

## 画像解析は不動産の特徴を識別可能か？

### ～ CNN を用いたオフィスと住宅の画像分類 ～

2021年7月12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 上席主任研究員 米倉勝弘

- ◆ 不動産投資にあたっては、対象物件の詳細情報が開示されない中で投資判断に向けた一次スクリーニングをしなければならない機会が多い。
- ◆ 画像データには様々な情報が内包されており、対象不動産における詳細な情報が得られなくても、画像データを用いて維持管理の状態や修繕履歴などの影響を簡易に推計できるとすれば、実務上も有益である。
- ◆ 本稿では、画像解析によって不動産の特徴を識別できるか否かを確認するため、CNNを用いた画像分類を行った。J-REITが保有する「オフィス」と「住宅」の画像を用いて「オフィス」と「住宅」を分類するモデルを作成した結果、畳み込み層1層のCNNというシンプルなモデルでも、「オフィス」と「住宅」の分類は高い正解率を示し、画像分類が不動産において有効に機能し得ることが確認できた。
- ◆ 不動産における画像解析は、キャップレート推計モデルや賃料推計モデル、経済的築年数(≒耐用年数－経済的残存耐用年数)の推計などへ応用が期待できる。

#### 1. はじめに

不動産投資にあたっては、対象物件の詳細情報が開示されない中で投資判断に向けた一次スクリーニングをしなければならない機会が多い。特に建物に関しては、日常の維持管理方法や修繕履歴など、所有者の協力なしに情報を得ることは難しいと言える。ここで、画像データに着目してみる。画像データには、様々な情報が内包されている。建物の外観だけをとり、「建築の年次」、「外壁の材質」、「維持管理・清掃の状態」、「破損の状態」、「修繕の状態」などが挙げられよう。画像データを用いて不動産の特徴を捉えることができれば、これらの要因を加味した投資判断が可能となる。対象物件における修繕履歴などの情報が得られなくても、画像データを用いてこれら要因を簡易に推計できるとすれば、実務上も有益であろう。

そこで本稿では、画像解析によって不動産の特徴を識別できるか否かを確認するため、CNN(Convolutional Neural Network: 畳み込みニューラルネットワーク)を用いた画像分類を行った。具体的には、J-REITが保有する「オフィス」と「住宅」の画像データを用いて「オフィス」と「住宅」を分類する(見分ける)モデルを作成し、その精度の確認を行っている。画像データを用いて不動産の特徴を捉えることが可能であると確認できれば、維持管理の状態や修繕履歴を反映した投資分析への応用が期待できるものと考えている。

#### 2. モデル構築およびテストケースの結果

後述のとおりの手順(<Appendix>「CNNを用いた「オフィス」と「住宅」の画像分類モデル構築の具体的手法」を参照)でモデルを構築し、「オフィス」と「住宅」の画像を用いて分類(見分け)を行わせた結果、トレーニングデー

タ(分類モデルを構築するためのデータ)120物件における Accuracy(正解率)は100%であった。また、モデル作成のサンプルには入っていないバリデーションデータ(モデル検証用データ)30物件でも93.3%(28/30)と高い Accuracy(正解率)を得ることができた(図表1参照)。図表2はバリデーションデータの結果を混同行列で示したものである。混同行列は4カテゴリーのデータが不均衡な場合に特に有効であるが、本項では正解の2値を均等(「オフィス」と「住宅」のサンプルが同数)にしているため、Precision(適合率)、Recall(再現率)ともに93.3%(14/15)で一致している。

図表1: トレーニングデータとバリデーションデータの結果

	Accuracy (正解率)
トレーニングデータ	100.00%
バリデーションデータ	93.33%

出所)三井住友トラスト基礎研究所

図表2: バリデーションデータの結果詳細

		推計	
		オフィス	住宅
実態	オフィス	14(TP)	1(FN)
	住宅	1(FP)	14(TN)

TP = True Positive    FN = False Negative

FP = False Positive    TN = True Negative

Accuracy(正解率): 分類の精度を確認する為の指標

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad (1)$$

Precision(適合率): 誤検知を少なくしたい場合に重視

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

Recall(再現率): 正例(Positive)の見逃しを避けたい場合に重視

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

さらに、トレーニングデータおよびバリデーションデータで用いたデータとは全く別の投資法人が保有する物件をテストデータとして本モデルの検証を行った。下に掲載したとおり、「オフィス」については「ジャパンリアルエステイト投資法人」、「住宅」については「コンフォリア・レジデンシャル投資法人」の物件をテストデータとして採用している。

テストデータ 10 物件の予測(分類)結果は、Accuracy(正解率)100%となった。SoftMax 関数にかけた出力値はいずれも正解データと一致する方が 90%以上となっており、90%以上の確度を持って正解している。

以上より、畳み込み層 1 層の CNN というシンプルなモデル(詳細は< Appendix >「CNN を用いた「オフィス」と「住宅」の画像分類モデル構築の具体的手法」を参照)でも、画像分類が不動産において有効に機能し得ることが確認できた。

#### <テストデータ>



出所)ジャパンリアルエステイト投資法人およびコンフォリア・レジデンシャル投資法人ホームページ

図表 3: テストデータの予測結果

	オフィス確率	住宅確率
オフィス①	99.87%	0.13%
オフィス②	98.94%	1.06%
オフィス③	100.00%	0.00%
オフィス④	99.22%	0.78%
オフィス⑤	100.00%	0.00%
住宅①	2.50%	97.50%
住宅②	9.28%	90.72%
住宅③	0.15%	99.85%
住宅④	1.64%	98.30%
住宅⑤	1.13%	98.87%

出所)三井住友トラスト基礎研究所

### 3. 不動産の各種分析・推計における画像解析の活用可能性

#### (1) キャップレート推計モデルや賃料推計モデルの説明変数として利用

不動産の価格もしくは賃料を考えた場合、その不動産の維持管理の状態や大規模修繕の有無等が水準に影響することは感覚的にイメージしやすいのではないだろうか。キャップレート推計モデルや賃料推計モデルを構築する際には、このような要因を反映する代理変数として「築年数」を説明変数に採用する場合も多く見受けられる。

しかしながら、当然に「築年数」のみでは、個別物件の維持管理の状態や大規模修繕の有無を完全に把握することはできない。築年数が古くなればなるほど、維持管理方法や修繕履歴等により物件の劣化状況は見掛けの築年数と乖離するものである。

回帰分析などを用いてキャップレートや賃料の推計を行う場合では、このような乖離が推計誤差を拡大している可能性も考えられる。競争を勝ち残った築古の優良物件であるが故に、築年がキャップレートを押し下げたり、賃料を押し上げたりと、仮説とは逆の傾向を示す「生存バイアス(i)」の存在が他の研究でも多数報告されているが、これらの一部には、維持管理の状態や修繕履歴等が影響している可能性がある。

<sup>i</sup> 経済合理性でみると、質の悪い建物は早期に取り壊される一方で、除却されずに長期間存続している建物は良質な建物のみであることから生じるバイアス

画像データをキャプレート推計モデルや賃料推計モデルに組み込んだ場合、維持管理の状態や修繕履歴等を加味した推計結果を得ることが期待できる。具体的な方法としては、画像データから抽出した特徴量に外部から入力される特徴量を付加する方法が考えられる。後述<Appendix>「CNNを用いた「オフィス」と「住宅」の画像分類モデル構築の具体的な手法」図表 A. 1 の「平坦化層」にベクトルとして外部から入力される特徴量を結合し、「全結合層」に流し込むこととなる。

## (2) 経済的築年数の推計

J-REIT の保有物件をはじめ、実際の築年数が公表されている物件は多数ある。一方で、不動産投資分析においては、今後どのくらいの期間利用可能であるかが重要であり、その観点からは実際の築年数よりも維持管理の状態や大規模修繕の有無等を考慮した「経済的築年数(≒耐用年数－経済的残存耐用年数)」という概念の方が重要であろう。

大半の物件において修繕履歴を遡及して把握することは難しいというのが実情であり、経済的耐用年数を簡易に推計できるとすれば、投資判断に向けた一次スクリーニングの有力な指標になり得る。

経済的築年数推計モデルの構築にあたって、サンプルの教師データとなる「経済的築年数」を仮定するための簡易的な方法としては、不動産鑑定評価の原価法において不動産鑑定士が査定している「経済的残存耐用年数」やエンジニアリング・レポート(ER)において推定されている「物理的耐用年数」等を用いることも一案である。不動産鑑定評価・ERを取得している物件をサンプルデータとしてモデル化すれば、投資判断時点において不動産鑑定評価・ERを取得していない物件においても経済的築年数を推計することが可能となる。

この方法を選択しても、個別物件毎に複数の画像(外観・内観)と不動産鑑定評価・ERのデータセットが必要であり、またデータへのラベル付けは基本的に人が行う作業のため、トレーニングデータの作成には非常にコストがかかる。よって、少ない画像サンプルから画像分類・画像認識モデルを作成する必要もあるだろう。その場合には、既存学習モデルを fine-tuning (転移学習(ii)) する方法などが考えられる。代表的な CNN のアーキテクチャとして、2012 年に画像認識コンペ「ILSVRC」で圧倒的な成績を残して CNN の火付け役となった「AlexNet (iii)」をはじめ、「VGG16(iv)」、「GoogLeNet(v)」、「ResNet(vi)」などが挙げられる。これらのモデルも含めて、別途の検証により不動産と親和性の高いモデルを模索していく必要がある。

ii ある領域において事前に学習させたモデルを別の領域に転用し適応させる技術

iii 2012 年「ILSVRC」優勝モデル(pooling 層で特徴マップを縮小しながら畳み込み層を 5 層、3 層の全結合層により出力を得る)

iv 2014 年「ILSVRC」準優勝モデル(pooling 層で特徴マップを縮小しながら畳み込み層を 13 層、3 層の全結合層により出力を得る)

v 2014 年「ILSVRC」優勝モデル(横にも層が広がる構造=Inception 構造を導入)

vi 2015 年「ILSVRC」優勝モデル(勾配消失問題を解決し、152 もの層を重ねることに成功)

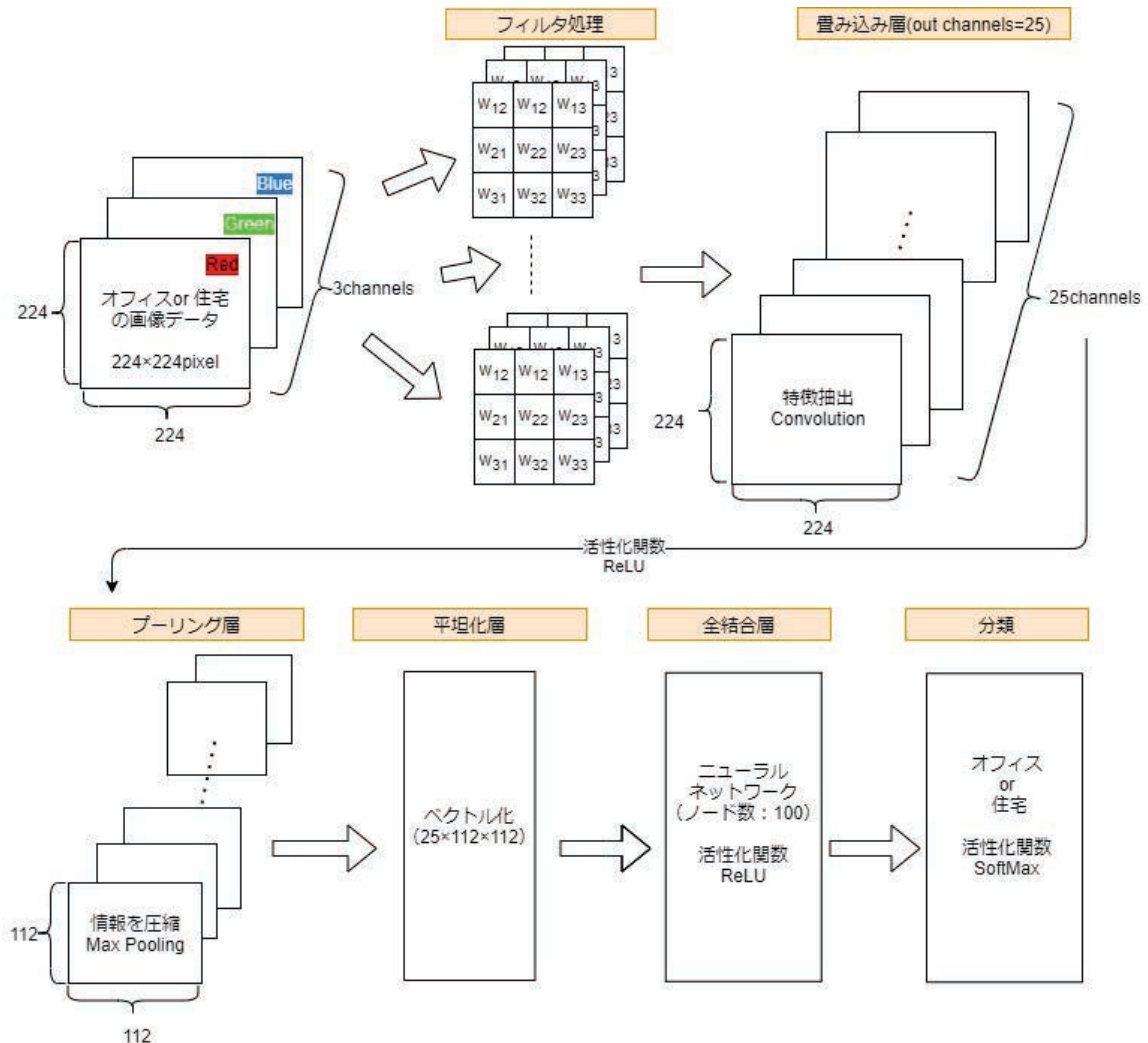
## <Appendix>CNN を用いた「オフィス」と「住宅」の画像分類モデル構築の具体的手法

本稿では、J-REIT が保有する「オフィス」と「住宅」の画像を用いて、「オフィス」と「住宅」を分類するモデルの作成を試みた。モデルには CNN (畳み込みニューラルネットワーク) を適用する。CNN とは、視覚神経を模した「ネオコグニトロン」というアルゴリズムを多層ニューラルネットワークに応用した深層学習モデルである。本稿では、比較的シンプルなモデルで見た目からどの程度不動産の特徴を正しく分類できるかを確認することを目的としている。なお、CNN の実装には、PyTorch (<https://pytorch.org/>) のラッパーライブラリである PyTorch Lightning を用いた。

### (1) CNN を用いた画像分類のフロー

まず 224×224pixel のカラー画像 (3 次元データ) を用意し、カーネルと呼ばれるフィルタにかけて画像データを分割した小さな部分から特徴を抽出する (フィルタ処理)。うまく特徴を抽出できるようにカーネルの各要素をニューラルネットワークによって学習している。本稿ではフィルタ処理によって各特徴量が集約された畳み込み層の出力 (縦×横×フィルタ数) を 25 チャンネルとしている。また、畳み込みによって得た特徴量から重要な要素を残しつつデータ量の削減を行うプリーングという処理を施し、データ量を 4 分の 1 に圧縮している。その後、ニューラルネットワークの全結合層に通すため、テンソルをベクトルに変換する平坦化 (Flatten) と呼ばれる処理を施す。全結合層ではベクトル化された特徴量から 100 の特徴量を抽出し、元の画像が「オフィス」または「住宅」であるかの分類を行っている (図表 A. 1 参照)。

図表 A. 1: CNN を用いたオフィスと住宅の画像分類のフロー図



出所) 三井住友トラスト基礎研究所



## (2) サンプルデータ

サンプルデータとして J-REIT が保有する「オフィス」および「住宅」の画像データ各 75 物件を採用した。なお、本稿では当該サンプルデータの 8 割 (各 60×2、計 120) をトレーニングデータ、2 割 (各 15×2、計 30) をバリデーションデータとして無作為に振り分け、バリデーションデータの結果を参考にハイパーパラメータのチューニングを行っている。

## (3) モデルの概要

個々の画像データは形状が異なるため、分析の前処理として 224×224pixel のサイズに拡大・縮小している。畳み込み層では、カーネルサイズ(vii)を縦横 3×3 の 3 チャンネルとして、カーネルを 1 ずつスライドさせて特徴量を抽出する。また、出力サイズを調整し、画像の端の特徴も捉えるためパディング(viii)を 1 として適用している。畳み込み後の活性化関数は勾配消失問題(ix)に対応するため ReLU 関数(x)を採用した(図表 A. 2 参照)。

プーリング層では MaxPooling(xi)を採用し、Max pooling を適用するカーネルのサイズを 2×2、カーネルをスライドさせる幅を 2 として、データサイズを 4 分の 1 に圧縮している。

平坦化層では当該 25×112×112 のテンソルデータを全結合層に入力出来るようにベクトルデータに変換している。

全結合層では平坦化によってベクトル化されたデータから 100 の特徴量を抽出し、活性化関数である ReLU 関数を用いて非線形変換の処理を行ったうえで、出力層にて「オフィス」または「住宅」の分類を行っている。なお、出力層では SoftMax 関数(xii)をかけることによって出力を確率とみなせるようにしている。全結合層以下のニューラルネットワークに関する考え方については、2021 年 3 月 8 日掲載のレポート「キャプレート推計モデルの予測精度向上に向けて～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～」を参照されたい。

([https://www.smtri.jp/report\\_column/report/2021\\_03\\_08\\_5129.html](https://www.smtri.jp/report_column/report/2021_03_08_5129.html))

図表 A. 2: モデルの概要

ネットワーク階層 ハイパーパラメータ	値
<b>畳み込み層</b>	
カーネルサイズ	3x3x3
ストライド	1
パディング	1
活性化関数	ReLU
<b>プーリング層</b>	
手法	Max Pooling
サイズ	2x2
ストライド	2
<b>平坦化層</b>	
サイズ	25x112x112
<b>全結合層</b>	
ノード数	100
活性化関数	ReLU
<b>出力層</b>	
ノード数	2
活性化関数	SoftMax

出所)三井住友トラスト基礎研究所

vii フィルタのサイズ

viii 画像の外側を囲う数

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

x 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

xi 指定領域 (2×2) のうち、最大値を取ることで全体の大きさを小さくする方法

xii 複数の出力値の合計が 100% になるように変換して出力する関数

本モデルでは、2 値分類問題を扱うため損失関数 ( $E$ ) として交差エントロピー誤差を用いている。(4) 式のとおり、損失関数 ( $E$ ) は正解データ ( $t$ ) とモデルの出力値 ( $y$ ) について対数をとった値を乗算して算出される。対数の特性によりモデルの出力値 ( $y$ ) の値が 0 に近いほど絶対値が大きくなり、モデルの出力値 ( $y$ ) の値が 1 に近いほど絶対値が小さくなる。正解データ ( $t$ ) が 1 の場合には右辺第 1 項のみが残り、正解データ ( $t$ ) が 0 の場合には右辺第 2 項のみが残る。正解データ ( $t$ ) が 1 の場合、それに対応するモデルの出力値 ( $y$ ) が 1 に近いほど損失関数 ( $E$ ) の値は小さくなる。つまり、正しく判別できている (真の確率分布に近い) 場合に損失が小さくなるのである。

また、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 (xiii) とエポック数 (xiv) については、バッチサイズを 10、Max エポック数を 20 と設定している。

さらに、損失関数 ( $E$ ) が限りなく 0 に近づいていくようなパラメータを求める最適化アルゴリズムとしては、Adam (xv) を採用している。

< 交差エントロピー誤差 (2 値分類の場合) >

$$E = - \sum_{n=1}^N \{ t_n \log y_n + (1 - t_n) \log (1 - y_n) \} \quad (4)$$

$E$  : 損失関数 (交差エントロピー誤差)       $N$  : サンプル数  
 $t$  : 1 or 0 の正解データ (教師データ)       $y$  : モデルの出力値

以上

---

xiii 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

xiv データセットを何回繰り返し学習させるか

xv モーメンタムと RMSProp を組み合わせた最適化アルゴリズム

**【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、あっ旋、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、お客さま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す。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。