

2022 年度 修士論文

建築物の外観特徴検出を前提とした  
建築年代の機械的判定方法の提案

弘前大学大学院 地域共創科学研究科

地域リノベーション専攻

レジリエンステクノロジー

20GC110 潘蔣杰

指導教員 片岡俊一

# 目次

## 1. 序論

1.1	研究背景・目的	2
1.2	開発環境	3
1.3	論文構成	3

## 2. 建築物の外観特徴と建築年代の関係

2.1	はじめに	4
2.2	住宅データセット	4
2.3	外観特徴と建築年代の関係	4
2.4	年代の予測に利用できる外観特徴	6

## 3. YOLOv3 を用いた外観特徴の検出

3.1	はじめに	7
3.2	物体検出アルゴリズム	7
3.3	評価指標	10
3.4	画像データセット	12
3.5	アノテーションデータの作成	12
3.6	学習モデルの作成	14
3.7	モデルの改良	15

## 4. 年代予測モデルの構築

4.1	はじめに	17
4.2	誤差逆伝播法	17
4.3	データセット	18
4.4	評価指標	18
4.5	モデルの学習	19
4.6	モデルの評価	19

## 5. 結論

5.1	まとめ	21
5.2	今後の課題	21

## 参考文献

## 謝辞

# 1. 序論

## 1.1 研究背景・目的

日本は地震による多くの被害を受けてきた世界有数の地震国である。地震による建築物の被害想定を行う際には、建築物の建築年数が必要となるが、対象地域全体の建築物の建築年数を把握することは容易ではない。

そこで本研究では建築物の外観と建築年数の関係に着目し、建築物の建築年代調査の簡易化を試みた。このような試みは、筑波大学の境先生が取り組んだのが最初であろう<sup>1</sup>。そして、2015年から弘前大学工学部地球環境学科（当時）の津村浩三先生が不動産サイトに掲載されている建築物の写真と基本情報から建築年代を推定する研究を始めた。2016年の卒業研究では長内奈津美さんが建築年や建物面積などの基本情報を整理し、判別方法を提案している<sup>2</sup>。しかしながら、建築年の判別で重要なことは建築基準法の改正に対応しているか否かであり、具体的な建築年ではない。そのため、筆者の卒業研究（弘前大学工学部地球環境防災学科 2020年提出）では長内が整理した建築データを用い、住宅の外観特徴から建築物が建築基準法の改正以前か以後に建てられたのかを予測するニューラルネットワークモデルを構築し、建築物の建築年数調査の簡易化を提案し<sup>3</sup>、令和2年度東北地域災害科学研究集会にて発表した<sup>4</sup>。その研究は、人が分類し、判別した建築情報から、ニューラルネットワークを用いて建築年代を推定するものである。その研究では、一定の精度を維持しながら、建築年代の推定に必要な建築物の情報を従来の半分以下にすることに成功した。

また、2017年から摂南大学の榊愛先生がディープラーニングを用いて、近畿圏の戸建住宅の外観写真から直接的に建築年代を推定する研究に取り込まれている<sup>5</sup>。

本研究では建築年代調査の更なる簡易化のため、物体検出技術を利用し、建築物の画像から建築年代を予測することを試みた。物体検出アルゴリズム YOLOv3 を用いて建築物の画像から外観特徴を判別し、その外観特徴データを用いた建築年代予測モデルを作成した。なお、本研究の建築物はすべて一戸建て住宅である。

本研究により、建築物の建築年代調査における手間は省けることになり、災害による被害想定や防災計画の作成の迅速化が期待される。それに伴い、地震災害軽減に役立つと考えている。

## 1.2 開発環境

本研究の開発環境は表 1-1 に示す。

表 1-1 開発環境

ソフトウェア	
OS	Windows10
プログラミング言語	Python3.5
統合開発環境	Visual Studio Code
フレームワーク	TensorFLOW
ライブラリ	Keras
ハードウェア	
CPU	AMD Ryzen 9 3900X
RAM	DDR4 32GB(16GBX2)
Storage	SSD 1TB
GPU	Nvidia GForce RTX 2070 Super

## 1.3 論文構成

本論文の構成は次の通りである。本章では研究背景、目的および本研究の開発環境について紹介した。第2章では建築物の外観特徴と建築年代の相関関係について説明する。第3章では建築年代によって内容が変化する外観特徴を物体検出技術を用いて、AIに判別させる試みについて説明する。第4章ではAIに判別させた外観特徴データを用いて、建築年代を推測するモデルの構築およびその結果について述べる。最後に第5章で本研究のまとめおよび今後の展望について述べる。

## 2. 建築物の外観特徴と建築年代の関係

### 2.1 はじめに

本章では建築物の外観特徴と建築年代の相関関係について検討する。建築専門家が住宅の外観から建築年代を推測できることから、外観特徴は建築年代によって変化することが伺える。まず2.2節で外観特徴と建築年代の関係を確認するために用いるデータセットについて説明し、2.3節でその関係を確認する。その結果を2.4節でまとめる。

### 2.2 住宅データセット

外観特徴と建築年代の関係を調べるには、長内 奈津美 (2016) の卒業論文「木造一戸建て住宅の外観による建築年代の決定に関する調査」で整理された住宅データを利用した<sup>2</sup>。このデータは不動産サイト「@nifty 不動産」から、青森県青森市・福島県福島市・兵庫県明石市それぞれについて、2015年9月から2015年12月までに、当時掲載されていた一戸建て住宅の情報を収集したものである。データセット総数は270であり、内訳は青森市が82件、福島市が77件、明石市が111件となっている。画像認識を前提とした外観特徴として、階数・外壁・玄関フード・ドアノブ・屋根・塀・換気口・窓のサッシの色の8項目に注目した。各外観特徴の分類は表2-1に示す。なお、この分類は長内が実施したものである。

表 2-1 各外観特徴の分類

階数	屋根	玄関フード	窓のサッシの色
1階	無落雪	あり	黒(暗色)茶, 暗い灰
2階	三角	なし	白(明色), 明るい灰
3階	斜め		
4階	瓦		
換気口	塀	外壁	ドアノブ
フード付き	ブロック塀	モルタル	握り玉ドアノブ
妻換気	木製	木製	引き戸
軒裏	コンクリ塀	タイル	サムラッチ錠
円型	モルタル塀	サイディング	レバードアノブ
四角型	レンガ塀		プッシュプルグリップ
	なし		

### 2.3 外観特徴と建築年代の関係

本研究では建築物の耐震性能が大きく変わることになる建築基準法の改正に着目し、1970年以前、1971年から1980年まで、1981年以降の3区分に分けて外観特徴と建築年代の関係を調べた。その結果を図2-1に示す。階数・玄関フード・窓のサッシの色・塀の4項目においては、建築年代による内容の変化が認められなかった。塀に関しては、1971年以降の建築物にモルタル塀やコンクリ塀が現れたものの、全体の比率に顕著な変化が見られなかった。一方で、ドアノブ・換気口・屋根・外壁の4項目において、年代によって内容が変化することが確認できた。

外観特徴の内容変化をまとめると次のようになる。

- ・ドアノブ：1971年以降の建築物にプッシュプル錠が現れ、1981年以降にその割合は大きく増加している。その一方で、引き戸の割合は年々減少している。
- ・換気口：フード付き換気口の割合は1981年以降に増加している。
- ・屋根：1981年以降に瓦屋根の割合は減少し、無落雪屋根の割合は増加している。
- ・外壁：建築年代が浅くなるにつれ、サイディングの割合は増加し、モルタルの割合は減少している。

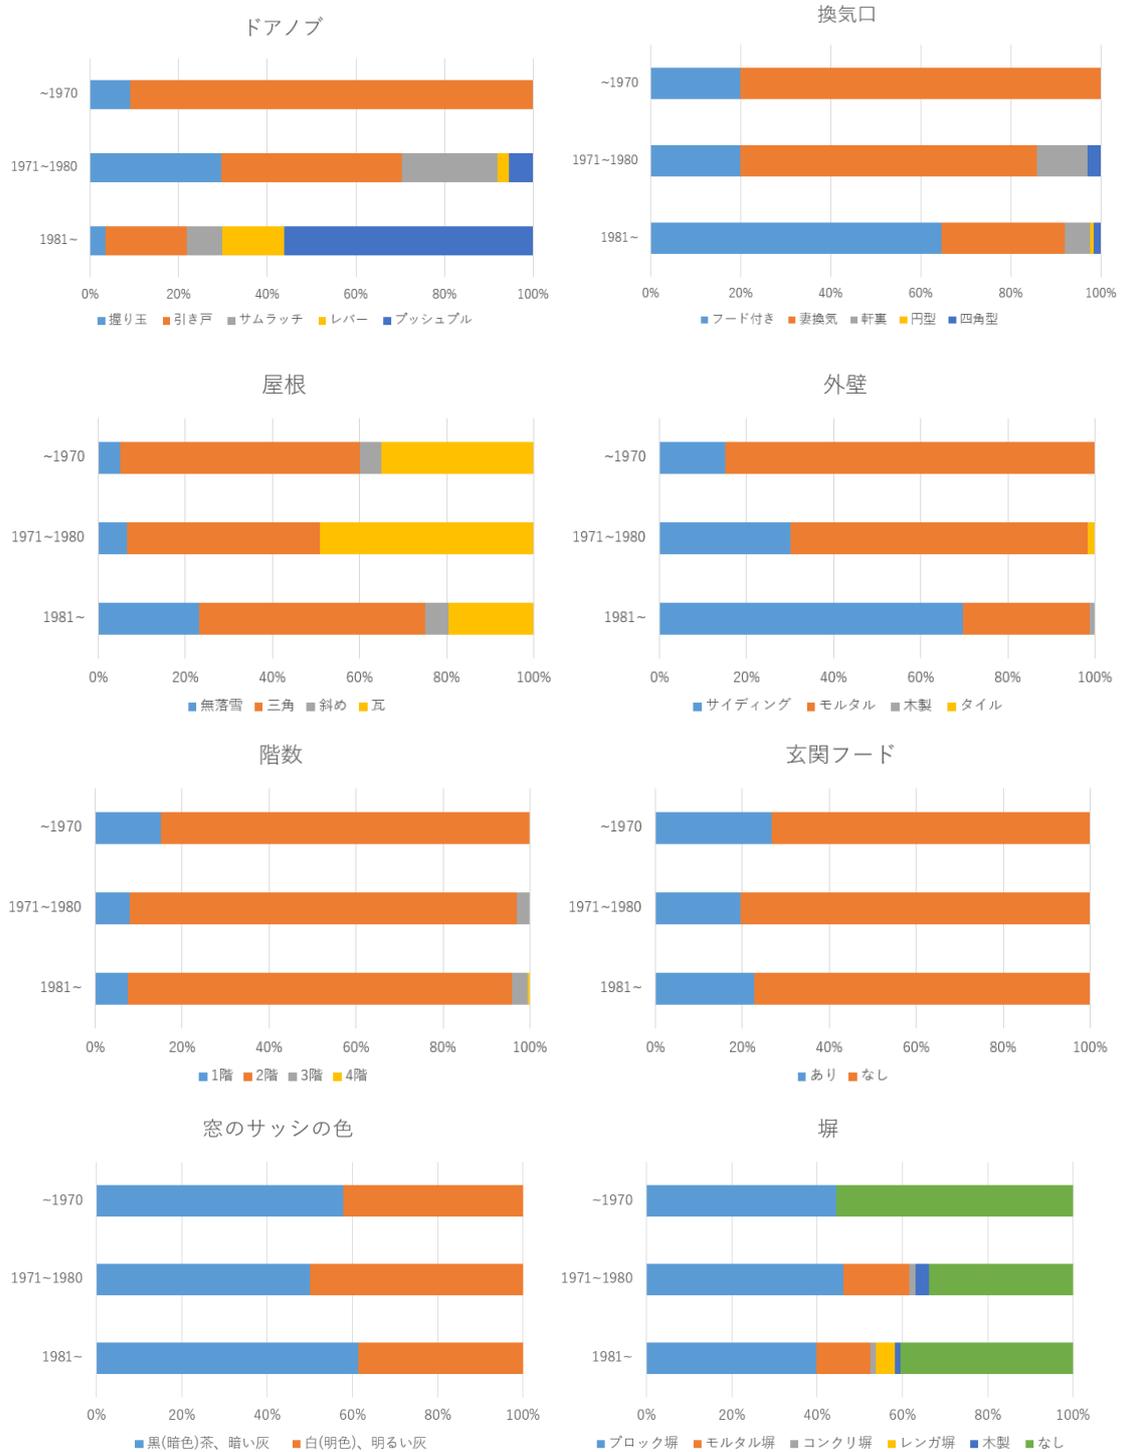


図 2-1 各外観特徴の建築年代によるの推移

## 2.4 年代の予測に利用できる外観特徴

2.3 節の結果をまとめると表 2-2 になる。前節で述べたように、ドアノブ・換気口・外壁・屋根の 4 項目において、建築年代によって内容が変化することが確認できたため、この 4 項目を検出するモデルを構築する。

表 2-2 外観特徴と建築年代の関係

建築年代によって変化する外観特徴	建築年代によって変化しない外観特徴
ドアノブ	階数
換気口	玄関フード
外壁	窓のサッシの色
屋根	塀

## 3. YOLOv3 を用いた外観特徴の検出

### 3.1 はじめに

本章では物体検出アルゴリズム YOLOv3<sup>6</sup> を用い、第 2 章で説明した建築年代によって変化する 4 種類の外観特徴を検出する物体検出モデルについて紹介する。まず 3.2 節で物体検出アルゴリズム YOLOv3 について紹介し、3.3 節でモデルの評価指標について説明する。3.4 節で利用する画像データセットについて説明し、3.5 節でアノテーションデータの作成について述べる。最後に 3.6 節で学習モデルの作成について説明し、3.7 節でモデルの改良について述べる。

### 3.2 物体検出アルゴリズム

本研究では YOLOv3 を用いて外観特徴の検出を行う。YOLO は入力画像全体をグリッド分割し、各グリッドの物体のカテゴリ（クラス）の確率と Bounding Box を求める一般物体検出アルゴリズムの一つである<sup>7</sup>。Joseph Redmon と Ali Farhadi が 2018 年に発表した研究では、物体検出のデータセット COCO を利用し、YOLOv3 を他の物体検出アルゴリズムと比較した。各物体検出アルゴリズムの AP（COCO では mAP を AP と呼ぶ<sup>8</sup>、AP と mAP については 3.3 節で説明する）を比較した結果、YOLOv3 の検出精度は RetinaNet より劣るが、検出速度は非常に速いとされている。図 3-1 に研究論文にある速度比較を示す図の横軸が検出速度である。さらに、図 3-2 に示すように、mAP<sub>50</sub> を評価指標とするのであれば YOLOv3 の検出精度は高くなり、検出速度も他の物体検出アルゴリズムの追随をするさない。このように、YOLO は他の物体検出アルゴリズムに比べ、処理速度が速いことと背景の誤検出が抑えられることによる高精度の検出が可能であることに特徴がある<sup>7</sup>。本研究では不動産サイトから収集した写真を用いて外観特徴の検出に取り組んでいるが、将来的にカメラの映像をリアルタイムに使う外観特徴を検出することで、建築年代推測の更なる迅速化を目指すことを考慮し、YOLOv3 を採用した。

図 3-3 に示すように、YOLOv3 では特徴量抽出に、3x3 と 1x1 の畳み込み層 (Convolutional layers) を連続させた 53 層の畳み込みニューラルネットワークを使用している。さらに、いくつかの shortcut path である Residual Block を加えたことで、前の層への入力を参照した残差関数の学習が可能となり、特徴量の学習がしやすくなる<sup>7</sup>。この 53 層の畳み込み層は Darknet53 と呼ばれている。なお、図 3-3 Residual Block を含む枠の左の数字は Residual Block の数である。例えば、2x は 2 つの Residual Block を意味している。1 つの Residual Block につき、2 層の畳み込み層を有するため、2x であれば 4 層の畳み込み層を意味する。

また、図 3-4 のように、YOLOv3 では、Darknet53 に加え、さらに 53 層を重ね、106 層の畳み込みアーキテクチャを実現している。YOLOv3 では、入力画像の次元をそれぞれ 32, 16, 8 倍にダウンサンプリングした 3 つの異なるスケールの特徴マップを用いて物体検出を行う<sup>9</sup>。図 3-4 に示すように、79 層目以降では、スケールの検出結果はそのスケールを介して得られることが分かる。細かい検出を行うために、79 層の特徴マップをアップサンプリングし始め、61 層目の特徴マップと合成することで、より薄い 91 層目の特徴マップを得ることができる。次に、91 層目の特徴マップを再度アップサンプリングし、36 層目の特徴マップと合成し、マップを作成する。最後に、入力画像に対して 8 倍ダウンサンプリングした特徴マップが得られる。これによって、小さい物体を検出するのに適している<sup>10</sup>。

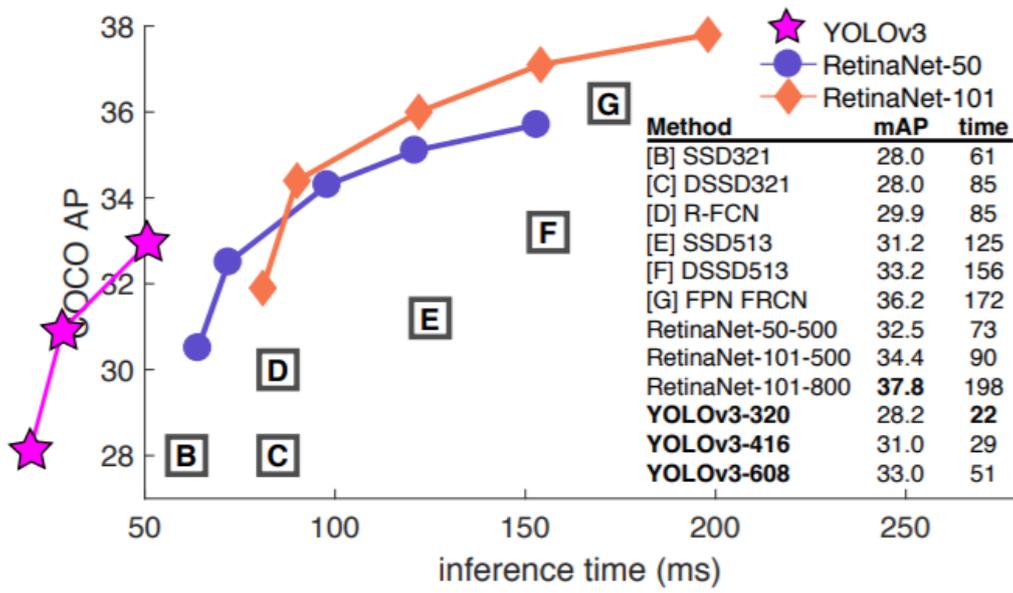


図 3-1 各物体検出アルゴリズムの COCO AP における性能の比較<sup>7</sup>

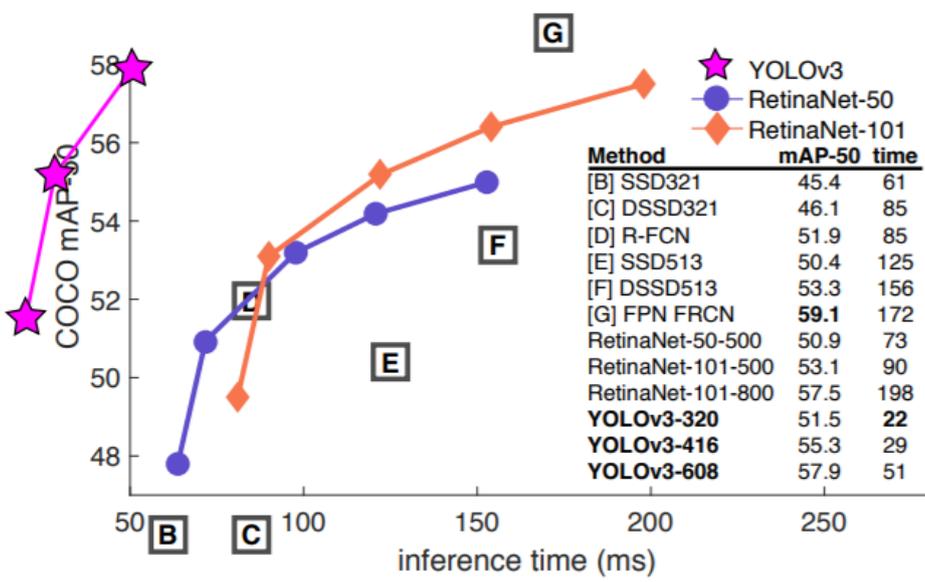


図 3-2 各物体検出アルゴリズムの COCO mAP<sub>50</sub> における性能の比較<sup>7</sup>

	Type	Filters	Size	Output
	Convolutional	32	3 × 3	256 × 256
	Convolutional	64	3 × 3 / 2	128 × 128
1x	Convolutional	32	1 × 1	
	Convolutional	64	3 × 3	
	Residual			128 × 128
	Convolutional	128	3 × 3 / 2	64 × 64
2x	Convolutional	64	1 × 1	
	Convolutional	128	3 × 3	
	Residual			64 × 64
	Convolutional	256	3 × 3 / 2	32 × 32
8x	Convolutional	128	1 × 1	
	Convolutional	256	3 × 3	
	Residual			32 × 32
	Convolutional	512	3 × 3 / 2	16 × 16
8x	Convolutional	256	1 × 1	
	Convolutional	512	3 × 3	
	Residual			16 × 16
	Convolutional	1024	3 × 3 / 2	8 × 8
4x	Convolutional	512	1 × 1	
	Convolutional	1024	3 × 3	
	Residual			8 × 8
	Avgpool		Global	
	Connected		1000	
	Softmax			

図 3-3 Darknet53 の構造<sup>7</sup>

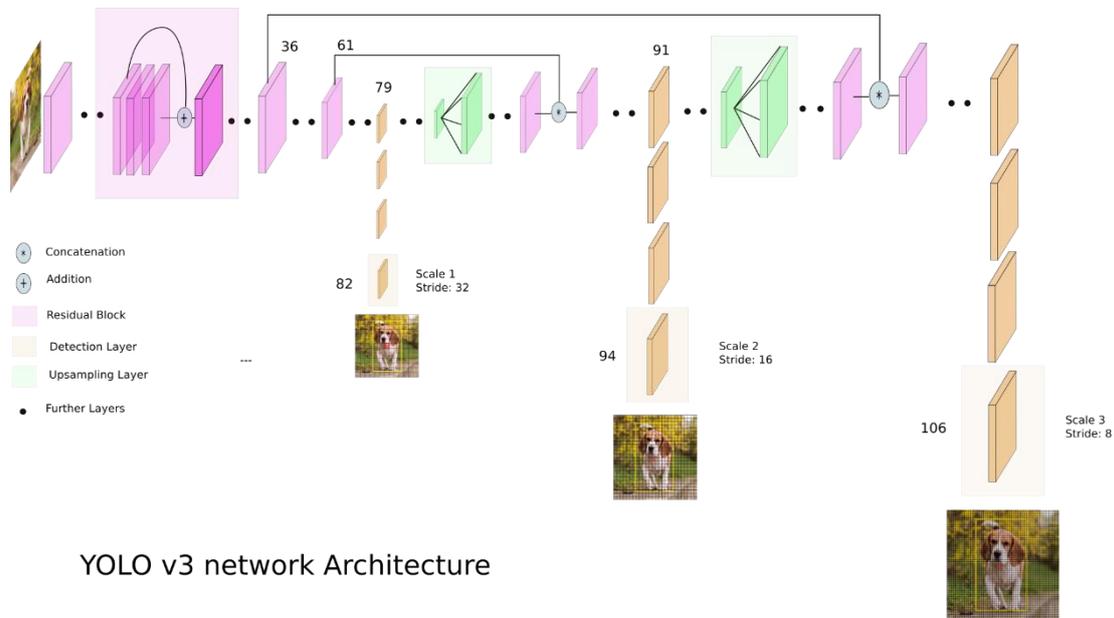


図 3-4 YOLOv3 のネットワークアーキテクチャ<sup>9</sup>

### 3.3 評価指標

作成したモデルの評価は AP (Average Precision) と mAP (mean Average Precision) を用いて行った<sup>11)</sup>。まず AP の計算に必要である閾値 IoU (Intersection over Union) について説明する。IoU とは、図 3-5 に示すように、2つの領域の積集合の面積を和集合の面積で割ったものである。なお、本研究では IoU が 0.5 以上であれば、正しく検出できたと判断する。次に、モデルの適合率 (Precision) と再現率 (Recall) を計算する。適合率と再現率は式(1)、(2)のように定義される。両式の分子は「正しく検出できた数」で同じであるが、検出できれば1増える。また、適合率の分母も一ずつ増えることになるが、再現率の分母は正解であるので変化しない。

次に、AP を計算するために、Precision を縦軸、Recall を横軸にとり、PR 曲線を描く。図 3-6 に示すように、PR 曲線 (青色の曲線) を包絡した場合、包絡後の PR 曲線 (赤色の曲線) の下側の面積の合計が AP となる。また、mAP はすべてのクラスについてさらに平均したものである。mAP の計算式の例を以下に挙げる。

$$Precision = \frac{\text{正しく (IoU} \geq 0.5) \text{ 検出できた数}}{\text{ここまで予測した Bounding Box の数}} \quad (1)$$

$$Recall = \frac{\text{正しく (IoU} \geq 0.5) \text{ 検出できた数}}{\text{すべての正解 Bounding Box の数}} \quad (2)$$

$$mAP_{\text{屋根}} = \frac{AP_{\text{無落雪}} + AP_{\text{三角}} + AP_{\text{斜め}} + AP_{\text{互}}}{4} \quad (3)$$

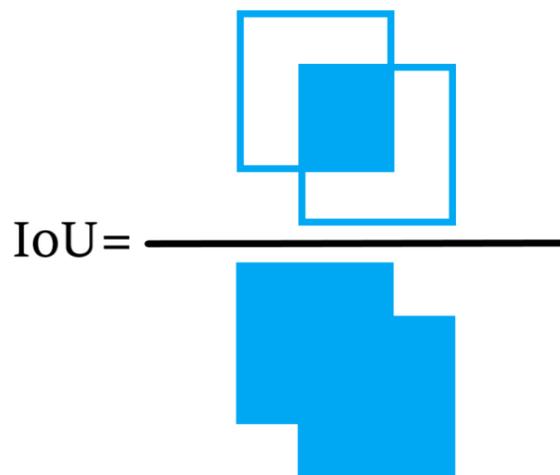


図 3-5 IoU の式

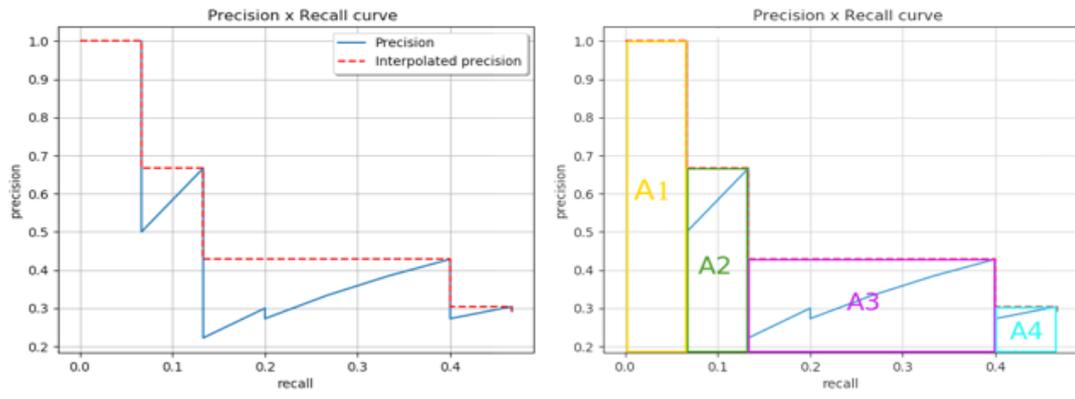


図 3-6 PR 曲線と AP の計算<sup>11</sup>

### 3.4 画像データセット

本章では利用する建築物の画像データセットについて紹介する。本画像データセットは不動産サイト「@nifty 不動産」および「athome」から収集した一戸建て住宅のものである。その一例を図 3-7 に示す。データ総数は 5000 である。そのうち 2000 個は画像のみのデータであり、3000 個は建築年がわかるデータである。画像の収集範囲は近畿以東であり、地方別の画像数は表 3-1 に示す。

表 3-1 地方別画像数

	近畿	中部	関東	東北	北海道	合計
建築年あり	830	470	1150	400	150	3000
建築年なし	532	351	734	383	0	2000
合計	1362	821	1884	783	150	5000



図 3-7 画像データの一例

### 3.5 アノテーションデータの作成

学習モデルを作成する際には、画像のデータセットの各画像に対して認識したいオブジェクトを Bounding Box で囲み、その Bounding Box で囲ったオブジェクトは何であるかを示すデータが必要である。そのデータをアノテーションデータと呼ぶ。今回はアノテーションツールの一つである LabelImg<sup>12</sup>を用い、アノテーションデータを作成する。図 3-8 は LabelImg を用いて画像にオブジェクトである玄関ドア（クラス分類：プッシュプルグリップ）のアノテーションデータを作成した例である。

YOLOv3 で使用するデータセットにおけるアノテーションの形式は図 3-9 のようになる。1 行につき 1 つのオブジェクトを示しており、各行はスペース区切りで左から、対象物のカテゴリの番号、Bounding Box 中心の x 座標、Bounding Box 中心の y 座標、Bounding Box の幅、Bounding Box の高さである。Bounding Box の中心座標 (x, y) は画像の左上を (0, 0)、画像の右下を (1, 1) としてときの座標である。また、Bounding Box の幅と高さは、画像全体の幅および高さを 1 としたときの相対値である。

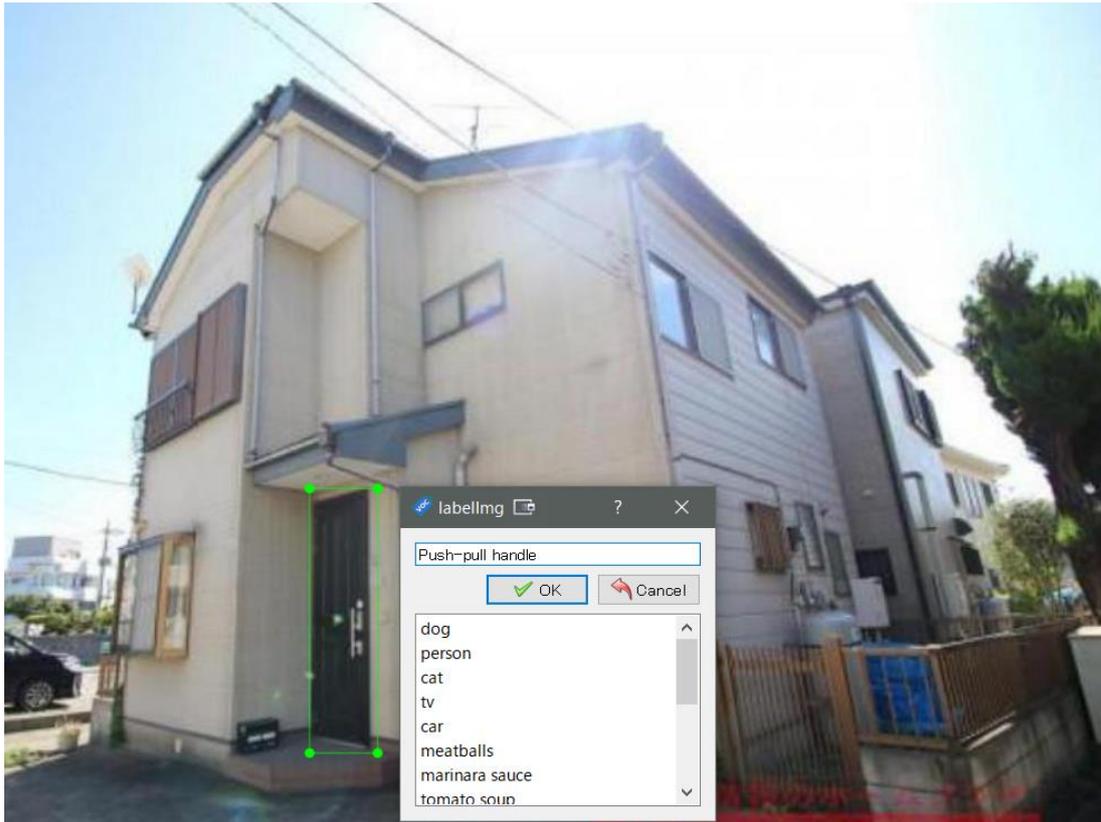


図 3-8 LabelImg を用いたアノテーションデータの作成（ドアの選択例）



図 3-9 アノテーションデータの形式

### 3.6 学習モデルの作成

上述したデータセットを用いて、学習モデルを作成する。5000 枚の画像のうち、3840 枚を学習データとし、1160 枚をテストデータとする。パッチサイズは 128、エポック数は 50000 で学習を行う。各外観特徴のクラス分類は表 3-2 に示す。

学習結果である各外観特徴の mAP<sub>50</sub> と外観特徴ごとのクラスの AP<sub>50</sub> を表 3-3 および表 3-4 に示す。なお、表に示す mAP, AP の下付数字である 50 は、IoU が 0.5 の時の AP と mAP の意味である。

表 3-2 学習モデルにおける各外観特徴のクラス分類

ドアノブ	外壁	換気口	屋根
握り玉	モルタル	フード付き	無落雪
引き戸	木製	妻換気	三角
サムラッチ錠	タイル	軒裏	斜め
レバードアノブ	サイディング	円型	瓦
プッシュプルグリップ		四角型	

表 3-3 学習モデルにおける各外観特徴の mAP<sub>50</sub>

	ドアノブ	外壁	換気口	屋根
mAP <sub>50</sub>	41.49	33.54	54.36	55.18

表 3-4 学習モデルにおける各クラスの AP<sub>50</sub>

	ドアノブ				
	握り玉	引き戸	サムラッチ	プッシュプルグリップ	レバードアノブ
AP <sub>50</sub>	38.15	68.31	29.76	36.47	34.76
	外壁				
	モルタル	木製	タイル	サイディング	
AP <sub>50</sub>	42.89	38.79	29.74	22.72	
	換気口				
	フード付き	妻換気	軒裏	円型	四角型
AP <sub>50</sub>	63.34	60.18	59.43	47.21	41.64
	屋根				
	無落雪	三角	斜め	瓦	
AP <sub>50</sub>	66.43	59.43	61.12	33.75	

学習モデルの mAP<sub>50</sub> と AP<sub>50</sub> を計算した結果、表 3-3 にあるように外壁の mAP<sub>50</sub> は 33.54% となり、外壁の各分類の AP<sub>50</sub> は全部 50% を下回ることが分かった。そのため、外壁の検出適合率は低く、検出が困難であると判断した。換気口と屋根の mAP<sub>50</sub> の値は外壁に比べて一段高いため、AP<sub>50</sub> が低いクラスの検出基準を改良すれば、利用できると考えられる。

ドアノブに関しては、引き戸の検出性能 AP が 68.31 と他のクラスより一段高いことが分かった。その理由は、不動産サイトで掲載されている一部の画像の解像度が低いため、ドアを分類する際に、解像度が低い画像に関しては、ドアノブではなく、ドアのアスペクト比によってドアを分類していると考えられる。握り玉・サム

ラッチ・プッシュプルグリップ・レバードアノブの4種類のドアのアスペクト比はほぼ一致しているため、それらの分類は困難と考えられる。したがって、2.3節で述べたドアノブと建築年代の関係を考慮し、握り玉・サムラッチ・プッシュプルグリップ・レバードアノブの4種類のドアを引き戸以外として分類すれば、ドアの検出は改良できると考えられる。

換気口に関しては、円型と四角型のAP<sub>50</sub>はフード付き・妻換気・軒裏より一段低いことが分かった。また、屋根に関しては、無落雪・三角・斜めは形であることに對し、瓦は材質であることから、瓦の検出性能が低いと考えられる。

### 3.7 モデルの改良

上述した考えられる原因を踏まえて、モデルの改良を試みる。外壁の検出は困難であるため、データセットから省く。ドアノブに関しては、2.3節で述べたドアノブと建築年代の関係を考慮し、握り玉・サムラッチ・プッシュプルグリップ・レバードアノブを引き戸以外としてまとめる。また、換気口について、換気口の位置に着目し、円型と四角型をフード付きとして扱う。屋根に関しては、瓦屋根の形は一般的に三角や複合形であるため、瓦屋根を三角屋根にまとめる。改良後のクラス分類を表3-5に示す。

改良モデルの学習は3.6節と同様に、5000枚の画像のうち、3840枚を学習データとし、1160枚をテストデータとする。パッチサイズは128、エポック数は50000で学習を行った。学習結果である各外観特徴のmAP<sub>50</sub>と外観特徴ごとのクラスのAP<sub>50</sub>は表3-6および表3-7に示す。

表3-5 改良モデルにおける各外観特徴のクラス分類

ドアノブ	換気口	屋根
引き戸	フード付き	無落雪
引き戸以外	妻換気	三角
	軒裏	斜め

表3-3 改良モデルにおける各外観特徴のmAP<sub>50</sub>

	ドアノブ	換気口	屋根
mAP <sub>50</sub>	69.68	61.39	66.27

表3-4 改良モデルにおける各クラスのAP<sub>50</sub>

	ドアノブ		
	引き戸	引き戸以外	
AP <sub>50</sub>	69.17	70.18	
	換気口		
	フード付き	妻換気	軒裏
AP <sub>50</sub>	68.14	57.24	58.79
	屋根		
	無落雪	三角	斜め
AP <sub>50</sub>	67.54	68.37	62.89

モデルを改良した結果、3.6節の初期モデルに比べ、ドアノブと屋根の検出性能を高めることができた。作成した改良モデルの外観特徴検出結果を図3-10に示す。赤色 Bounding Box に囲まれた対象物は正しく三角屋根として検出されている。同様に、黄色 Bounding Box に囲まれた対象物はフード付き換気口として、紫色 Bounding Box に囲まれた対象物は引き戸以外のドアとして検出され、空色 Bounding Box に囲まれた対象物引き戸として検出されている。



図 3-10 外観特徴の検出例

## 4. 年代予測モデルの構築

### 4.1 はじめに

本章では階層型ニューラルネットワークを用いて、建築年代予測モデルを構築する。まず4.2節でニューラルネットワークの学習方法である誤差逆伝播法について説明する。4.3節で予測モデルの構築に用いるデータセットについて述べ、4.4節でモデルの評価指標を紹介する。4.5節で予測モデルの構築について説明し、その評価を4.6節で述べる。

### 4.2 誤差逆伝播法

ニューラルネットワークの学習には誤差逆伝播法を利用する<sup>13</sup>。誤差逆伝播法は、図4-1に示すように、出力を計算し終えたときに、正解値を教師信号として与え、その教師信号と出力信号で比較し誤差を割り出す。次にその誤差の情報を入力層に返し、各層間の重みを調整しつつ再び出力を行う。この作業を何度も繰り返す、誤差を許容範囲まで学習を繰り返すものである。

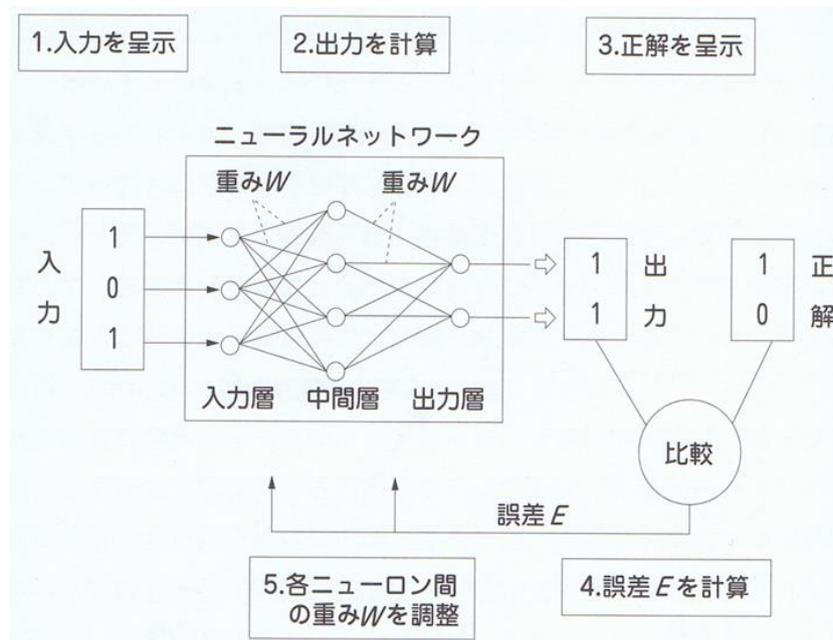


図 4-1 誤差逆伝播法<sup>13</sup>

出力層から中間層への重み付け  $W$  と誤差  $E$  を以下の式で示す。 $t_i$  は教師信号とし、 $o_i$  は出力とする。 $\Delta W_{kj}$  は  $k$  層（出力層） $j$  番目のニューロンにかかる重みの修正量で、 $\eta$  は学習係数、 $X$  は中間層からの出力である。

$$E = \frac{1}{2} \sum_{i=1}^n (t_i - o_i)^2$$
$$\Delta W_{kj} = -\eta \frac{\partial E}{\partial W_{kj}} = -\eta \delta_k X_j$$

\*  $\delta_k = (t_k - o_k) o_k (1 - o_k)$

### 4.3 データセット

本節では利用するデータセットは第3章の改良モデルが出力した1160個のテストデータである。当データセットの内容は、建築年と改良モデルによって検出された外観特徴のデータである。当データセットの内容は表4-1に示す。また、表4-1に示すように、各外観特徴をモデルに入力するため、数値化している。また、データ入力時に、データの数値を0~1の範囲に納める必要があるため、データの正規化を行う。

表 4-1 各データの数値化

換気口	屋根	ドアノブ	建築年代
0.フード付き	0.無落雪	0.引き戸	0.~1970
1.妻換気	1.三角	1.引き戸以外	1.1971~1980
2.軒裏	2.斜め		2.1981~

### 4.4 評価指標

各モデルの精度は、次式で示す平均絶対誤差 (MAE) と二乗平均平方根誤差 (RMSE) 及び混同行列 (図 4-2) の正解率と適合率および再現率で評価する。MAE と RMSE が 0 に近づくほどモデルの精度が高い。

$$MAE = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n}$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}}$$

$n$ : データ数

		予 測	
		1	0
実 際	1	TP	FN
	0	FP	TN

図 4-2 混同行列

$$\text{正解率} = \frac{TP + TN}{TP + FP + FN + TN}$$

$$\text{適合率} = \frac{TP}{TP + FP}$$

$$\text{再現率} = \frac{TP}{TP + FN}$$

#### 4.5 モデルの学習

ニューラルネットワークの学習に用いる入力データはドアノブ(以下, frontdoor\_doorknob), 換気口(以下, airvent), 屋根(以下, roof)の計3種である。建築年代を教師信号とする。

以下の学習パターンを実施した。

- ・入力層(frontdoor\_doorknob, airvent, roof), 中間層ユニット数3(以下, O3)
- ・入力層(frontdoor\_doorknob, airvent, roof), 中間層ユニット数4(以下, O4)
- ・入力層(frontdoor\_doorknob, airvent, roof), 中間層ユニット数5(以下, O5)

全1160個データのうち, 960個のデータを学習データとし, 残りの200個のデータをテストデータとする。パッチサイズは32, エポック数は50000で学習を行う。

#### 4.6 モデルの評価

3通りのパターンで学習させた結果, 各モデルの混同行列を表4-2~表4-4に, テストデータのMAEとRMSE, 並びに正解率と適合率および再現率を表4-5に示す。

表 4-2 03 モデルの混同行列

		予測値		
		1	0.5	0
真 値	1	8	24	13
	0.5	21	74	34
	0	7	11	8

表 4-3 04 モデルの混同行列

		予測値		
		1	0.5	0
真 値	1	22	14	9
	0.5	28	71	30
	0	6	8	12

表 4-4 05 モデルの混同行列

		予測値		
		1	0.5	0
真 値	1	19	18	8
	0.5	12	76	41
	0	8	14	4

表 4-5 学習モデルの評価

モデル	MAE	RMSE	正解率	適合率	再現率
03	0.2945	0.5352	0.4500	0.3489	0.3530
04	0.2288	0.3919	0.5250	0.4639	0.5002
05	0.2769	0.5003	0.4950	0.4221	0.3884

テストデータにおける MAE と RMSE, 並びに正解率と適合率および再現率を計算した結果, 04 モデルの正解率と再現率が 50%以上になることが分かった。また, 各モデルの正解率は 50%前後であるものの, AI によって生成された入力データを用いたことから, 物体検出モデルをさらに改良することで, より高精度で建築年代を予測できると考えられる。

## 5. 結論

### 5.1 まとめ

本研究では建築物の建築年代調査の簡易化のため、物体検出技術を用いて外観特徴をAIに検出させ、ニューラルネットワークモデルを利用する手法を提案した上で、その可能性を評価した。

また、本研究で使用した物体検出アルゴリズムであるYOLOv3は処理速度が速いため、今後Googleストリートビューなどの技術と持ち合わせれば、より迅速的に建築物の建築年代を把握できると考えられる。

### 5.2 今後の課題

現段階では、図5-1と図5-2に示すように、誤検出のデータが多く、物体検出モデルの精度はまだ高くない。例えば、図5-1では、勝手口を玄関ドアとして検出しており、勝手口の右にある窓を引き戸として検出している。図5-2では、隣の建物の屋根を検出している。また、玄関ドアのBounding Boxはドアでないものを囲んでいる。したがって、今後の課題として、画像データをさらに増やし、物体検出モデルの精度を高めることや、より高精度な検出が可能となる手法の開発などが挙げられる。



図 5-1 勝手口の誤検出



図 5-2 玄関ドアと屋根の誤検出

## 参考文献

1. 戸田 和徳, 境 有紀 (2011), 強震観測点周辺における木造建物群の実被害データの補正 (その1) 建物写真を用いた建築年判定方法の検討, 日本建築学会大会学術講演梗概集, 構造II, pp.901-902.
2. 長内 奈津美 (2016), 木造一戸建て住宅の外観による建築年代の決定に関する調査, 平成28年地球環境学科卒業研究.
3. 潘 蔣杰 (2020), ニューラルネットワークを利用した既存一戸建て住宅の建築年代予測, 平成31年地球環境防災学科卒業研究.
4. 潘 蔣杰, 片岡 俊一 (2021), ニューラルネットワークを利用した既存一戸建て住宅の建築年代予測, 東北地域災害科学研究. vol.57, pp. 103-108.
5. 空間情報クラブ編集部 (2022), “AIは建物のどこを見て築年代を予測するのか | Grad-CAMによる画像判断根拠の可視化”, <<https://club.informatix.co.jp/?p=15061>>, 2022年1月18日アクセス.
6. YOLO, <<https://pjreddie.com/darknet/yolo/>>, 2021年アクセス.
7. J.Redmon, A.Farhadi (2018), “YOLOv3: An Incremental Improvement”, arXiv:1804.02767.
8. COCO, <<https://cocodataset.org/#detection-eval>>, 2022年1月27日アクセス.
9. Ayoosh Kathuria (2018), “What’s new in YOLOv3?”, <<https://towardsdatascience.com/yolo-v3-object-detection-53fb7d3bfe6b>>, 2022年1月24日アクセス.
10. Shenshen GU, Wei Zeng, Yuxuan Jia, Zheng Yan (2019), “Intelligent Tennis Robot Based on a Deep Neural Network”, Appl. Sci. Vol.9, No.18, 3746, <<https://doi.org/10.3390/app9183746>>.
11. Rafaelpadilla (2018), “Object-Detection-Metrics”, <<https://github.com/rafaelpadilla/Object-Detection-Metrics>>.
12. LabelImg, <<https://github.com/tzutalin/labelImg>>, 2020年アクセス.
13. 田辺和利 (2003), 『NEUROSIM/Lによるニューラルネットワーク入門』, 日刊工業新聞社.
14. At Home, “不動産のことなら【アットホーム】物件探しから住宅情報まで”, <<https://www.athome.co.jp/>>, 2021年アクセス.
15. NIFTY Lifestyle, “不動産・住宅情報をまとめて検索【ニフティ不動産】”, <<https://myhome.nifty.com/>>, 2021年アクセス.
16. 萩原克幸 (2006), ニューラルネットワークの基礎と理論的に重要な課題, J. Plasma Fusion Res. Vol.82, No.5, pp. 282-286.

## 謝辞

本論文は筆者が弘前大学大学院地域共創科学研究科に在籍中の研究の成果をまとめたものである。本研究を進めるにあたって、指導教員である片岡俊一 教授には数多くのご指導と助言をしていただきました。心から深く感謝申し上げます。

また、増山篤 教授，上原子晶久 准教授には多くの助言をいただきました。深く感謝申し上げます。最後になりましたが，これまで温かい目で見守ってくれた友人たちに，深く御礼を申し上げます。