

キャップレート推計モデルの予測精度向上へ向けて

～ ディープニューラルネットワークを用いたモデル構築の試行 ～

2021年3月8日

株式会社三井住友トラスト基礎研究所

私募投資顧問部 主任研究員 米倉勝弘

- ◆ 本稿では、キャップレートの予測精度向上を目的にディープニューラルネットワーク(Deep Neural Network)を用いた推計モデルの構築を試みた。重回帰モデルによる予測結果と比較したところ、ディープニューラルネットワークモデルの RMSE は重回帰モデルの RSME を下回っており、予測精度が向上していることが確認できた。今後は、ニューラルネットワークを拡張した再起型ニューラルネットワーク (RNN) や長短期記憶ニューラルネットワーク (LSTM) を適用することにより、時系列的な分析を進めるこことを考えている。
- ◆ ディープニューラルネットワークを用いたモデルは、データ数が豊富にあり、非線形的関係や交互作用の影響を反映したい場合、複数の目的変数を扱う場合などにおいて特に有用である。キャップレートの推計モデルにおいては、画像データなどを取り入れることで、予測精度の更なる向上が期待できる。ディープニューラルネットワークモデルに対する世の中の理解が進めば、その精度の高さから、メインモデルの結果の精度確認や、メインモデルの結果を幅で捉える際のサブモデルとして、ディープニューラルネットワークモデルを使用することも考えられるのではないだろうか。

1. はじめに

不動産投資を行うにあたって不動産のフェアバリューを把握することは極めて重要であり、キャップレートの予測を行う目的で様々な手法により推計モデルの構築が試されている。推計モデルを構築する際の着眼点としては大きく2つある。モデルの解釈性に着目する場合と予測精度に着目する場合である。モデルの解釈性に着目する場合では、従来の統計的手法(回帰分析などの多変量解析)によりモデルを構築するケースが一般的であるが、予測精度に着目する場合、深層学習を含む機械学習手法(決定木ベースのアンサンブル学習やディープニューラルネットワーク)が活用されるケースが出てきている。

そこで本稿では、キャップレート推計モデルの予測精度向上を目的として、ディープニューラルネットワークを用いたモデル構築を試みた。データサンプルは、東京都に所在するオフィスの J-REIT 取引データを利用している。また、予測精度向上を確認するため同一サンプルを用いた重回帰モデルによる予測値との比較を行った。なお、ディープニューラルネットワークの実装には、Python の深層学習ライブラリである PyTorch (<https://pytorch.org/>) を用いている。

2. ディープニューラルネットワークを用いたモデルの構築

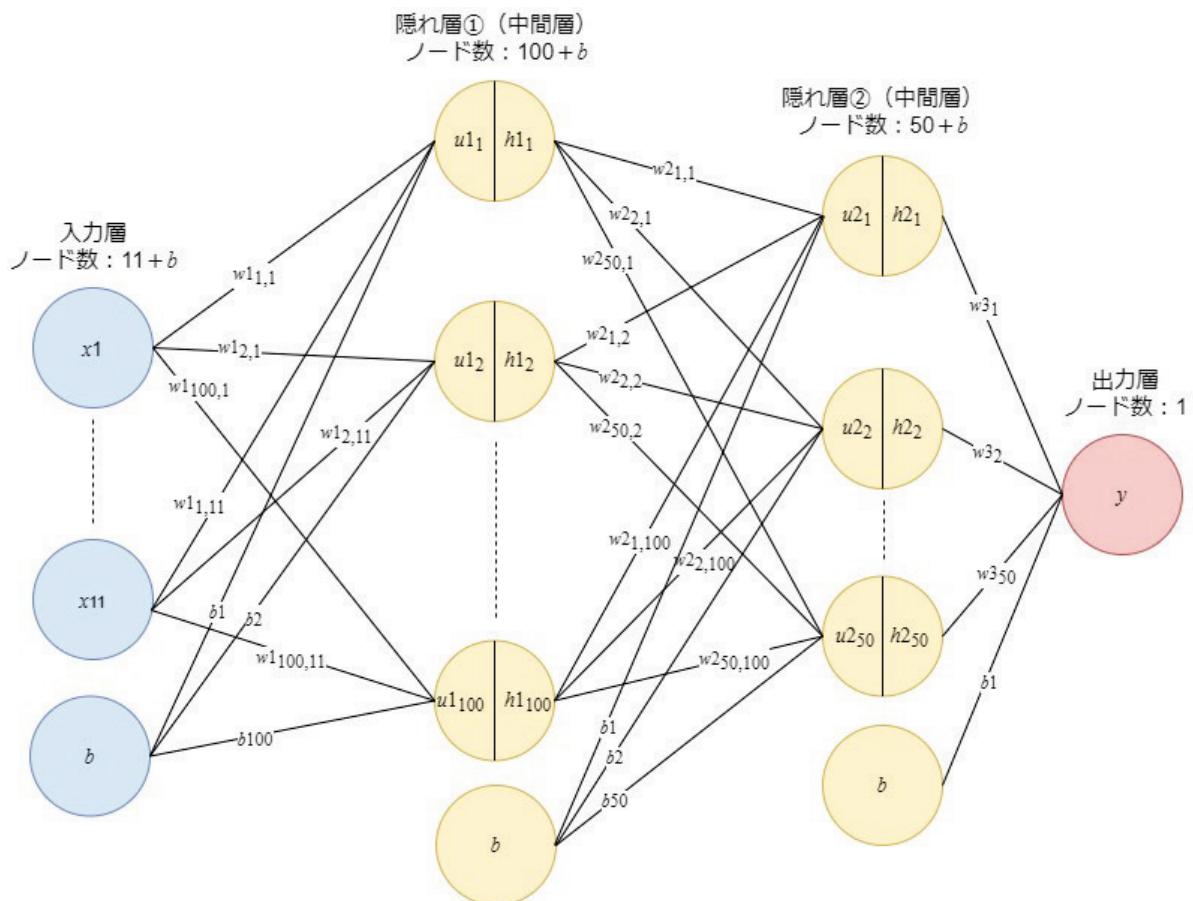
ディープニューラルネットワークは、脳の神経回路の一部を模した数理モデルであるニューラルネットワークを多層に結合した深層学習モデルである。本モデルは、目的変数と説明変数の非線形的関係や説明変数の交互作用の影響を表現し易い。交互作用とは、2つ以上の要因が考えられるとき、要因が組み合わさったときにだけ現れ

る作用を示す。

その理由は、以下のモデルの構造にある。このモデルは、分析者が説明変数を与える入力層と目的変数の出力層、その間の複数の隠れ層（中間層）で構築されている。説明変数から直接的に目的変数を予測するのではなく、複数の隠れ層（中間層）を経由して目的変数を予測する。最初の隠れ層では、入力層から多数の特徴量が抽出され、その情報は非線形に変換された上で、次の隠れ層に伝達される。この時、目的変数の実績値と予測値の誤差が最も小さくなるようにモデルが自ら学習を繰り返し、説明変数や特徴量の重み付けが決められる。この過程において、人間の思考では整理しきれない変数間の交互作用がモデルに反映され、予測精度を高めることが可能となっている。但し、この点は深層学習の中身がブラックボックスであると言われる所以でもある。

本稿では、サンプルデータの一部を用いたバリデーションデータ（モデル検証用データ）による試行錯誤の結果、隠れ層を2層にしたモデルを採用した（図表1参照）。

図表1:ディープニューラルネットワークを用いたキャップレート推計のフロー図



出所)三井住友トラスト基礎研究所

入力層の入力変数 x にはキャップレート形成要因である行政的要因（容積率、用途地域等）、立地要因（最寄り駅までの距離、中心部までの距離等）、ビルスペック要因（延床面積、築年数等）、市況要因（マーケット賃料水準等）の 11 変数を用いた。また、隠れ層①では入力変数から 100 の特徴量ⁱを抽出し（図表 1 の $u_{11} \sim u_{100}$ ）、活性化関数（後述）を用いて非線形変換の処理を行っている（図表 1 の $h_{11} \sim h_{100}$ ）。同様に隠れ層②では隠れ層①から 50 の特徴量を抽出し、活性化関数を用いて非線形変換の処理を行っている。本モデルでは回帰問題を扱うた

ⁱ 対象となるデータの特徴を定量的に表した変数。ディープニューラルネットワークでは、データそのものを教師データとして学習し、コンピューターがデータに内在する特徴量を自動的に抽出している。

め、出力層のノードは1つとなっている。

入力層から出力層への計算の流れ(左⇒右)を順伝播(Forward Propagation)といい、順伝播で通った経路を逆向き(右⇒左)に閾数の勾配の掛け算によって重み w やバイアス b を修正していくアルゴリズムを誤差逆伝播法(Back Propagation)という。後述のように、ディープニューラルネットワークを用いたモデル構築では、この過程を繰り返し学習することにより精度向上を図っていく。

<順伝播型ニューラルネットワーク>

隠れ層①の $u1$ は入力変数 x それぞれに対して $w1$ で重み付けした値とバイアス b を合計した値である((1)式)。入力層で与えられた入力変数から変数同士の交互作用を見つけだし、重回帰モデルでは反映しきれない新たな特徴量(変数)が生成されると捉えることができる。隠れ層②の $u2$ は $u1$ に活性化閾数を通した $h1$ それぞれに対して $w2$ で重み付けした値とバイアス b を合計した値である((2)式)。活性化閾数を通すことで、目的変数と説明変数の関係性を非線形で表現できる。出力層の y は $u2$ に活性化閾数を通した $h2$ それぞれに対して $w3$ で重み付けした値である((3)式)。ディープニューラルネットワークモデルは、ハイパーパラメータとして設定されたノードの数だけ特徴量をコンピューターが自ら抽出しており、多層構造とすることで最終的な予測精度が高められている。

$$u1 = Wx + b \quad (1)$$

$$u2 = Wh1 + b \quad (2)$$

$$y = w^T h2 + b \quad (3)$$

$u1$: 隠れ層①における100の特徴量抽出結果

x : 入力変数(1サンプルのみを考えた場合はベクトル)

※本稿では築年数を含むキャップレート形成要因11変数(行政的要因、立地要因、ビルスペック要因、市況要因)を入力変数としている

W : 各層における各ノードへの重み(出力数×入力数の行列)

b : バイアス

$u2$: 隠れ層②における50の特徴量抽出結果

$h1: u1$ に活性化閾数を通した特徴量

y : 出力変数(1サンプルのみを考えた場合はスカラー)

※本稿ではキャップレート

$h2: u2$ に活性化閾数を通した特徴量

w : 隠れ層②から出力層への重み(ベクトル)

つまり、入力層から隠れ層①の流れを表記した(1)式は下記のように表現できる。

$$\mathbf{x}^T = [x_1, x_2, \dots, x_{11}] \quad (4) \quad \mathbf{b}^T = [b_1, b_2, \dots, b_{100}] \quad (5)$$

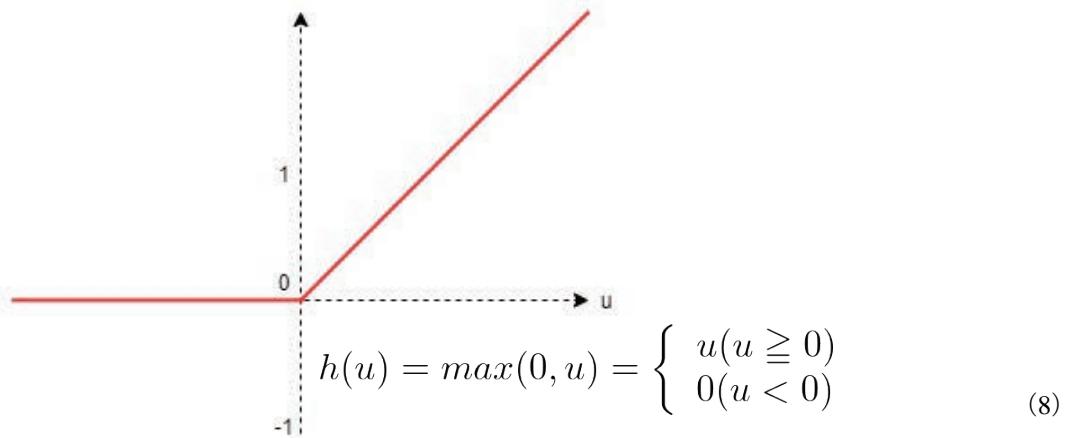
$$\mathbf{W} = \begin{bmatrix} w_{1,1} & w_{1,2} & \cdots & w_{1,11} \\ w_{2,1} & w_{2,2} & \cdots & w_{2,11} \\ \vdots & \vdots & \ddots & \vdots \\ w_{100,1} & w_{100,2} & \cdots & w_{100,11} \end{bmatrix} \quad (6)$$

なお、本稿ではサンプルを複数束ねて分析(ミニバッチ学習)するため、入力層の \mathbf{x}, \mathbf{b} は下記のとおり行列として表現される。

$$\mathbf{U1} = \mathbf{WX} + \mathbf{B} \quad (7)$$

また、 $u1 \Rightarrow h1, u2 \Rightarrow h2$ の非線形変換の処理にあたって、活性化関数として ReLU (Rectified Linear Unit) 関数を採用した。ReLU 関数とは、関数への入力値が 0 以下の場合には出力値が常に 0、入力値が 0 超の場合には出力値が入力値と同じ値となる関数である((8)式)。ReLU 関数は勾配消失問題ⁱⁱの解消やニューロン群の活性化をスペースⁱⁱⁱにするなどメリットが多く、深層学習の活性化関数として広く利用されている。

図表 2:ReLU 関数



出所)三井住友トラスト基礎研究所

＜誤差逆伝播法＞

順伝播型ニューラルネットワークにおける各重み w の初期値はランダムに与えられるので、入力情報に対して適切な出力がされているとは限らない。そこで、実績値と予測値の誤差(損失関数)を教師信号として与えることにより、各重み付けを変化させながら最終的に正しい出力が得られるようにする。損失関数として RMSE(平方平均二乗誤差)を用いる((9)式)。

ⁱⁱ 活性化関数を通した特徴量の数値が小さい場合に、モデル学習の最中に勾配が 0 となってしまう問題。

ⁱⁱⁱ 発火しない(出力を出さない)ニューロンの表現。

$$L = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (9)$$

L :損失関数(RMSE)

N :サンプル数

y :キヤップレートの実績値(教師データ)

\hat{y} :キヤップレートの予測値

出力層から隠れ層②への逆伝播において、図表1における $w3_1$ のパラメータ更新を考える。損失関数 L の値が0となる(近づく)ようにパラメータを更新していくこととなる。まず、損失関数 L を合成関数の微分を用いて $w3_1$ で偏微分し((10)式)、これより得られた勾配に学習率を乗じた値を元の重み $w3_1$ から差し引いて重み w を更新していく((11)式)。 w は勾配と逆方向に修正されるため、損失関数 L は限りなく0に近づいていくことが期待される。なお、学習率 ρ はハイパーパラメータであり、本稿では0.01と設定した。

$$\frac{\partial L}{\partial w3_1} = \frac{\partial L}{\partial \hat{y}} \cdot \frac{\partial \hat{y}}{\partial w3_1} \quad (10)$$

$$w = w3_1 - \rho \frac{\partial L}{\partial w3_1} \quad (11)$$

ρ :学習率

3. ディープニューラルネットワークにおけるモデルの学習

モデルの学習にあたってはミニバッチ学習法を採用し、ハイパーパラメータであるバッチサイズ^{iv}とエポック数^vについては、バッチサイズを50、エポック数を300と設定している。

また、損失関数 L が限りなく0に近づいていくようなパラメータ w を求める最適化アルゴリズムとしては、Adamを採用した。Adamは、モーメンタム^{vi}と RMSProp^{vii}を組み合わせた最適化アルゴリズムである。

なお、本モデルにおいてはノード数も多く過学習が懸念されるため、過学習の抑制対策としてDropout^{viii}を用いてユニットを2割ランダムに消失させている。

以上の設定を行ったうえでモデルを学習させたところ、学習回数に伴って損失関数であるRMSEが小さくなつており、適切に学習が進んでいることが確認できた(図表3参照)。

^{iv} バッチサイズ (Batch size) : データセットをサブセットに分ける際にサブセットに含むデータの数。

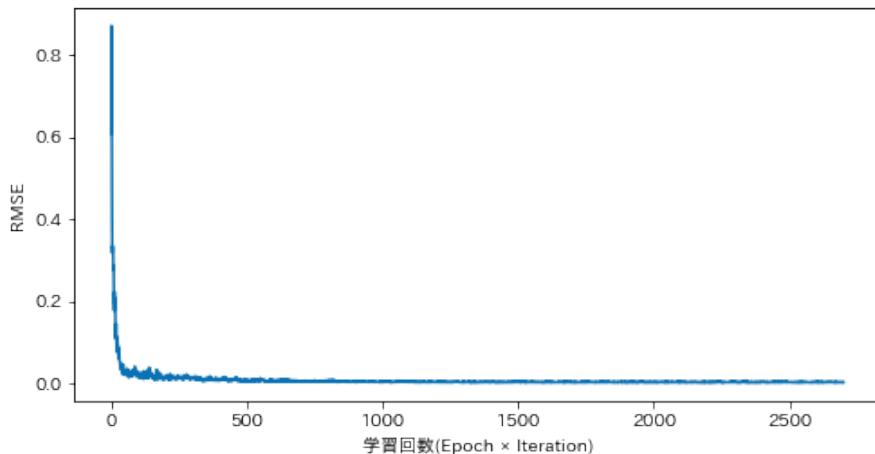
^v エポック (Epoch) : データセットを何回繰り返して学習させるか。

^{vi} 勾配を使って確率的にパラメータを更新する確率的勾配降下法に移動平均を適用して振動を抑制した手法。

^{vii} 勾配の大きさに応じて学習率を調整し、振動を抑制した手法。

^{viii} ニューラルネットワーク内のユニットをランダムに消失させた状態で学習する手法。

図表 3: ディープニューラルネットワークにおけるモデルの学習状態

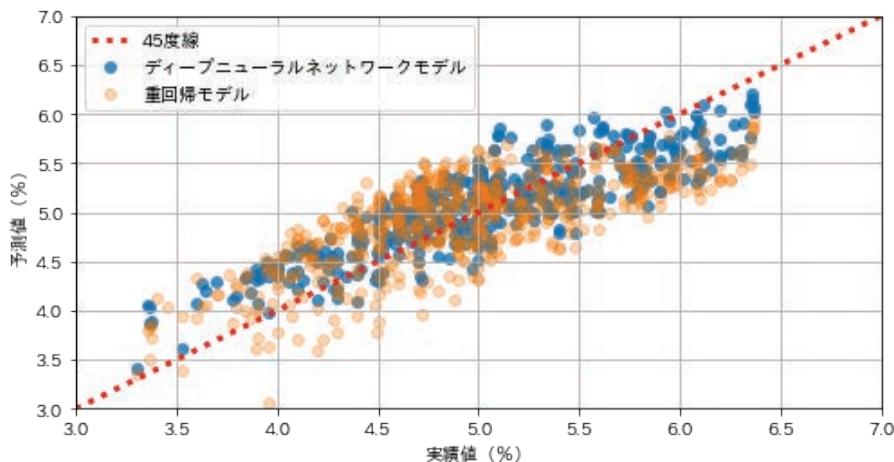


出所)三井住友トラスト基礎研究所

4. ディープニューラルネットワークモデルと重回帰モデルにおける予測精度の比較

ディープニューラルネットワークを用いたキャップレートの予測結果を図表 4 に示した(青のドット)。横軸に実績値、縦軸に予測値をとっており、実績値と予測値が完全に一致していれば 45 度線上にプロットされる。比較の観点から重回帰モデル((12)式)を用いて予測した結果もグラフに描画した(橙のドット)。両モデルの RMSE はディープニューラルネットワークモデルが 0.0037、重回帰モデルが 0.0044 となった。図表 4 でもディープニューラルネットワークモデルの結果は重回帰モデルの結果よりも 45 度線近くにプロットされているものが多く、予測精度が向上していることが確認できる。

図表 4: 実績値と予測値の比較



出所)三井住友トラスト基礎研究所

<重回帰モデル>

$$\mathbf{y} = \mathbf{X}\mathbf{w} + \boldsymbol{\varepsilon} \quad (12)$$

\mathbf{y} :キャップレートの実績値

\mathbf{w} :重みベクトル(回帰係数)

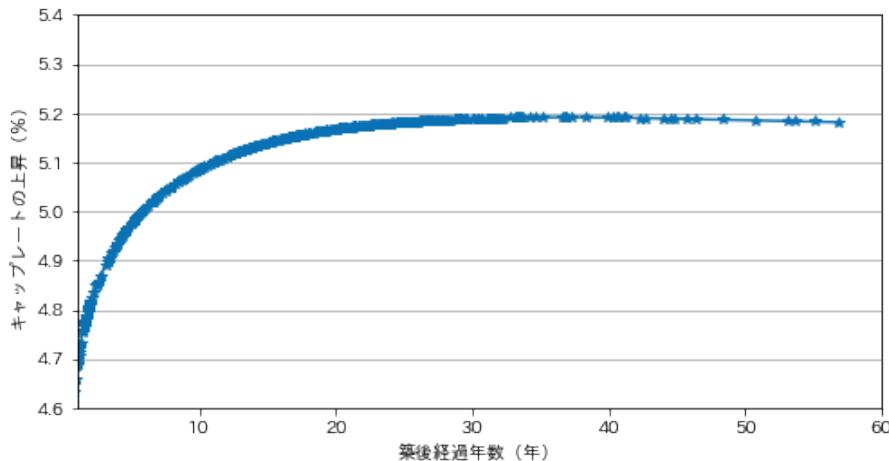
\mathbf{X} :サンプル数×キャップレート形成要因数(定数項を含む説明変数)の行列

$\boldsymbol{\varepsilon}$:誤差項

データ数が豊富にあり、非線形的関係や入力変数間(説明変数)の組み合わせによって生じる複雑な交互作用の影響を反映したい場合、キャップレートや賃料を同時に予測するというような複数の出力変数(目的変数)を扱う場合などにおいて、ディープニューラルネットワークモデルは特に有用である。また、ディープニューラルネットワークモデルは中身がブラックボックスで解釈性が低いと言われるが、Permutation Importance^{ix}や PDP(Partial Dependence Plot)^x、LIME(Local Interpretable Model-agnostic Explanations)^{xi}、SHAP(SHapley Additive exPlanation)^{xii}などモデルを解釈する方法も提案されている。

なお参考として、入力変数(説明変数)のうち「築後経過年数」を対象に Partial Dependence Plot((13)式)を行った結果を記載しておく。ディープニューラルネットワークモデルの解釈性については研究途上にあるが、モデルのなかで重要であると判断された変数において Partial Dependence Plot で近似的な変化を捉える方法が考案されている。但し、もともと同モデルは人間が整理しきれない他の説明変数との複雑な交互作用を非線形で表現したものであり、Partial Dependence Plot で捉えた一つの説明変数と目的変数の関係性は、これまで持っていたイメージと異なる場合も多分にある。そのことは、Partial Dependence Plot の結果を否定するものではなく、その点も踏まえて深層学習における解釈性に関する方法の開発余地が残されているということだろう。

図表 5: 築後経過年数を対象とした Partial Dependence Plot



出所)三井住友トラスト基礎研究所

<Partial Dependence Function>

$$\bar{f}_s(x_s) = \frac{1}{N} \sum_{i=1}^N \hat{f}(x_s, x_{ci}) \quad (13)$$

$\bar{f}(x)$: 予測結果の平均

$\hat{f}(x)$: 入力変数を x とした学習済みモデル

x_s : 対象とする入力変数 x (本稿では「築後経過年数」)

x_c : その他の入力変数 x

^{ix} 特定の説明変数の値のみをシャッフルして予測精度へのインパクトが大きい変数を探索する手法。

^x 重要度の高い説明変数について、当該変数の値のみを変化させることにより予測結果にどのように影響するかを観察する手法。

^{xi} 対象サンプルの周囲のデータ空間から線形回帰を近似し、説明変数の予測結果に対する寄与度を説明する手法。

^{xii} 協力ゲーム理論における Shapley 値を利用して説明変数の予測結果に対する寄与度を説明する手法。

5. 深層学習を含む機械学習手法への期待

予測モデルの構築にあたっては、複数のアプローチによる分析結果を比較することは重要であり、深層学習を含む機械学習手法に対する期待は大きい。上記の検証では、キャップレート推計モデルにおいて、重回帰分析と同じ説明変数により目的変数の予測精度を高めることができた。今後は、ニューラルネットワークを拡張した再起型ニューラルネットワーク(RNN)や長短期記憶ニューラルネットワーク(LSTM)を適用することにより、時系列的な分析を進めることを考えている。

加えて、深層学習は、特微量が膨大となる場合に特に有用であり、キャップレート推計モデルにおいても、たとえば、対象不動産の外観写真や室内写真など画像データを豊富に収集できる場合に、畳み込みニューラルネットワーク(CNN)を組み合わせることにより、デザインや維持管理の状態を形成要因に加えたモデルの構築が考えられる。これにより、キャップレートにおける予測精度の更なる向上が期待できる。

実務では、解釈性の観点からメインモデルとして重回帰モデルが利用されることが多い。モデルの選択肢としては、今回検証したディープニューラルネットワークモデルの前に、決定木ベースのアンサンブル学習等を含め、よりシンプルなモデルの利用も考えられる。

それでも、今後ディープニューラルネットワークモデルに対する世の中の理解が進めば、その精度の高さから、メインモデルの結果の精度確認や、メインモデルの結果を幅で捉える際のサブモデルとして、ディープニューラルネットワークモデルを使用することも考えられるのではないだろうか。

以上

【本件のお問い合わせ先】**私募投資顧問部 担当:米倉**

TEL:080-7207-5117(直)

<https://www.smtri.jp/contact/form-private/index.php>**株式会社三井住友トラスト基礎研究所**

〒105-8574 東京都港区芝3-33-1 三井住友信託銀行芝ビル11階

<https://www.smtri.jp/>

1. この書類を含め、当社が提供する資料類は、情報の提供を唯一の目的としたものであり、不動産および金融商品を含む商品、サービスまたは権利の販売その他の取引の申込み、勧誘、あつ旋、媒介等を目的としたものではありません。銘柄等の選択、投資判断の最終決定、またはこの書類のご利用に際しては、お客様ご自身でご判断くださいますようお願いいたします。
2. この書類を含め、当社が提供する資料類は、信頼できると考えられる情報に基づいて作成していますが、当社はその正確性および完全性に関して責任を負うものではありません。また、本資料は作成時点または調査時点において入手可能な情報等に基づいて作成されたものであり、ここに示したすべての内容は、作成日における判断を示したもので、また、今後の見通し、予測、推計等は将来を保証するものではありません。本資料の内容は、予告なく変更される場合があります。当社は、本資料の論旨と一致しない他の資料を公表している、あるいは今後公表する場合があります。
3. この資料の権利は当社に帰属しております。当社の事前の了承なく、その目的や方法の如何を問わず、本資料の全部または一部を複製・転載・改変等してご使用されないようお願いいたします。
4. 当社は不動産鑑定業者ではなく、不動産等について鑑定評価書を作成、交付することはありません。当社は不動産投資顧問業者または金融商品取引業者として、投資対象商品の価値または価値の分析に基づく投資判断に関する助言業務を行います。当社は助言業務を遂行する過程で、不動産等について資産価値を算出する場合があります。しかし、この資産価値の算出は、当社の助言業務遂行上の必要に応じて行うものであり、ひとつの金額表示は行わず、複数、幅、分布等により表示いたします。