動性及び市場変動の大きさに与える影響について、詳細な分析を試みた。

HFT が市場流動性に与える影響の分析では、時期や最良気配の変化によって HFT の取引行動の変化はあるものの、今回の分析の範囲では、取消注文も考慮したうえで総じて一定の流動性を供給していることが確認された。HFT が市場変動の大きさに与える影響の分析では、取引戦略の違いにより、HFT が市場変動を拡大する方向に寄与する場合もあるが、全体としては、HFT が市場変動を抑制する方向に寄与する取引を行っている可能性が示唆された。

一方、今回の分析は 2023 年 12 月という特定期間の HFT の動向を分析したものであることには留意が必要である。HFT が市場に与える影響は時期や市場の状況等により異なる可能性があり、様々な方向から検証を続ける必要がある。例えば、ボラティリティの高い相場や最終取引日含むイベント通過時等の HFT の動向は、HFT の平均的な動向とは異なりうるほか、HFT 業者はアルゴリズムを常に改善・変更し続けていると考えられるため、分析対象とする期間³¹や商品を変えた分析も有効である。

引き続き、分析手法の改善や分析対象の拡大等を通じて、HFT の取引行動が市場に与える影響について実態把握を進めていく。

³¹ 例えば、12 月の後半にかけては休暇に入る市場参加者も多いと言われており、そうした季節要因が今回の分析結果に影響を与えている可能性もある。