

〈自由論文〉

COVID-19 収束後の日米株価指数の変動の検証

—ベイジアンモデルと AI シミュレーションを用いた株価指数の実証分析—

A Verification of Japanese and U.S. Stock Index Fluctuations after the Convergence of COVID-19 Pandemic

- An Empirical Analysis of Stock Index Using Bayesian Model and AI Simulation -

小林 稔

Minoru Kobayashi

[Abstract]

In the 1980s, Japan was praised as “Japan as number one” and was the focus of the world’s attention. The economy was expanding steadily, dominating the world market share in the high-tech products of the time: TVs, VTRs, cameras, automobiles, and semiconductors. However, Japan’s export expansion led to trade friction with advanced economies, and the Plaza Accord of 1985 attempted to curb Japan’s export expansion by inducing the dollar-yen exchange rate to appreciate against the yen. The curtailment of exports by the strong yen led to a recession in Japan, and the economy temporarily stagnated. However, in 1986, the Bank of Japan lowered the official discount rate and changed course to an easy monetary policy. Banks and other financial institutions aggressively expanded loans to corporations and individuals. As a result, there was a money glut in the market, and consumers continued to prefer expensive products, an unusual situation. On December 29, 1989, the Nikkei Stock Average hit an all-time high of 38,915 yen, marking the peak of the so-called bubble economy. In 1990, the Bank of Japan raised the official discount rate and shifted to a tight monetary policy. The bubble economy collapsed, and land prices and stock prices fell sharply. Banks and other financial institutions, concerned about non-performing loans, began to recover their funds at an early stage. The Japanese economy experienced an exhausting and then nearly three decades of stagnation. The Nikkei Stock Average continued to decline, falling to 7,607 yen in April 2003. It then recovered to 18,261 yen in July 2007, but the Lehman shock in September 2008 brought it to 6,994 yen on October 28, 2008, its lowest level since the burst of the bubble economy. After a long period of stagnation, the Japanese economy gradually began to recover from 2013 onward with the shift to bold monetary easing policies under the Abenomics policy. But, the economy was unable to break free from deflation. Furthermore, entering 2020, the economy fell again due to the global pandemic of the new coronavirus. However, by the beginning of 2023, the pandemic of the new coronavirus had subsided and the domestic economy gradually began to recover, raising hopes for a revival of the Japanese economy. The Nikkei Stock Average has continued to rise since late 2023, reaching an all-time high of 40,109 yen on March 3, 2024. In this paper, I have analyzed the trend of the stock market, which has been going through twists and turns and reached its highest level in 34 years, from the perspectives of corporate performance, interest rates, and inflation using a state-space model. I also attempted to predict

future stock prices using artificial intelligence (AI). Based on the results, we discussed the challenges of the current Japanese economy and the prospects for the stock market.

【キーワード】

COVID-19, 株式市場, 為替レート, 株価予測, MCMC, AI, 人工知能, ベイズ

1. はじめに

1.1. COVID-19 収束後の株価指数の変動

今から40年前の1980年代に、日本は「Japan as number one」と賞賛され、世界の注目を集めていた。当時のハイテク製品であったテレビ、VTR、カメラ、自動車、半導体で世界のシェアを席巻して経済は順調に拡大していた。1988年には、実質GDPの成長率が前年比6%を上回り、またドル建ての名目GDPは、米国の約60%の水準を維持して、当時の中国の名目GDPの約12倍の規模であった。米国への日本車やハイテク製品の輸出の増加は、米国における対日貿易赤字を拡大させ、日米貿易摩擦に発展し、デトロイトで労働者が日本車を破壊する象徴的な映像がニュースで放送されるなど日米間の深刻な問題となっていた。

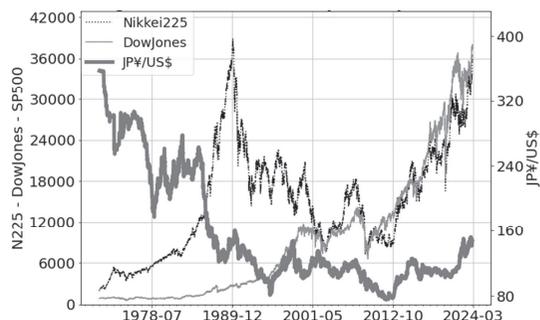
1985年9月に先進5カ国の財務大臣・中央銀行総裁による会議が米国ニューヨーク市のプラザホテルで開催され、日本の対米貿易黒字の削減に関して、いわゆるプラザ合意がなされた。プラザ合意では、ドル円為替レートを円高へ誘導して、日本の輸出拡大を抑制することを目論んだ。日本は、輸出主導の経済運営から内需主導の経済運営への移行を余儀なくされた。プラザ合意の発表翌日の9月23日には、24時間で、ドル円為替レートは1ドル235円から約20円円高へ移行し、1年後の1986年には150円台で取引されるようになった (Fig.1.1.)。

日本では、円高による輸出の抑制によって円高不況が懸念されるようになり一時的に経済は停滞することになったが、1986年に入ると日本銀行は公定歩合を引き下げて金融緩和政策に舵取りを

変更した。公定歩合の引き下げによって名目金利は低下し、銀行など金融機関は積極的に企業や個人へ融資を拡大させた。その結果、市中ではカネ余りの状態となり、消費者は高額の商品を好んで購入するという異常な事態が続き、多くの企業が本業から財務テクノロジーにのめり込み、土地の売買価格だけではなく株価も異常な上昇を続けた。1989年12月29日には、日経平均株価が3万8915円と史上最高値を付け、いわゆるバブル経済のピークとなった (Fig.1.1.)。

1990年に入ると、日本銀行が公定歩合を引き上げ金融引き締め政策へ移行したことによって、バブル経済は崩壊し、土地の売買価格、株価は大幅に下落し、積極的に融資を拡大させてきた銀行などの金融機関は、不良債権を懸念して貸し剥がしによって早期の資金回収を図った。日本経済は、萎縮するとともに疲弊し、その後の約30年にわたる低迷を経験してきたのである。不良債権による負の連鎖は、その後、金融危機に発展し、1997年11月には、北海道拓殖銀行や日本で第4位の証券会社であった山一証券が破綻し、さらに

Fig.1.1. Nikkei225-Dowjones-US\$/JP¥



(注) Japanese Yen to U.S. Dollar Spot Exchange Rate, Board of Governors of the Federal Reserve System (US), Dow Jones Averages, "S&P Dow Jones Indices LLC", 日本経済新聞社の日足、終値データより作成。

1998 年秋には、日本長期信用銀行や日本債券信用銀行が破綻した。

日経平均株価は下落を続け、2003 年 4 月には、7607 円まで下落した。その後、2007 年 7 月には 1 万 8261 円まで回復したものの 2008 年 9 月のリーマンショックによって 2008 年 10 月 28 日には 6994 円のバブル崩壊後最安値をつけた (Fig.1.1.)。

長期の低迷を続けていた日本経済は、2013 年以降、アベノミクス政策により、大胆な金融緩和政策へ移行し徐々に回復へと向かっていたが、依然としてデフレ経済から脱却できず、さらに 2020 年に入ると新型コロナウイルスの世界的なパンデミックによって再び経済は落ち込んでいった。新型コロナウイルスのパンデミックに直面した世界各国は多様な経済支援策を発動して市中への資金供給を拡大させ、マネタリーベースは大幅に拡大した。また、2022 年 2 月に端を発したロシアによるウクライナ侵攻によって、エネルギーや食料を中心に商品市況が上昇し世界的なインフレ傾向がみられるようになった。しかし、2023 年に入ると新型コロナウイルスのパンデミックは収束し、経済は徐々に回復へ向かい、日本経済の復活への期待が高まってきた。

2023 年後半から日経平均株価は、急速に上昇を続け、2024 年 2 月 22 日には 1989 年 12 月 29 日につけた 3 万 8915 円を上回り 3 万 9098 円と 34 年ぶりに史上最高値を更新した (Fig.1.1.)。

本稿では、紆余曲折を経て 34 年ぶりの高値をつけている株式市場の動向を状態空間モデルを用いて企業業績、金利およびインフレといった視点から分析するとともに、AI (人工知能) を用いて今後の株価の予測を試みる。またその結果から、現在の日本経済の課題や株式市場の展望について考究していく。

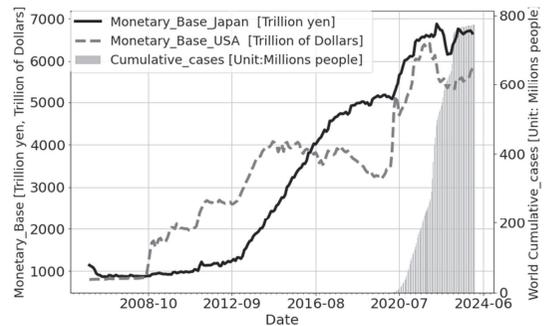
2. 株価指数の上昇の背景

2.1. マネタリーベースの急拡大

世界の社会経済活動は、COVID-19 のパンデミックによって 2020 年初頭から 2022 年にかけて

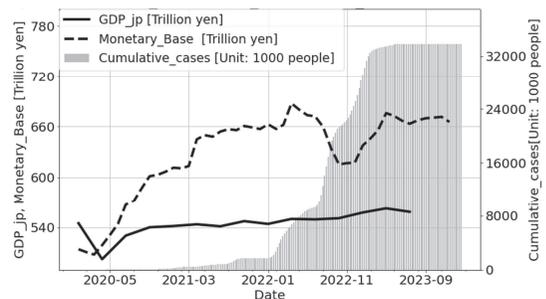
長期の低迷を続けていた。しかし、2023 年に入るとパンデミックは沈静化へ向かい、わが国では同年 5 月に COVID-19 を季節性インフルエンザと同じ第 5 類感染症に位置付けた。社会経済活動は徐々に日常へと戻りつつある。パンデミックの初期は、感染防止のため世界的に人流が抑制され社会経済活動は低迷を余儀なくされた。世界の各国は、各種の補助金や助成金などの給付金の支給や金融緩和策を押し進めて経済活動を下支えしてきた。その結果、経済活動は下支えされたが、一方で過剰ともいえる資金供給が継続されてきた¹⁾ (Fig.2.1.)。

Fig.2.1. World COVID-19_Cumulative_cases-Monetary_Base



(注) Japanese Yen to U.S. Dollar Spot Exchange Rate, Monetary Base H.6 Money Stock Measures, Source: Board of Governors of the Federal Reserve System (US), 日本のマネタリーベースは、日本銀行、独自のプログラムで作成。

Fig.2.2. COVID-19_Cumulative_cases-Real_GDP-Monetary_Base



(注) 日本の新規感染者数と実質 GDP, マネタリーベースの推移。単位：千人 “WHO-COVID-19-global-data”, 実質 GDP は内閣府経済社会総合研究所, 国民経済計算, 国内総生産, 季節調整系列, マネタリーベースは、日本銀行、独自のプログラムで作成。

わが国も例外ではなく、政府、日銀による大規模な金融緩和策や特別定額給付金、新型コロナウイルス感染症対応休業支援金・給付金、雇用調整助成金など多様な支援政策が進められ、資金供給の指標となるマネタリーベースは急拡大した。その結果、Fig.2.2. に示すように国内 GDP は2020年第三四半期以降、緩やかに回復傾向を示している。米国も同様の状況にあり、COVID-19のパンデミック初期には、経済が一時的に低迷したものの現金給付など潤沢な資金供給によりマネタリーベースは急拡大し、2020年第三四半期以降、経済は回復基調を継続してきた。このようにCOVID-19に対する感染対策を進める一方で、市場への潤沢な資金供給が行われマネタリーベースは急速に拡大した。

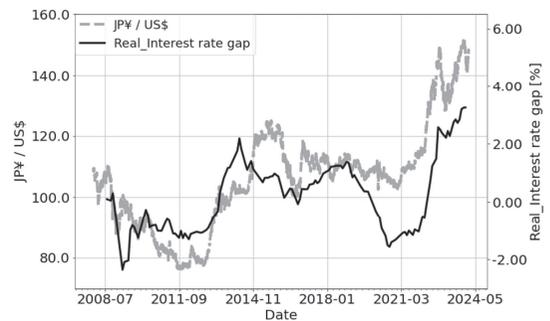
2.2. 日米の金融政策

日本の金融政策は、COVID-19のパンデミック以前から日本銀行が2%の「物価安定の目標」の達成に向けて金融緩和策を継続してきた。一方、米国は、2021年後半から経済の回復が進み、消費者物価指数（以下ではCPI）が急上昇したことによって、インフレーションへの警戒感が強まっていった。2022年5月には、連邦準備理事会（Federal Reserve Board: 以下ではFRB）²⁾ は、フェデラルファンドレート（Federal Funds Rate, 以下ではFFレート）³⁾ を0.5ポイント引き上げ、金融緩和から金融引き締めめに姿勢を転じた。さらに、FOMC（Federal Open Market Committee: 連邦公開市場委員会）⁴⁾ は、2023年7月までにFFレートを5.25～5.50%と22年ぶりの高水準にまで引き上げた。

一方、日本では、2024年1月1日に能登半島で発生した「令和6年能登半島地震」の復興を最優先とするため、2024年1月に開催された日本銀行の金融政策決定会合では、長期金利は1%を超えても一定の水準までは容認するとしているが、基本的には短期金利をマイナスにし、長期金利をゼロ%程度に抑えるこれまでの大規模な金融緩和策の維持を決定している。

Fig.2.3. に日米の実質金利差の推移を示す⁵⁾。

Fig.2.3. Interest rate gap & JP¥/US\$



(注) 実質金利は、浜町 SCI が公表している物価連動国債⁶⁾ 7年ものの利回り、米国の債券利回りは、Board of Governors of the Federal Reserve System (US)、ドル/円為替レートは日本銀行のデータを使用して作成した。

Fig.2.3. から金融緩和を継続する日本と米国の実質金利差は拡大傾向が鮮明となっている。

2022年2月以降、ロシアのウクライナ侵攻を契機としたドル/円為替レートの急速な円安は、日米の金融政策の逆転によって金利差が拡大し、さらに拍車がかかっている。Fig.2.3. に示すようにドル円為替レートは、2022年10月には一時1ドル150円を上回る急速な円安となり、その後一旦は1ドル130円台まで円高方向へ戻したものの、2023年後半以降は1ドル140円台後半の円安水準で推移している。

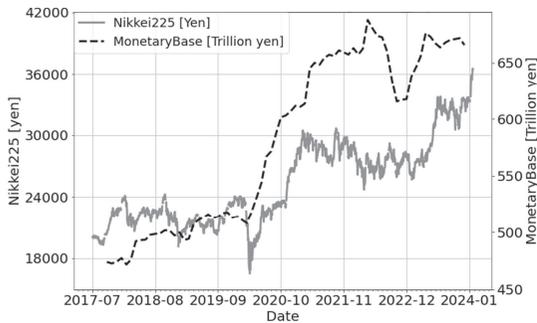
2.3. 株式市場は史上最高値を更新

株式市場に目を転ずると、日経平均株価は、COVID-19の感染初期は1万6000円台まで急落したが、潤沢な資金供給を背景に、2021年第二四半期には一時的にバブル経済崩壊後の最高値をつけて3万円を上回った（Fig.2.4.）。

Fig.2.5. に示すように、米国の株式市場においてもダウ平均株価が3万6000ドルを超えて史上最高値をつけるなど過熱感が高まっていった。しかし、2021年後半になると米国ではインフレーションへの懸念が台頭し、さらに2022年5月以降はFRBが金融引き締め策へ転換したことによって調整局面へ入り、ダウ平均株価は、一時的に2万9000ドルを割り込んだ（Fig.2.5.）。

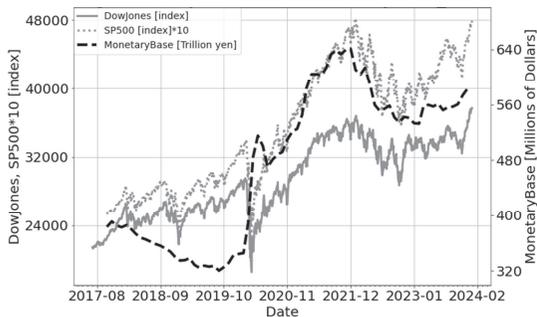
日本の株式市場も、米国の株式市場の調整やロシアのウクライナ侵攻を契機とした急速な円安な

Fig.2.4. Nikkei225-MonetaryBase_japan



(注) 日経 225 は日本経済新聞社の日足、終値、マネタリーベースは日本銀行、独自のプログラムで集計して作成。

Fig.2.5. Dowjones-SP500-MonetaryBase_USA



(注) Monetary Base H.6 Money Stock Measures, Board of Governors of the Federal Reserve System (US), S&P500, Dow Jones Averages, "S&P Dow Jones Indices LLC", 独自のプログラムで作成。

ど世界的な金融市場の混乱の影響を受けて、2022年3月には2万5000円を割り込んでいる (Fig.2.4)。

しかし、2023年に入ると COVID-19 のパンデミックが収束し社会経済活動が日常へと戻る過程で、米国の株式市場は、金利高にもかかわらず、今後も好調な経済が継続することを期待して上昇に転じ、2024年1月22日にはダウ平均株価は3万8000ドル、S&P500指数は4868と史上最高値を更新した (Fig.2.5)。

日本でも、米国が金融引き締め策へと転換した2022年5月以降も金融緩和策を継続してきたこと、さらに2023年に入ると COVID-19 のパンデミックが収束し、経済復活への期待が急速に高まり、2024年2月22日には日経平均株価が3万9098円と34年ぶりに史上最高値を更新した (Fig.2.4)。

以上のように、2024年2月時点で、日米の株式市場は金融政策の逆転があるものの、ともに活況を呈している。

2.4. マネタリーベースと株価指数の相関

ここでは、マネタリーベースと株価指数の相関について考察する (Fig.2.4. ~ Fig.2.5)。まず、マネタリーベースの推移を2008年のリーマンショックの前後で比較してみる。

日本の場合、データが取得できた1970年から2008年までのマネタリーベースの増加率は年率換算で8.06%であるのに対して、2008年から2023年までの増加率は年率13.26%であり、2008年以降のマネタリーベースの増加率が高くなっている (Table.2.1)。第2次安倍晋三内閣によるいわゆるアベノミクスによって大胆な金融緩和が始まった2013年から2023年の増加率は15.1%と、さらに高くなっている。

米国では、1959年から2008年までは年率6.26%であるが、2008年から2023年は12.19%と、やはり2008年以降はマネタリーベースが拡大した (Table.2.1)。

さらに、COVID-19 のパンデミックに対する経済政策として各種の経済支援策を実施した2020年から2021年のマネタリーベースの増加率は、日本が15.9%、米国は31.15%であり、市場への資金供給は急増した (Table.2.1)。

一方、1959年から2008年までの米国の名目GDPの成長率は年率換算で7.06%と、同期間のマネタリーベースの増加率6.29%とほぼ同じ水準であり、実体経済の拡大に合わせてマネタリーベースが増加してきたことが確認できる。しかし、2008年から2023年では、米国の名目GDPの年平均成長率が4.19%なのに対して、マネタリーベースの年平均増加率は12.19%であるから、2008年以降はマネタリーベースが実体経済とはかけ離れて増加してきたことが分かる。

Table.2.2. から、米国のマネタリーベースと名目GDPの相関係数は、1994年から2008年のリーマンショックまでは0.99であり、GDPとマネタリーベースとの相関は極めて高いが、リーマン

Table.2.1. Monetary Base and Nominal GDP Growth Rate

Period	Monetary Base Growth Rate (Annual Rate %)		Nominal GDP Growth Rate (Annual Rate %)	
	Japan	USA	Japan	USA
1959～2008年	-	6.26	-	7.06
1970～2008年	8.06	6.92	-	7.14
1970～2013年	8.62	9.08	-	6.62
1994～2008年	5.47	6.45	0.23	5.18
1994～2013年	7.39	11.49	-0.001	4.52
2008～2013年	12.95	26.92	-0.72	2.71
2008～2023年	13.26	12.19	0.75	4.19
2013～2023年	15.06	5.48	1.49	4.95
2020～2021年	15.90	31.15	2.46	10.65

(注) Monetary Base H.6 Money Stock Measures, Board of Governors of the Federal Reserve System (US), U.S. Bureau of Economic Analysis, Gross Domestic Product, 日本のマネタリーベースは日本銀行, 名目 GDP は内閣府経済社会総合研究所, 国内総生産, 季節調整系列より独自のプログラムで作成した。

Table.2.2. Correlation with The Monetary Base

Period	Nominal GDP		Stock Index		
	Japan	USA	N225	Dow	SP500
1994～2008年	0.12	0.99	-0.71	0.84	0.71
2008～2013年	-0.08	0.86	0.47	0.65	0.61
2008～2023年	0.92	0.89	0.97	0.90	0.92
2013～2023年	0.82	0.77	0.93	0.80	0.86
2020～2021年	0.53	0.72	0.92	0.92	0.92

(注) U.S. Bureau of Economic Analysis, Gross Domestic Product, S&P500, Dow Jones Averages, "S&P Dow Jones Indices LLC", 名目 GDP は内閣府経済社会総合研究所, 国内総生産, 季節調整系列, 日経平均株価は日本経済新聞社より独自のプログラムで作成した。

ショック後の2008年から2023年第三四半期までは0.89と低下している。1994年から2008年のマネタリーベースとダウ平均株価, S&P500指数との相関は, それぞれ0.84, 0.71であり, GDPとの相関係数より低かったが, 2008年から2023年では, 0.90, 0.92とGDPより相関係数は高くなっている (Table.2.2.)。さらに, 2020年3月から2021年9月に株価指数が急上昇した期間では, 0.92, 0.92とやはり相関係数は高い (Table.2.2.)。マネタリーベースの拡大が株価を牽引したことを示す結果となっている。

一方, 日本の分析結果については, 評価が難しい。バブル経済崩壊後の1994年から2008年のリーマンショックまでの名目GDP成長率は, 年率換算では0.23%とほぼ横ばいの状態であり, 日本経済は長期にわたり低成長を余儀なくされた。このため同期間のマネタリーベースと名目GDPとの相関係数は0.12と低くなっている (Table.2.2.)。

しかし, 2013年から2023年第三四半期の相関係数は0.82であり, アベノミクスが開始された2013年以降は, マネタリーベースと名目GDPの相関係数が上昇した。日本では大胆な金融緩和策によってマネタリーベースを拡大させてGDPの成長を促した結果, マネタリーベースと名目GDPの相関係数が高まったと考えられる (Table.2.2.)。

一方, 2013年から2023年の名目GDPの成長率が年率で約1.49%であったのに対して, 同期間のマネタリーベースは年率で15.1%拡大しており, 日本も米国と同様に名目GDPの成長率を遥かに上回る資金供給が行われていた。

マネタリーベースと日経平均株価との相関係数は, 1994年から2008年までは, 日経平均株価が大きく下落していた局面であり, マイナス0.71と負値であったが, アベノミクスが導入された2013年から2023年は相関係数が0.93と高く, マネタリーベースと日経平均株価の相関が高まったことを示している (Table.2.2.)。また, COVID-19のパンデミックの混乱によって株価指数が急落した2020年3月から, その後に株価指数が急上昇した2021年9月までのマネタリー

ベースと日経平均株価の相関係数は、やはり 0.92 と高い (Table.2.2.)。

つまり、度重なる経済対策の結果として、マネタリーベースが急増し、その資金の一部が余剰なマネーとなり短期運用や投機マネーとして株式市場や米国の場合は不動産市場へ流入して株価や不動産価格が急騰する、いわゆる資産バブル的な状況が発生したと考えられる。

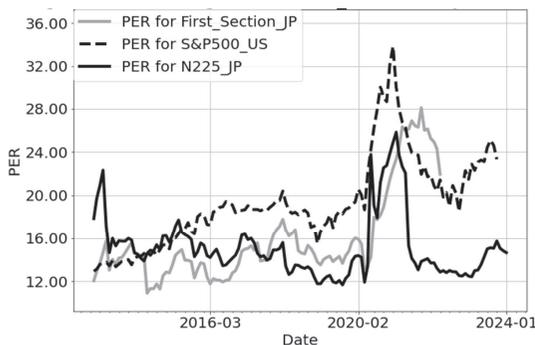
以上のように、マネタリーベースの増加によりその一部の資金は株式市場へ流入して、株価を押し上げる一つの要因となっていることが推測される。

2.5. 株式市場が活況を呈する背景

2024年2月時点で、日米の株式市場は史上最高値を更新する勢いである。まず、日米の株式市場を下支えしているのは、急速に拡大したマネタリーベースにみられるように、市中への潤沢な資金供給により、いわゆるカネ余りが生じていることが指摘できる。もっともマネタリーベースの拡大は、米国では2008年のリーマンショック以降、日本では2013年より始まったアベノミクス以降に一貫してみられる傾向であるが、COVID-19のパンデミックはこの傾向を一層強めることになった。

Fig.2.6. に2013年から2023年12月までのS&P500および日経平均株価、東証第一部上場企

Fig.2.6. Price Earnings Ratio (PER)_N225, FS of JPX, S&P500



(注) S&P500, “S&P Dow Jones Indices LLC”, 東証第一部は日本取引所グループが公表するデータから独自のプログラムで作成。

業 (2022年3月まで) のPER (Price Earnings Ratio)⁷⁾を示す。Fig.2.6. から、S&P500, 日経平均株価, 東証第一部上場企業ともにマネタリーベースが拡大した2013年以降はPERの上昇傾向がみられ、この期間に利益の裏付けのない株価の上昇があったことを確認できる。

また、COVID-19のパンデミックに対する経済対策によってマネタリーベースが拡大し、日米の株価指数が急上昇した2020年後半から2021年にかけてS&P500, 日経平均株価のPERは急上昇しており、この間の株価指数の上昇は利益に裏付けされたものではなかったことが分かる。

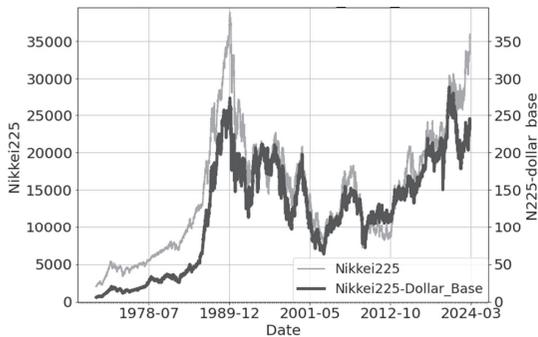
2019年1月からCOVID-19のパンデミック初期である2020年3月までの米国S&P500のPERを計算すると⁸⁾18.46, 同様に日経平均株価は、12.67であったが、2020年4月から日米の株価指数が上昇を続けていた2021年9月までのPERの平均値は、S&P500が26.85, 日経平均株価は19.65と、パンデミックの前後でPERは急上昇している。以上の考察から、2024年2月時点における株式市場の活況は企業業績の拡大だけでなく、その背景には過剰流動性による影響が含まれていると考えられる。

また米国では、金融引き締め策が継続する高金利の中で、引き続き好調な経済が継続するとの期待、さらに金融引き締め策が終盤を迎えて、そろそろ金融緩和策への転換が予想されるなど、楽観的な見方が株式市場を下支えしている。

一方、日本は引き続き大胆な金融緩和策を継続している。加えて、COVID-19のパンデミックが収束し社会経済活動が日常へと戻る過程で、企業業績の回復や賃金上昇が徐々に現実のものとなり、これまでの長期にわたる経済の低迷から脱却することが期待され、株式市場の下支えとなっている。

さらに、日本の株式市場の場合は、外国人投資家の比率が高いことが現在の株価上昇の一因として指摘できる。東京証券取引所などの株式分布状況調査によると、2022年度の日本株の外国人保有比率は30.1%であり3年連続で30%を超えている。

Fig.2.7. Nikkei225-Dollar_Base_N225



(注) Japanese Yen to U.S. Dollar Spot Exchange Rate. Source: Board of Governors of the Federal Reserve System (US), 日本経済新聞社の日足、終値データより独自のプログラムで作成。

Fig.2.7. にドルベースでみた日経平均株価の推移を示す。Fig.2.7. から、ドル円為替レートが、1ドル150円前後で推移している現状で、外国人投資家からみたドルベースの日経平均株価はまだまだ割安であり、外国人投資家による日本株の買い越しが株価上昇の一因として指摘できる。

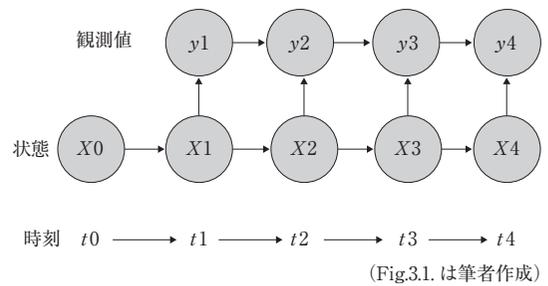
それでは、株価を理論的にみた場合はどうか。例えば、米国では金利高にもかかわらず、株式市場は史上最高値を更新している。金利と株価の関係はどのように理解すれば良いのか。企業業績の改善による株価への影響はどの程度あるのか。また、現在、世界中で懸念されているインフレーションが株価に与える影響はどのようなものであるか。次節以降では、このように株式市場と企業業績、金利、インフレーションとの関係を金融市場のデータを収集し、状態空間モデルにより分析するとともに、AIを用いて今後の株価指数の動きをシミュレートする。

3. 状態空間モデルによる分析

3.1. 状態空間モデルの構築

ここでは、株価指数の変動に対する企業業績、金利、インフレーションの影響を分析するため新たに状態空間モデルを構築する。構築した状態空間モデルの分析結果から、現在の株価指数の上昇に対する企業業績、金利、インフレーションの影

Fig.3.1. 状態空間モデルの概念図



(Fig.3.1. は筆者作成)

響を計測する。つまり、企業業績、金利、インフレーションの変化率が株価指数の上昇率に与える影響を計測し、その結果から2024年2月時点における日米の株式市場の活況の要因を検証する。

状態空間モデルは、時系列で起きる事象の状態を状態方程式で表現する。状態方程式では、現在の状態は、Fig.3.1. に示すように過去の状態に確率的な変動が加わることで表現される。また観測者が実際に観測する値は、各時点における状態に確率的な変動が加わったものである。つまり、観測者が観測するデータには、確率的な変動によって表現されるノイズが加わっているものとして扱い、事象の状態を状態方程式で表現することで、観測誤差と事象の本来の構造を区別して分析を行うことができる。状態空間方程式から得られるパラメータは時変係数であり、時系列データを扱う分析では、時間の経過による構造の変化に対応した分析が可能となる。

従来からの回帰モデルでは、時間の経過による構造変化に対応したパラメータを推定することは困難であるが、状態空間モデルは、ベイズの定理から構造変化に対応した時変係数としてパラメータを推定することが可能である。このため、本稿では時間の経過に対応して事象の構造変化を分析できる状態空間モデルを用いて分析を行う。

3.2. 状態空間モデルの定式化

株価の最も代表的な配当割引モデルでは、(式3.1) に示すように株価は、将来支払われると予想される期待配当を市場金利で現在価値に割り引いて算出する。

$$P_t = \frac{D}{(1+r)} + \frac{D}{(1+r)^2} + \frac{D}{(1+r)^3} + \dots$$

$$+ \frac{D}{(1+r)^n}$$

$$\text{if } n \rightarrow \infty, P_t = \frac{D}{r} \dots (3.1)$$

ここで、 P_t ：現在の株価、 D ：将来の配当額、 r ：市場金利である。

利益 E が一定の割合 g で成長すると仮定した定率成長配当割引モデルでは、(式 3.2) に示すようになる。

$$P_t = \frac{D}{(1+r)} + \frac{D \cdot (1+g)}{(1+r)^2} + \frac{D \cdot (1+g)^2}{(1+r)^3}$$

$$+ \dots + \frac{D \cdot (1+g)^{n-1}}{(1+r)^n}$$

$$\text{if } n \rightarrow \infty, P_t = \frac{D}{r-g} \dots (3.2)$$

このように、配当割引モデルや定率成長配当割引モデルでは、株価はその株式を発行している企業が将来支払うと予想される配当と将来に予想される市場金利によって決定されると考える。つまり、企業が配当を支払うだけの利益を得ていることが前提となっている。したがって、足下における企業の利益が減少している状況においては、将来の利益の拡大を予想することは困難であり株価は下落に転ずることが自然である。もちろん、現状の利益が減少していても将来に利益を拡大する何らかの根拠があれば、株価はその期待によって上昇すると考えられる。

ここで、将来の配当は将来の企業業績を予想することによって推定される。一方、現在価値に割引く際の将来の市場金利は、現在の金利水準を考慮して予想することになる。つまり、将来の配当や金利は、現在の企業業績や金利をベースに経済環境などを勘案して予想することになる。

そのように考えると株価は、現在の企業業績を示す一株当たり利益 (Eps: Earnings Per Share) と現在の金利の関数として表現できる。

本稿では、金利として実質金利を使用する。ここで金利は、実質金利と物価上昇率に分解できるから、一株当たり利益と金利の関数として表現した株価は、一株当たり利益と実質金利およびインフレーションの関数として表せる。

なお、配当割引モデルや定率成長配当割引モデルは、企業業績の結果である配当と金利から株価を説明する一つのモデルであり、株価の変動に影響を与えるその他の多様な要因を含んでいない。ダイナミックに変動する実際の株価を説明する理論としては十分なものではない。実際に、2024年1月の米国の株価指数は、歴史的に相当な金利高にもかかわらず史上最高値を更新するなど、配当割引モデルや定率成長配当割引モデルでは説明が困難である。

本稿では、株価指数に対する一株当たり利益や金利の影響を考察する上で配当割引モデルや定率成長配当割引モデルを参考にしている。しかし、本稿で構築するモデルは、配当割引モデルや定率成長配当割引モデルを踏襲したものではなく、株価指数に対する一株当たり利益、実質金利、インフレーションの影響を分析するために新たに構築したものである。

本稿では、株価指数の変化率を一株当たり利益（以下では利益⁹⁾）の変化率、実質金利（以下では金利）の変化率、インフレーションの変化率と定数項である水準成分で表現するモデルを構築した(式 3.11)。ただし、ここで構築するモデルは状態空間モデルであり、利益の変化率、金利の変化率、インフレーションの変化率の重みである各パラメータは観測する時間とともに変化する時変係数であり、定数項である水準成分も同様に観測する時間とともに変化する。

まず、株価指数を P 、利益を E 、金利を R 、インフレーションを I として (式 3.3) で示すモデルを考える。(式 3.3) で P 、 E 、 R 、 I の添字 t は時間を表している。つまり、 t は当該の観測時点であり $t-n$ は、 t より n 期前の時点を示す。またここで構築したモデルでは、株価指数 P の上昇に対する E 、 R 、 I の変化の影響にはタイムラグがあると考え、 E 、 R 、 I のデータは株価

指数のデータより n 期前のデータを用いる。つまり、 t 期の株価指数 P の変化率に対する $t-n$ 期の利益 E 、金利 R 、インフレーション I の変化率の影響を分析する。本稿では、タイムラグとして $n = 0, 1, 3, 6$ の4つのケースについて分析を行った。

$$P_t = f(E_{t-n}, R_{t-n}, I_{t-n}) = A_t \cdot E_{t-n}^{a_t} \cdot R_{t-n}^{\beta_t} \cdot I_{t-n}^{\gamma_t} \dots \quad (3.3)$$

$$n \in \{0, 1, 3, 6\}$$

$$\begin{aligned} \ln(P_t) &= \ln(A_t) + a_t \cdot \ln(E_{t-n}) + \\ &\quad \beta_t \cdot \ln(R_{t-n}) + \gamma_t \cdot \ln(I_{t-n}) \\ &\quad \dots \quad (3.4) \end{aligned}$$

まず、(式3.3)の対数を取ると、(式3.4)となる。(式3.4)を E 、 R 、 I のそれぞれで偏微分すると(式3.5)、(式3.7)、(式3.9)となり、それぞれ(式3.6)、(式3.8)、(式3.10)のように整理すれば、パラメータ a は株価指数 P に対する利益 E の弾力性(式3.6)、パラメータ β は株価指数 P に対する金利 R の弾力性(式3.8)、パラメータ γ は株価指数 P に対するインフレーション I の弾力性(式3.10)となる。したがって、株価指数 P の変化率は、全微分から(式3.11)のように利益 E 、金利 R 、インフレーション I の変化率とそれぞれの弾力性である a 、 β 、 γ で表現できる。

$$\frac{1}{P_t} \cdot \frac{\partial P_t}{\partial E_{t-n}} = a_t \cdot \frac{1}{E_{t-n}} \dots \quad (3.5)$$

$$a_t = \frac{E_{t-n}}{P_t} \cdot \frac{\partial P_t}{\partial E_{t-n}} = \frac{\partial P_t}{P_t} \bigg/ \frac{\partial E_{t-n}}{E_{t-n}} \dots \quad (3.6)$$

$$\frac{1}{P_t} \cdot \frac{\partial P_t}{\partial R_{t-n}} = \beta_t \cdot \frac{1}{R_{t-n}} \dots \quad (3.7)$$

$$\beta_t = \frac{R_{t-n}}{P_t} \cdot \frac{\partial P_t}{\partial R_{t-n}} = \frac{\partial P_t}{P_t} \bigg/ \frac{\partial R_{t-n}}{R_{t-n}} \dots \quad (3.8)$$

$$\frac{1}{P_t} \cdot \frac{\partial P_t}{\partial I_{t-n}} = \gamma_t \cdot \frac{1}{I_{t-n}} \dots \quad (3.9)$$

$$\gamma_t = \frac{I_{t-n}}{P_t} \cdot \frac{\partial P_t}{\partial I_{t-n}} = \frac{\partial P_t}{P_t} \bigg/ \frac{\partial I_{t-n}}{I_{t-n}} \dots \quad (3.10)$$

$$\begin{aligned} \frac{\partial P_t}{P_t} &= \left\{ a_t \cdot \frac{\partial E_{t-n}}{E_{t-n}} + \beta_t \cdot \frac{\partial R_{t-n}}{R_{t-n}} + \gamma_t \cdot \frac{\partial I_{t-n}}{I_{t-n}} \right. \\ &\quad \left. + \frac{\partial A_t}{A_t} \right\} \dots \quad (3.11) \end{aligned}$$

(式3.11)のパラメータ A 、 a 、 β 、 γ は、(式3.12)、(式3.13)、(式3.14)、(式3.15)で示されるように現在より1期前の A_{t-1} 、 a_{t-1} 、 β_{t-1} 、 γ_{t-1} の値に確率的な変動が加わった値とする。つまり、 A 、 a 、 β 、 γ は時間とともにパラメータの値も変化する時変係数である。

$$A_t = A_{t-1} + \sigma_A \dots \quad (3.12)$$

$$a_t = a_{t-1} + \sigma_a \dots \quad (3.13)$$

$$\beta_t = \beta_{t-1} + \sigma_\beta \dots \quad (3.14)$$

$$\gamma_t = \gamma_{t-1} + \sigma_\gamma \dots \quad (3.15)$$

ここで、(式3.3)、(式3.4)は状態を表す状態モデルであり、(式3.16)は状態モデルから観測値を得るための観測モデルである。

$$\ln(P_{obs_t}) = \ln(P_t) + \sigma_{obs} \dots \quad (3.16)$$

状態モデルから得られた P_t に確率的なノイズが加わって観測値 P_{obs_t} が得られる。

なお、(式3.17)、(式3.18)、(式3.19)、(式3.20)、(式3.21)で示される $\sigma_{_A}$ 、 $\sigma_{_a}$ 、 $\sigma_{_\beta}$ 、

σ_{γ} , σ_{obs} は、それぞれ平均 0, 標準偏差 $S_{_A}$, $S_{_a}$, $S_{_b}$, $S_{_c}$, $S_{_d}$ の確率密度関数である。

$$\sigma_{_A} \sim Normal(0, S_{_A}) \dots (3.17)$$

$$\sigma_{_a} \sim Normal(0, S_{_a}) \dots (3.18)$$

$$\sigma_{_b} \sim Normal(0, S_{_b}) \dots (3.19)$$

$$\sigma_{_c} \sim Normal(0, S_{_c}) \dots (3.20)$$

$$\sigma_{obs} \sim Normal(0, S_{obs}) \dots (3.21)$$

3.3. 状態空間モデルのデータ

前節で構築したモデルの株価指数 P の変化率は、実際の株価指数の月次データから前月比を算出して求める。日本の株価指数については、日経平均株価を用いた。一方、米国の株価指数につい

ては、一株当たり利益のデータが取得可能な S&P500¹⁰⁾ を用いた。日米それぞれの株価指数はともに日次データから月間平均値を算出して月次データとして使用した。

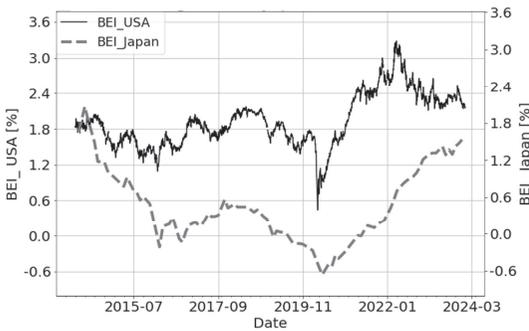
ここで使用する株価指数は、各月の一株当たり利益 (Eps) を計算できる¹¹⁾。利益 E の変化率は、取得した月次の Eps の前月比を用いた。金利の変化率は、インフレーションの影響を相殺した実質金利の前月との差分を使用した。具体的には、データが連続的に取得可能な日米の物価連動債 7 年もの¹²⁾ の月次の利回りをを用いて前月の利回りとの差分を金利の変化率とした。

インフレーションの変化率は、2 つのパターンを用いて分析した。1 つ目のパターンは、市場が予想する期待インフレ率であるブレイク・イーブン・インフレ率 (BEI: Break Even Inflation rate)¹³⁾ を用いた。具体的には、まず日米の国債 7 年ものの利回りから日米の物価連動債 7 年もの実質利回りを差し引いて月次の BEI データを算出する。さらに、当月の BEI と前月の BEI との差分を計算してインフレーションの変化率とした。

2 つ目のパターンは、日米の消費者物価指数 (全国の総合指数、以下では CPI) の月次データから前年同月比を算出してこれをインフレ率と定義し、インフレ率の前月との差分をインフレーションの変化率とした。Fig.3.2. に日米の BEI, Fig.3.3. に日米のインフレ率の推移を示す。

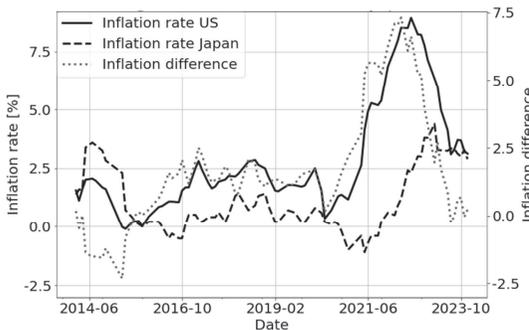
なお、(式 3.11) の説明変数である利益の変化率、金利の変化率、インフレーションの変化率の

Fig.3.2. BEI Japan & USA



(注) 財務省が公表している国債金利情報、物価連動国債のデータは浜町 SCI が公表している 7 年、米国の債券利回りは、Board of Governors of the Federal Reserve System (US) のデータを使用し独自のプログラムにより作成した。

Fig.3.3. Inflation rate US & Japan



(注) 米国の CPI は、U.S. Bureau of Labor Statistics, Consumer Price Index for All Urban Consumers, 日本の CPI は総務省の消費者物価指数 (総合指数) から独自のプログラムで作成した。

Table.3.1. VIF Factor of Explanatory Variables

VIF Factor of BEI model		
Explanatory variables	NIKKEI225	SP500
Eps	1.004	1.008
Real interest rate	10.471	1.657
Bei	10.473	1.665
VIF Factor of CPI model		
Explanatory variables	NIKKEI225	SP500
Eps	1.015	1.301
Real interest rate	1.000	1.000
Cpi	1.015	1.301

(Table.3.1. は筆者が算出および作成した)

相互の多重共線性について VIF (Variance Inflation Factor)¹⁴⁾ を算出して検証した結果が、Table.3.1. である。

Table.3.1. から、インフレーションにインフレ率 (CPI の前年同月比) を用いたパターンでは、日経平均株価、S&P500 を対象とした分析において各変数の VIF 値は概ね 1 ~ 2 程度であり多重共線性を考慮する水準にはなく (式 3.11) のモデルは分析可能と判断した。

一方、BEI を用いたパターンでは Table.3.1. から日経平均株価を対象とした分析において、実質金利と BEI の VIF 値が 10 を超えており多重共線性が認められた。

日経平均株価を用いた分析の期間は、2008 年 10 月から 2023 年 12 月までであり、日本のこの期間は短期金利がマイナスに誘導されるなど超低金利政策が続いていたもののデフレからの脱却が見通せない時期であり、実質金利が低下すれば、市場の期待インフレ率である BEI も低下するなど両者の相関性が強かったと考えられる。

しかし、S&P500 を用いた分析では、BEI を用いたパターンでも各説明変数の VIF 値は概ね 1.0 程度であり多重共線性はほとんど認められなかった。

したがって、日経平均株価を対象とした分析では、インフレーションとしてインフレ率を用いたパターンだけを行い、S&P500 を対象とした分析では、インフレーションとして BEI、インフレ率のそれぞれを用いた 2 つのパターンについて分析を行った。

3.4. MCMC による状態空間モデルの推定

前節で説明した状態空間モデルの各パラメータを推計するには、ベイズの定理によって、設定したパラメータの事前分布から事後分布を求める必要がある。ここで、パラメータを θ 、分析するデータベクトル \mathbf{x} を (式 3.22) とすると、ベイズの定理から事後分布確率 $p(\theta/\mathbf{x})$ は、事前分布確率 $p(\theta)$ 、尤度 $p(\mathbf{x}/\theta)$ を用いて、(式 3.23) のようになる。

$$\mathbf{x} = \{x_1, x_2, x_3, \dots, x_n\} \dots (3.22)$$

$$\begin{aligned} P(\theta/\mathbf{x}) \cdot P(\mathbf{x}) &= P(\theta/x_1, x_2, x_3, \dots, x_n) \\ &\quad \cdot P(x_1, x_2, x_3, \dots, x_n) \\ &= P(x_1, x_2, x_3, \dots, x_n/\theta) \cdot P(\theta) \dots (3.23) \end{aligned}$$

したがって、事後分布確率 $p(\theta/\mathbf{x})$ は、(式 3.24) となる。

$$\begin{aligned} P(\theta/\mathbf{x}) &= P(\theta/x_1, x_2, x_3, \dots, x_n) = \\ &= \frac{P(x_1, x_2, x_3, \dots, x_n/\theta) \cdot P(\theta)}{\int P(x_1, x_2, x_3, \dots, x_n/\theta) \cdot P(\theta) d\theta} \dots (3.24) \end{aligned}$$

事後分布から点推定としてパラメータ θ の期待値 θ_{EAP} を計算するには、(式 3.25) の積分計算を行う。

$$\begin{aligned} \theta_{EAP} &= \int \theta \cdot P(\theta/\mathbf{x}) d\theta = \\ &= \int \theta \cdot \frac{P(x_1, x_2, x_3, \dots, x_n/\theta) \cdot P(\theta)}{P(x_1, x_2, x_3, \dots, x_n)} d\theta \\ &\quad \dots (3.25) \end{aligned}$$

したがって、(式 3.11) のパラメータ a 、 β 、 γ の点推定による期待値を得るには (式 3.26) (式 3.27) (式 3.28) の計算を行う必要がある。

$$\begin{aligned} a_{EAP} &= \int a \cdot P(a/\mathbf{x}) da \\ &= \int a \iint P(a, \beta, \gamma/x_1, x_2, x_3, \dots, x_n) d\gamma d\beta da \\ &\quad \dots (3.26) \end{aligned}$$

$$\begin{aligned} \beta_{EAP} &= \int \beta \cdot P(\beta/\mathbf{x}) d\beta \\ &= \int \beta \iint P(\beta, a, \gamma/x_1, x_2, x_3, \dots, x_n) d\gamma da d\beta \\ &\quad \dots (3.27) \end{aligned}$$

$$\begin{aligned} \gamma_{EAP} &= \int \gamma \cdot P(\gamma/\mathbf{x}) d\gamma \\ &= \int \gamma \iint P(\gamma, \alpha, \beta/x_1, x_2, x_3, \dots, x_n) d\beta d\alpha d\gamma \\ &\dots (3.28) \end{aligned}$$

本稿では、事後分布を求めるために上記の積分計算ではなく、事後分布に従う乱数をマルコフ連鎖モンテカルロ法¹⁵⁾ (Markov Chain Monte Carlo, 以下ではMCMC) を用いて発生させ、サンプリングすることによって事後分布を求めた。MCMC法では、サンプリングされた事後分布に従う乱数の平均値を算出すればパラメータの点推定が可能である。本稿では、(式3.3) から(式3.16) で表現される状態空間モデルを確率的プログラミング言語 stan¹⁶⁾ を用いてプログラムとして実装し、MCMCによるサンプリングによってモデルのパラメータ推定を行った。

なお、パラメータ推定に必要な事前分布は、以下の通りである。

α , β , γ は弾力性であるから基準値は1として(式3.30) ~ (式3.32) のように平均値1, 標準偏差3の正規分布を弱情報事前分布として設定した。

A は、水準成分であるから(式3.29) のように若干広めの平均値1, 標準偏差5の正規分布を弱情報事前分布として設定した。

$$A_0 \sim Normal(1, 5) \dots (3.29)$$

$$\alpha_0 \sim Normal(1, 3) \dots (3.30)$$

$$\beta_0 \sim Normal(1, 3) \dots (3.31)$$

$$\gamma_0 \sim Normal(1, 3) \dots (3.32)$$

MCMC法の実行に必要な設定は次の通りである。それぞれのモデルともに収束の目安として各パラメータの *Rhat* が1.1以下となるように以下の設定値を決定した。

繰り返し数 (*iter*)¹⁷⁾: 4000回

バーイン期間 (*warmup*)¹⁸⁾: 1000回

間引き (*thin*): 設定なし

チェーン (*chains*)¹⁹⁾: 4

上記の設定により、(式3.11) のモデルをMCMCによりサンプリングした²⁰⁾。

本稿では、 t 期の株価指数の変化率に対する $t-n$ 期の利益 E , 金利 R , インフレーション I の変化率の影響を分析する。ここでは、タイムラグ n として $n = 0, 1, 3, 6$ の4つのケースについて分析を行った。サンプリングの結果, *Rhat*²¹⁾ の値は、主なパラメータで概ね1.1以下であり収束していることが確認できた。

3.5. 状態空間モデルの分析結果

MCMCの実行で得られたそれぞれのパラメータの収束状態を確認するため、一例として2010年1月の日経平均株価の分析から(式3.11)のパラメータ α , もう一つの例として分析期間の終了時点である2023年12月の米国S&P500の分析から(式3.11)のパラメータ β のサンプリング結果を Fig.3.4 ~ Fig.3.5. に示す。Fig.3.4. ~ Fig.3.5. から各パラメータが収束している状態を確認するこ

Fig.3.4. NIKKEI225-Histogram of parameter α [18]_Year-Month:2010-1

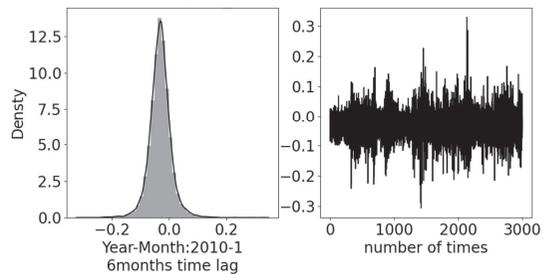
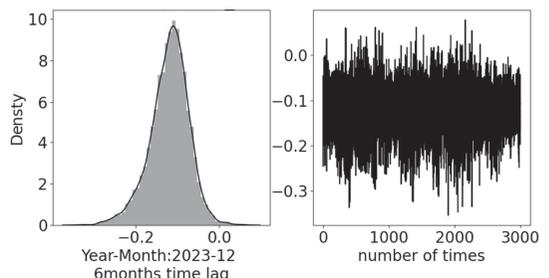


Fig.3.5. S&P500-Histogram of parameter β [185]_Year-Month:2023-12



とができる。

3.6. 利益と株価指数の変動の考察

ここでは、状態空間モデルの分析結果から利益 E 、金利 R 、インフレーション I の変化が株価指数 P の変動に与える影響について考察していく。

まず、企業の利益 E の変化と株価指数 P の変動の相関について確認する。(式 3.11) のパラメータ a が株価指数 P の変動に対する利益 E の弾力性である。最初に、日経平均株価の株価指数 P の変動と利益 E の変化について検証する。日経平均株価の分析は、本稿執筆時点でデータを取得可能な 2008 年 7 月から 2023 年 12 月まで実施した。

Fig.3.6. ~ Fig.3.7. は、それぞれ日経平均株価、S&P500 を分析対象として、インフレーションにインフレ率を用いたパターンのパラメータ a の推

Fig.3.6. Parameter 'a' for NIKKEI225 CPI model mean value for each time lag

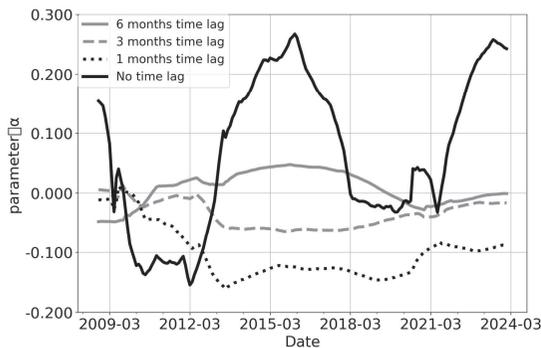
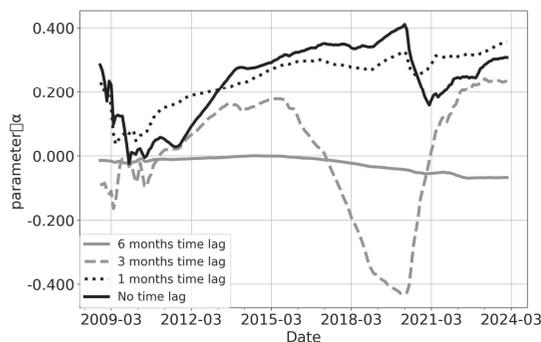


Fig.3.7. Parameter 'a' for SP500 CPI model mean value for each time lag



移である。

Fig.3.6. から日経平均株価の株価指数 P の変動に対する利益 E の弾力性であるパラメータ a の値は、タイムラグ 6 ヶ月および 3 ヶ月の場合、概ねゼロ前後で推移しており、株価指数 P の変動に与える影響はほとんどみられない。タイムラグ 1 ヶ月はマイナス 0.1 前後で推移しており、株価指数 P の変動に与える影響は若干のネガティブであった。

一方、タイムラグ無のパラメータ a の値は、2008 年のリーマンショックから 2012 年まではマイナス値であったが、2013 ~ 2017 年はプラス 0.2 程度まで上昇して、株価指数 P の変動に与える影響はポジティブに転じている。その後、2018 ~ 2021 年初めまではゼロ付近で推移していたが、2021 年半ば以降はプラス 0.2 を超えて推移している。分析結果から、2023 年 12 月時点では株価指数 P の変動に与える影響はポジティブである。

このように、日経平均株価では、配当割引モデルや定率成長配当割引モデルの理論に概ね整合的であり、利益 E の増加が株価指数 P の上昇となっていることが確認できた。

2023 年後半から、日経平均株価の株価指数 P は急上昇を続けているが、 a の値もタイムラグ無でプラス 0.2 を超えており、この間の株価指数 P の上昇は、利益 E のポジティブな効果が一因となっていることが分かった。

次に、米国の株価指数 S&P500 と利益 E の関係を考察する。Fig.3.7. から S&P500 では、タイムラグ 6 ヶ月以外で、 a の値は概ねプラス 0.20 ~ 0.30 前後と安定しており a の絶対値も大きい。

一方、タイムラグ 6 ヶ月は、 a の値が 0 前後で推移しており、株価指数 P の変動に対する影響はほとんどみられない。

このように、S&P500 の変動は配当割引モデルや定率成長配当割引モデルの理論の通りに、利益 E に対してはポジティブに反応し、利益 E の増加によって株価指数 P が上昇する素直な市場であることが分かった。

しかし、タイムラグ 3 ヶ月では、2020 年 3 月前後に a が大きくマイナスとなっている。これは、

COVID-19 のパンデミック初期に株式市場が大きく下落した時期と一致している。この時期は、利益 E の増加も株価指数 P の上昇とはならなかったためと考えられる。同じ期間に、タイムラグ無やタイムラグ 1 ヶ月、6 ヶ月で a の値が低下していないのは、COVID-19 のパンデミックによって利益 E も減少したため、利益の減少と株価指数の下落のタイミングにより a の値がマイナス値へ下降しなかったと考えられる。

3.7. 金利と株価指数の変動の考察

ここでは、金利 R の変化が株価指数 P の変動に与える影響を考察する。(式 3.11) のパラメータ β が、株価指数 P の変動に対する金利 R の弾力性である。Fig.3.8. ~ Fig.3.9. は、それぞれ日経平均株価、S&P500 を分析対象として、インフレーションにインフレ率を用いたパターンのパラメータ β の推移である。

Fig.3.8. Parameter ' β ' for NIKKEI225 CPI model mean value for each time lag

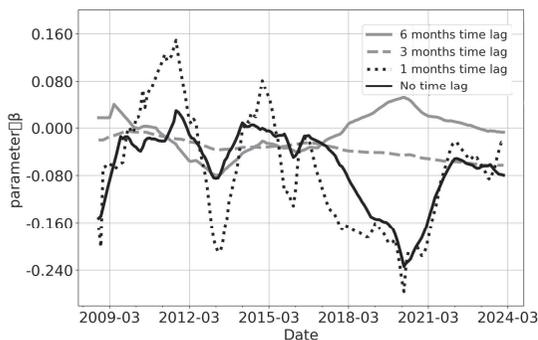
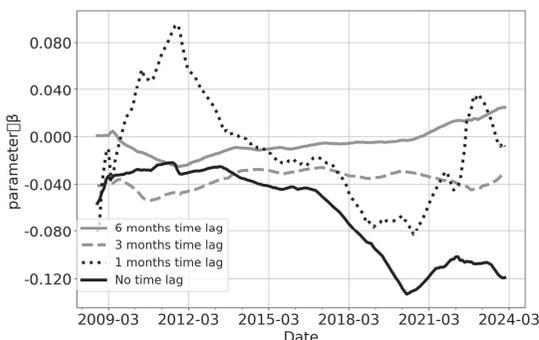


Fig.3.9. Parameter ' β ' for SP500 CPI model mean value for each time lag



まず、日経平均株価の金利 R の変化に対する株価指数 P の変動について検証する。Fig.3.8. から、タイムラグ 1 ヶ月はリーマンショック後の 2011 年および日銀が量的・質的金融緩和政策を強化した 2015 年頃にプラス値に転じたものの 2016 年以降はマイナス値で推移し、さらに COVID-19 のパンデミック後の 2020 年後半にはマイナス 0.2 を下回っている。タイムラグ無、タイムラグ 3 ヶ月のパラメータ β の値はマイナス値で推移しており、特にタイムラグ無は 2020 年後半にマイナス 0.2 を下回っている。一方、タイムラグ 6 ヶ月は、2017 年まではマイナス値で推移していたが、2019 年前後にプラス 0.05 前後に転じ 2020 年以降はゼロ前後で推移している。

以上を整理すると、金利 R の変化が株価指数 P の変動に与える影響は、タイムラグ無、タイムラグ 1 ヶ月、タイムラグ 3 ヶ月でネガティブであった。

タイムラグ 6 ヶ月は 2019 年前後にポジティブであったが、それ以外の期間では株価指数 P に与える影響はほとんどみられない。

総合的に考えれば、金利 R の変化は株価指数 P にネガティブな影響を与えており、配当割引モデルや定率成長配当割引モデルの理論に概ね整合的であった。

タイムラグ 1 ヶ月で 2015 年頃まで β の値がプラス値とマイナス値の間を大きく変動していたのは、日本銀行による大胆な金融緩和政策によって短期金利がマイナスに誘導されるなど、それまでに経験したことのない経済環境の中にあったことが要因と考えられる。つまり、金利 R の上昇はデフレ経済からの脱却と将来の経済成長を期待させ、従来の株価の理論とは逆に、一時的に金利 R が株価指数 P の変動にポジティブな影響を与えることになったと考えられる。

次に、Fig.3.9. から米国の S&P500 の株価指数 P と金利 R の関係を考察する。

タイムラグ 1 ヶ月では、2011 年から 2014 年頃まで β の値が 0 ~ 0.08 とプラス値であったが、それ以外のタイムラグではほぼマイナス値で推移していた。2011 年頃は、2008 年のリーマンショッ

クの影響が少なからず残っていた時期であり、配当割引モデルや定率成長配当割引モデルの理論とは逆に、タイムラグ1ヶ月では金利 R の変動が株価指数 P の変動にポジティブな影響を与えていた。しかし、2014年以降は、全てのタイムラグおよびタイムラグ無しで β の値はマイナス値かゼロ前後で推移し、金利 R の変化が株価指数 P の変動に与える影響はネガティブであった。

以上の動きを整理すると、S&P500では、 β の値の推移から、金利 R の変化が株価指数 P の変動にネガティブな影響を与えており、利益 E と同様に配当割引モデルや定率成長配当割引モデルの理論と整合的な結果となった。

3.8. インフレと株価指数の変動の考察

ここでは、インフレーション I の変化が、株価指数 P の変動に与える影響について考察する。

(式 3.11) のパラメータ γ が、株価指数 P の変動に対するインフレーション I の弾力性である。

Fig.3.10. ~ Fig.3.11. は、それぞれ日経平均株価、S&P500を分析対象として、インフレーション I にインフレ率を用いたパターンのパラメータ γ の推移である。

Fig.3.12. は、S&P500を分析対象として、インフレーション I にBEIを用いたパターンのパラメータ γ の推移である。

なお Table.3.1. に示したように、VIF 値の検証の結果、日経平均株価の分析では、インフレーション I にBEIを用いた場合、(式 3.11) のパラメータ間で多重共線性が認められた。このため、日経平均株価はインフレーション I にインフレ率を用いたパターンだけ分析した。

まず、日経平均株価についてインフレーション I の変化と株価指数 P の変動の関係を考察する。Fig.3.10. から、インフレ率をインフレーション I としたパターンの分析結果をみると、タイムラグ3ヶ月は分析期間を通してマイナス値であり2020年以降はマイナス0.03前後で推移している。タイムラグ6ヶ月は2018年まではマイナス0.05~0で推移していたが、2018年以降はプラス値に転じて2020年には0.015まで上昇し、その後はゼ

Fig.3.10. Parameter ' γ ' for NIKKEI225 CPI model mean value for each time lag

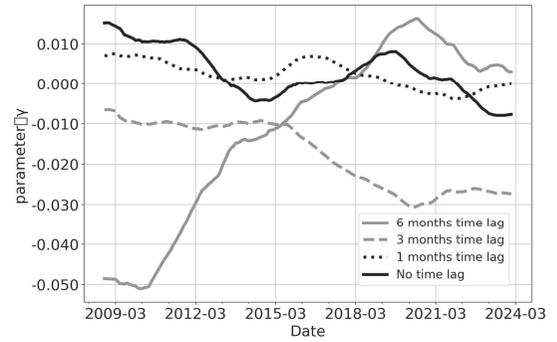


Fig.3.11. Parameter ' γ ' for SP500 CPI model mean value for each time lag

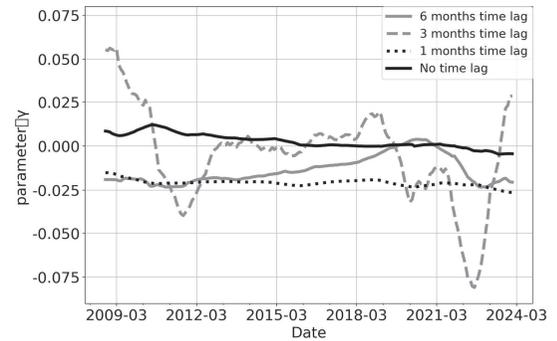
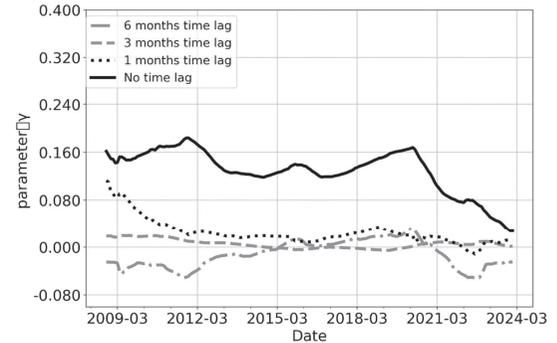


Fig.3.12. Parameter ' γ ' for SP500 BEI model mean value for each time lag



ロ前後で推移している。

タイムラグ無、タイムラグ1ヶ月は、僅かなプラス値とマイナス値を繰り返し概ねゼロ付近で推移している。

ただし、 γ の値の絶対値は a や β と比較して一桁小さなものであり、その影響の程度は限定的で

あった。つまり、インフレーション I の変化が株価指数 P の変動に与える影響は、タイムラグ 6 ヶ月では若干のポジティブの期間が見られたものの、その程度は小さなものであり、総合的に考えれば株価指数 P の変動に与える明確な影響はみられなかった。

次に、S&P500 についてインフレーション I の変化が株価指数 P の変動に与えた影響を考察する。Fig.3.11. から、インフレ率を用いた分析のパラメータ γ の値は、タイムラグ 3 ヶ月で変動が見られるものの概ねマイナス 0.00 ~ 0.03 であった。タイムラグ 1 ヶ月は、分析期間を通してマイナス 0.02 前後で推移していた。総合的に考えると、インフレ率を用いた分析では、インフレーション I の変化が株価指数 P の変動に与える影響は若干のネガティブであったが、 γ の値の絶対値は小さく、その影響は軽微なものであった。

一方、Fig.3.12. から BEI を用いた分析結果をみると、タイムラグ 1 ヶ月、3 ヶ月、6 ヶ月では分析期間を通して γ の値は、ほぼゼロ前後で推移している。しかし、タイムラグ無は、2021 年頃まではプラス 0.15 前後と比較的大きなプラス値で推移しており、BEI の変化が株価指数 P の変動に与える影響は明確にポジティブであった。しかし、分析期間の終盤にかけて γ の値は低下し、2023 年以降はプラス値は維持しているがゼロ前後で推移している。

以上のように、米国の S&P500 の分析から、市場が予想する期待インフレ率である BEI が、株価指数 P の変動に与える影響は、2020 年頃まではタイムラグ無でポジティブであったが、2023 年では若干のポジティブとなっている。

一方、足下のインフレーションの状態を示すインフレ率の変化は、株価指数 P の変動に与える影響はほとんどみられなかった。

3.9. タイムラグの検証

ここでは、(式 3.11.) で示す状態空間モデルの分析結果から、株価指数 P の変動と利益 E 、金利 R 、インフレーション I の変化とのタイムラグについて検証する。

Fig.3.13. Parameter α & β & γ for NIKKEI225 CPI model mean value for 6 months & NO time lag

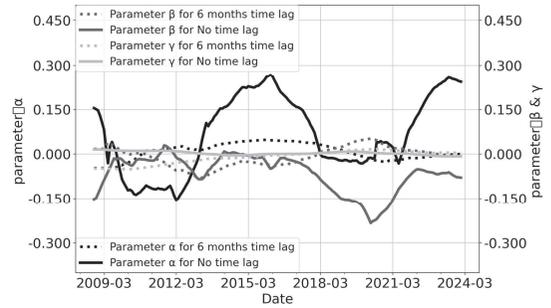


Fig.3.14. Parameter α & β & γ of SP500 CPI model mean value for 6 months & NO time lag

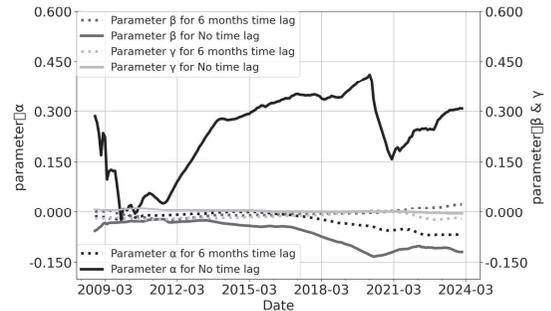


Fig.3.15. Parameter α & β & γ of SP500 BEI model mean value for 6 months & NO time lag

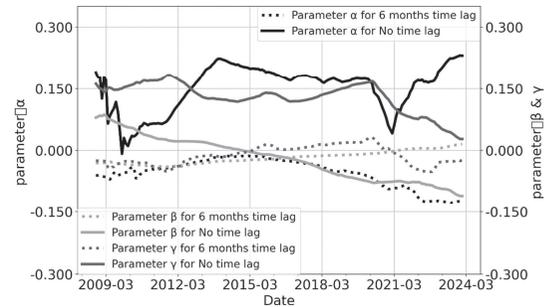


Fig.3.13. ~ Fig.3.14. は、日経平均株価、S&P500 を対象とした、インフレーションにインフレ率を用いた分析結果であり、それぞれタイムラグ無およびタイムラグ 6 ヶ月のパラメータ α 、 β 、 γ の推移を示している。

まず、Fig.3.13. から、日経平均株価の α 、 β 、 γ をみるとタイムラグ無の α 、 β の絶対値が大きくなっている。日経平均株価の分析では、株価指数 P に与える影響はタイムラグ無の利益 E およ

び金利 R が大きかったことが分かる。

一方、 γ の絶対値はタイムラグにかかわらず小さくインフレーション I が株価指数 P に与える影響は小さかった。

次に、Fig.3.14. から S&P500 のパラメータ α 、 β 、 γ の値をみると、タイムラグ無の α と β 、タイムラグ6ヶ月の α の絶対値が大きい。特に、タイムラグ無の α の絶対値が大きくなっており、米国の S&P500 では、 α と β の符号を考慮すれば、利益 E はタイムラグ無しで株価指数 P の変動にポジティブな影響が強く、金利 R はタイムラグ無でネガティブな影響が強いことが分かった。

最後に、インフレーションに BEI を用いたパターンにおける S&P500 を対象とした分析結果を Fig.3.15. に示す。Fig.3.15. からタイムラグ無の α 、 β 、 γ 、タイムラグ6ヶ月の α の絶対値が大きい。特に、タイムラグ無の γ は2020年頃までは安定してプラス0.1～0.15を維持している。

以上の結果から、株価指数 P の変動に与える影響は、タイムラグ無で利益 E 、BEI がポジティブ、金利 R がネガティブ、タイムラグ6ヶ月では利益 E が2020年以降に若干のネガティブであった。以上のように、S & P500 では、2020年頃までは BEI が株価指数 P に安定的にポジティブな影響を与えていたことが確認できた。

3.10. 状態空間モデルの分析結果の検証

以上のように、利益 E 、金利 R 、インフレーション I の変化が株価指数 P の変動に与える影響を状態空間モデルによって分析した。分析結果から、日経平均株価、S&P500 では、利益 E が株価指数の変動にポジティブな影響を与えていたことが分かった。

次に、金利 R が株価指数 P の変動に与えた影響は、日経平均株価、S&P500 とともにネガティブであった。

インフレーション I の変化が株価指数 P の変動に与える影響は、インフレーション I にインフレ率を用いた分析では明確な影響は確認できなかった。

一方、S&P500 の BEI を用いた分析では、2020

年頃までは、タイムラグ無で BEI が株価指数 P に与える影響は明確にポジティブであることが確認できた。

以上の分析結果から考察すると、2023年後半から始まった株価指数 P の急騰において、利益 E は株価指数にポジティブ、金利 R はネガティブ、インフレーション I は、インフレ率、BEI を用いたいずれの分析でも明確な影響はみられなかった。

この結果から、2023年後半以降の日米の株価指数の急騰の要因を考察すると、利益 E のポジティブな影響が強まったことが一因であると考えられる。また、米国では BEI が若干であるが株価指数 P の変動にポジティブに作用しており、市場の期待インフレ率の高まりが株価指数を押し上げる要因の一つとなっている。

しかし、2023年11月から2024年2月の本稿執筆時点までに、日本の株価指数は日経平均株価が上昇率20%超、TOPIXは16%弱、米国の S&P500 は20%弱の上昇であるのに対して、2023年12月に野村証券が公表した2023～2024年度の企業業績見通しによれば、Russell/Nomura Large Cap 指数の構成企業を対象にした業績予想は、経常利益ベースで2023年度が11.8%増、2024年度は8.3%増、税引利益ベースでは2023年度が9.0%増、2024年度は8.0%増に留まっている。

一方、継続的にデータが取得可能な S&P500 の PER を計算すると COVID-19 のパンデミック以前の2017年1月から2020年3月までの平均が18.5であったのに対して、株価の急騰が始まった2023年6月から10月までの PER は24.4まで上昇している (Fig.2.6)。

つまり、企業業績の結果である利益 E だけでは2023年後半からの株価指数の急騰を説明することは困難である。過剰流動性や経済回復への高い期待が、実態を上回る株価指数の上昇を演出している。

4. AI を用いた株価指数のシミュレーション

4.1. 株価指数の AI シミュレーション

ここでは、ディープラーニングを用いた「AI 株価指数予測モデル ver2」²²⁾ を構築して、株価指数を Eps, 金利, インフレーションなどのデータを用いてシミュレートする。「AI 株価指数予測モデル ver2」による分析を通して企業業績, 金利, インフレーションが、株価指数へ与える影響を考察するとともに、次節で試みる 18 ヶ月先の株価指数予測のためのモデルの構築を行う。

4.2. 株価指数のシミュレーションの概要

「AI 株価指数予測モデル ver2」は、時系列データの処理に特化した LSTM 層²³⁾ を 2 層, 全結合層を 7 層, ドロップ層を 1 層として構築した。「AI 株価指数予測モデル ver2」のラベルデータは、時点 t における株価指数の前月からの変化分である。一方、入力データは、株価指数と Eps (一株当たり利益), 金利, インフレーションのそれぞれの前月からの変化分である。

本稿では、株価指数のデータだけを用いて過去の株価指数の変動から予測を行うタイプ A, 株価指数のデータと金利, インフレーションの変化分を入力データとしたタイプ B, 株価指数のデータと Eps, 金利, インフレーションの変化分を入力データとしたタイプ C の 3 つのモデルを構築した。

なお、ここでは日本の代表的な株価指数である日経平均株価の月次の平均値をシミュレートする。

各タイプでは、ラベルデータを以下のようにシミュレートしている。

「AI 株価指数予測モデル ver2」では、モデルのデータである株価指数の原データをそのまま使用するのではなく、各時点における株価指数のデータと当該時点より 1 期前のデータとの差分を計算し、さらにその差分データに標準化の処理を行なったものをラベルデータとしている。

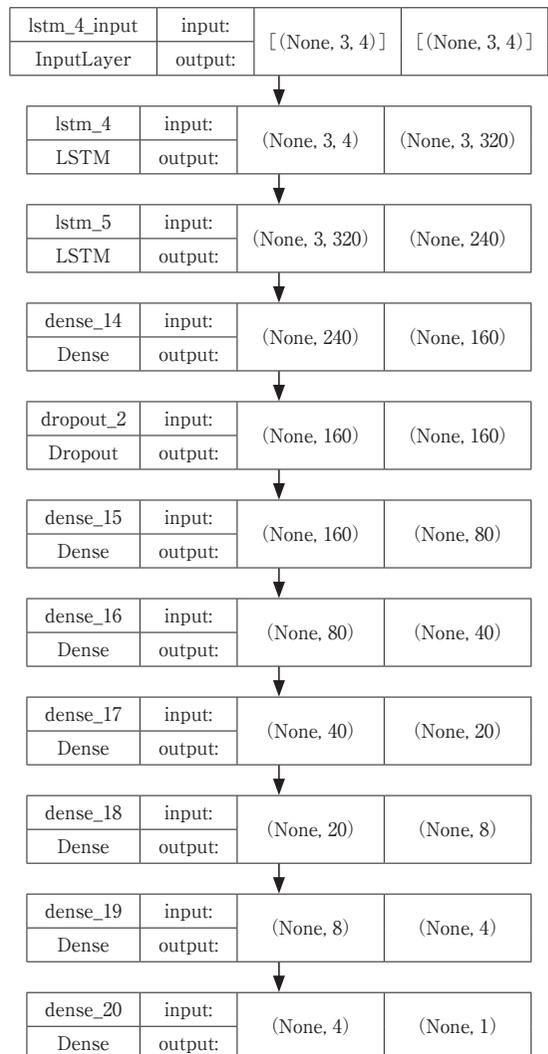
つまり、「AI 株価指数予測モデル ver2」のタイプ A では、 t 時点の株価指数と 1 期前の $t-1$ 時

点の株価指数との差分にさらに標準化の処理を行なったラベルデータを、 t 時点より 1~3 期前の株価指数とそれぞれその 1 期前の株価指数との差分を標準化したデータにより予測する。

より具体的には、 t 時点と $t-1$ 時点の株価指数の差分を標準化したデータを、 $t-1$ 時点と $t-2$ 時点の株価指数の差分の標準化, $t-2$ 時点と $t-3$ 時点の株価指数の差分の標準化, $t-3$ 時点と $t-4$ 時点の株価指数の差分の標準化したデータにより予測する。

同様にタイプ B では、 t 時点の株価指数と 1 期

Fig.4.1. 「AI 株価指数予測モデル ver2」
タイプ C の構成



前の株価指数との差分にさらに標準化の処理を行なったデータを、 t 時点より1～3期前の株価指数、金利、インフレーションとそれぞれ1期前のデータとの差分を標準化したデータにより予測する。

タイプCは、 t 時点の株価指数と1期前の株価指数との差分にさらに標準化の処理を行なったデータを、 t 時点より1～3期前の株価指数、Eps、金利、インフレーションとそれぞれ1期前のデータとの差分を標準化したデータにより予測する。

まず、設定した学習期間のデータについて「AI 株価指数予測モデル ver2」を学習させる。ここでは、「AI 株価指数予測モデル ver2」の学習期間を2008年7月～2024年1月とし、2008年10月～2024年2月の標準化した株価指数の差分を予測した。次に、予測した数値に標準化の逆計算を行って株価指数の前期との差分の予測値を算出し、その予測値を前期の株価に加えた値をAIモデルによる株価指数の予測値とした。

本稿では、「AI 株価指数予測モデル ver2」によって予測した株価指数と実際の株価指数のデータからモデルの誤差や予測の一致の程度を評価指標として算出した。

代表的なモデルとしてタイプCの構成をFig.4.1.に示す。

4.3. シミュレーションのデータ

ここでは、タイプA、タイプB、タイプCのそれぞれのモデルによって株価指数のシミュレーションを行い、その結果を比較することで株価指数、Eps、金利、インフレーションが、株価指数へ与える影響を検証する。

「AI 株価指数予測モデル ver2」では、株価指数、Eps、金利、インフレーションの月次のデータを用いてシミュレートしている。

まず、株価指数については日経平均株価の日次データの終値から月次の平均値を算出して使用した。

Epsは、日本経済新聞社が公表しているPER(加重平均)の日次データから算出し、月間平均

値を計算して使用した。金利は、実質金利とし、物価連動債7年ものの利回りのデータを使用した。また、インフレーションについては、国債7年もの物価連動債7年ものの利回りから算出したBEIを用いた。

このように「AI 株価指数予測モデル ver2」のタイプA、タイプB、タイプCをそれぞれの入力データによって学習させ、学習済みモデルによって株価指数の変動をシミュレートした。

モデルの学習期間は、2008年7月から2024年1月までとした。この学習済みのモデルで任意の t 期の株価指数をシミュレートするには、 $t-1$ 、 $t-2$ 、 $t-3$ 期のデータが必要であるから、株価指数をシミュレートする期間は、2008年10月から2024年2月までである。

また、予測値と実際の株価指数のデータからそれぞれのモデルのRoot Mean Squared Error (RMSE)²⁴⁾ およびRMSEを分析期間の株価指数の平均値で除した数値を $RMSE_prc$ [%]として算出しモデルの評価指標とした。

なお、タイプA、タイプB、タイプCともにエポック数は100回とし、それをワンセットとして200回、総計2万回学習させて $RMSE_prc$ [%]が最小となったモデルを選択してそれぞれのタイプの学習済みモデルとした。

4.4. 株価指数のシミュレーションの結果

タイプA、タイプB、タイプCのシミュレーションの結果をFig.4.2.～Fig.4.4.に示す。Fig.4.2.～Fig.4.4.には、各モデルの予測値と実測値をプロットしている。Fig.4.2.～Fig.4.4.から、各モデルによる株価指数の予測値は、完全とは言えないまでも概ね実際の株価指数の動きを捉えている。「AI 株価指数予測モデル ver2」の評価指標として予測値と実績値とのRMSEおよびRMSEを分析期間の平均値で除した $RMSE_prc$ [%]を各グラフ内に記載している。

タイプAの $RMSE_prc$ は2.60% (Fig.4.2.)、タイプBは0.17% (Fig.4.3.)、タイプCは0.13% (Fig.4.4.)であった。

$RMSE_prc$ は、タイプAよりタイプB、さら

Fig.4.2. DL model NIKKEI225 Type A



Fig.4.3. DL model NIKKEI225 Type B



Fig.4.4. DL model NIKKEI225 Type C



にタイプBよりタイプCが低い値となっている。つまり、株価指数だけを用いてシミュレートするタイプAよりも株価指数、金利、インフレーションを用いてシミュレートするタイプB、さらに株価指数、Eps、金利、インフレーションを用いてシミュレートするタイプCの方がより少ない誤差でシミュレートしていることが確認できた。

Fig.4.2. ~ Fig.4.4. のグラフ中にある up_precision, down_precision は、それぞれのモデルにおいて、翌月の株価指数が上昇するか下落するかをどの程度の精度で予測したのかを示す数字である。Fig.4.4. からタイプCでは、上昇は96.3%、下落は98.63%の精度で予測したことを示す。

この結果から、株価指数と Eps、金利、BEI (インフレーション) を使用するタイプCが、株価指数のシミュレーションには有効であることが確認できた。

このことは、株価指数の変動に Eps、金利、BEI が影響を与えていることを示すものであり、前節の状態空間モデルによる分析と一部で整合性のある結果となっている。

5. AI を用いた株価指数の予測

5.1. 18ヶ月後の株価指数のシミュレーション

ここでは、本稿執筆時点で、株価指数、Eps、金利、インフレーションなどのデータが取得および算出可能な2008年7月から2024年2月までの月次データを用いて前節のタイプCを学習させ、2024年2月から18ヶ月先の2025年8月までの株価指数の変動をシミュレートした。

2024年2月から18ヶ月後までの株価指数の予測の方法は以下の通りである。まず学習済みのタイプCのモデルを用いて、1ヶ月先の株価指数の予測値をシミュレートする。この1ヶ月先の株価指数の予測値を最新の実績値データとして入力データを再設定し、再び学習済みのタイプCのモデルによりさらにその翌月の予測を行う。この

Table.5.1. Prediction Conditions and Prediction Results

Case. No.	Fig.No.	Eps [%]	Change in Interest Rate [%]	Change in BEI [%]	Predicted Max [¥]	Predicted Value [¥]
1	Fig.5.1.	10.00	0.0	0.0	46,007	46,007
2	Fig.5.2.	10.00	0.0	0.5	44,321	44,321
3	Fig.5.3.	15.00	0.5	-0.5	41,623	38,904
4	Fig.5.4.	10.00	1.0	-1.0	40,657	36,062
5	Fig.5.5.	5.00	1.5	-1.5	40,095	31,741

Fig.5.1. TYPE C NIKKEI225 Predict to 2025/08

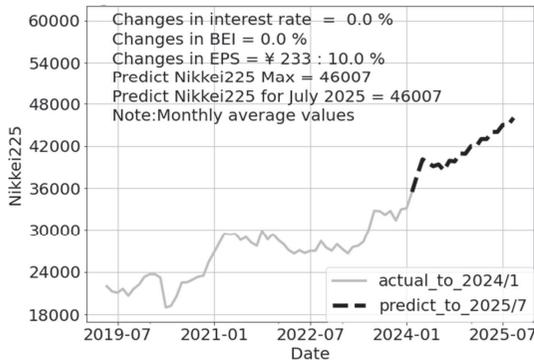


Fig.5.4. TYPE C NIKKEI225 Predict to 2025/08

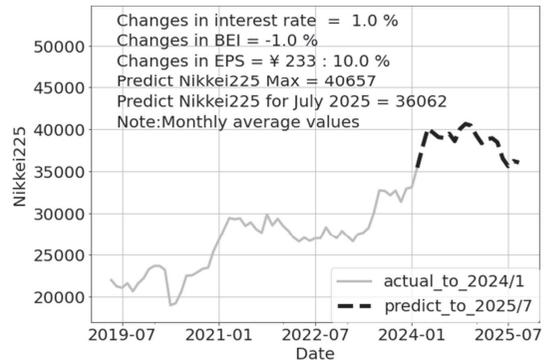


Fig.5.2. TYPE C NIKKEI225 Predict to 2025/08

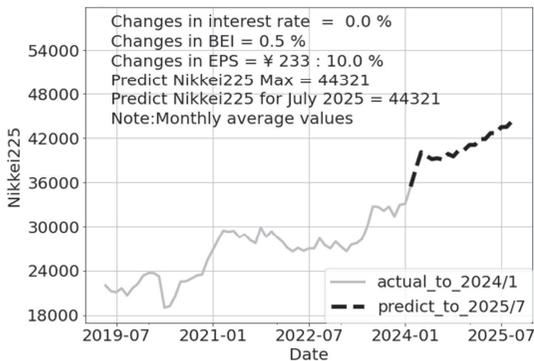


Fig.5.5. TYPE C NIKKEI225 Predict to 2025/08

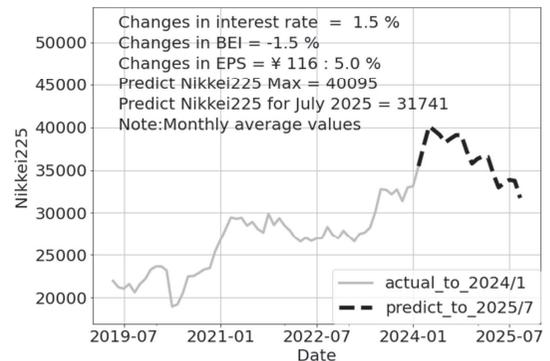
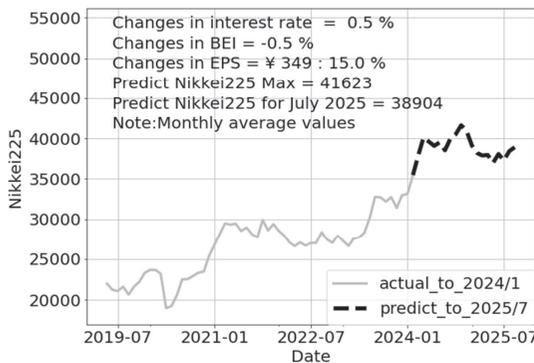


Fig.5.3. TYPE C NIKKEI225 Predict to 2025/08



作業を繰り返して18ヶ月先の株価指数を予測した。

Table.5.1. の Case.No.1 ~ 5 に予測条件とその条件によって予測した2025年8月時点の株価指数を示す。なお、ここで予測した株価指数は月次の平均値である。Fig.5.1. ~ Fig.5.5. にケース1からケース5のシミュレーション結果を示す。

前述の通り、ここでのシミュレーションの株価指数は、月間平均値であって日次の瞬時的なピークを予測するものではないことに注意されたい。つまり、2024年3月時点で日経平均株価は日次ベースではすでに4万円を上回っているが、これは日次ベースの瞬時的に付けた数字であり月間の平均値ではない。ここでの予測値は月間平均値であるから、日次ベースでの瞬時的な高値よりは低い数字になることを確認しておきたい。また、今回のシミュレーションでは、モデルは2024年2月までのデータを学習しており、日経平均株価が急騰し4万円を上回った2024年3月のデータは学習していない。したがって、モデルの予測は2024年3月の株価指数の急騰は反映されていない。このように、ここでの予測にはモデルの学習期間による誤差が含まれている。

まず、Table.5.1. のケース1は、18ヶ月後の2025年8月までに、Epsは10%増加、金利は変

化なし、BEI も変化なしとする条件である。

この場合、Eps は、2024 年 2 月時点の月間平均値 Eps_{202402} に 1 ヶ月毎に $(10/18) \% \times Eps_{202402}$ だけ加算されて 18 ヶ月後の 2025 年 8 月に 10% 増加する。

このケース 1 は、Fig.5.1. に示すように、18 ヶ月後の 2025 年 8 月の日経平均株価を 4 万 6007 円と史上最高値を更新する予測となった。

ケース 2 は、18 ヶ月後の 2025 年 7 月までに、Eps は 10% 増加し、金利は変化なし、一方で、BEI は 0.5% 上昇とする条件である。この場合は、BEI が 1 ヶ月毎に $(0.5/18)$ ポイント上昇する。このケース 2 は、Fig.5.2. に示すように、18 ヶ月後の 2025 年 8 月の日経平均株価を 4 万 4321 円と予測している。

一方、Table.5.1. のケース 3 は、18 ヶ月後の 2025 年 8 月までに、Eps は 15% 増加、金利は 0.5 ポイント上昇し、その結果として BEI はマイナス 0.5 ポイント低下する条件である。

このケース 3 は、Fig.5.3. に示すように、株価指数の月間平均値のピークは 4 万 1623 円まで上昇するが、その後は下落に転じて 18 ヶ月後の 2025 年 8 月の日経平均株価を 3 万 8904 円と予測している。

さらに、Table.5.1. のケース 4 は、18 ヶ月後の 2025 年 8 月までに、Eps は 10% 増加、金利は 1.0 ポイント上昇し、その結果として BEI は 1.0 ポイント下落するとした条件である。

この場合は、Fig.5.4. から、株価指数のピークは 4 万 0657 円、その後は下落に転じて 18 ヶ月後の 2025 年 8 月の日経平均株価は、3 万 6062 円と 2024 年 1 月時点と同水準となることを予測した。

最後に、Table.5.1. のケース 5 は、18 ヶ月後の 2025 年 8 月までに、Eps は 5% 上昇、金利が 1.5 ポイント上昇し、金利の上昇によって BEI は 1.5 ポイント低下するとした条件である。この場合は、Fig.5.5. から、株価指数のピークは、4 万 0095 円まで上昇し、その後は下落に転じて 18 ヶ月後の 2025 年 8 月の日経平均株価は、3 万 1741 円と 2024 年 2 月時点より大きく下落する予測となった。

今回の予測モデルが学習した後半の期間は、

COVID-19 のパンデミックやロシアによるウクライナ侵攻など予測できない事象の発生やその結果としての為替レートの変動、物価上昇などの社会経済が混乱していた時期でありその影響を AI が学習している。このように実際の社会経済環境は時系列で刻々と変化し、ここで前提条件としたケース 1～5 とはかけ離れた状態になる場合がむしろ多いのではないだろうか。ここでの予測は、あくまで設定した前提条件の中で AI が予測した一つの可能性であることを付け加えておく。

6. おわりに

本稿では、COVID-19 収束後の株価指数の変動をマネタリーベースの拡大、ドル円為替レート、企業業績、金利、インフレーションという観点から分析と検討を試みた。

COVID-19 のパンデミックは、世界の社会経済を混乱の渦へと陥れた。各国は市場への資金供給を中心とした経済対策を実施し、その結果、マネタリーベースは急速に拡大し、その一部は株式市場や不動産市場へ流入した。

また、2022 年 2 月にはロシアがウクライナに侵攻し、2023 年にはイスラエルとパレスチナが戦闘状態に入っている。世界情勢は混沌とし、原油などのエネルギーや食料の国際市況は急上昇している。加えて、日本では 2024 年初頭に「令和 6 年能登半島地震」が発生し、災害からの復興のため日本銀行は大胆な金融緩和策を維持する姿勢を示している。このため、米国をはじめとした世界の主要国と日本の金利差は拡大し、為替レートは大幅な円安の状態にある。輸入物価は高止まりであり、インフレ率は賃金上昇率を上回り厳しい経済環境が継続している。このような混乱の中であって、株式市場だけはバブル崩壊後の最高値を更新するなど活況を呈している。

本稿では、現在の株価指数の上昇は、企業業績の拡大が一つの要因になっていることを状態空間モデルの分析から明らかにした。

COVID-19 のパンデミックが収束し、社会経済活動が日常へと戻りつつある中で、企業業績が

回復するとの期待も株価を押し上げる要因の一つとなっている。

同時に、その背景にはマネタリーベースの拡大があることを指摘した。つまり、市場に供給した資金の一部は余剰なマネーとして株式市場へ流入し、株価の上昇を支えている。

本稿では、新たに状態空間モデルを構築して、利益の変化、金利の変化、インフレーションの変化が株価指数の変動に与える影響を分析した。その結果、現在の株式市場において、利益の拡大や一部では市場の期待インフレ率である BEI の変化が株価指数の変動にポジティブに作用していることを確認した。

しかし、2023年10月から2024年2月時点の日米の株式市場は、日経平均株価が20%超、米国の S&P500 は20%前後と急上昇している。他方、野村証券が公表している Russell/Nomura Large Cap 指数の構成企業を対象にした業績予想は、税引利益ベースで2023年度が9.0%増、2024年度は8.0%増に留まっている。

また、継続的に比較可能なデータが取得できる S&P500 の PER を計算すると COVID-19 のパンデミック以前の2017年1月から2020年3月までの平均が18.5であったのに対して、株価の急騰が始まった2023年6月から10月までの PER は24.4と上昇している (Fig.2.6.)。

このことから考えて、2024年2月時点における日米の株価指数の急騰は企業業績だけから説明することは困難であり、マネタリーベースの拡大による過剰流動性の影響が含まれていると考えられる。

さらに日本の場合、ドル円為替レートが大幅に円安に移行したことで、円ベースで急騰したもののドルベースではまだ割安感があるため、外国人投資家による更なる買い越しが継続し株価指数の上昇率を押し上げている。

このように、2024年2月時点における株式市場の活況は、企業業績の回復やその期待に加えて、過剰流動性や日本の特殊要因などが一因であると考えられる。

さらに、AIモデルを用いた株価指数の予測で

は、Eps, 金利, BEI などの条件が揃えば、日経平均株価は4万5000円を上回る可能性があることを示した。

以上のように本稿では、2024年2月時点の株式市場の状態を分析し、その結果から株価指数の急騰の要因を考察した。世界の社会経済活動は、COVID-19 収束後の回復軌道にあるものの、ウクライナ、イスラエル、北朝鮮など地政学的なリスクは高まりつつあり、予断はできない状況が続いている。好調な株式市場が、突発的な事象によって急変することは歴史的にみれば必然でもある。本稿の分析結果は一定の前提条件の下で行っているものであり、確定的なものではない。ただし、考え方の道程を示した上で将来の方向性を考えることは必要である。その意味で、本稿が、株式市場の現状と将来を考えるための一資料になれば望外の喜びである。

今後も引き続き金融市場の動向を注視して、そこで発生しうる多様な事象について実証的な分析を試みることを課題としたい。

※本研究は JSPS 科研費 JP 20K01948 の助成を受けたものである。

This work was supported by JSPS KAKENHI Grant Number JP20K01948

【注】

- 1) 日本のマネタリーベースは、日本銀行が公表しているマネタリーベース = 「日本銀行券発行高」 + 「貨幣流通高」 + 「日銀当座預金」を使用した。米国のマネタリーベースは、Board of Governors of the Federal Reserve System (US), Monetary Base を使用した。
- 2) 米国の連邦準備制度理事会 (Federal Reserve Board) のことである。アメリカ合衆国の中央銀行制度である連邦準備制度の最高意思決定機関である。
- 3) 米国の代表的な短期金利である。連邦準備銀行に預け入れるために加盟銀行が互いに短期資金をやりとりする市場で成立する金利のこと。FRB が金融市場を調整する際の誘導金利としての政策金利でもある。
- 4) 米連邦公開市場委員会 (FOMC) は、年8回開催される。FRB 理事7名と地区連銀総裁12名から構成され、その内の12名に投票権がある。政策金利は、雇用と物価水準の状況によって決定される。
- 5) 日本の物価連動国債7年、米国財務省物価連動国債7年 (Treasury Securities at 7-Year, Inflation-Indexed) を用い

て算出した。

- 6) 日本では 2004 年 2 月から物価連動国債が発行されている。財務省ホームページに物価連動国債の商品設計などについて詳細な説明がある。
- 7) 株価収益率のことである。PER (Price Earnings Ratio) は、株価を 1 株当たり利益 (EPS) で除して算出する。
- 8) ここでは、株価指数の日次の終値から算出した月次の株価指数の平均値と日本取引所グループおよびダウジョーンズが公表している EPS のデータから月次の PER を計算して、分析期間の PER の期間平均を算出した。
- 9) 一株当たり利益は、発行済み株式数が変化しなければ企業業績である税引き利益によって決定する。したがって、株価は、利益と実質金利とインフレーションの関数として表現できる。
- 10) S&P500 は、S&P ダウ・ジョーンズ・インデックス社が公表する米国の株式市場を代表する株価指数である。ニューヨーク証券取引所および NASDAQ に上場している代表的な 500 銘柄の時価総額により算出している。Eps の月次のデータを取得できる。
- 11) 日経平均株価の Eps は、日本経済新聞社が公表している日次の株価指数と PER のデータから算出し月次の平均値を使用した。S&P500 の Eps は、2023 年 9 月までは S&P ダウ・ジョーンズ・インデックス社が公表しているデータを使用した。2023 年 9 月以降は、S&P ダウ・ジョーンズ・インデックス社のマーケットアナリストが公表している予測値を使用した。
- 12) 日本の物価連動債のデータは、浜町 SCI が公表している物価連動債 7 年もの、米国はインフレ連動型 7 年定期満期の米国財務省証券の市場利回りを使用した。
- 13) 名目債券利回り と 実質利回り との差がブレイク・イーブン・インフレーション (Break Even Inflation rate: BEI) である。BEI には、期待インフレーションと市場の流動性リスクなどを示すリスクプレミアムが含まれているが、実際にはリスクプレミアムの測定は困難である。またその値は期待インフレーションと比較して小さいため、本稿では BEI をほぼ市場の期待インフレーションに等しいと想定して議論を進めている。
- 14) 説明変数間の多重共線性を検証する指標である。説明変数の中から 1 個を目的変数とし、残りの変数を説明変数にして重回帰分析を行い、得られた決定係数を 1 から引いて求めたトレランスの逆数である。また、説明変数間の相関係数行列の逆行列の対角要素である。変数の VIF 値が 10 を超えた場合は、多重共線性が疑われるため当該の変数を除外することが推奨される。
- 15) 計算したい事後分布を均衡分布とするマルコフ連鎖を生成して、計算ではなくサンプリングによって事後分布を得るアルゴリズムの総称である。
- 16) Stan は統計的推論のための確率的プログラミング言語である。確率的プログラミング言語には、多様な確率分布や尤度の計算のための関数群が多量用意されている。本稿で使用した Stan では MCMC のアルゴリズムとして、HMC (ハミルトニアンモンテカルロ法) の実装方法の一つである NUTS が使われている。
- 17) *iter* とは、乱数の発生個数のことである。収束のために必

要な回数が設定される。

- 18) 乱数発生初期値の依存性を避けるために最初に発生した乱数を切り捨てる必要がある。この切り捨てる期間のことをバーイン期間 (*warmup*) という。
- 19) 収束を評価するために MCMC による乱数生成を指定した回数実施する。この回数がチェーン (*chains*) である。
- 20) 本稿では、MCMC の実行に、*iter* = 4000, *warmup* = 1000, *thin* = 0, *chains* = 4 とした。したがって得られる乱数の数 M は、以下のように計算される。

$$M = (4000 - 1000) * 4 = 12000$$
 と計算できる。
- 21) *Rhat* は、MCMC が収束したかどうかを確認する指標の一つであり、MCMC サンプルの分散からパラメータごとに算出される。一般的に、この数値が 1.1 未満になると収束したとみなす。
- 22) 「AI 株価指数予測モデル ver2」は、以下の文献で概要を示した「AI 株価指数予測モデル」をベースにバージョンアップを行なったものである。小林稔「新型コロナウイルスのパンデミックが株式市場に与えた変動の分析と検証 (その 2) —AI (人工知能) を用いた日米の株価指数のシミュレーション分析—」, 『和光経済』第 54 巻第 1 号, pp. 1-24, 2021 年 7 月。
- 23) Long Short Term Memory (LSTM): 時系列データおよびシーケンスデータの長期的な依存関係を学習するリカレントニューラルネットワークの一種である。
- 24) Root Mean Squared Error: 2 乗平均平方根誤差のこと。誤差を二乗平均してその平方根をとった値である。

【参考文献】

- 山村光司「状態空間モデルによる昆虫個体数変動の解析における諸問題」, 『日本生態学会誌』66: 339-350, 2016.
- 福井紳也「地域別確率的景気指数と地域間景気連動性—状態空間モデルと LA-VAR による接近—」, 『産開研論集』第 19 号, pp. 1-15, 2007.
- 久保拓弥「最近のベイズ理論の進展と応用 [I] 階層ベイズモデルの基礎」『電子情報通信学会誌』92 (10), 881-885, 2009.
- 和合肇「ベイズ計量経済分析における最近の発展」, 『日本統計学会誌』第 28 巻第 3 号, pp. 253-305, 1998.
- 久保拓弥「簡単な例題で理解する空間統計モデル」, 『日本生態学会誌』59, pp. 187-196, 2009.
- 森川浩司・捧保浩「階層回帰モデルとベイズ推定による POS データの分析」, 『日立 TO 技報』第 16 号, pp. 52-57, 2010.
- 阿部誠「RFM 指標と顧客生涯価値: 階層ベイズモデルを使った非契約型顧客関係管理における消費者行動の分析」『日本統計学会誌』第 41 巻, 第 1 号, pp. 51-81, 2011 年 9 月。
- 馬場真哉『時系列分析と状態空間モデルの基礎』プレアデス出版, 2018 年 3 月。
- 北村行伸「物価連動債の市場価格より得られる情報: 米国財務省物価連動債の評価」Discussion Paper No. 2004-J-7, 日本銀行金融研究所, 2004 年 2 月。
- 藪友良「購買力平価 (PPP) パズルの解明: 時系列的アプローチの視点から」金融研究第 26 巻第 4 号, pp. 75-105, 日本銀行, 2007 年 12 月。

- 小林稔「低迷を続ける日本の賃金上昇率に関する構造的な課題の検証：ベイズモデルとAIシミュレーションを用いた実証分析」, 『和光経済』第56巻第1号, pp. 15-40, 2023年8月。
- 小林稔「COVID-19のパンデミックが小売販売額へ与えた影響に関する実証分析—ベジアンモデルを用いた業態別小売販売額の変動の検証—」, 『説得交渉学研究』第15巻第1号, pp. 15-34, 日本説得交渉学会, 2023年12月。
- 小林稔「インフレーションおよび日米の金利差がドル/円為替レートへ与える影響に関する検証—ベイズモデルとAIシミュレーションを用いた実証分析—」, 『和光経済』第55巻第3号, pp. 23-46, 2023年3月。
- 小林稔「金融市場における意思決定ツールとしての人工知能の検証—AIを用いた株価指数のシミュレーション—」, 『説得交渉学研究』第14巻第1号, pp. 27-44, 日本説得交渉学会, 2022年12月。
- 小林稔「急速な円安進行による株価指数の変動に関するベイズモデルを用いた実証分析」, 『和光経済』第55巻第2号, pp. 15-31, 2022年12月。
- 小林稔「内外金利差とドル/円為替レートの変動に関するAIシミュレーション分析」, 『和光経済』第55巻第1号, pp. 23-39, 2022年8月。
- 小林稔「新型コロナウイルスのパンデミックが株式市場に与えた変動の分析と検証—AI（人工知能）を用いた株価指数の実験的シミュレーション—」, 『和光経済』第53巻第3号, pp. 1-15, 2021年3月。
- 小林稔「新型コロナウイルスのパンデミックが株式市場に与えた変動の分析と検証（その2）—AI（人工知能）を用いた日米の株価指数のシミュレーション分析—」, 『和光経済』第54巻第1号, pp. 1-24, 2021年7月。
- 小林稔「新型コロナウイルスのパンデミックが国内小売販売額へ与えた影響に関する分析—階層ベイズモデルを用いた地域および時間による変動の検証—」, 『和光経済』第54巻第2・3号, pp. 47-62, 2022年3月。
- 小林稔「AI時代の説得交渉に関する一考察」, 『説得交渉学研究』第11巻, pp. 15-30, 日本説得交渉学会, 2019年12月。
- 磯貝孝「切断安定分布による資産収益率のファットテイル性のモデル化とVaR・ESの計測手法におけるモデル・リスクの数値的分析」, 『日本銀行ワーキングペーパーシリーズ』No. 13-J-3, pp. 1-85, 2013年3月。
- 安藤美孝「ヒストリカル法によるバリュエーション・アット・リスクの計測：市場価格変動の非定常性への実務的対応」, 『金融研究』第23巻別冊第2号, pp. 1-41, 日本銀行金融研究所, 2004年11月。
- 中川慧・今村光良・吉田健一「株価変動パターンの類似性を用いた株価予測 Stock Price Prediction Using Similarity of Stock Price Fluctuation Patterns」, 2017年度人工知能学会全国大会（第31回）論文集, 2017。
- Takahashi, Shuntaro Chen, Yu, "Long Memory and Predictability in Financial Markets, Implications from Empirical Studies and Applications of the LSTM model", The 31st Annual Conference of the Japanese Society for Artificial Intelligence, 2017.
- 岡田克彦・羽室行信「株式市場における株価大崩落の兆し検知への挑戦 A challenge to obtain the crystal ball in the stock market - A candle chart based graph density」, 2017年度人工知能学会全国大会（第31回）論文集, 2017。
- 羽室行信・岡田克彦「個別銘柄の運動類似度グラフおよびグラフ研磨手法を用いた株価予測 Finding a group of stocks to be focused based on the similarity graph approach - Effectiveness of graph polishing in detecting a herd -」, 2017年度人工知能学会全国大会（第31回）論文集, 2017。
- 宮崎邦洋・松尾豊「深層学習を用いた株価予測の分析 Stock Prediction Analysis using Deep Learning Technique」, 2017年度人工知能学会全国大会（第31回）論文集, 2017。
- 加藤旺樹・穴田一「テクニカル指標による株式投資の戦略構築」2018年度人工知能学会全国大会（第32回）論文集, 2018。
- Aurélien Géron, *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*, O'REILLY, 2019.
- David Foster, *Generative Deep Learning: Teaching Machines to Paint, Write, Compose, and Play*, O'Reilly, 2019.
- Takahashi, Shuntaro Chen, Yu, "Long Memory and Predictability in Financial Markets, Implications from Empirical Studies and Applications of the LSTM model", The 31st Annual Conference of the Japanese Society for Artificial Intelligence, 2017.

(2024年1月31日 受稿)
(2024年2月11日 受理)