

銘柄属性と市場情報を用いた 深層学習株式リターン予測モデルの予測根拠の分析

Analyzing Basis of Stock Returns Prediction Model Based Deep Learning Using Stock Attributions and Market Information

小寺俊哉¹ 佐藤史仁¹ 坂地泰紀² 和泉潔²

Shunya Kodera¹, Fumihito Sato¹, Hiroki Sakaji², and Kiyoshi Izumi²

¹ 日興リサーチセンター株式会社 投資工学研究所

¹Institute of Investment Technology, Nikko Research Center, Inc.

² 東京大学大学院工学系研究科 システム創成学専攻

²Department of Systems Innovation, School of Engineering, The University of Tokyo

Abstract: 近年、個別株式のリターン予測において、様々なファクターの中から予測に有用な特徴量を自動で抽出することのできる深層学習技術の応用研究がなされている。しかしながら、深層学習は計算の過程が複雑で、人間にはその予測根拠の把握が難しく、意思決定に理由が求められる実務での利用において、解釈の困難さが課題視されることがある。一方、深層学習の解釈手法についても研究が行われており、深層学習において研究が盛んな画像分類等のタスクだけでなく株価指数や株式個別銘柄等の資産価格リターン予測を行う深層学習モデルに対しても解釈を行う研究が行われている。本稿では、モデルの解釈に焦点を当て、個別銘柄のリターン予測をタスクとした深層学習モデルについて、LRP と呼ばれる深層学習の解釈手法を用いて、各入力値の寄与度を個別銘柄レベルで確認した。さらに、深層学習モデルの入力値に個別銘柄属性だけでなくマーケット指数等の市場情報を用いることで、銘柄属性と市場トレンドの 2 つの側面での分析を行った。

1 はじめに

近年、ビッグデータと呼ばれる大規模で多種多様なデータの活用や計算機の大規模並列処理能力の向上を背景に、与えられたデータからパターンを抽出し、分類や予測を行う機械学習の技術が目覚ましい発展を遂げている。特に、分類や予測等、対象とするタスクに有効な特徴量を人手で与えることなく、自ら選択、抽出することのできる深層学習の技術が、様々な分野で注目を浴びている。

資産運用業界等でも、ポートフォリオマネジメントにおけるリスク管理や投資戦略等に対し、深層学習を用いた研究がなされている。例えば、株価指数や株式個別銘柄のリターン等の予測[11][23]、それを応用したポートフォリオ選択[3][13]、リスクヘッジに関する予測[7]、ボラティリティ予測[14][20]等が挙げられる。その中でもリターン予測は、投資戦略だけでなくポートフォリオ構築やリスク管理にも活用できる非常に関心の高いテーマとなっている。

ところで、ファイナンス分野の研究において、株

式等の資産のリターンを説明するファクターモデルがいくつも提案されている。最も基本的なモデルである資本資産評価モデル (CAPM) では、個別資産のリターンは、市場全体のマーケットポートフォリオに対する感応度 β で特徴づけられている[10][15]。そして、株式の個別銘柄のリターンに対しては、 β 以外に、企業規模や簿価時価比率を説明力のある変数として組み入れた Fama-French の 3 ファクターモデル[4]や、さらにモメンタムを組み入れた Carhart の 4 ファクターモデル[2]、その他、財務変数等を組み入れた様々なマルチファクターモデルが提案されている[5][6][8]。このような個別銘柄のリターンに対して一定の説明力があると報告された変数は 300 以上あるものの、どの変数がリターンを説明する本質的な要因であるか、もしくはそれらをどのように組み合わせるとリターンを説明するモデルとするか、未だ明確な答えはない。また、運用実務において、個別銘柄間の相対的な投資魅力度を定量的に推計するために、いくつかの銘柄属性等の変数をファクターとし

て、クロスセクションで各銘柄のリターンを説明するマルチファクターモデルが利用されることがある。しかし、多数のファクターの膨大な組み合わせから有効なものをどう選択するか、また、ファクター間やファクターとリターンとの非線形な関係をどのように取り込むかが課題となる場合が多い。このような課題に対して、深層学習は、与えられたデータから有効な特徴量を自動で抽出し、線形・非線形なモデルの構築が行える手法として高い親和性が期待される。

しかしながら、深層学習が特徴量の自動抽出や非線形の複雑な表現を扱える一方で、入力と出力間にどのような関係性を学習したか人間が理解できる形で確認することは難しく、ブラックボックス化してしまう問題がある。深層学習を銘柄選定等の投資運用実務に用いる場合、この問題によって投資判断の根拠を示しにくく、投資信託等の運用マネージャーの説明責任や、投資家の投資への納得性に対して障壁になることが少なくない。これらは、深層学習技術の実務への応用に対する重要な課題の一つだろう。

一方で、深層学習の解釈手法¹に関する研究も盛んに行われており、様々な手法が提案されている[9][18]。例えば LRP(Layer-Wise Relevance Propagation)²[1]と呼ばれる手法は、深層学習のモデル構造に手を加えず、モデルの出力値からその計算を遡ることで各入力値が出力に対してどの程度貢献したかを計算することができる。この技術を用いて、深層学習での画像分類やテキストの極性判定において、どの入力部分が貢献したかを分析した研究が報告されている[19][21]。

金融分野においても、深層学習モデルの予測や推論の根拠の理解に関する研究は注目度が高く、深層学習を用いてリターン予測や株式選択を行う際に、各入力変数の貢献度を分析して予測結果の解釈性を高める研究が盛んに行われている。Shiら[16]は深層学習を用いて株式を選択する手法を提案し、多変量解析法の一つである MDS (多次元尺度構成法)を用いて推論根拠の可視化を行った。Wuら[17]は GRU (Gated Recurrent Unit) ネットワークと呼ばれる深層学習の手法を用いて、過去の価格データから将来の株価リターンを予測し、予測結果をユーザに解釈しやすい決定木の形に変換する GRU-Tree という解釈可能なモデルを提案した。塩野[22]は、多数の経済金融時系列を入力とし、資産価格リターンの予想を

行う CNN (畳み込みニューラルネットワーク) を、マクロ経済の理論モデルとのマルチタスク学習により過学習を緩和する方法を提案した。その際に、LRP を応用することで、マクロ経済モデルでの経済ファクターと資産価格リターン予測における共通因子を特定し、モデルの解釈性を高めた。Nakagawaら[12]は、深層学習による株式個別のリターン予測モデルに LRP を適用し各入力値の影響を分析する手法を提案した。これらの研究に対し、本稿では、株式個別銘柄のリターン予測をタスクとした深層学習モデルの出力の解釈に焦点を当てた分析を行った。深層学習の解釈性を高める手法は[12][22]と同様に LRP を用いた。予測根拠の解釈対象の深層学習モデルは、入力データに ROE 等の個別銘柄の属性であるファクター値の他、マーケット指数等の市場情報を用い、ファンダメンタルズと市場全体のトレンドの両方を考慮したモデルとした。このことにより、関連研究にはない銘柄属性と市場トレンドの2つの側面での貢献度分析が可能となる。具体的には、深層学習が、入力値とした代表的な各銘柄属性に対して、どのような特性を持つ銘柄のリターンを相対的に高く(又は低く)予測したかを、予測リターン順を基にしたロングポートフォリオとショートポートフォリオの平均 LRP 貢献度や、入力ファクターとその LRP 貢献度の散布図から確認した他、個別銘柄レベルでの各属性の貢献度を確認した。また、マーケット指数等の LRP 貢献度の時系列の変化や、特定の局面において特に市場情報に影響を受けていた銘柄の属性について分析を行った。

2 実験設定

2.1 リターン予測の深層学習モデル設定

まず、LRP による予測根拠の解釈を行う学習済みモデルとして、本稿では、クロスセクションでの株式個別銘柄の相対的な投資魅力度を、時価総額や自己資本比率等の銘柄属性等から予測する深層学習モデルを構築した。深層学習モデルは、多層パーセプトロンを用いた。また、各月末ごとにモデルを構築し1ヶ月後を予測するローリング方式を想定した。教師データは、その月末から翌月末までのリターンとし、入力データは、各月末時点で入手可能なデータから作成した個別銘柄の属性である各ファクター

¹ 説明可能な AI 技術及びその研究分野の事を XAI (Explainable AI) と呼び、内閣府の人工知能技術戦略会議の人工知能技術戦略実行計画 (<https://www8.cao.go.jp/cstp/tyousakai/jinkochino/keikaku.pdf>) や総務省の AI ネットワーク社会推進会議の 2018 年報告書 (http://www.soumu.go.jp/main_content/000564147.pdf) にも明記

されている人工知能研究において重要なテーマの1つである。

² LRP は、深層学習モデルにおいて通常通りにデータを入力し順伝播させた後に、レイヤー間の関係性を逆伝播することで入力と出力の関係性を求める手法で、サンプルごとに出力値に対する各入力値の貢献度を計算することができる。

値や東証 33 業種のダミー変数の他、月のダミー変数やマーケット指数等、計 126 変数（各変数は表 3、4 参照）を用いた。なお、各データは必要に応じて標準化や正規化の処理を行った。学習データには、各月末時点で東証一部に上場している銘柄をユニバースとし、計算可能な入力データと教師データ過去 36 ヶ月分を用いた。学習したモデルによって予測される各銘柄の 1 ヶ月リターンの順位付けを行い、これを相対的投資魅力度とした。なお、モデルのハイパーパラメータは予測日によらず共通の値（表 5 参照）を用いた。

2.2 パフォーマンス検証

各月末に構築した深層学習モデルで予想される投資魅力度の評価として、投資魅力度をもとにロングとショートのパフォーマンスを構築し、月次リバランスでロングショートポートフォリオを運用した場合のパフォーマンスを計測した。ユニバースは東証一部上場銘柄とし、投資魅力度の高い順に 10 分位ポートフォリオを等ウェイトで構築、最高分位をロング、最低分位をショートのパフォーマンスとした。各ポートフォリオの平均リターンの差であるスプレッドリターンをロングショートポートフォリオのリターンとして 2005 年 12 月末から 2019 年 12 月末まで計測し、各種パフォーマンス値を表 1 に示した。

ロングショートポートフォリオのリターン/リスク比は 1.63 であった。また、各パフォーマンス値について、ロングポートフォリオは、TOPIX 対比でアウトパフォームしたのに対し、ショートポートフォリオはアンダーパフォームとなった。実際の運用では、売買コストやキャパシティ、投資可能な営業日数等の制約があることに注意が必要ではあるが、これらの結果から、深層学習モデルによるリターン予測を投資戦略等へ応用することで、一定のパフォー

表 1. ポートフォリオの各種パフォーマンス値

	ロング	ショート	ロング ショート	TOPIX
リターン	15.91%	-5.20%	20.72%	2.31%
リスク	19.67%	21.52%	12.75%	17.72%
リターン/ リスク比	0.81	-0.24	1.63	0.13
最大ドロー ダウン	-44.18%	-74.42%	-22.38%	-56.23%

(注) リターン及びリスクは年率の値を示す。参考として TOPIX (配当込み) も示す。

マンスを得られることが期待できるだろう。

3 予測根拠の分析

LRP 貢献度は、深層学習モデルによる個別銘柄ごとの予測リターンの計算に用いられた全ての入力値について算出される。各 LRP 貢献度はプラスに大きいほど、その入力ファクター値が出力の予測リターンに対してプラスに大きく寄与し、マイナスに大きいほど、マイナスに大きく寄与することを表す。

本稿では、入力データの内、代表的な銘柄属性ファクターの LRP 貢献度に対し、予測リターンが高い銘柄と低い銘柄間での傾向等を確認することで、予測リターンの根拠の分析を行った。また、2019 年 6 月末の予測日における深層学習の予測結果を対象とし、予測リターンが高い銘柄を前述のロングポートフォリオの銘柄、低い銘柄をショートポートフォリオの銘柄として分析を行った。さらに、市場情報について、ロングとショートのパフォーマンスにおける平均 LRP 貢献度を算出し、その時系列変化や、特定の局面において、予測リターンに対して市場情報がポジティブ（又はネガティブ）に影響した銘柄群の特性について調べた。

3.1 個別銘柄の予測に対する根拠の提示

まず、個別銘柄ごとにどのファクターが予測に寄与しているのかを確認した。表 2 は、ロングとショートのパフォーマンスからそれぞれ 5 銘柄ずつ選択した計 10 銘柄の予測リターンとファクター値及び LRP 貢献度を示している。予想経常利益修正～予想売上高成長率の表中数値は深層学習モデルに入力された各ファクター値、その色は LRP 貢献度を示す。LRP 貢献度が 0 の場合に白色、プラスに大きいほど赤色が濃く、マイナスに大きいほど青色が濃くなるように色を付与した。

銘柄ごとの予測リターンに対するファクターの LRP 貢献度を見ると、例えば<4502>の場合では、予想経常利益修正や予想益回り、時価総額、予想 ROE、予想売上高成長率の色が濃く、リターン予測に大きく寄与していたことが分かる。また、これらファクターについて、予想売上高成長率は赤色であるためプラス方向、それ以外は青色であるためマイナス方向の寄与であることが分かる。ファクター値と合わせて見ると、予測リターンに対して、売上の拡大（予想売上高成長率のファクター値がプラス）に関してプラス方向に評価（LRP 貢献度が赤色）されているものの、収益性の低下（予想 ROE、予想経常利益修正のファクター値がマイナス）や割高（予想益回り


表 2. 個別銘柄の予測リターンと各ファクター値及び LRP 貢献度

ポート フォリオ	銘柄	予測リ ターン	数値：入力変数値 / 色：LRP 貢献度 (高[赤]-0[白]-低[青])									
			予想経 常利益 修正	自己資 本比率	自己資 本株価 比	予想益 利回り	1ヶ月 リター ン	12ヶ月 リター ン	36ヶ月 リター ン	時価総 額	予想 ROE	予想売 上高成 長率
シ ョ ー ト	4502	-0.40	-3.14	-0.66	-0.33	-3.02	0.27	-0.03	-0.77	2.90	-2.52	3.74
	6326	-0.28	-0.02	-0.23	-0.65	-0.20	0.97	0.65	0.15	2.28	0.23	0.25
	2503	-0.27	-1.07	-0.54	-0.88	-0.99	-0.36	-0.08	0.22	2.25	-0.37	-0.09
	9202	-0.25	-0.10	-0.49	-0.30	0.26	-0.65	0.41	-0.04	1.92	0.08	0.01
	7974	-0.25	-0.06	1.54	-1.09	-0.82	-0.05	1.17	1.94	2.81	0.66	0.26
ロ ン グ	3769	0.15	-0.02	-1.42	-1.38	-1.43	-0.13	1.34	1.69	1.42	1.80	2.40
	4188	0.15	-2.32	-1.26	0.13	1.60	0.51	-0.10	0.76	1.86	0.44	-0.04
	4684	0.17	0.09	1.82	-1.20	-1.05	-1.49	2.27	1.37	1.91	0.83	0.41
	3765	0.18	1.01	1.22	-1.10	-0.29	-2.20	1.55	-0.38	1.00	2.18	-0.14
	6770	0.27	-0.44	0.14	-0.25	0.09	-0.22	-0.96	-0.68	1.21	-0.10	-0.27

りのファクター値がマイナス) によるマイナス評価 (LRP 貢献度が青色) の寄与がより大きかったため、投資魅力度が低く判定されたと推察することができる。同様に解釈すると、<3765>は、ファクター値と LRP 貢献度を合わせて見ると、予測リターンに対して、割高気味 (自己資本株価比のファクター値がマイナス、12ヶ月リターンがプラス) であることがマイナスに評価 (LRP 貢献度が青色) されるものの、収益性 (予想 ROE のファクター値がプラス) や安全性 (自己資本比率のファクター値がプラス) についてはプラス評価 (LRP 貢献度が赤色) を受け、さらに直近の株価下落 (1ヶ月リターンのファクター値がマイナス) に対するリバウンドが見込めるため投資魅力度が高く判定されたと推察することができる。

3.2 ファクター効果の分析

次に、投資魅力度の高い (又は低い) 銘柄群では、どのファクターがその予測に寄与している傾向があるのかを確認するため、個別銘柄ごとに算出された LRP 貢献度について、ロングとショートのパートフォリオでの各ファクターの平均値を算出した。また、ファクターごとのポートフォリオ間での LRP 貢献度の平均に有意な差があるかの検定も行った。その結果を図 1 に示す。ロングポートフォリオでは、1ヶ月リターン、予想 ROE、予想益利回り、自己資本比率がプラス予測に寄与していた。ショートポートフォリオでは、1ヶ月リターン、自己資本比率、時価総額がマイナス予測に寄与していた。これらは全て 1%



(注) 各ファクターにおける平均の差の検定において、*は 5%、**は 1%有意水準を示す。

図 1. ポートフォリオの平均 LRP 貢献度

有意水準となった。また、1ヶ月リターンのように、ロング側でもショート側でも予測に対する寄与が大きいファクターがある一方で、予想 ROE や時価総額のように、ロング側かショート側かどちらか一方の予測に対して寄与するファクターもあった。入力データの分布にもよるが、投資魅力度の高い (低い) 予測に対して、深層学習モデルがどのファクターに注目しているかの傾向を知る手掛かりになるだろう。

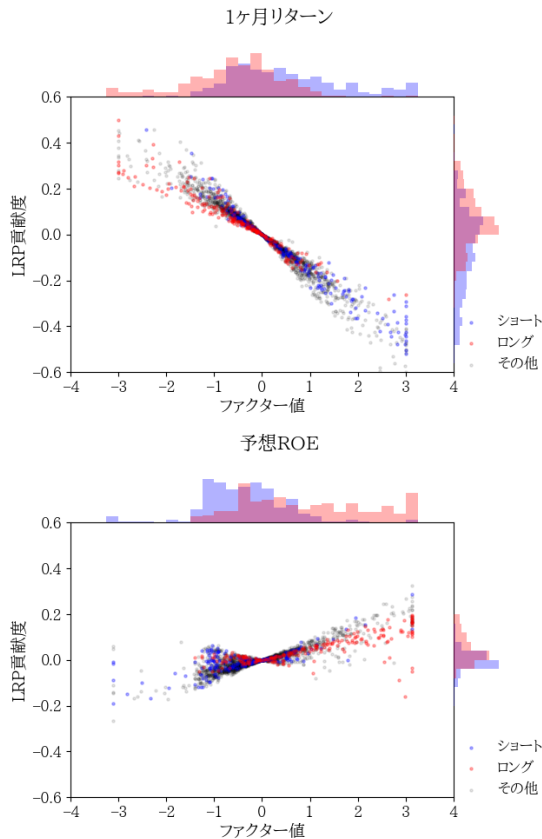


図2. ファクター値とLRP貢献度の関係

図1で、特に1ヶ月リターンや予想ROE等のファクターにおいてポートフォリオ間での平均LRP貢献度の差が大きいことが分かった。しかし、この情報だけでは、どのファクターが予測リターンに寄与している傾向にあるかは分かるが、ファクターの値の大小と予測リターンの関係性は確認することができない。つまり、ファクターの値とLRP貢献度の関係性や、これらと予測リターンの関係性で表わされる個別銘柄レベルでの全体的な傾向を確認することができない。そこで、銘柄のファクター値とLRP貢献度の散布図と各変数のロングとショートポートフォリオ別のヒストグラムを用いて確認した。例として、図2に1ヶ月リターンと予想ROEでの結果を示す。1ヶ月リターンではファクター値とLRP貢献度は全体として負の相関関係にあり、特にロングポートフォリオの銘柄ではファクター値はマイナス、LRP貢献度はプラスに裾野が広がっていた。ショートポートフォリオの銘柄では逆にファクター値はプラス、LRP貢献度はマイナスに裾野が広がっている傾向が見られた。一方、予想ROEではファクター値がプラスの範囲ではファクター値とLRP貢献度は正の相関があるが、ファクター値がマイナスの範囲では明確な相関は見られず、ロングポートフォリオ

の銘柄ではLRP貢献度の分布はプラス側に寄っているが、ショートポートフォリオの銘柄ではLRP貢献度の分布は0付近に集中していた。1ヶ月リターンにおいて、ファクター値とLRP貢献度には負の相関があることから、この深層学習モデルは、この月の東証一部市場の全体の傾向として、短期リバーサル効果が働くことを予想していると解釈することができる。また、予想ROEにおいて、高収益性で見たクオリティ効果が働くことを予想していると解釈できるだろう。さらに、ロングやショートのポートフォリオの銘柄に対し、LRP貢献度が0付近のものについて、そのファクター以外のファクターが予測リターンに寄与していると解釈できるだろう。

興味深い点として、銘柄間でファクター値とLRP貢献度に相関がある中でも、同じファクター値の水準でありながらLRP貢献度に正負が異なるようなばらつきがある点や、ファクター値が正の範囲と負の範囲でファクター値とLRP貢献度の関係性が異なる傾向が見えたことが挙げられる。これらは、深層学習の予測に他のファクターとの関係性や非線形性が考慮されていた結果であるかもしれない。

3.3 市場情報を用いた分析

本稿で分析対象とした深層学習モデルでは、銘柄属性だけでなく、TOPIXや為替といった市場情報も入力値に用いた。これらの情報の予測リターンへの寄与を確認することで、深層学習モデルが市場情報をどう取り入れて予測したかについて分析した。

図3では、4つの市場情報についてロングとショートの各ポートフォリオでのLRP貢献度の平均値の差を時系列で確認した。市場情報は、クロスセクションでは銘柄間で同じ値の入力であるものの、時期によってロングとショートのポートフォリオ間で異なる傾向が見られた。例えば、TOPIX変化率は2008年10月や2011年3月、2012年2月、2016年7月、2019年10月にロングとショートのポートフォリオ間でLRP貢献度の平均の差が大きかった。その他にも、日本国債金利10年は2011年3月、ドル/円は、2013年12月や、2014年8月、2019年3月で差が大きかった。一方で、他の指標と比べVIXでは目立った動きは見られなかった。

次に、TOPIX変化率においてLRP貢献度のポートフォリオ間の差が大きかった2008年10月に注目した。2008年10月は、2008年9月に起きたリーマンショックによる金融危機の影響でTOPIXは大きく下落した。深層学習によるリターン予測において、このTOPIXの下落をポジティブやネガティブに捉えられた銘柄群にそれぞれどのような特性があるか




図 3. ロングとショートポートフォリオ間での各市場情報の平均 LRP 貢献度の差




図 4. 2008 年 10 月末における TOPIX 変化率の LRP による分位の各平均ファクター値

を確認した。図 4 では、2008 年 10 月末を予測日とした際の TOPIX 変化率の LRP 貢献度で 10 分位し、最も高分位と低分位の銘柄をそれぞれ高 LRP、低 LRP ポートフォリオとし、代表的な 10 個の銘柄属性についてファクター値の平均を示した。その結果、TOPIX の下落に対し深層学習の予測がポジティブな影響を受けている銘柄の属性は、相対的に自己資本株価比や予想利益回りが高く、1 ヶ月リターン、12 ヶ月リターン、36 ヶ月リターン、時価総額が低かった。反対にネガティブな影響を受けている銘柄の属性は、相対的に自己資本株価比や予想利益回りが低く、1 ヶ月リターン、12 ヶ月リターン、36 ヶ月リターン、時価総額が高いという結果であった。この結果から、深層学習モデルは TOPIX の下落が予測リタ

ーンに対してポジティブかネガティブか銘柄属性によって異なるよう学習していると解釈できるだろう。

4 まとめ

本稿では、LRP を用いて深層学習による個別銘柄の予測リターンに対する根拠の分析を行った。

表 2 では、銘柄ごとにどのようなファクターが予測に寄与しているかの確認を行った。例えば、<4502>は収益性の低下や割高であることが要因として投資魅力度が低く判定され、<3765>は収益性や安全性が高いことや、直近株価の下落に対するリバウンドを見込んで投資魅力度が高く判定されたという解釈を得ることができた。

また、図 1 や図 2 から、投資魅力度の高い（又は低い）銘柄群で予測リターンに対し、どのようなファクターの寄与が大きい傾向にあるか、市場全体での予測リターンに対するファクター効果として、個々の銘柄の予測におけるファクター値と LRP 貢献度の関係について分析した。具体的には、対象とした 2019 年 6 月末を予測日として構築した深層学習モデルが、東証一部の銘柄に対し、1 ヶ月リターンについて短期のリバーサル効果を予測していることや、予想 ROE では、高収益性で見たクオリティー効果を予測しているとの解釈結果を得ることができた。

図 3 では、入力値に用いた市場情報の内 4 つについて、時系列でロングとショートのポートフォリオ間の平均 LRP 貢献度の差を分析した。市場情報は、個別銘柄間では、入力値としては同じ値だが、出力の予測リターンに対して異なった寄与を持つことが確認できた。また、2008 年 10 月の金融危機による下落局面において、TOPIX の下落情報をポジティブ（又はネガティブ）に捉える銘柄の属性について図 4 で確認を行った。

5 おわりに

本稿では、LRP を用いて個別株式のリターン予測をタスクとした深層学習モデルに対して、ファクターごとの予測リターンに対する貢献度を算出し、その予測根拠の分析を行った。その結果、LRP 貢献度を測る事で深層学習モデルが各銘柄の予測において、どのファクターに着目してリターンの予測を行っているか、ファクターごとに全体的な傾向として予測リターンにどのように影響しているかを確認することができた。本稿で用いた手法により、ファクターとリターンの線形的な関係だけでなく、深層学習の特徴である他の変数との関係や非線形性を考慮したファクターの効果を確認することができた。

また、実際に予測根拠を解釈する場合、図1で概観を確認し、図2で注目すべきファクターの貢献度との関係性を調べ、最終的には表2の個別銘柄での貢献度を確認する等の手順で、ブラックボックスであった予測に対する根拠の手がかりが示せるだろう。

さらに、図3、図4のように銘柄の固有属性であるファクターの他、クロスセクションで銘柄間共通の値となる市場情報についても寄与度分析を行うことで、市場環境に応じてどのような情報が予測に用いられるか確認することが可能となる。このように、銘柄ごとの市場環境の影響を分析することで、モデルのより詳細な解釈に繋がるだろう。

参考文献

- [1] Bach, S., Binder, A., Montavon, G., Klauschen, F., Müller, K. R., and Samek, W.: On Pixel-Wise Explanations for Non-Linear Classifier Decisions by Layer-Wise Relevance Propagation, *PLoS ONE*, 10(7): e0130140, (2015)
- [2] Carhart, M. M.: On Persistence in Mutual Fund Performance, *The Journal of Finance*, Vol. 52, No. 1, pp. 57-82, (1997)
- [3] Chakravorty, G., Awasthi, A., and Silva, B. D.: Deep Learning for Global Tactical Asset Allocation, *Available at SSRN* 3242432, (2018)
- [4] Fama, E. F., and French, K. R.: Common risk factors in the returns on stocks and bonds, *Journal of Financial Economics*, Vol. 33, No. 1, pp. 3-56, (1993)
- [5] Fama, E. F., and French, K. R.: A five-factor asset pricing model, *Journal of Financial Economics*, Vol. 116, No. 1, pp. 1-22, (2015)
- [6] Fama, E. F., and French, K. R.: Choosing factors, *Journal of Financial Economics*, Vol. 128, No. 2, pp. 234-252, (2018)
- [7] Fécamp, S., Mikael, J., and Warin, X.: Risk management with machine-learning-based algorithms, *arXiv: 1902.05287v3*, (2019)
- [8] Hou, K., Xue, C., and Zhang, L.: Digesting Anomalies: An Investment Approach, *The Review of Financial Studies*, Vol. 28, No. 3, pp. 650-705, (2015)
- [9] Ito, T., Tsubouchi, K., Sakaji, H., Izumi, K., and Yamashita, T.: CSNN: Contextual Sentiment Neural Network, *19th IEEE International Conference on Data Mining (ICDM)*, pp.1126-1131, (2019)
- [10] Lintner, J.: The Valuation of Risk Assets and the Selection of Risky Investments in Stock Portfolios and Capital Budgets, *The Review of Economics and Statistics*, Vol. 47, No. 1, pp. 13-37, (1965)
- [11] Moghaddam, A. H., Moghaddam, M. H., and Esfandyari M.: Stock market index prediction using artificial neural network, *Journal of Economics, Finance and Administrative Science*, Vol. 21, No. 41, pp. 89-93, (2016)
- [12] Nakagawa, K., Uchida, T., and Aoshima, T.: Deep Factor Model, *ECML PKDD 2018 Workshops*, pp. 37-50, (2018)
- [13] Obeidat, S., Shapiro, D., Lemay, M., MacPherson, M. K., and Bolic, M.: Adaptive Portfolio Asset Allocation Optimization with Deep Learning, *International Journal On Advances in Intelligent Systems*, Vol. 11, No. 1 & 2, (2018)
- [14] Sardelich, M., and Manandhar, S.: Multimodal deep learning for short-term stock volatility prediction, *arXiv: 1812.10479v1*, (2018)
- [15] Sharpe, W. F.: Capital Asset Prices: A Theory of Market Equilibrium under Conditions of Risk, *The Journal of Finance*, Vol. 19, No. 3, pp. 425-442, (1964)
- [16] Shi, L., Teng, Z., Wang, L., Zhang, Y., and Binder, A.: DeepClue: Visual Interpretation of Text-based Deep Stock Prediction, *IEEE Transactions on Knowledge and Data Engineering*, Vol.31, No.6, pp.1094-1108, (2018)
- [17] Wu, W., Wang, Y., Fu, J., Yan, J., Wang, Z., Liu, J., Wang, W., and Wang, X.: Preliminary Study on Interpreting Stock Price Forecasting Based on Tree Regularization of GRU, *International Conference of Pioneering Computer Scientists, Engineers and Educators*, pp.476-487, (2019)
- [18] Zeiler, M. D., and Fergus, R.: Visualizing and Understanding Convolutional Networks, *European Conference on Computer Vision - ECCV 2014*, pp. 818-833, (2014)
- [19] 伊藤友貴, 坂地泰紀, 和泉潔: 深層学習を用いた経済テキスト可視化の検証, 第20回人工知能学会金融情報学研究会, pp. 61-66, (2018)
- [20] 五島圭一, 高橋大志, 山田哲也: 自然言語処理による景況感ニュース指数の構築とボラティリティ予測への応用, 日本銀行金融研究所ディスカッション・ペーパー・シリーズ, 2019-J-3, (2019)
- [21] 酒井博貴, 亀谷由隆, 曾田尚宏, 有江浩明: LRP法による畳み込みニューラルネットワークにおける中間層の振る舞いの可視化, 人工知能学会全国大会論文集 JSAI 2018, 2A2-04, (2018)
- [22] 塩野剛志: アセット・リターン予測 AI とマクロ経済理論の融合—マルチタスク学習による正則化と識別—, 第21回人工知能学会金融情報学研究会, pp.33-40, (2018)
- [23] 宮崎邦洋, 松尾豊: Deep Learning を用いた株価予測の分析, 人工知能学会全国大会論文集 JSAI2017, 2D3-OS-19a-3, (2017)

Appendix

表 3. 個別銘柄の属性値

入力変数名				
実績売上高 成長率	実績配当利回り	予想 EBITDA/EV 比率	6ヶ月リターン	実績益利回り
予想売上高 成長率	予想配当利回り	時価総額	12ヶ月リターン	予想益利回り
実績経常利益 成長率	自己資本株価比	自己資本	36ヶ月リターン	売上高営業 利益率
予想経常利益 成長率	予想益利回り 変化幅	売上高	β 値	自己資本比率
実績純利益 成長率	時系列基準化 益利回り	出来高回転率	倒産確率	負債比率
予想純利益 成長率	予想キャッシュフロー 株価比	1ヶ月リターン	予想経常利益 修正	純債務比率
予想 ROE	予想売上高 株価比	3ヶ月リターン		

表 4. マーケット指数等

	生値	1ヶ月 変化率	1ヶ月 差
TOPIX	○	○	-
日経平均	○	○	-
NY ダウ	○	○	-
S&P500	○	○	-
DAX	○	○	-
FTSE	○	○	-
ドル/円	○	○	-
ユーロ/円	○	○	-
日本国債金利 2 年	○	-	○
日本国債金利 5 年	○	-	○
日本国債金利 10 年	○	-	○
日本国債金利 20 年	○	-	○

	生値	1ヶ月 変化率	1ヶ月 差
日本国債金利 30 年	○	-	○
米国債金利 2 年	○	-	○
米国債金利 5 年	○	-	○
米国債金利 10 年	○	-	○
米国債金利 30 年	○	-	○
独国債金利 10 年	○	-	○
英国債金利 10 年	○	-	○
日経平均 VI	○	○	-
VIX	○	○	-
CRB 指数	○	○	-
WTI 原油先物	○	○	-
金先物	○	○	-

(注) 表中○のものを入力変数として用いる。

表 5. 深層学習のハイパーパラメータ

ハイパーパラメータ		値
入力層	ユニット数	126
	活性化関数	linear
隠れ層 1	ユニット数	64
	活性化関数	tanh
	ドロップアウト	0.4
	ドロップアウト	0.4
隠れ層 2	ユニット数	64
	活性化関数	tanh
	ドロップアウト	0.4
	ドロップアウト	0.4
隠れ層 3	ユニット数	32
	活性化関数	tanh
	ドロップアウト	0.4
	ドロップアウト	0.4
出力層	ユニット数	1
	活性化関数	linear
損失関数		二乗誤差
最適化アルゴリズム		Adam
ミニバッチサイズ / エポック数		300 / 20