

AIを使った運用のポイントと 実務的応用の可能性

～伝統的な運用手法との融合について～

統計数理研究所 リスク戦略解析センター 客員教授
ニッセイアセットマネジメント 投資工学開発センター長

吉野 貴晶



1. はじめに

近年、運用実務においてAI (artificial intelligence、人工知能) を用いた投資が注目を集めている。AIの手法を用いた銘柄選別のシステムや、アロケーションなどを行うファンドも増えている。一方、最近ではAIに対して過度な期待は、禁物とも言われ始めている。

〈目次〉

1. はじめに
2. 運用に用いられるAIの特徴と今後
3. 伝統的な投資戦略のP/B-ROEモデル
4. P/B-ROEの将来のパラメータ予測概要
5. 分析方法
6. 分析結果
7. おわりに

今後、運用実務においてAIの活用が、更に加速すると見込まれるなか、我々は、その方向がどのように進んでいくのか知っておく必要がある。本稿は、株式の運用実務におけるAIの特徴を確認した後、今後の発展の方向を考察し、伝統的な計量投資手法との融合モデルを考案する。

AIを利用した戦略の1つには、次のようなものがある。現在の株価変動のパターンと類似する過去の変動局面を探して、当時の株価推移から、将来の株価変動を予測するものである。類似度の尺度には様々なものがあるため、単純な株価推移の形が似ているものを探すわけではない。しかし、この戦略は過去の株価情報のみを使っているため、予測手法の根拠に、伝統的なファイナンスの理論や、近年、注目の行動ファイナンスからの解釈も必要となっている。

AIの戦略は一般の投資家からブラックボックスで解釈が難しいものと捉えられがちで

ある。今後は期待される効果に関して、理論的な根拠が重視されるだろう。そして、説明が可能になれば、ファイナンス理論に基づく重要なツールとして、伝統的な統計手法を使って行われてきた戦略と融合した戦略への発展も期待できる。

本稿でAIを論じる上で、以下ではAIについて改めて確認をする。AIには明確な定義はないが、実務面では「人間のもつ知能を再現するために作られた機械」という、広い概念がある。更に「知能を再現するための機能の1つで、データから規則性を発見すること」が近年、広く使われる機械学習とされる。つまり、機械学習はAIを実現するための手法の1つである。機械学習ではサンプルが多い方が、学習精度が高まるため、近年はビックデータを利用するケースが増えている^(注1)。ビックデータの活用が進むなかで、共にAIも発展している。

そして、ここで近年AIが注目されてきた背景を整理すると、以下の3つがあげられる。

第1に、コンピュータの処理能力や記録容量の増大と、利用コストの低下である。高性能のGPU (Graphics Processing Unit) の開発が進むなか、機械学習する上で、その搭載マシンにより学習時間も短縮できるため、効率が高まり、実務面での有用性も高まっている。

第2に、POSや、クレジットカードなどの利用可能なデータも増えていることである。様々なデータが大量に取得できるようにな

り、機械学習の活躍分野が増えている。

第3に、実用面でAI導入の効果が実証されてきたことである。身近では例えば医学における画像診断や、自動運転などの発展も見られている。

今後こうした流れは、加速するだろう。

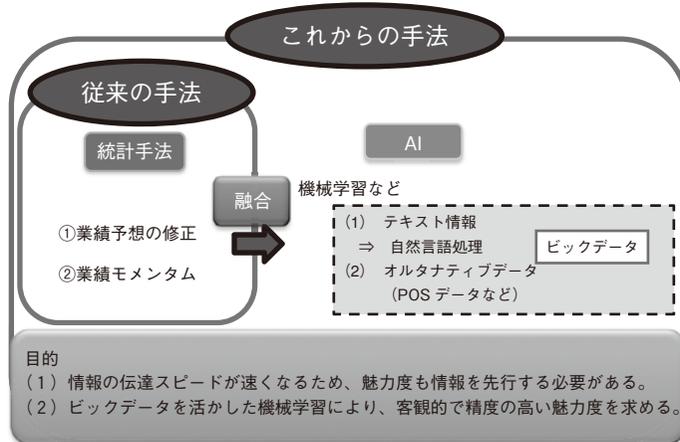
■ 2. 運用に用いられるAIの特徴と今後

—伝統的な投資戦略との融合—

本章では、近年のAIを使った株式運用手法に関する特徴と、今後のAIの活用の方向を考察する。機械学習の手法やアルゴリズムではなく、実務における有用性の観点に焦点をあてて整理する。

AIの投資手法への活用は、従来の回帰分析などの統計手法の利用から、更に進んだ定量ツールとしての期待が、背景にある。そのうちの1つが、自然言語処理と言われるように、テキスト (文書) 情報の評価である。例えば、証券会社などのアナリストが作成する企業評価のレポートを評価して、得点 (極性値) を付与する戦略がある。一般に投資家はアナリストの将来の利益予想に注目している。予想値が修正されると、株価も反応するため、その修正後に投資する戦略がある。運用実務では利益予想のリビジョン戦略と呼ばれている。自然言語処理によるアナリストレポートの得点化に関しては、次のような根拠がある。実際のアナリストが利益予想を修正

(図表1) AIを運用手法に応用する流れ



する前に、文脈に情報が現れているという考えである。アナリストにとって数値情報である予想利益の修正は、投資家へのインパクトも大きい。従って、確信度が高くなってから実際の修正に踏み切るものと考えられる。しかし、アナリストの利益の方向への表現はレポートの文脈に表れていると考えられる。レポートの得点化は、将来のアナリストの利益予想修正の予兆を捉える趣旨がある。

一方、近年、これまで一部の組織などで管理されていたデータも取引されるようになっており、別の組織でも分析や活用がなされるようになってきている。代表的なものがトランザクション (transaction: 取引) データである。商品の受発注や支払いなどを記録したもので、代表的なものがPOS (Point of Sales) である。店のレジで販売される時のデータである。こうした大量なデータが取得できることは、学習サンプルが多い点から機械学習を使

うことに多くのメリットがある。例えば、POSを使う株式投資戦略に関しては、日々ベースで取得できるデータから、企業の売り上げの伸びを先行して捉えることも可能となるだろう。

こうした考え方の根底には、伝統的に運用実務で用いられてきた個別銘柄の魅力度を、従来の手法より先行して算出する目的がある。

新たに取得可能となったテキスト情報やPOSから、AIを用いることで、銘柄の魅力度がより早く捉えられるようになる。前者は、利益予想リビジョンを先行する目的であり、後者は、業績モメンタムを先行して捉えるものである。こうした、より早い魅力度の算出が、AIを運用手法に応用する上で重要な第1の目的である。

近年、インターネットや様々な情報ベンダーなどを通じて、市場に情報が伝わるスピー

ドが速まっている。このため従来の方法で求めた魅力度では、得られるリターンが小さくなっている。ビッグデータや、AIの手法を活かして、より早く魅力度を求めることで高いリターンの獲得を目指すことが可能となる。

また、AIを運用手法に応用する上で重要な第2の目的は、AIの客観性を重視するものである。機械学習では大量なデータを学習させることで客観的な判断ができる。企業評価をする場面では、様々な財務指標が注目される。人間の判断では、先入観や様々な“思い”などから、恣意的な評価が行われる可能性がある。AIを使うと、大量なデータの処理から客観的な企業評価が可能となる。

その一方で、AIを活用する上で留意すべき点は、AIが将来の予想を的中させる道具として行き過ぎた期待をすることである。予測精度が悪い場合に、説明変数を増やしたり、モデルを複雑にすると、過学習に陥りやすくなる。ファイナンス理論などから、これまでも実務で用いられている魅力度に関して、先行性や、推計の客観性に着目して、AIを利用する戦略が効果的である。そして、従来の統計手法との融合により、より銘柄選択能力の高い魅力度を求めることができるようになる。

■ 3. 伝統的な投資戦略の P/B-ROEモデル

(1) P/B-ROEモデル

近年、運用実務において、PBRとROEを

変数に用いて企業の魅力を算出するP/B-ROEモデルが広く利用されている。そこで本稿は同モデルに関して、AIを適用する手法を考案する。

P/B-ROEモデルはWilcox [1984] で考案されたものである。基本は(1)式の回帰モデルが用いられる。

$$\ln(PBR_{i,t}) = a_t + b_t \times ROE_{i,t} + \varepsilon_{i,t} \quad (1)$$

$PBR_{i,t}$: i 銘柄の t 時点におけるPBR

$ROE_{i,t}$: i 銘柄の t 時点におけるROE

a_t, b_t : t 時点における回帰分析の切片項及び回帰係数

$\varepsilon_{i,t}$: i 銘柄の t 時点における回帰分析の残差項

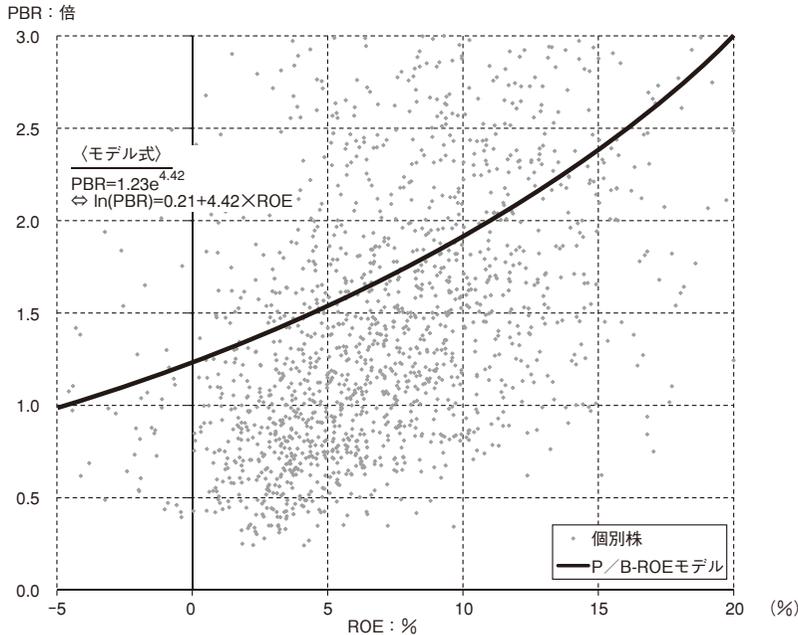
P/B-ROEモデルに関しては、様々な発展的な利用方法も見られるが、ベースは、次のように用いられる。まず、ある時点における、ユニバースの銘柄群を設定する。そしてROEを説明変数とする一方、自然対数を取ったPBRを被説明変数として、(1)式のクロスセクション回帰分析を行い残差項を求める。そして、残差($\varepsilon_{i,t}$)が小さい(マイナスが大きい)銘柄を割安株と捉えるものである。

(2) PBR、PERとROEの関係

本節では、P/B-ROEモデルの理論的根拠を示す。同モデルはPBR、PERとROEの関係を基本としている。PBR、PERとROEは(2)式の関係を持つ。

$$PBR = PER \times ROE \quad (2)$$

(図表 2) PBRとROEの散布図と回帰モデル



(注) 2018年7月末時点。ROEに用いた純利益は東洋経済新報社の予想利益を用いている。

ここで(2)式を確認する。仮に、右辺のPERを固定して考える。PERは正数であるため、ROEが高ければ高いほど、左辺のPBRが高水準まで許容される。

これを具体的な企業活動で考えると次のようである。ROEが将来も持続すると考えた場合に、内部留保の部分が将来の自己資本として積み上がっていく。高ROEが持続できる企業ほど毎年積み上がる自己資本が大きくなるため、将来は大きな自己資本が見込まれる。このため現在の自己資本を基準に求めたPBRでは、高水準まで許容される。

更に、実際のP/B-ROEモデルは(1)式の左辺で示されるように、PBRは対数値に

なっている。そして、i銘柄のt時点での対数PBRの期待値は、実際のデータから回帰分析により求める切片(\hat{a}_t)と回帰係数(\hat{b}_t)を用いた(3)式で推計される。

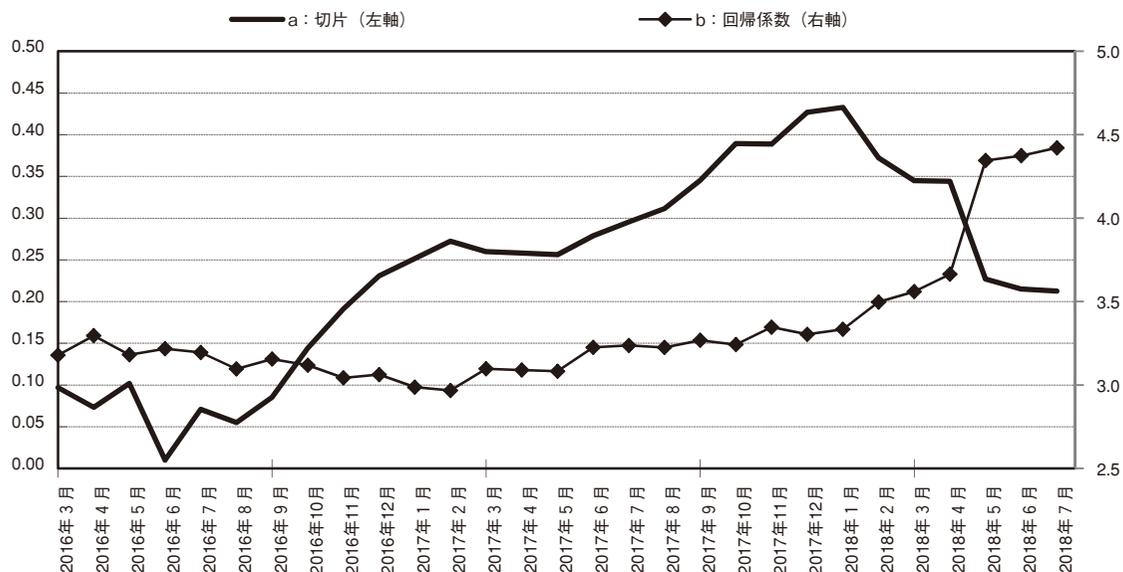
$$E[\ln(PBR_{i,t})] = \hat{a}_t + \hat{b}_t \times ROE_{i,t} \quad (3)$$

E[]:期待値

\hat{a}_t, \hat{b}_t : a_t, b_t の推計値

更に、(3)式を指数の形に変換すると(4)式となる。これは、自己資本が、ROEに関してPERの意味を持つ代理変数を通じて、複利ベースで伸びていくことを示している。

(図表3) 切片と回帰係数の時系列変化



(注) 対象期間は2016年3月末から2018年7月末。対数ベースでの値を表示している。

$$E[PBR_{i,t}] = e^{\hat{a}_t} \times e^{\hat{b}_t \times ROE_{i,t}} \quad (4)$$

図表2では、2018年7月末時点の、(4)式の回帰線と、銘柄の散布図を示している。回帰線に関しては次のようである。東証1部企業を対象に7月末でクロスセクショナルに(1)式の回帰分析を行い、推計した切片(\hat{a}_t)と回帰係数(\hat{b}_t)を用いている。

こうした東証1部企業のサンプルから推計した切片(\hat{a}_t)と回帰係数(\hat{b}_t)は、対象企業の切片と回帰係数が同じ確率分布を持つという前提に基づいている(注2)。そして、傾向線からの乖離を基準とした値が、ROEの観点から見て、PBRの割安度を示している(注3)。

(3) 傾向線のシフトについて

図表2の傾向線は、個別銘柄のPBRとROEの時系列の変化に伴いシフトする。図表3は本稿で行う実証分析の対象期間とする、2016年3月以降の切片(\hat{a}_t)と回帰係数(\hat{b}_t)の推移である。

切片(\hat{a}_t)の変動は、投資家のセンチメントと関係が強いと考えられる。2016年終盤から2017年初頭にかけての上昇と、2017年月中旬から年末にかけての上昇と、大きく2つの上昇期が見られる。前者は米国でトランプ氏が大統領に決まった後のトランプラリーとも呼ばれる上昇相場であり、後者は2017年10月の衆院選で自公連立与党の大勝によるアベノミクス継続期待による相場上昇場面である。一方、

2018年に入ってから切片は低下している。これは欧州や米国の金利上昇により1月下旬から世界的に株価が下落した場面との関係が強い。

回帰係数(\hat{b}_t)は切片の変動と、対称的に推移する。2018年以降は切片が大きく下がった一方で、回帰係数は上昇している。そして、回帰係数はROEの持続性に関係すると見られる。高ROE銘柄の高PBRが許容される場面は、高ROEが持続するために、将来の自己資本の高い積み上がりが見込まれる状況である。これはROEの平均回帰^(注4)が考えにくい環境である。

切片と回帰係数は、経済環境や投資家のセンチメントにより変化する。このため、現在のP/B-ROEモデルから魅力度が高いと考えられていても、P/B-ROEモデルの傾向線がシフトすることで、将来の魅力度は下がる可能性もある。従って、将来の傾向性が予測できるなら、より妥当に魅力度が求められると考えられる。

このような傾向線の将来のシフトを、マクロ経済指標などを使って、伝統的な統計手法やAIを用いて予測可能ならば、より有用な戦略が期待できる。

そこで、本稿ではAIを用いて、P/B-ROEモデルの将来の切片(\hat{a}_t)と回帰係数(\hat{b}_t)を予測する戦略を考案する。

■ 4. P/B-ROEの将来のパラメータ予測概要

本章では、AIを用いたP/B-ROEモデルの将来の切片(\hat{a}_t)と回帰係数(\hat{b}_t)を予測するモデルを示す。具体的には、図表4に示されるように中間層が3層のニューラルネットワークモデルを設定して、機械学習によりモデルを特定する。本稿では、AIの手法にどの程度の効果があるのかをシンプルに観察する目的から、モデルは複雑なものを設定していない。

入力層は、P/B-ROEモデルの切片と回帰係数の変動に影響を与えると考えられる3627系列を変数とした。これらはマクロ指標やセミマクロ指標などである。

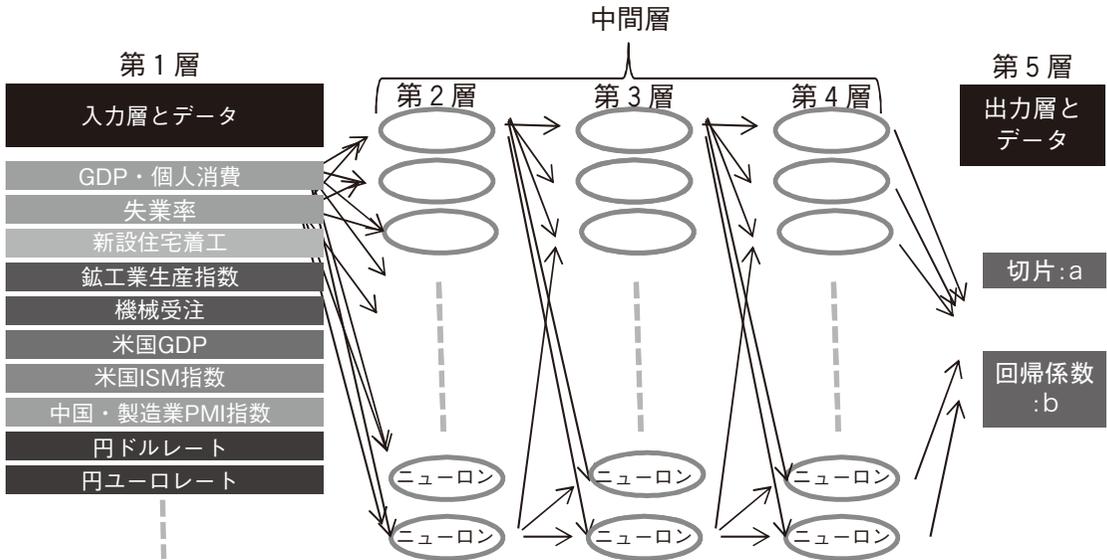
出力層は切片(\hat{a}_t)と回帰係数(\hat{b}_t)を同時に推計するモデルを設定する。これは前述したように、切片と回帰係数の変動はお互いに関係が強く見られるからである。

ニューロンの数などのハイパーパラメータに関しては、グリッドサーチ^(注5)により設定している。

更に、予測手法による有効性の違いを比較するため、伝統的な統計手法の1つとして回帰モデルも取り上げる。入力データは同じものを設定して、切片と回帰係数のパラメータの予測も行うものである。

実際のモデルは(5)式で示される。前月のマクロ変数を用いて、翌月の切片項と回帰

(図表4) ニューラルネットワークモデル構造



係数を別々に予測する (注6)。また、回帰モデルの説明変数に関しては、3627系列を対象に、ステップワイズによる変数選択により絞る (注7)。

象があるが、本稿ではシンプルに機械的な処理に従った。

5. 分析方法

(1) ベースとなるP/B-ROEモデルの算出

本章ではP/B-ROEモデルに関して、ニューラルネットワークモデルでパラメータを予測する場合の銘柄選択効果の検証方法を示す。

分析ユニバースとする東証1部企業を対象に、毎月末に、回帰分析を行いP/B-ROEモデルの切片(\hat{a}_t)と回帰係数(\hat{b}_t)の推計を行う。

説明変数に個別銘柄のROE、被説明変数

$$E[a_{t+1}] = \hat{\alpha} + \sum_{k=1}^n \hat{\beta}_k \cdot state_{t,k} \quad (5)$$

a_t : t時点の切片項、又は、回帰係数

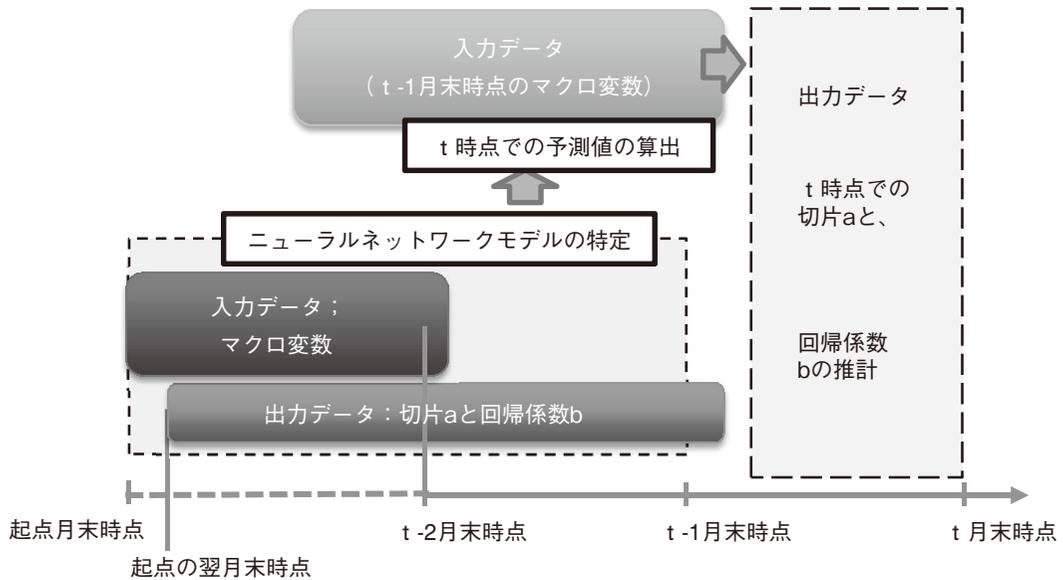
$state_{t,k}$: t時点のk番目のマクロ指標などの変数

$\hat{\alpha}, \hat{\beta}$: 回帰分析により求めた α, β の推計値

本稿における、切片と回帰係数の予測値に関する検証の直近値は、2018年7月末のデータである。同時点で予測に用いられる変数は、ステップワイズにより切片が48変数、回帰係数が38変数に絞られる。

一般に回帰モデルとしては、変数が多い印

(図表 5) 予測モデルにおける時間的關係



が対数PBRを設定している。これらは連結決算優先で求めている。ROEに関しては、各月末時点で本決算で明らかになっている実績自己資本と、予想純利益を用いている。予想純利益は東洋経済新報社の予想を用いている。そして、月末から将来12カ月間の予想値を使うため、1期先予想と2期先予想を按分する。一方、PBRに関しては、各月末時点で取得可能な自己資本と時価総額を用いる。そして、回帰分析を行う際の変数は、ユニバース対象に上下1%点で丸める異常値処理を行った。

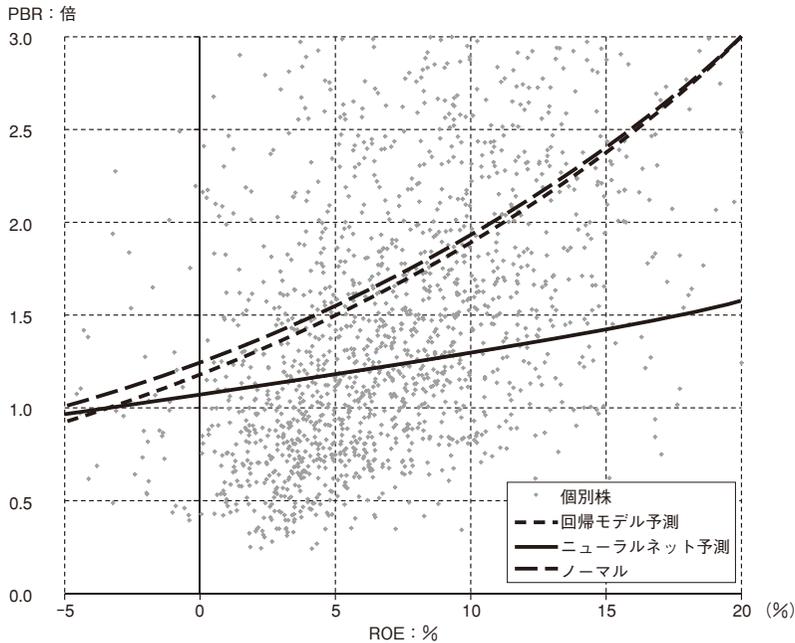
このように検証に用いるP/B-ROEモデルの回帰分析の推計は2008年9月から2018年7月末までとする。しかし、ここから推計される切片と回帰係数を用いて、更にニューラ

ルネットワークで出力値として切片と回帰係数を予測後、それらの、予測値によるP/B-ROEモデルの有効性の検証を行う。

従って、実際にリターンとの関係を検証するための、モデルの有効性の検証分析については、リターンの分析対象期間は2016年4月から(2016年度以降)2018年8月までとする。そして、月次サイクルベースの月次リターンを用いている。

これに対応して、P/B-ROEモデルで求める魅力度に対する、翌月のリターンとの検証を行うため、ニューラルネットでの予測P/B-ROEモデルは、上述したリターンの分析期間に応じて、それぞれ1カ月前の2016年3月末から2018年7月末の毎月次で推計する。

(図表6) 3つのP/B-ROEモデルの傾向線



(注) 2018年7月末時点。ROEに用いた純利益は東洋経済新報社の予想利益を用いている。

(2) ニューラルネットワークモデルによる将来のパラメータ予測

本節はニューラルネットワークモデルによる将来のパラメータ予測の時間的関係を示す。

実際には次のようである。t月末時点でのP/B-ROEモデルの切片と回帰係数の推計には、t月末時点のマクロ指標などの様々な変数が必要である。そして、t-1月末時点で決定したニューラルネットワークモデルを用いる。t-1月末時点でモデルを特定するには、t-2月末時点でのマクロ変数と、t-1月末時点のP/B-ROEモデルを使って、回帰分析で求めた切片と回帰係数の関係まで用

いることができる。前述したように学習データ起点は、2008年9月である。そして、その前月末のマクロ変数と当月の切片、回帰係数とのデータを学習させる。

今回の分析ではP/B-ROEモデルは2016年3月末から月次サイクルで推計値が必要となる。推計における学習サンプルの取得では、サンプル数を増やすことから、起点は固定している。このような月次サイクルの分析では学習サンプルの確保が難しいことが問題となる。そこで学習データの起点を固定することでなるべくサンプルを増やすことに努める。

また、ニューラルネットワークモデルにおけるパラメータの推計においては、初期値が

(図表 7) 銘柄選択効果の分析結果

	ノーマル	回帰モデル予測	ニューラルネット予測
平均値	-0.406%	-0.056%	0.605%
標準偏差	14.171%	14.040%	13.946%
平均÷標準偏差	-0.029	-0.004	0.043

(注) 2016年8月から2018年7月までの分析結果

(図表 8) 有効性の差の分析結果

	回帰モデル予測	ニューラルネット予測
差の平均値	0.797%	0.351%
差の標準偏差	1.432%	0.396%
平均÷標準偏差	0.557	0.886

(注) 2016年8月から2018年7月までの分析結果。月次のリターンの差の平均値と標準偏差を求めている。

ランダムであるために 実行するたびに結果が異なる。このため、パラメータの推計は100回行い、その平均値を用いる。

比較のために、行った回帰モデルによる予測も、データの入出力や予測値の時間的關係は図表5と同様に扱っている。

図表6は、ニューラルネットワークモデル、回帰モデルとノーマル（切片と回帰係数に関して、単純にP/B-ROEモデルでの回帰分析で求めたもの）の3つのパターンにおいて、2018年7月末におけるモデルの推計値をプロットしている。回帰モデルはノーマルと余り大きく違いが見られない。一方、ニューラルネットワークモデルは大きく異なっている。これは、むしろ長期的な傾向性のシフトを示している可能性もある。

6. 分析結果

本節では検証結果を示す。分析対象はTOPIX500銘柄に絞った。これは銘柄の流動性の点で、運用実務面での有用性を検証する観点からである。

先ず、月次でP/B-ROEモデルに関して、シンプルにクロスセクション回帰分析で求めたものの銘柄選択効果を求める。それに対して、ニューラルネットワークモデルで推計したものがどの程度、効果が高まるかの検証である。

銘柄選択効果の算出方法は、運用実務で一般的なスプレッドリターンの手法を用いる。毎月末にP/B-ROEモデルから推計した銘柄別の魅力度をTOPIX500を対象として、上位20%の銘柄で作った等金額投資ポートフォリオの翌月のリターンを求めた後、下位20%

(図表9) 近年注目のファイナンスのテーマ

	カテゴリー	内容	実務面での利用について
1	行動ファイナンス	リターン分布の標準偏差など	低リスク投資
2		リターン分布のテイルリスク	テイルリスクが大きい銘柄への投資
3	企業経営の質	ESG	ESG投資
4		ROEの持続性	クオリティ投資
5		設備投資額	妥当な設備投資企業の評価→経営力の評価
6		キャッシュ保有とグロースオプション	妥当なキャッシュ保有と、対応するグロースオプション
7		組織資本 (organization capital)	企業の組織資本が大きい企業への投資
8		企業文化 (organization culture)	企業文化が優れている企業への投資
9		利益マニピレーション	利益マニピレーションの可能性が高い企業をネガティブ銘柄として選別
10		信用リスクモデル	信用リスクの観点での銘柄選別
11		サプライチェーン	複雑性の評価
12		企業のライフサイクル	ライフステージごとの企業評価尺度
13	会社計画の行動	経営者予想の保守的バイアス	保守的な利益予想のパターン
14	決算発表イベント	決算時の株価反応	上方/下方修正企業の実際の株価反応の違い
15	リスクプレミアム	市場センチメント	β コントロール戦略
16		ハーディング	ハーディング銘柄を回避する投資
17		銘柄保有の集中度	将来の株式需給の予測
18		流動性リスクプレミアム	流動性に対するリスクプレミアムの計測とそれを利用した投資
19		ニュースイベントに対する反応	反応の大きさに応じた投資戦略
20	情報の不確実性	市場の効率、成熟度合	市場の効率度合いで使うモデルを変える
21	市場の流動性	長短期的な株価予測	ティックデータ、板情報や出来高を用いた予測

の銘柄で作った等金額投資ポートフォリオのリターンを引いたスプレッドのリターンを求めるものである。

図表7はそれらの平均値を年率換算したものである。分析結果から、ニューラルネットワークによる推計が最もリターンが大きかった。また、月次のリターンの変動を示す標準偏差で除した値も大きく、有効性が高かった。

この結果、ニューラルネットワークにより、将来のP/B-ROEモデルのシフトを予測する戦略は、ノーマルなものより銘柄選択効果が高まることが明らかとなった。また、回帰モデルによるシフトの予測よりも効果が高いことも分かった。

更に、図表8では、ニューラルネットワークによる推計と、予測を行わずにシンプルなものの月次のリターンとの差がどの程度であるかを比較している。ただ、この分析の結果から差は大きくなく、図表中には示していないが、統計的な有意性は確認される程度ではなかった。

今回、検証に用いたニューラルネットワークモデルは、シンプルなものであった。今後は、より精度の高いモデルへの発展も必要となる。

7. おわりに

本稿は、株式運用実務に応用の流れが見ら

れるAIを確認した後、AIの手法を適用したP/B-ROEモデルを考案した。

銘柄選択効果の検証結果から、通常用いられているような将来のP/B-ROEモデルのシフトの予測を行わないものより、AIを使った予測を用いたものの方が、銘柄選択効果は高まることが明らかになった。

様々なファイナンス理論を背景とした、投資戦略の分野においても、AIを用いることで、これまで使われてきた統計手法による戦略からの更なる発展が期待される。

図表9では、近年の運用実務におけるファイナンスのテーマであり、伝統的な統計手法などが使われていた主な分野を取り上げている。今後、これらの分野でも、AIを用いたモデルの活躍が期待されている。

AIのモデルは、これまでの統計モデルと異なり、要因分解などが分かり難い。このため、実証分析の分野よりも“予測手法”の面での発展が期待される。今後は、効果的に伝統的な手法との融合を行っていくには、どのようにアプローチすべきかが重要なテーマとなるだろう。

本稿を作成するにあたり、片山幸成氏、高野 幸太氏、大平貴之氏（以上、ニッセイアセットマネジメント）より有益なコメントを頂いた。ここに記し、感謝申し上げます。本稿に掲載されている内容や意見は筆者個人に属し、筆者が所属する組織の公式見解ではない。また、あり得べき誤りは、全て筆者に帰属するものである。

[参考文献]

- ・ Wilcox, J.W. 1984. “The P/B - ROE Valuation Model” *Financial analysts journal*. 40 (No. 1 (Jan. - Feb., 1984)) : pp. 58 - 66.
- ・ Wilcox, J.W. & Philips, T.K. 2005. “The P/B-ROE Valuation Model Revisited” *The journal of portfolio management*. 31 (4) : pp. 56 - 66.

- (注1) データ量に関して、サンプルは多い方が良いが、説明する変数が多いと過学習になることは注意点である。
- (注2) 運用実務では業種などのカテゴリー毎に、パラメータの分布が異なるとするケースがある。この場合は、業種毎に回帰モデルを行い、パラメータを推計するケースもある。
- (注3) 実際は対数ベースの(1)式の残差自体が投資尺度とされる。図表2のPBRからの傾向線からの乖離ではROEの水準別に乖離の分散が大きく異なる。
- (注4) 高ROE銘柄の将来のROEが低下する一方、低ROE銘柄の将来のROEが上昇する現象。
- (注5) ハイパーパラメータを自動的に最適化して求める。Pythonのscikit learnを用いている。
- (注6) ニューラルネットワークモデルと同様に、切片と回帰係数を同時に推計するモデルも考えられるが、ここではシンプルな回帰モデルと比較することを目的とする。
- (注7) 変数の絞り込みを厳しくするため、ステップワイズにおける変数を加える基準を厳しく、除外する基準は緩くしている。