日興リサーチセンター
SMBC日興証券グループ

LRP を用いた深層学習株式リターン予測モデルの解釈の試み

Research Report
2020 年 3 月

投資工学研究所
小寺　俊哉
佐藤　史仁

要　約

近年、株式の個別銘柄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効な特徴量を自動で抽出できる深層学習技術の応用研究がなされている。しかし、深層学習は計算過程が複雑で、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とされることがある。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式の指数や個別銘柄等の資産価格リターン予測をタスクとした深層学習モデルに対しても解釈に関する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、各入力値の予測リターンに対する貢献度を個別銘柄レベルで確認し、モデルの予測根拠の解釈を試みた。また、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。これらの分析の結果、個別銘柄の予測の根拠として深層学習モデルがどのようなファクターに注目しているか、マーケットの傾向としてどのようなファクター効果を予測しているか、また、銘柄属性によって同じ市場情報でもポジティブに捉えるかネガティブ捉えるか異なる場合があることが分かった。このような情報を提示することで、金融実務における深層学習の利便性の向上が期待されるだろう。

目次

1. はじめに
2. 深層学習と LRP
　2.1　深層学習とは
　2.2　LRP とは
3. 実験設定
　3.1　リターン予測の深層学習モデル設定
　3.2　パフォーマンス検証
4. 予測根拠の分析
　4.1　個別銘柄の予測に対する根拠の提示
　4.2　ファクター効果の分析
　4.3　市場情報を用いた分析
5. おわりに

本資料は、信頼性の高いデータから作成されておりますが、当社はその正確性・確実性に関し、いかなる保証をするものではございません。本資料は、情報提供を目的としており、投資勧誘を目的としたものではございません。証券投資に関する最終判断は、投資家ご自身の判断でなさるようにお願いいたします。本資料の著作権は当社に帰属し、本資料の転用および販売は固く禁じられております。

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[Moghaddam 他 2016][宮崎, 松尾 2017]、それを応用したポートフォリオ選択[Chakravorty 他 2018][Obeidat 他 2018]、リスクヘッジに関する予測[Fécamp 他 2019]、ボラティリティ予測[Sardelich, Manandhar 2018][五島他 2019]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[Lintner 1965][Sharpe 1964]。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[Fama, French 1993]や、さらに価格モメンタムを組み入れた Carhart の 4 ファクターモデル[Carhart 1997]、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[Fama, French 2015][Fama, French 2018][Hou 他 2015]。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て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の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を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。

本資料は、信頼性の高いデータから作成されておりますが、当社はその正確性・確実性に関し、いかなる保証をするものではございません。本資料は、情報提供を目的としており、投資勧誘を目的としたものではございません。証券投資に関する最終判断は、投資家ご自身の判断でなさるようにお願いいたします。本資料の著作権は当社に帰属し、本資料の転用および販売は固く禁じられております。

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[Zeiler 他 2014][Ito 他 2019]。例えば LRP(Layer-Wise Relevance Propagation)[Bach 他 2015]と呼ばれる手法では、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、深層学習を用いた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[伊藤他 2018][酒井他 2018]。

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、深層学習を用いて株式のリターン予測や銘柄選択を行う際に、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[Shi 他 2018]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[Wu 他 2019]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式リターンを予測し、予測結果をユーザー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[塩野 2018]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[Nakagawa 他 2018]は、深層学習による株式個別銘柄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[Nakagawa 他 2018] [塩野 2018]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、銘柄の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。分析内容として具体的には、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も確認した。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。本稿の構成は以下の通りである。第 2 章は深層学習と LRP の紹介、第 3 章は本稿での予測根拠の解釈対象である深層学習モデルの設定の説明、第 4 章は LRP による深層学習モデルの解釈に関する分析、第 5 章はまとめとなっている。

[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。

本資料は、信頼性の高いデータから作成されておりますが、当社はその正確性・確実性に関し、いかなる保証をするものではございません。本資料は、情報提供を目的としており、投資勧誘を目的としたものではございません。証券投資に関する最終判断は、投資家ご自身の判断でなさるようにお願いいたします。本資料の著作権は当社に帰属し、本資料の転用および販売は固く禁じられております。

2. 深層学習と LRP

2.1 深層学習とは

深層学習（Deep Learning）とは、機械学習手法の一つで、生物の神経回路網を模倣した人工ニューラルネットを多層に組み合わせた多層ニューラルネットワーク（Deep Neural Network）を用いた学習方法のことを指す。用途によって様々な構造の深層学習モデルが提案されているが、本稿ではその中でも代表的な全結合多層パーセプトロン（順伝搬型ニューラルネットワーク）について紹介する。

深層学習を模式図にする場合は図表 1 のようにニューロン（円）とノード（線）で表されることが多い。このニューロンの集まりをレイヤーと呼び、レイヤーを多層に組み合わせてモデルを構築する。深層学習モデルは、他の機械学習手法と同様に各データの特徴量を n 次元のベクトルとして受け取り、入力側のレイヤーのニューロンから各ノードを通し、次のレイヤーのニューロンに値を伝搬する。この際に最初に入力値を受け取るレイヤーのことを入力層、最終的な出力値を渡すレイヤーを出力層、入力層と出力層の間のレイヤーを中間層（隠れ層）と呼ぶ。

図表 1. 深層学習モデル構造の基本的用語

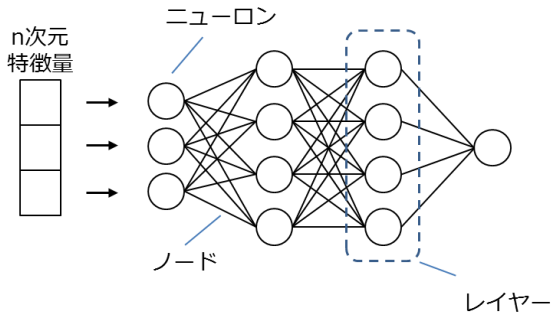

（出所）日興リサーチセンター作成

ここで、単一のニューロンにおける計算方法を図表 2 に示す。ニューロンは手前のレイヤーの各ニューロンから入力変数x_iにノードが保有する重み変数w_iを乗じたもの及び定数 1 にバイアス変数[2]bを乗じたバイアス項を受け取る。

図表 2. ニューロンにおける演算処理

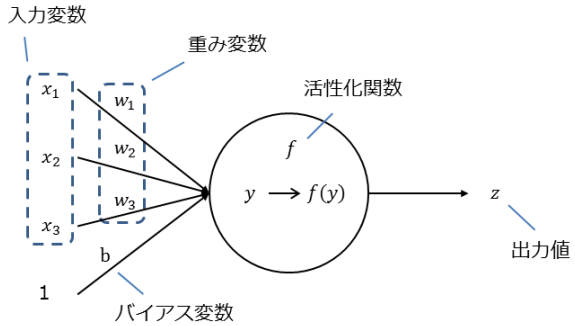

（出所）日興リサーチセンター作成

[2] バイアス変数は、線形回帰式における切片に相当し、出力を調整するパラメータとして用いられる。

本資料は、信頼性の高いデータから作成されておりますが、当社はその正確性・確実性に関し、いかなる保証をするものではございません。本資料は、情報提供を目的としており、投資勧誘を目的としたものではございません。証券投資に関する最終判断は、投資家ご自身の判断でなさるようにお願いいたします。本資料の著作権は当社に帰属し、本資料の転用および販売は固く禁じられております。

そして(式 1)のように全てのノードから受け取った値の合計値yを(式 2)の活性化関数[3]$f(y)$と呼ばれる関数により変換し、出力値zを得る。

$$\mathrm{y} = x_1 w_1 + x_2 w_2 + x_3 w_3 + b$$
$$= \sum_i w_i x_i + b \qquad \text{(式 1)}$$
$$z = f(\mathrm{y}) \qquad \text{(式 2)}$$

次に多数のニューロンを組み合わせたニューラルネットワークの計算例を図表 3 に示す。ただし、単純化のためここではバイアス項を省略した。各レイヤーの活性化関数f、g、hは任意の活性化関数を示し、レイヤーごとに異なるものを用いることもできる。

図表 3. ニューラルネットワークにおける演算処理

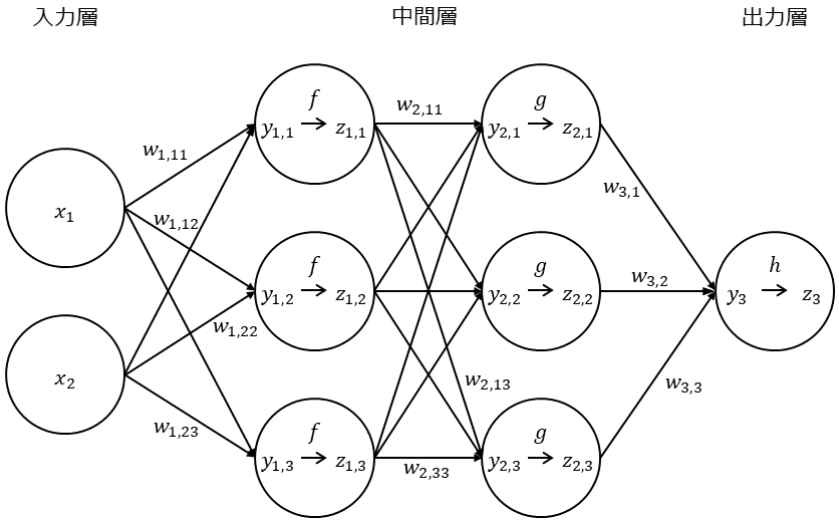

（出所）日興リサーチセンター作成

個々のニューロンの計算は(式 1)(式 2)と同様の計算で行われるが、全結合多層パーセプトロンでは、ノードはレイヤー間でのニューロンの組み合わせの数だけ存在し、一般的には、複数のニューロンを同時に計算するために、行列式を用いて記述される。まずは、入力層から一つ目の中間層の計算において、(式 3)のように入力値に重み変数を乗じたものを合計し、(式 4)でそれらの値を活性化関数により変換する。

$$(x_1 \quad x_2)\begin{pmatrix} w_{1,11} & w_{1,12} & w_{1,13} \\ w_{1,21} & w_{1,22} & w_{1,23} \end{pmatrix} = (y_{1,1} \quad y_{1,2} \quad y_{1,3}) \qquad \text{(式 3)}$$

$$(f(y_{1,1}) \quad f(y_{1,2}) \quad f(y_{1,3})) = (z_{1,1} \quad z_{1,2} \quad z_{1,3}) \qquad \text{(式 4)}$$

[3] 活性化関数は、シグモイド関数（sigmoid）、双曲線正接（tanh）、正規化線形関数（relu）等がよく用いられる。

本資料は、信頼性の高いデータから作成されておりますが、当社はその正確性・確実性に関し、いかなる保証をするものではございません。本資料は、情報提供を目的としており、投資勧誘を目的としたものではございません。証券投資に関する最終判断は、投資家ご自身の判断でなさるようにお願いいたします。本資料の著作権は当社に帰属し、本資料の転用および販売は固く禁じられております。

次に、一つ目の中間層から二つ目の中間層においても同様に(式 5)(式 6)の計算を行う。

$$(z_{1,1} \quad z_{1,2} \quad z_{1,3}) \begin{pmatrix} w_{2,11} & w_{2,12} & w_{2,13} \\ w_{2,21} & w_{2,22} & w_{2,23} \\ w_{2,31} & w_{2,32} & w_{2,33} \end{pmatrix} = (y_{2,1} \quad y_{2,2} \quad y_{2,3}) \qquad (式\ 5)$$

$$(g(y_{2,1}) \quad g(y_{2,2}) \quad g(y_{2,3})) = (z_{2,1} \quad z_{2,2} \quad z_{2,3}) \qquad (式\ 6)$$

最後に、二つ目の中間層から出力層においても同様に(式 7)(式 8)の計算を行い、出力値oを得る。

$$(z_{2,1} \quad z_{2,2} \quad z_{2,3}) \begin{pmatrix} w_{3,1} \\ w_{3,2} \\ w_{3,3} \end{pmatrix} = y_3 \qquad (式\ 7)$$

$$h(y_3) = z_3 = o \qquad (式\ 8)$$

ここまでの計算は 1 つの合成関数として(式 9)の様に表すことができる。ただし、(式 3)～(式 8)では省略したバイアス項を含めて表記した。

$$o = h\left(\sum_k g\left(\sum_j f\left(\sum_i w_{ji}x_{ji} + b_j\right)w_{kj} + b_k\right)w_k + b_o\right) \qquad (式\ 9)$$

深層学習では、このように入力層から出力層まで順に値を計算（順伝搬）する。そして、与えられた入力値から算出された出力値と真の値との誤差を適切な損失関数[4]を用いて定義し、誤差が小さくなるよう重み変数を調整する。その際の重み変数の最適化には各種手法が考案されている[5]。ただし、いずれの手法においても各重み変数の誤差に対する勾配ベクトルが必要となる。かつては、各重み変数の誤差に対する数値微分を用いて勾配ベクトルを求める方法がとられていたが、レイヤーが多層になるにつれ計算量が膨大になるという課題を抱え、最近では、連鎖率を用いて出力側から誤差の偏微分を伝搬して勾配ベクトルを求めるバックプロパゲーション（誤差逆伝搬法）が一般的に用いられる。

深層学習のモデルは、原理的には数式で記述できるが、その関数形は極めて複雑である。実際には、上述の例より多層に、多くのニューロンでモデルを構築することが多く、その関数は(式 9)よりも複雑なものとなる。そのため、各入力値がどのような重み付けで、変数間でどう影響し合い出力を得ているか等を人間が関数を読み解くことで理解するのは非常に困難と言えよう。

[4] 対象タスクが回帰問題の場合は、二乗誤差関数、分類問題の場合は、交差エントロピー誤差関数等が用いられることが多い。
[5] 重みの調整方法を最適化アルゴリズムと言い、SGD や Adam 等がよく用いられる。

本資料は、信頼性の高いデータから作成されておりますが、当社はその正確性・確実性に関し、いかなる保証をするものではございません。本資料は、情報提供を目的としており、投資勧誘を目的としたものではございません。証券投資に関する最終判断は、投資家ご自身の判断でなさるようにお願いいたします。本資料の著作権は当社に帰属し、本資料の転用および販売は固く禁じられております。

2.2　LRP とは

LRP（Layer-Wise Relevance Propagation）は深層学習の解釈手法の一つである。出力に対する各入力の貢献度合いの総和は各レイヤー間で等しく、伝搬する中でその配分を変動させているという仮定のもと、一度通常通りに深層学習にデータを入力し出力層まで順伝搬させた後に、レイヤー間の関係性を出力層から入力層まで層ごとに逆伝搬することで、最終的に各入力値の出力値に対する関係性を貢献度として計算することができる。図表 4 がその順伝搬と逆伝搬のイメージを示し、(式 10)、(式 11)は一つの層のあるユニットにおける出力値に対する貢献度の逆伝搬の計算式を示している。これを出力層から入力層まで遡って計算することにより、深層学習の予測において予測サンプルごとにその出力値に対する各入力値の貢献度を算出することができる。

$$R_i^{(l)} = \sum_j R_{i\leftarrow j}^{(l,l+1)} \qquad \text{(式 10)}$$

$$R_{i\leftarrow j}^{(l,l+1)} = \frac{z_{ij}}{z_j + \varepsilon \cdot sign(z_j)} R_j^{(l+1)} \qquad \text{(式 11)}$$

$R_i^{(l)}$　：層lユニットiの出力値に対する貢献度
$R_{i\leftarrow j}^{(l,l+1)}$　：層$l+1$ユニットjから層lユニットiへ逆伝搬する貢献度
z_j　：層$l+1$ユニットjの出力値
z_{ij}　：層lユニットiから層$l+1$ユニットjへ順伝搬する値
ε　：ハイパーパラメータ(0.001 とした)

図表 4. LRP の計算イメージ図

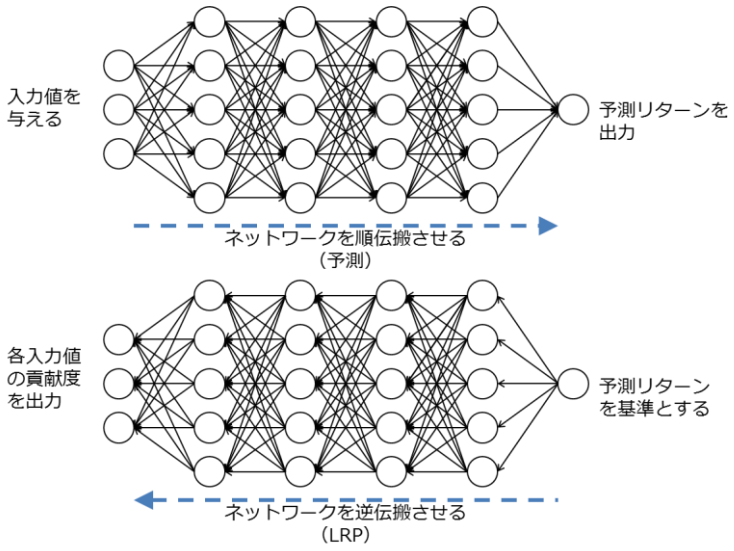

（出所）日興リサーチセンター作成

本資料は、信頼性の高いデータから作成されておりますが、当社はその正確性・確実性に関し、いかなる保証をするものではございません。本資料は、情報提供を目的としており、投資勧誘を目的としたものではございません。証券投資に関する最終判断は、投資家ご自身の判断でなさるようにお願いいたします。本資料の著作権は当社に帰属し、本資料の転用および販売は固く禁じられております。

3. 実験設定

3.1 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及び株式指数等のマーケット情報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、図表 5 のように、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（各変数は図表 13、14 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（図表 15 参照）を用い、実装は Chainer[6]で行った。

図表 5. クロスセクションでの学習と予測

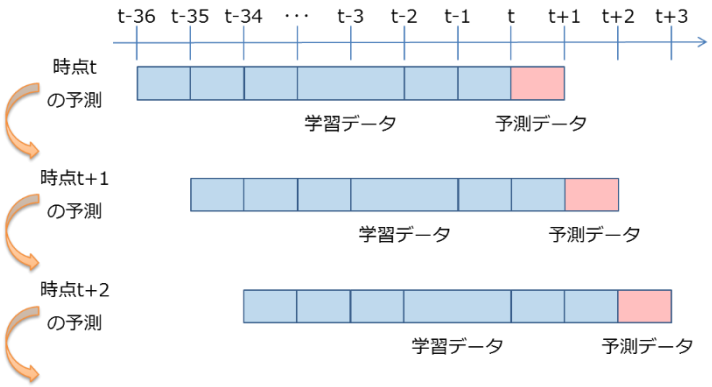

（出所）日興リサーチセンター作成

3.2 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ポジションを構築し、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、最高分位をロングポートフォリオ、最低分位をショートポートフォリオとした。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、その累積値を図表 6 に、各種パフォーマンス値を図表 7 に示した。また、参考としてロングポートフォリオとショートポートフォリオ、TOPIX のパフォーマンスも示した。ただし、TOPIX は配当込 TOPIX を示す。

[6] 本稿では、Python の深層学習のオープンソースライブラリである Chainer（https://chainer.org/）を用いた。

本資料は、信頼性の高いデータから作成されておりますが、当社はその正確性・確実性に関し、いかなる保証をするものではございません。本資料は、情報提供を目的としており、投資勧誘を目的としたものではございません。証券投資に関する最終判断は、投資家ご自身の判断でなさるようにお願いいたします。本資料の著作権は当社に帰属し、本資料の転用および販売は固く禁じられております。

図表 6. 各ポートフォリオのリターン累積値

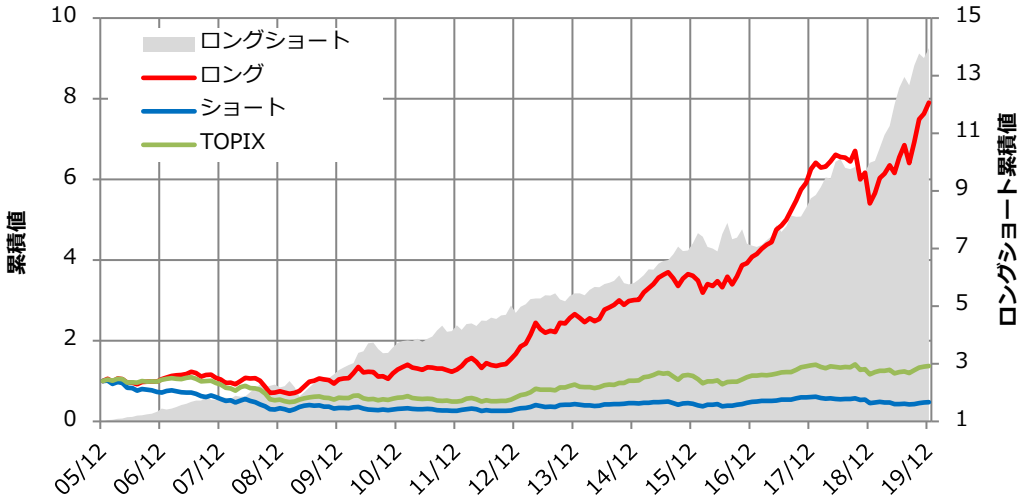

（注）各ポートフォリオの 2005 年 12 月末を 1 とし、各月のリターンの累積値を示す。

（出所）QUICK、SMBC 日興証券データより日興リサーチセンター作成

図表 7. 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（年率）	15.91%	-5.20%	20.72%	2.31%
リスク（年率）	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%

（出所）QUICK、SMBC 日興証券データより日興リサーチセンター作成

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、一定のパフォーマンスを得られることが期待できるだろう。

4. 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 貢献度は値がプラスに大きいほど、その入力の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

本資料は、信頼性の高いデータから作成されておりますが、当社はその正確性・確実性に関し、いかなる保証をするものではございません。本資料は、情報提供を目的としており、投資勧誘を目的としたものではございません。証券投資に関する最終判断は、投資家ご自身の判断でなさるようにお願いいたします。本資料の著作権は当社に帰属し、本資料の転用および販売は固く禁じられております。

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ポートフォリオにおける平均 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。

4.1　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。図表 8 は、ロングとショートのポートフォリオからそれぞれ 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。

図表 8. 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

（出所）QUICK、SMBC 日興証券データより日興リサーチセンター作成

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、色が濃い予想経常利益修正や予想益利回り、時価総額、予想 ROE、予想売上高成長率が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

本資料は、信頼性の高いデータから作成されておりますが、当社はその正確性・確実性に関し、いかなる保証をするものではございません。本資料は、情報提供を目的としており、投資勧誘を目的としたものではございません。証券投資に関する最終判断は、投資家ご自身の判断でなさるようにお願いいたします。本資料の著作権は当社に帰属し、本資料の転用および販売は固く禁じられております。

益修正のファクター値がマイナス）や割高（予想益利回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だろう。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だろう。

また、ファクターごとに銘柄間でその効果の違いを確認すると、例えば予想 ROE の場合、10 銘柄の中ではそのファクター値がプラスであれば LRP 貢献度もプラスに、ファクター値がマイナスであれば LRP 貢献度もマイナスであり、その値が大きいほど色が濃い傾向があった。しかし、<3769>と<3765>に着目すると、<3769>のファクター値は 1.80 と<3765>の 2.18 よりも小さいが、LRP 貢献度の色は<3769>の方がより濃い赤となっており、予測リターンに対し、より大きいプラスの寄与であった。これは単一のファクターの値の大小だけでなく、他の銘柄属性等によって、そのファクターの寄与の大きさが異なることが理由の一つと考えられる。

4.2　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ポ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 貢献度の平均に優位な差があるかの検定も行った。その結果を図表 9 に示す。

図表 9. ポートフォリオの平均 LRP 貢献度

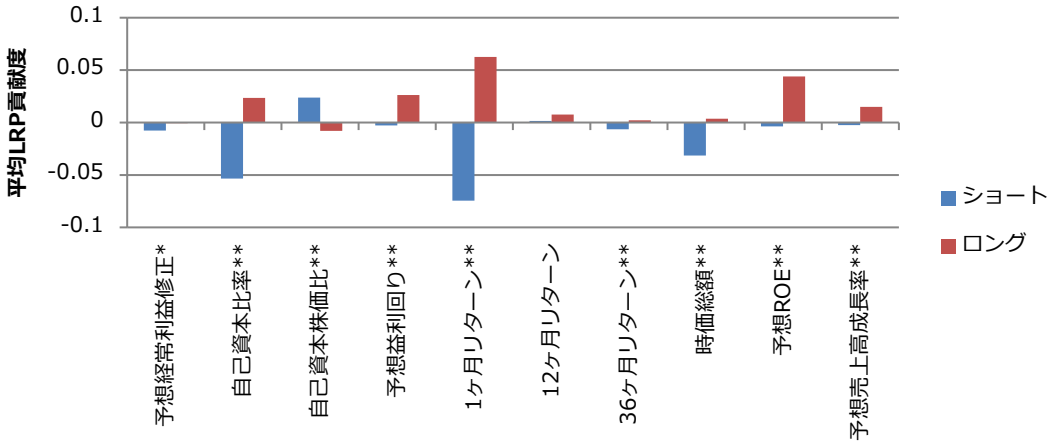

（注）各ファクターにおける平均の差の検定において、*は 5%、**は 1%有意水準をしめす。

（出所）QUICK、SMBC 日興証券データより日興リサーチセンター作成

本資料は、信頼性の高いデータから作成されておりますが、当社はその正確性・確実性に関し、いかなる保証をするものではございません。本資料は、情報提供を目的としており、投資勧誘を目的としたものではございません。証券投資に関する最終判断は、投資家ご自身の判断でなさるようにお願いいたします。本資料の著作権は当社に帰属し、本資料の転用および販売は固く禁じられております。

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%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と言えるだろう。

図表 9 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される個別銘柄レベルでの全体的な傾向が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の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、図表 10 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。

図表 10. ファクター値と LRP 貢献度の関係

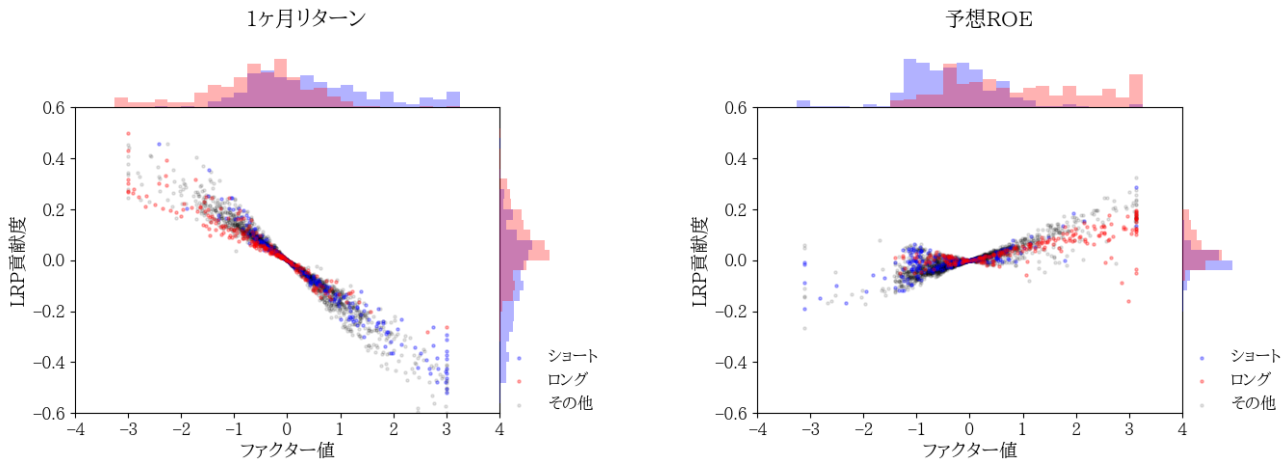

（出所）QUICK、SMBC 日興証券データより日興リサーチセンター作成

本資料は、信頼性の高いデータから作成されておりますが、当社はその正確性・確実性に関し、いかなる保証をするものではございません。本資料は、情報提供を目的としており、投資勧誘を目的としたものではございません。証券投資に関する最終判断は、投資家ご自身の判断でなさるようにお願いいたします。本資料の著作権は当社に帰属し、本資料の転用および販売は固く禁じられております。

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だろう。また、予想 ROE においては、高収益性で見たクオリティー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は、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。

4.3 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 や為替レート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。

図表 11 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、リターン予測への貢献度については、時期によってロングポートフォリオとショートポートフォリオ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の 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。

図表 11. 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

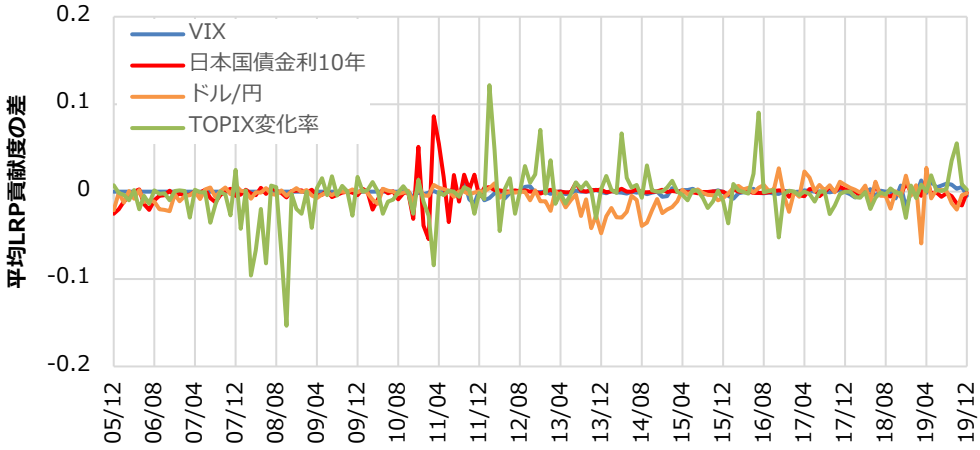

（出所）QUICK、SMBC 日興証券データより日興リサーチセンター作成

本資料は、信頼性の高いデータから作成されておりますが、当社はその正確性・確実性に関し、いかなる保証をするものではございません。本資料は、情報提供を目的としており、投資勧誘を目的としたものではございません。証券投資に関する最終判断は、投資家ご自身の判断でなさるようにお願いいたします。本資料の著作権は当社に帰属し、本資料の転用および販売は固く禁じられております。

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又は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を確認した。図表 12 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益利回りが高く、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益利回りが低く、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。

図表 12.TOPIX 変化率の LRP 貢献度順による分位の各平均ファクター値
（2008 年 10 月末基準）

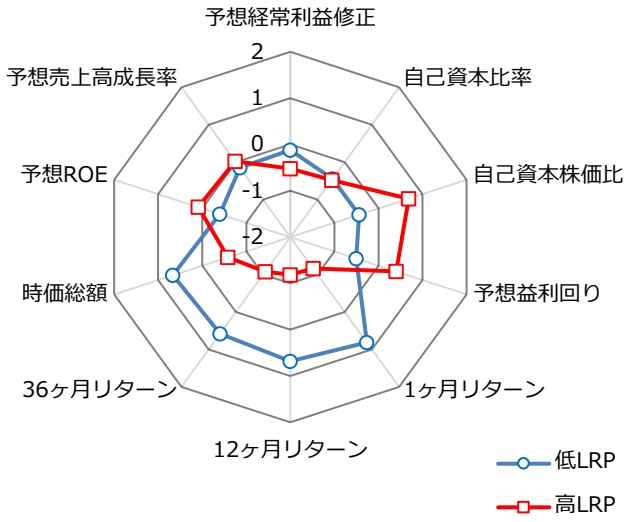

（出所）QUICK、SMBC 日興証券データより日興リサーチセンター作成

5. おわりに

本稿では、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おいて、LRP を用いることで、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。具体的な例として、個別銘柄の予測根拠の分析では、<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たこと、<3765>は収益性や安全性が高いこと

本資料は、信頼性の高いデータから作成されておりますが、当社はその正確性・確実性に関し、いかなる保証をするものではございません。本資料は、情報提供を目的としており、投資勧誘を目的としたものではございません。証券投資に関する最終判断は、投資家ご自身の判断でなさるようにお願いいたします。本資料の著作権は当社に帰属し、本資料の転用および販売は固く禁じられております。

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、全体的な傾向として、2019 年 6 月末を予測日に構築した深層学習モデルでは、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が働くことを予想しているとの解釈結果を得ることができた。さらに、予想 ROE においてファクターの値がプラスの範囲とマイナスの範囲でファクターの効果が異なる傾向がある等、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。市場情報を含めた解釈では、市場情報は個別銘柄間で入力値としては同じ値だが出力の予想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ける TOPIX の下落情報が予想リターンにポジティブな寄与とネガティブな寄与を与えている各銘柄群の属性の特徴を確認することができた。

実際に予測根拠を解釈する場合、図表 9 で概観を確認し、図表 10 で注目すべきファクターの貢献度との関係性を調べ、最終的には図表 8 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、図表 11、図表 12 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貢献度分析を行うことで、銘柄ごとの予測リターンに対する銘柄属性と市場環境との関係等を含めたより詳細な解釈が可能となる。これらの分析を時系列で行うことや、他の市場情報や銘柄属性についても同様に分析することで、深層学習による予測モデルのメリットを享受しつつ、その予測根拠への理解の向上や、実務へのさらなる応用が期待できるだろう。

（このレポートは 2019 年 10 月発行の同タイトルのレポートに加筆修正を行った改訂版になります。）

＊ 本稿の作成にあたり、東京大学大学院工学系研究科教授和泉潔先生と特任講師坂地泰紀先生に、多大なるご指導とご助言を頂いた。心から感謝の意を表したい。なお、本稿の内容・意見は全て当社に属する。

以上

参考文献

Bach, S.・Binder, A.・Montavon, G.・Klauschen, F.・Müller, K. R.・Samek, W.[2015],「On Pixel-Wise Explanations for Non-Linear Classifier Decisions by Layer-Wise Relevance Propagation」, *PLoS ONE*, 10(7): e0130140, 2015.

Carhart, M. M.[1997], 「On Persistence in Mutual Fund Performance」, *The Journal of Finance*, Vol. 52, No. 1, pp. 57-82, 1997.

Chakravorty, G.・Awasthi, A.・Silva, B. D.[2018], 「Deep Learning for Global Tactical Asset Allocation」, *Available at SSRN* 3242432, 2018.

Fama, E. F.・French, K. R.[1993],「Common risk factors in the returns on stocks and bonds」, *Journal of Financial Economics*, Vol. 33, No. 1, pp. 3-56, 1993.

本資料は、信頼性の高いデータから作成されておりますが、当社はその正確性・確実性に関し、いかなる保証をするものではございません。本資料は、情報提供を目的としており、投資勧誘を目的としたものではございません。証券投資に関する最終判断は、投資家ご自身の判断でなさるようにお願いいたします。本資料の著作権は当社に帰属し、本資料の転用および販売は固く禁じられております。

Fama, E. F.・French, K. R.[2015],「A five-factor asset pricing model」, *Journal of Financial Economics*, Vol. 116, No. 1, pp. 1-22, 2015.

Fama, E. F.・French, K. R.[2018],「Choosing factors」, *Journal of Financial Economics*, Vol. 128, No. 2, pp. 234-252, 2018.

Fécamp, S.・Mikael, J.・Warin, X.[2019], 「Risk management with machine-learning-based algorithms」, *arXiv*: 1902.05287v3, 2019.

Hou, K.・Xue, C.・Zhang, L.[2015], 「Digesting Anomalies: An Investment Approach」, *The Review of Financial Studies*, Vol. 28, No. 3, pp. 650-705, 2015.

Ito, T.・Tsubouchi, K.・Sakaji, H.・Izumi, K.・Yamashita, T.[2019],「CSNN: Contextual Sentiment Neural Network」, *19th IEEE International Conference on Data Mining (ICDM),* pp.1126-1131, 2019.

Lintner, J.[1965], 「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.

Moghaddam, A. H.・Moghaddam, M. H.・Esfandyari, M.[2016], 「Stock market index prediction using artificial neural network」, *Journal of Economics, Finance and Administrative Science*, Vol. 21, No. 41, pp. 89-93, 2016.

Nakagawa, K.・Uchida, T.・Aoshima, T.[2018], 「Deep Factor Model」, *ECML PKDD 2018 Workshops*, pp. 37-50, 2018.

Obeidat, S.・Shapiro, D.・Lemay, M.・MacPherson, M. K.・Bolic, M.[2018], 「Adaptive Portfolio Asset Allocation Optimization with Deep Learning」, *International Journal On Advances in Intelligent Systems*, Vol. 11, No. 1 & 2, 2018.

Sardelich, M.・Manandhar, S.[2018], 「Multimodal deep learning for short-term stock volatility prediction」, *arXiv*: 1812.10479v1, 2018.

Sharpe, W. F.[1964], 「Capital Asset Prices: A Theory of Market Equilibrium under Conditions of Risk」, *The Journal of Finance*, Vol. 19, No. 3, pp. 425-442, 1964.

Shi, L.・Teng, Z.・Wang, L.・Zhang, Y.・Binder, A.[2018], 「DeepClue: Visual Interpretation of Text-based Deep Stock Prediction」, *IEEE Transactions on Knowledge and Data Engineering*, Vol.31, No.6, pp.1094-1108, 2018.

Wu, W.・Wang, Y.・Fu, J.・Yan, J.・Wang, Z.・Liu, J.・Wang, W.・Wang, X.[2019], 「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.

Zeiler, M. D.・Fergus, R.[2014], 「Visualizing and Understanding Convolutional Networks」,

本資料は、信頼性の高いデータから作成されておりますが、当社はその正確性・確実性に関し、いかなる保証をするものではございません。本資料は、情報提供を目的としており、投資勧誘を目的としたものではございません。証券投資に関する最終判断は、投資家ご自身の判断でなさるようにお願いいたします。本資料の著作権は当社に帰属し、本資料の転用および販売は固く禁じられております。

European Conference on Computer Vision - ECCV 2014, pp. 818-833, 2014.

伊藤友貴・坂地泰紀・和泉潔[2018], 「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.

五島圭一・高橋大志・山田哲也[2019], 「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.

酒井博貴・亀谷由隆・曽田尚宏・有江浩明[2018], 「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 *JSAI2018*, 2A2-04, 2018.

塩野剛志[2018], 「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.

宮崎邦洋・松尾豊[2017], 「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

図表 13. 個別銘柄の属性値（ファクター値）

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

（出所）日興リサーチセンター作成

本資料は、信頼性の高いデータから作成されておりますが、当社はその正確性・確実性に関し、いかなる保証をするものではございません。本資料は、情報提供を目的としており、投資勧誘を目的としたものではございません。証券投資に関する最終判断は、投資家ご自身の判断でなさるようにお願いいたします。本資料の著作権は当社に帰属し、本資料の転用および販売は固く禁じられております。

図表 14. 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。

（出所）日興リサーチセンター作成

図表 15. 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	ニューロン数	126
隠れ層 1	ニューロン数	64
	活性化関数	tanh
	ドロップアウト	0.4
隠れ層 2	ニューロン数	64
	活性化関数	tanh
	ドロップアウト	0.4
隠れ層 3	ニューロン数	32
	活性化関数	tanh
	ドロップアウト	0.4
出力層	ニューロン数	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

（出所）日興リサーチセンター作成

本資料は、信頼性の高いデータから作成されておりますが、当社はその正確性・確実性に関し、いかなる保証をするものではございません。本資料は、情報提供を目的としており、投資勧誘を目的としたものではございません。証券投資に関する最終判断は、投資家ご自身の判断でなさるようにお願いいたします。本資料の著作権は当社に帰属し、本資料の転用および販売は固く禁じられております。