

不動産物件画像分類におけるラベルノイズの影響

市原 大也^{†a)} 岡本 一志^{†b)} 柴田 淳司^{††c)}

Effects of Noisy Labels on Real Estate Image Classification

Hiroya ICHIHARA^{†a)}, Kazushi OKAMOTO^{†b)}, and Atsushi SHIBATA^{††c)}

あらまし 不動産業界では、不動産物件画像の分類のように画像を活用した研究が取り組まれているが、近年ラベルの品質の問題が指摘されている。不動産物件画像にはキッチンやトイレなどの画像に対応するラベルが1対1で存在するが、誤ったラベルが付与された画像や、複数のラベルを付与すべき画像の存在、画像が曖昧であり適切なラベルが存在しない画像、といったラベルノイズの問題がある。本研究では、3種類のラベルノイズを仮定し、それらの分布を明らかにし、不動産物件画像の分類におけるラベルノイズの影響を調査する。LIFULL HOME'S データセットに対して、複数のアノテータによって3種類のラベルノイズに分類し、それらを使用してラベルノイズの有無による不動産物件画像の分類モデルの予測精度の比較をする。実験の結果、30,800画像のうち17%がラベルノイズであり、予測精度の向上の観点では、誤ったラベルが付与されている画像は学習データから除去することが望ましく、複数のラベルを付与すべきであるが一つのみ付与されている画像は除去しなくてもよいことを確認している。

キーワード 不動産、画像分類、ラベルノイズ、アノテーション

1. ま え が き

不動産業界では賃料、面積、築年数などの物件の属性情報の他に、間取り図や外観、内観といった画像データが活用されている。特に、賃貸・売買の契約を検討している人にとって、物件の写真のニーズは高く [1]、例えば、深層学習を用いて不動産物件画像の分類モデルを構築し、不動産業者の入稿作業の負担を軽減する試みがある [2]。また、清田らは、画像分類モデルなどの AI を活用した不動産物件画像のデータベースの整備がユーザ体験の向上に重要であるとしている [3]。このような背景の中で、近年、物件の画像に付与されるラベルの品質が問題として指摘されている [4]。具体的には、不動産情報サイトに掲載されている物件の画像は、所有者や不動産業者が独自に撮影やラベル付与

を行っているため統制が取れておらず、適切なラベル付与がされていないケースがあるというものである。

一般に、データセットのラベルノイズとは、犬の画像に猫のラベルが付与されることのように、付与された単一のラベルに誤りがあることを指す [5], [6]。近年では、画像認識分野のベンチマークデータセットの一つである ImageNet [7] のラベルの品質が分析されており [8], [9]、特に、画像中に複数の物体が写っているにもかかわらず、画像1枚につき一つのラベルのみが付与されることの問題が指摘されている [10], [11]。

現在、不動産分野の研究で広く利用されている LIFULL HOME'S データセット [12] では物件ごとの間取り図や外観、内観などの画像データが含まれているが、例えば、キッチンの画像にトイレのラベルが付与されているなど、画像に付与されたラベルに誤りがあるケースが存在する。これは、一般的なデータセットにおけるラベルノイズの問題に相当する。加えて、玄関とキッチンが写っている画像に付与されたラベルがキッチンのみなどの、前述の ImageNet でのラベルノイズの問題も確認している。更に、画像内容に適切なラベルが存在しないケースも確認している。本研究では、これらの観察をもとに、LIFULL HOME'S データセットの各画像に対して3種類のラベルノイズを仮定

[†] 電気通信大学大学院情報理工学研究所, 調布市

Graduate School of Informatics and Engineering, The University of Electro-Communications, 1-5-1 Chofugaoka, Chofu-shi, 182-8585 Japan

^{††} 東京都立産業技術大学院大学産業技術研究所, 東京都

Graduate School of Industrial Technology, Advanced Institute of Industrial Technology, 1-10-40 Higashi-Ōi, Shinagawa-ku, Tokyo, 140-0011 Japan

a) E-mail: ichihara@uec.ac.jp

b) E-mail: kazushi@uec.ac.jp

c) E-mail: shibata-atsushi@aait.ac.jp

DOI:10.14923/transinfj.2023DEP0005

し、次の二つのリサーチクエスチョンに取り組む。

RQ1：不動産物件画像におけるラベルノイズの分布を明らかにする。

RQ2：学習データ中のラベルノイズが不動産物件画像の分類モデルの予測精度に与える影響を明らかにする。

RQ1 では、LIFULL HOME'S データセット中の不動産物件画像をランダムサンプリングし、得られた30,800枚の画像にラベルノイズの有無とその種類を複数人でアノテーションする実験を行う。ラベルノイズのアノテーションにおいては、誤ったラベルが付与されている画像、複数のラベルを付与すべきであるが一つのみ付与されている画像、適切なラベルが存在しない画像の3種類のラベルノイズを仮定する。アノテーション実験で得られたラベルノイズの集計結果から、起こりやすい種類のラベルノイズやラベルごとのラベルノイズの分布などを分析する。

RQ2 では、まず、RQ1 でアノテーションした画像について、3種類のラベルノイズの除去の組み合わせで全8通りの学習データを構築する。次に、不動産物件画像の分類モデルを構築した8種類の学習データでそれぞれ学習し、各モデルの予測精度を評価する実験を行う。この実験を通して、不動産物件画像の分類モデルの予測精度低下につながる学習データ中のラベルノイズの種類を明らかにする。

本論文の構成は次のとおりである。2. では、不動産物件画像への機械学習の応用とラベルノイズに関する先行研究を紹介する。3. では、研究デザインと仮定するラベルノイズ、実験で用いるデータセットについて説明する。4. と 5. では、ラベルノイズのアノテーション実験とラベルノイズの有無による不動産物件画像の分類モデルの予測精度の評価実験についてそれぞれ述べ、得られた実験結果の分析と考察を行う。

2. 関連研究

2.1 不動産物件画像への機械学習の応用研究

間取り図や物件の内観画像などの不動産物件画像を活用した研究が行われている。例えば、深層学習を用いて不動産物件画像から築年数や賃料などの属性情報を推定するタスクがある[13]~[15]。加えて、トイレや浴室などの画像の内容を表したラベルを付与する画像分類タスクがあり[16]~[18]、情報入力の手間削減や正確なラベル付けにおいて重要なタスクである[3]。

不動産物件画像を活用した研究では、国内において

は、国立情報学研究所の情報学研究データリポジトリで公開されているLIFULL HOME'S データセット[12]が利用される場合がある[19]~[23]。例えば、石田らや田中らはニューラルネットワークによる不動産物件画像の分類モデルを開発している[2], [24]。LIFULL HOME'S データセットは、2015年11月時点で不動産物件情報サイトLIFULL HOME'Sに掲載された物件の情報で構成されており、実際の不動産情報サービスで扱われているデータのスナップショットといえる。その一方で、不動産情報サイトの課題として、誤ったラベルが付与された画像が投稿される場合があることが指摘されている[4]。これは、不動産情報サイトに掲載されている物件画像は所有者や不動産業者が投稿したものであるが、不動産情報サイトでは毎日数百万枚の写真データが投稿されているため、運営者が個々の画像が投稿規則に準拠しているかの判断を人手で行えないことに起因する。したがって、サービスデータのスナップショットであるLIFULL HOME'S データセットにも誤ったラベルが付与された画像が含まれることとなり、我々の観察でもその存在を確認している。

2.2 ラベルノイズに関する研究

一般的な画像のデータセットにおいて、ラベルノイズとは画像に付与されたラベルに誤りがあることを意味しており、データセットを活用するうえでラベルノイズの除去や修正などの対処が求められる[5], [6]。また、Alganらはデータセットによって考慮すべきラベルノイズは多様であり、データセットの特徴に応じて対処の仕方が異なることを指摘している[25]。Xiaoらは衣服画像データセットに対してConfusing NoiseとPure Random Noiseの2種類をラベルノイズとして仮定し、それに頑健なモデルを提案している[26]。

代表的な画像データセットであるImageNetを対象に、データセットの品質を分析する研究が行われている[8], [9]。これらの研究では特に、ImageNetデータセットは単一のラベルを想定しているにもかかわらず、実際に画像に付与すべきラベルが複数存在するラベルノイズをラベルの品質の問題として着目している。Beyerらは、ImageNetデータセットにおけるラベルノイズとして、(1)画像に複数のラベルの物体が存在、(2)同義または階層的に他のラベルを含む複数のラベルが存在、(3)画像に内在する曖昧さにより複数の適切なラベルが存在、の3種類を仮定し、このようなデータが原因で画像分類モデルに対して正確な評価を行えないことを指摘している[10]。また、Beyerらは訓練

データから間違っただラベルをもつ画像を除去することで、画像分類モデルの予測精度が向上することを明らかにしている。我々はこの中でも、(1)のラベルノイズに加え、付与ラベルに誤りがあるラベルノイズが不動産物件画像にも混在していることを確認している。

誤ったラベルが付与された画像の存在は、例えば、分類モデルの研究における学習や評価に影響を与えるものと考えられる。しかしながら、不動産物件画像データベースに含まれているラベルノイズの種類や割合などは調査されておらず、それらが不動産物件画像の分類モデルに与える影響について検証されていない。これらを明らかにすることは、不動産物件画像の適切な扱い方の示唆を得ることに繋がり、その示唆は不動産物件画像の分類モデルの精度向上や不動産物件画像を活用した研究の発展などに寄与するものと思われる。

3. 研究デザイン

本研究では、LIFULL HOME'S データセットの観察に基づき、不動産物件画像に対する3種類のラベルノイズを仮定し、次の二つの実験を行う。

- (1) 不動産物件画像のアノテーションによるラベルノイズの分析 (RQ1)
- (2) ラベルノイズの有無による分類モデルの予測精度の評価 (RQ2)

本章では、不動産物件画像におけるラベルノイズの仮定について述べる。

3.1 仮定するラベルノイズ

LIFULL HOME'S データセットにおける不動産物件画像は、画像データとラベルが1対1対応しており、画像の分類タスクなどに適用できる。その一方で、我々がデータセット中の画像とそのラベルを観察したところ、誤ったラベルが付与された画像、複数のラベルを付与すべきだが単一のラベルのみ付与されている画像、適切なラベルが存在しない画像が含まれていることを確認している。これらの例を図1・図2・図3に示す。ここで、図のoriginalとは既に付与されているラベル、groundtruthとは修正が望ましいと思われるラベルを意味する。これらの観察に基づき、本研究では画像データのラベルノイズとして次の3種類を仮定する。

- **Single Label (SL) ノイズ**：誤ったラベルが付与されているケース。図1はSLノイズの画像例である。図1は適切なラベルは「外観」であるが付



図1 SLノイズの例 (original: 周辺, groundtruth: 外観)



図2 MLノイズの例 (original: キッチン, groundtruth: キッチン, 玄関)



図3 NLノイズの例 (original: キッチン, groundtruth: 無し)

与されたラベルは「周辺」である。このように、適切なラベルは存在するが誤ったラベルが付与されている画像のラベルはSLノイズに分類される。

- **Multi Label (ML) ノイズ**：複数のラベルを付与すべきであるが、一つのみ付与されているケース。図2はMLノイズの画像例である。図2は適切なラベルが「キッチン」と「玄関」であるが付与されたラベルは「キッチン」のみである。このように、複数ラベルを付与すべきであるが、そのうちの一つしか付与されていない画像のラベルはMLノイズに分類される。
- **No-groundtruth Label (NL) ノイズ**：適切なラベルが存在しないケース。図3はNLノイズの画像例である。図3は「キッチン」が付与されているが、適切なラベルの候補が存在せず修正先のラベルが存在しない。このように、修正先のラベルが存在しない画像のラベルはNLノイズに分類される。

3.2 使用データセットの概要

日本国内で利用されている不動産情報サイトでは、物件に付随する画像データに対して一つのラベルが表示される商習慣上の特性がある。豊原らは不動産物件画像のラベル付けシステムでは尤もらしいラベルを一つ付与することが必要であることを述べている[27]。本研究で使用するLIFULL HOME'S データセットは、

表1 ラベル名一覧とラベルごとの画像数

ラベル名 (LIFULL)	ラベル名 (新規付与)	画像数 [万枚]	割合 [%]	使用
間取り		523	6.3	✓
外観		946	11.4	✓
地図		12	0.14	
周辺		1,413	17.1	✓
内装		941	11.4	
その他		2,298	27.8	
玄関		269	3.2	✓
居間		558	6.7	
キッチン		453	5.4	✓
寝室		88	1.0	✓
子供部屋		1.9	0.0	
風呂		363	4.4	✓
-	トイレ	64	0.7	✓
-	洗面所	54	0.6	✓
-	収納	85	1.0	✓
-	設備	87	1.0	✓
-	バルコニー	37	0.45	✓
-	共有部	38	0.46	✓
-	駐車場	13	0.16	✓
-	室内	0.12	0.0	

2015年11月時点での不動産物件情報サイト LIFULL HOME'S に掲載された物件の賃料、面積、立地、築年数などの賃貸物件データに加え、間取り図、キッチン、外観などの計 20 種類のラベルのうち一つが付与された JPEG 形式の画像データが約 8,300 万枚含まれているスナップショットデータである。加えて、LIFULL HOME'S 以外の不動産情報ポータルサイトで保有されている画像データ [27],[28] では、LIFULL HOME'S データセットと共通するラベルが多く含まれ、画像数の分布も類似している傾向がある。また、これらの研究では本研究が対象としている不動産物件画像の分類タスクに取り組んでいる。そのため、LIFULL HOME'S データセットは一般的な不動産物件画像データセットの特性と共通しており、一般的な不動産物件画像データセットでも同様の考察・結論が得られることが期待できる。

表 1 に LIFULL HOME'S データセットのラベルごとの画像の枚数と割合を示す。なお、与えられたデータセットのマスタファイルにはラベル名が欠損しているラベルがあり、これらは画像内容を確認した上で、新たにラベル名を付与している。この作業で新規付与したラベル名を表の 2 列目に記載している。表 1 のラベルのうち、物件画像とは関係のない地図や画像の枚数が少ない子供部屋と室内、様々なラベルの画像を含有しているその他、内装、居間以外の計 14 種類のラベルのうち一つが付与された画像を扱う。

4. 実験 1：不動産物件画像のアノテーションによるラベルノイズの分析 (RQ1)

本章では、LIFULL HOME'S データセットからランダムサンプリングした画像に対して、3.1 で定義した 3 種類のラベルノイズの有無を手でアノテーションする実験について述べる。この実験により、不動産物件画像データセット中のラベルノイズの分布を明らかにする。

4.1 実験手順

本実験では、表 1 に記載した 14 種類のラベルのいずれか一つが付与された不動産物件画像について、各ラベルをもつ画像をそれぞれ 2,200 枚ランダムサンプリングし、計 30,800 枚 (14 ラベル × 2,200 枚) の実験用画像データセットを構築する。この実験用データセットに対して、各画像のラベルが、非ノイズ・SL ノイズ・ML ノイズ・NL ノイズのいずれかに該当するかのアノテーションを手で実施する。

30,800 枚の画像に一貫したアノテーションを実施するため、実験の概要や判断基準、分類例を記載したアノテーションガイドと練習問題を作成している。練習問題は、我々が作成したアノテーション例とアノテータの回答との一致率が一定の基準を超えるまで実施する。ラベルノイズのアノテーションは、理工系大学の大学生 4 名及び大学院生 7 名の計 11 人に作業依頼している。事前の分析により、間取り図ラベルの画像では各ラベルノイズがほとんど観測されなかったため、第 1 著者によるアノテーション結果を採用している。間取り図以外の 13 ラベル 28,600 枚の画像のうち 1 人当たり各ラベル 200 枚、計 2,600 枚の画像をアノテーション対象としている。アノテーション作業では、画像と付与されたラベルを一つずつ確認し、アノテーションガイドを参考に、3.1 で定義した 3 種類のラベルノイズの分類を実施する。アノテータに対してアノテーションの作業時間は 2 時間程度の見積もりであることを伝え、疲労による影響を防ぐために適切な休憩を促し、第 1 著者とアノテータとのコミュニケーションを保ちアノテーションを行っている。

アノテーションツールには、マイクロソフト社の VoTT (Visual Object Tagging Tool) を使用する。VoTT は物体検出タスクで使用されており、ピクセルレベルのアノテーションが可能で、ラベルと画像内の位置を含んだ JSON ファイルを出力できる。本実験ではピクセルレベルのラベルは使用せず、画像全体としてのラ

ベル情報のみを JSON ファイルから抽出して実験で使用する。

4.2 アノテーター致率

11 人によるアノテーション結果と、事前に作業時間の見積もりをするために第 1 著者が実施したアノテーション結果との一致率を 2 者によるアノテーションの一致率の指標である Cohen's κ 係数 [29] で評価したところ、0.728 となった。Landis らによる κ 係数の基準に従うと Substantial (0.61~0.80) となり、十分な一致率を有している [30]。また、アノテーションにおける疲労の影響の有無を調査するために、各アノテーターについて、作業前半にアノテーションされた 1,300 枚と作業後半にアノテーションされた 1,300 枚の結果をそれぞれ抽出し、前半の作業リスト 14,300 枚 (= 1,300 枚 × 11 名) と後半の作業リスト 14,300 枚 (= 1,300 枚 × 11 名) を作成した。この二つの作業リストについて、第 1 著者がアノテーションした結果 (28,600 枚) との一致率を Cohen's κ 係数で評価した。その結果、前半のリストで 0.728、後半のリストで 0.729 となり、作業前半と作業後半での一致率に差が見られないことから、疲労の影響は無視できるものと考えられる。

表 2 実験用画像データセット中のラベルノイズ画像数

	画像数 [枚]	割合 [%]
非ノイズ	25,544	82.9
SL ノイズ	2,680	8.7
ML ノイズ	2,412	7.8
NL ノイズ	164	0.5

4.3 結果と考察

4.3.1 ラベルごとのラベルノイズの分析

アノテーション作業により確認した実験用画像データセット中の画像でラベルノイズと判断された画像数を表 2 に示す。表 2 より、30,800 画像のうち、5,256 画像でラベルノイズがあることが確認できる。これは全体の 17% に相当し、その中でも SL ノイズと ML ノイズと判断された画像が 90% 以上を占めている。その一方で、NL ノイズの割合は全体の 1% 未満であった。

表 3 にラベルごとにラベルノイズと判断された画像数の内訳を示す。表の SL ノイズ・ML ノイズ・NL ノイズの列の割合の値は、当該ラベルでラベルノイズありと判断された画像のうち、各ラベルノイズに該当する画像の割合を意味しており、行方向に (3 種類のラベルノイズの中で) この割合の値が最も高い箇所を太字としている。また、全体の列の割合の値は、各ラベルでラベルノイズとなる画像数を、全てのラベルノイズ画像の数 (5,256 枚) で割ったものを意味している。

表 3 より、間取りや周辺のラベルではラベルノイズと判定された画像がそれぞれ 9 枚と 96 枚となっており、他のラベルと比較してラベルノイズが生じにくい傾向がある。また、全 14 ラベルのうち 11 のラベルの画像で半数以上が SL ノイズとなっており、更に、SL ノイズの割合の列の平均は 57.6% であることから、ML ノイズ・NL ノイズと比べて出現割合が高く、SL ノイズが多くラベルの画像で生じている。その中でも、SL ノイズの割合が 81.3% と最も高い設備のラベ

表 3 ラベルノイズと判定された画像の内訳

ラベル	SL ノイズ		ML ノイズ		NL ノイズ		全体	
	画像数 [枚] (a)	割合 [%] (a) / (d)	画像数 [枚] (b)	割合 [%] (b) / (d)	画像数 [枚] (c)	割合 [%] (c) / (d)	画像数 [枚] (d)	割合 [%] (d) / 5,256
間取り	7	77.8	2	22.2	0	0	9	0.171
外観	215	50.2	191	44.6	22	5.14	428	8.14
周辺	72	75.0	11	11.5	13	13.5	96	1.83
玄関	374	54.5	292	42.6	20	2.92	686	13.1
キッチン	153	56.7	111	41.1	6	2.22	270	5.14
寝室	146	62.4	82	35.0	6	2.56	234	4.45
風呂	149	18.8	638	80.4	7	0.882	794	15.1
トイレ	152	55.5	118	43.1	4	1.46	274	5.21
洗面所	243	34.7	448	64.0	9	1.29	700	13.3
収納	137	43.1	168	52.8	13	4.09	318	6.05
設備	471	81.3	88	15.2	20	3.45	579	11.0
バルコニー	208	74.3	57	20.4	15	5.36	280	5.33
共有部	170	68.5	64	25.8	14	5.65	248	4.72
駐車場	183	53.8	142	41.8	15	4.41	340	6.47
画像数の合計	2,680	-	2,412	-	164	-	5,256	-
割合の平均	-	57.6	-	38.6	-	3.78	-	-
割合の標準偏差	-	17.6	-	19.1	-	3.31	-	-

表4 大都市, 非大都市における各ラベルノイズの発生数 (発生確率)

	SL ノイズ	ML ノイズ	NL ノイズ	非ノイズ
大都市	1,537 枚 (8.7%)	1,283 枚 (7.3%)	92 枚 (0.5%)	14,758 枚 (83.5%)
非大都市	1,136 枚 (8.7%)	1,127 枚 (8.6%)	72 枚 (0.5%)	10,795 枚 (82.2%)

ルが付与された画像では、トイレや収納のような、より細分化されたラベルが適切な画像が含まれる傾向を確認している。この傾向から、投稿者間でのラベル付けの統制が取れていないことに起因して SL ノイズが発生していると考えられる。

その一方で、ML ノイズと判断された画像が半数以上となるラベルは 14 ラベルのうち 3 ラベルでのみとなっており、多く出現するラベルが特定のラベルに偏っている。これは、複数のラベルを付与すべき画像である ML ノイズはラベル間で発生する確率が異なることを示唆している。ML ノイズの画像を観察したところ、例えば、ML ノイズの割合が 80.4% と最も高い風呂のラベルが付与された画像では、ユニットバスのように浴槽や便器、洗面台が同時に写る傾向を確認している。そのため、不動産物件画像において、複数のラベルに関係するオブジェクトが写っている場合などがあり、これは風呂、洗面所、収納などのラベルの画像に多く発生していると考えられる。

最後に、NL ノイズは各ラベルでも出現してはいるものの、全てのラベルで SL ノイズや ML ノイズの画像数に比べ相対的に画像数が少なく、生じる確率は低い傾向がある。

4.3.2 物件種別, 地域ごとのラベルノイズの分析

不動産物件画像においてラベルノイズが発生する原因の知見を得ることは品質の向上につながり、それを利用したサービスの向上につながると考えられる。そこで、物件種別や地域ごとに各ラベルノイズの発生確率を分析する。

まず、物件が撮影された都市の規模の違いによるラベルノイズの発生確率を比較する。総務省統計局の定義にならない、東京都特別区部及び政令指定都市を大都市、それ以外を非大都市とする。大都市と非大都市における各ラベルノイズの発生数 (発生確率) を表 4 に示す。表 4 より、大都市と比較して非大都市における ML ノイズの割合は 1% ほど多いもののその差は小さく、都市の規模による各ラベルノイズの発生確率に差は見られない。

表5 物件種別ごとの各ラベルノイズの発生数 (発生確率)

	SL ノイズ	ML ノイズ	NL ノイズ	非ノイズ
マンション	1,655 枚 (8.6%)	1,401 枚 (7.3%)	85 枚 (0.4%)	16,125 枚 (83.7%)
アパート	931 枚 (8.8%)	941 枚 (8.9%)	67 枚 (0.6%)	8,690 枚 (81.8%)
一戸建て	33 枚 (7.6%)	33 枚 (7.6%)	7 枚 (1.6%)	361 枚 (83.2%)
テラスハウス	25 枚 (7.7%)	28 枚 (8.7%)	1 枚 (0.3%)	269 枚 (83.3%)
事業用賃貸	29 枚 (20.0%)	7 枚 (4.7%)	4 枚 (2.7%)	108 枚 (73.0%)

次に、物件種別の違いによる各ラベルノイズの発生確率を比較する。マンション、アパート、一戸建て、テラスハウス、事業用賃貸におけるラベルノイズの発生数 (発生確率) を表 5 に示す。表 5 より、画像数の多いマンション、アパートの物件種別における各ラベルノイズの割合には大きな違いが見られない。

以上の分析から、不動産物件画像においてラベルノイズを減少させるためには、地域や撮影された物件種別にかかわらず、新たに入稿される未知の画像に対して精度の良いラベル付けをするシステムや既にラベル付けされたデータに対して、どのラベルに修正すべきかの候補を提示するシステムなどのラベル品質維持の取り組みが重要であると考えられる。

5. 実験 2: ラベルノイズの有無による分類モデルの予測精度の評価 (RQ2)

本章では、4. でアノテーションした画像について、3 種類のラベルノイズの除去の組み合わせで全 8 通りの学習データを構築し、各学習データで不動産物件画像の分類モデルを学習したときの予測精度を比較する実験を行う。LIFULL HOME'S データセット中の画像には単一のラベルしか付与されておらず、マルチラベルを付与可能な画像を評価用データとして抽出することはコストが高いため、データセット準備の都合上、本実験での不動産物件画像の分類モデルは、入力画像に対して一つのラベルを付与するものとする。本実験により、不動産物件画像の分類モデルの予測精度に影響を与えるラベルノイズの種類を明らかにする。

5.1 実験手順

本実験で用いる学習データ・テストデータ・不動産物件画像の分類モデルの 3 点について述べる。

5.1.1 学習データの構築

不動産物件画像の分類モデルの学習に使用する学習

表6 構築する8通りの学習データ(各学習データでは除去する種類のラベルノイズ画像が異なる)

学習データ	除去するラベルノイズ		
	SLノイズ	MLノイズ	NLノイズ
ϕ			
w/o SL, ML, NL	✓	✓	✓
w/o SL	✓		
w/o ML		✓	
w/o NL			✓
w/o ML, NL		✓	✓
w/o SL, NL	✓		✓
w/o SL, ML	✓	✓	

データの構築には、4. でラベルノイズのアノテーションを実施した 30,800 枚の画像を用いる。構築する学習データは全 8 通りであり、30,800 枚の画像から該当するラベルノイズの画像を除去することで各学習データを構築する。不動産物件画像の分類モデルは、一つのベースモデルについて、各学習データを使用して学習し、最終的に 8 種類の分類モデルを作成する。構築する学習データの一覧を表 6 に示す。表 6 の各行では、学習データから除去する種類のラベルノイズを記載している。例えば、w/o ML, NL の学習データでは、30,800 枚の画像から ML ノイズ, NL ノイズに分類された画像を除去したデータセットを意味している。

5.1.2 テストデータの作成

不動産物件画像の分類モデルの予測精度の評価には、14 ラベルの画像からそれぞれ 200 枚ずつ新規にランダムサンプリングした計 2,800 枚の画像を評価用データ(テストデータ)として使用する。テストデータでは、学習データと同様にラベルノイズが含まれている可能性がある。そのため、3 人のアノテータによる多数決によって、テストデータの画像に適切なラベルを付与するラベル修正を実施する。アノテータの属性は、ラベルノイズのアノテーション(4. の実験)参加者 1 名、第 1 著者、及び理工系大学の大学生 1 名の計 3 人である。なお、4. の実験では、第 1 著者は間取り図ラベルのチェックのみ、この最後の理工系大学の大学生 1 名は不参加となっている。ラベル修正の手順は、各画像と付与されたラベルを一つずつ確認し、誤ったラベルであれば適切なラベルに修正することで実施する。もし、ラベル修正の際に、適切なラベルが付与できない場合はその他のラベルを付与する。

テストデータのアノテーション作業後、各画像について、3 人によるラベル修正後の画像のうち二つ以上のラベルが一致しており、かつ、ラベルがその他でない画




図4 テストデータのラベルの修正前後の比較(縦:修正前のラベル, 横:修正後のラベル)

像を 2,723 枚抽出し、それらを不動産物件画像の分類モデルの評価用のテストデータとして使用する。3 人によるラベル修正の一致率を、複数人によるアノテーションの一致率の指標として使用される [31] Fleiss's κ 係数 [32] で評価したところ値が 0.895 であった。その結果より、アノテータ間で高い同意を得られており、3 人によるチェックの品質は担保されているものと考えられる。各ラベルの修正前後の結果を図 4 の混同行列に示す。

5.1.3 不動産物件画像の分類モデル

画像分類タスクにおいては、大規模データセットでの学習済みモデルを使用することで効率的に解けることが知られている。そこで本実験では、学習済み畳み込みニューラルネットワーク [33] である VGG16 [34] と ResNet50 [35], ResNet100, EfficientNetB3 [36] を不動産物件画像でファインチューニングして使用する。学習済みモデルの利用にあたっては、各モデルの最後の全結合層を削除し、最終層に活性化関数に ReLU を使用した 256 ユニットの全結合層、ドロップアウト率 0.5 のドロップアウト層、活性化関数にソフトマックス関数を使用した 14 ユニットの出力層を追加する。

ファインチューニングで用いる最適化アルゴリズムには確率的勾配降下法を使用し、エポック数は 50、バッチサイズは 64 としている。学習率、momentum、weight decay のハイパーパラメータは、ベースラインとなる学習データ ϕ を用いた 5-fold 交差検証でのグリッドサーチにより最適なパラメータを探索する。その結

表7 ハイパーパラメータ探索の結果

モデル	学習率	momentum	weight decay
VGG16	0.0001	0.0	0.0
ResNet50	0.00001	0.9	0.0
ResNet101	0.0001	0.0	0.0
EfficientNetB3	0.0001	0.9	0.0001

果を表7に示す。また、損失関数にはカテゴリーカルクロスエントロピー損失 (Categorical Cross Entropy Loss : CCE) を、評価指標には正解率 (Accuracy) を使用する。ここで、データ数を N 、クラス数を C 、画像 \mathbf{x} の正解ラベルの one-hot 表現を $\mathbf{y}(\mathbf{x}) \in \{0, 1\}^C$ 、画像分類モデルの出力を $f(\mathbf{x}) \in [0, 1]^C$ とすると、CCE は、

$$-\frac{1}{N} \sum_{n=1}^N \sum_{c=1}^C y^{(c)}(\mathbf{x}_n) \log f^{(c)}(\mathbf{x}_n) \quad (1)$$

で定義される。Accuracy は予測ラベルと正解ラベルが一致している割合を示す指標であり、

$$\frac{1}{N} \sum_{n=1}^N \mathbb{1}(\operatorname{argmax} f(\mathbf{x}_n) = \operatorname{argmax} \mathbf{y}(\mathbf{x}_n)) \quad (2)$$

と表現される。

5.2 結果と考察

5.2.1 予測精度による分析

学習データ中の各種ラベルノイズの有無によるファインチューニング後の分類モデル (VGG16, ResNet50, ResNet100, EfficientNetB3) の Accuracy と CCE をそれぞれ表8と表9に示す。表8より、ベースラインであるラベルノイズを除去しない学習データ ϕ の場合と比較して、VGG16, ResNet101, EfficientNetB3 では学習データ w/o SL, NL の場合に、ResNet50 では学習データ w/o SL の場合に Accuracy が最も向上し、それぞれ 2.1, 0.9, 1.7, 1.9% 増加した。また、表9より、CCE は全てのモデルで学習データ w/o SL, NL の場合に最も改善し、それぞれ 0.089, 0.044, 0.028, 0.048 減少した。

以上の結果から、Accuracy が向上し、CCE が改善する場合には SL ノイズを除去していることが共通している。したがって、SL ノイズは不動産物件画像の分類モデルに対して悪影響を与えているため除去すべきデータといえる。また、学習データ w/o ML つまり ML ノイズを除去した際は、学習データ ϕ の場合と比較して全モデルで Accuracy が減少し、CCE が増加していることから ML ノイズの画像は除去すべきでない有用なデータであると考えられる。その一方で、表8、

表8 学習データ中のラベルノイズの有無によるファインチューニング後の分類モデルの Accuracy の比較

学習データ	VGG16	ResNet50	ResNet101	EfficientNetB3
ϕ	85.4	87.5	87.8	88.4
w/o SL, ML, NL	87.4	87.8	88.4	88.0
w/o SL	87.3	89.4	87.3	90.0
w/o ML	84.6	86.3	87.0	87.9
w/o NL	83.8	87.1	87.7	88.8
w/o ML, NL	84.0	87.4	87.0	87.3
w/o SL, NL	87.5	88.5	88.7	90.1
w/o SL, ML	87.2	88.6	88.1	88.3

表9 学習データ中のラベルノイズの有無によるファインチューニング後の分類モデルの CCE の比較

学習データ	VGG16	ResNet50	ResNet101	EfficientNetB3
ϕ	0.483	0.395	0.395	0.369
w/o SL, ML, NL	0.454	0.427	0.457	0.381
w/o SL	0.394	0.351	0.367	0.321
w/o ML	0.520	0.425	0.430	0.418
w/o NL	0.520	0.405	0.406	0.362
w/o ML, NL	0.522	0.410	0.429	0.421
w/o SL, NL	0.401	0.357	0.368	0.324
w/o SL, ML	0.460	0.403	0.434	0.386

9より、学習データ w/o SL, NL の場合に SL ノイズに加え、NL ノイズを除去することで予測精度が向上している。そのため、NL ノイズの画像も出現する確率は低いが、可能であれば、SL ノイズの画像と加えて除去することが望ましい。

実際に SL ノイズや NL ノイズの画像を大規模な学習データから除去するためには、本研究と同様の人手による除去の他に、Northcutt らの誤ったラベルが付与された画像を自動で特定し除去する手法 [37] が適用可能である。このようにして作成したデータセットで学習した分類モデルを使用することで、新たに入稿される未知の画像に対して精度の良いラベル付けや、既にラベル付けされたデータに対して、どのラベルに修正すべきかの候補を提示するといったデータセットのラベル品質維持の取り組みへの利用が期待される。

5.2.2 混同行列による分析

学習データ中の各種ラベルノイズの有無が不動産物件画像の分類モデルに与える影響を混同行列を用いて分析する。VGG16におけるラベルノイズの有無による8通りの分類モデルによる混同行列を図5に示す。また、学習データ ϕ で学習した分類モデルと他の7通り学習データで学習した分類モデルにおける混同行列の各対角成分 (ラベルごとの正解した画像数) の割合を図6に示す。VGG16と同様に、ResNet50, ResNet101, EfficientNetB3における混同行列の各対角成分の割合

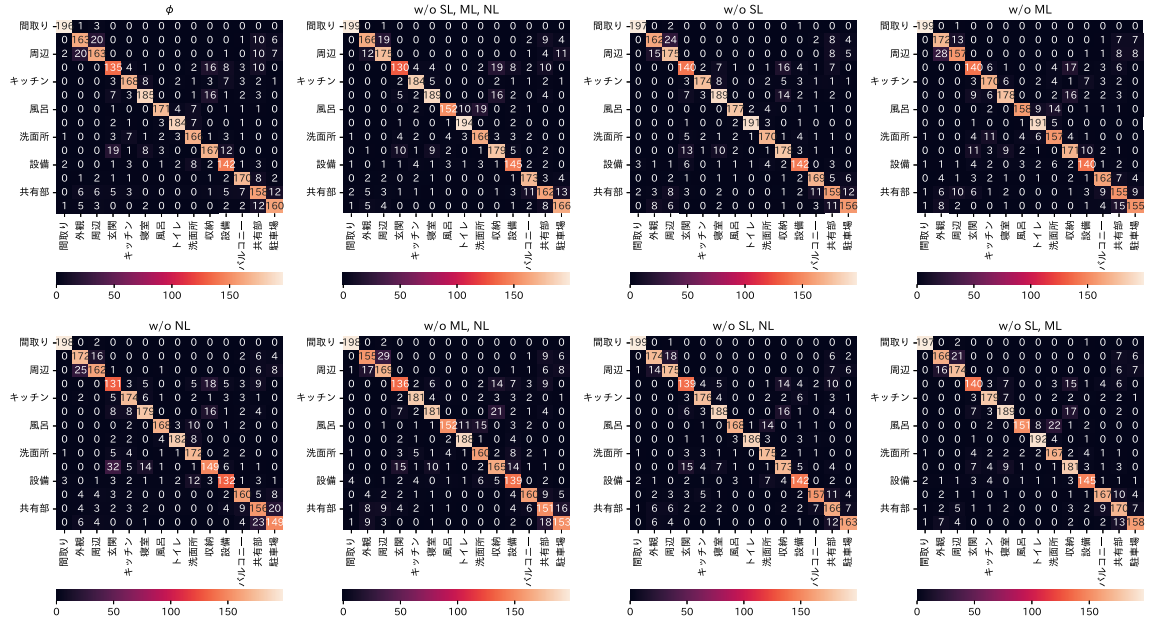


図5 VGG16による不動産物件画像の分類モデルの混同行列(縦:正解ラベル,横:分類モデルの予測)




図6 VGG16における混同行列の各対角成分の比率(縦軸の学習データ/学習データ φ)




図7 ResNet50における混同行列の各対角成分の比率(縦軸の学習データ/学習データ φ)

を図7, 8, 9に示す. 図6~9における各値は100を基準に, 100より大きければそのラベルの画像の予測精度が向上し, 100より小さければそのラベルの画像の予測精度が低下することを表す.

図6~9より, 四つのベースモデルでは共通して, 学習データ w/o SL, ML, NL, w/o ML, w/o ML, NL, w/o SL, ML の場合において風呂ラベルの画像の予測精度

が低くなっている. これらの場合ではMLノイズを学習データから共通して除去していること, 表3より風呂ラベルではMLノイズが多いことから, MLノイズの除去により分類に貢献する情報が失われているためと考える. 実際に, 図5より, MLノイズを除去した場合は, それ以外の場合と比べ, 風呂ラベルの画像はトイレや洗面所に誤認識される数が多い傾向がある. また,




図8 ResNet101における混同行列の各対角成分の比率（縦軸の学習データ/学習データ ϕ ）




図9 EfficientNetB3における混同行列の各対角成分の比率（縦軸の学習データ/学習データ ϕ ）

同様の傾向は、ResNet50、ResNet101、EfficientNetB3でも確認している。4.2で述べたMLノイズの観察より、風呂のラベルが付与された画像には複数のラベルに関係するオブジェクトが写っている場合などがあり、その画像の除去によってラベル間の関係性の情報が失われている可能性がある。したがって、MLノイズをもつ画像は除去ではなく、不動産物件画像の各ラベルに含まれる画像の内容の関係を考慮して扱うことが重要と考える。

6. むすび

本研究では、不動産物件画像におけるラベルノイズの分布とラベルノイズが不動産物件画像の分類モデルに与える影響を明らかにすることを目的に、3種類のラベルノイズを仮定し、二つの実験に取り組んでいる。一つ目の不動産物件画像におけるラベルノイズの分類実験では、11名によるアノテーションを実施し、3種類のラベルノイズの分布を分析している。その結果、ランダムサンプリングした30,800画像のうち17%がラベルノイズに分類され、そのうち誤ったラベルが付与されている画像と複数のラベルを付与すべきであるが一つのみ付与されている画像が多数を占めることを確認している。二つ目の学習データ中のラベルノイズの有無による分類モデルの予測精度の評価実験では、ラベルノイズの除去の組み合わせで全8通りの学習データを準備し、各学習データで学習した分類モデルの予測精度を評価した。その結果、予測精度の向上の観点では、誤ったラベルが付与されている画像の除去が望ましいこと、複数のラベルを付与すべきであるが一つのみ付与されている画像は除去すべきでない有用なデータであることを明らかにしている。

本研究のリミテーションとして、実験では学習の効率化を図るために学習済みモデルによるファインチューニングをしている。その学習に使用されているImageNetにはラベルノイズが存在することが報告されているが[10]、本研究ではこの影響を無視している。この影響を排除して評価するためには、学習済みのパラメータを使用しないで実験する必要がある。今後の課題としている。更に、今後の展望として、先行研究[5],[6]でラベルノイズの対処法として挙げられているラベルノイズの除去だけでなく修正した際の影響を明らかにする。また、複数のラベルを付与すべきであるが一つのみ付与された画像に対して、各ラベルに含まれる画像の内容の関係を考慮して分類モデルの学習で扱うための方法はまだ明らかにできていないが、最適輸送コスト[38],[39]などの方法の適用を検討しその有効性を検証したい。

謝辞 本研究では、国立情報学研究所のIDRデータセット提供サービスにより株式会社LIFULLから提供を受けた「LIFULL HOME'S データセット」を利用した。本研究はJSPS 科研費JP21H03553の助成を受けたものです。

文 献

- [1] 不動産情報サイト事業者連絡協議会, “「不動産情報サイト利用者意識アンケート」調査結果,” <https://www.rsc-web.jp/webkanri/kanri/wp-content/uploads/2022/10/4708da8fc92e33e7b670b35f9adae117.pdf>, Oct. 2022.
- [2] 石田陽太, 清田陽司, “住居選択支援を目的とした不動産物件画像からの深層学習による情報抽出の試み,” *Web インテリジェンスとインタラクシオン研究会予稿集*, vol.8, pp.29–30, Kagoshima, Japan, June 2016. DOI:10.57413/wii.8.0_29
- [3] 清田陽司, 椎橋怜史, 二宮 健, 横山貴史, 埜 拓朗, 衛藤剛史, 横山明子, 菊地 慧, 小林武蔵, 亀田朱音, 瀧川和樹, 齋藤裕介, 花多山和志, “AI 活用による不動産分野の UX 革新の取り組み,” *人工知能学会全国大会論文集*, vol.JSAI2019, Niigata, Japan, June 2019. DOI:10.11517/pjsai.JSAI2019.0_ID3OS10b04
- [4] Y. Kiyota, “Frontiers of computer vision technologies on real estate property photographs and floorplans,” *Front. of Real Estate Sci. in Jpn*, pp.325–337, Feb. 2021. DOI:10.1007/978-981-15-8848-8_23
- [5] B. Frenay and M. Verleysen, “Classification in the presence of label noise: A survey,” *IEEE Trans. Neural Networks and Learn. Syst.*, vol.25, no.5, pp.845–869, May 2014. DOI:10.1109/TNNLS.2013.2292894
- [6] H. Song, M. Kim, D. Park, and J. Lee, “Learning from noisy labels with deep neural networks: A survey,” *arXiv*, arXiv:2007.08199, July 2020. DOI:10.48550/arXiv.2007.08199
- [7] J. Deng, W. Dong, R. Socher, L.J. Li, K. Li, and L. Fei-Fei, “ImageNet: A large-scale hierarchical image database,” *Proc. 2009 IEEE Conf. on Comput. Vis. and Pattern Recognit.*, pp.248–255, Miami, FL, USA, June 2009. DOI:10.1109/CVPR.2009.5206848
- [8] D. Tsipras, S. Santurkar, L. Engstrom, A. Ilyas, and A. Madry, “From ImageNet to image classification: Contextualizing progress on benchmarks,” *Proc. 37th Int. Conf. on Mach. Learn.*, vol.119, pp.9625–9635, July 2020.
- [9] V. Shankar, R. Roelofs, H. Mania, A. Fang, B. Recht, and L. Schmidt, “Evaluating machine accuracy on ImageNet,” *Proc. 37th Int. Conf. on Mach. Learn.*, vol.119, pp.8634–8644, July 2020.
- [10] L. Beyer, O.J. Henaff, A. Kolcsnik, X. Zhai, and A.V.D. Oord, “Are we done with imagenet?,” *arXiv*, arXiv:2006.07159, June 2020. DOI:10.48550/arXiv.2006.07159
- [11] S. Yun, S.J. Oh, B. Heo, D. Han, J. Choe, and S. Chun, “Re-labeling ImageNet: From single to multi-Labels, from global to localized labels,” *Proc. 2021 IEEE/CVF Conf. on Comput. Vision and Pattern Recognit.*, pp.2340–2350, Nashville, TN, USA, June 2021. DOI:10.1109/CVPR46437.2021.00237
- [12] 株式会社 LIFULL, “LIFULL HOME’S データセット,” *国立情報学研究所情報学研究データリポジトリ*, Nov. 2015. DOI:10.32130/idr.6.0
- [13] O. Poursaeed, T. Matera, and S.J. Belongie, “Vision-based real estate price estimation,” *Mach. Vis. and Appl.*, vol.29, pp.667–676, May 2018. DOI:10.1007/s00138-018-0922-2
- [14] E. Ahmed and M.N. Moustafa, “House price estimation from visual and textual features,” *Proc. 8th Int. Conf. on Neural Comput. Theory and Appl.*, Porto, Portugal, Nov. 2016. DOI:10.5220/00060407006200068
- [15] Q. You, R. Pang, L. Cao, and J. Luo, “Image based appraisal of real estate properties,” *IEEE Trans. on Multimedia*, vol.19, no.12, pp.2751–2759, Dec. 2017. DOI:10.1109/TMM.2017.2710804
- [16] A. Quattoni and A. Torralba, “Recognizing indoor scenes,” *Proc. 2009 IEEE Conf. on Comput. Vis. and Pattern Recognit.*, pp.413–420, Miami, FL, USA, June 2009. DOI:10.1109/CVPR.2009.5206537
- [17] J.H. Bappy, J.R. Barr, N. Srinivasan, and A.K. Roy-Chowdhury, “Real estate image classification,” *Proc. 2017 IEEE Winter Conf. Appl. of Comput. Vis.*, pp.373–381, Santa Rosa, CA, USA, March 2017. DOI:10.1109/WACV.2017.48
- [18] N. Guilherme, L. Camila, B. Vinicius, L. Anisio, and N.E.R., “A robust indoor scene recognition method based on sparse representation,” *Prog. in Pattern Recognit., Image Anal., Comput. Vis., and Appl.*, pp.408–415, Feb. 2018. DOI:10.1007/978-3-319-75193-1_49
- [19] R. Hattori, K. Okamoto, and A. Shibata, “Rent prediction models with floor plan images,” *Proc. IEEE 8th Glob. Conf. on Consum. Electron.*, pp.451–452, Osaka, Japan, Oct. 2019. DOI:10.1109/GCCE46687.2019.9015208
- [20] R. Hattori, K. Okamoto, and A. Shibata, “Visualizing the importance of floor-plan image features in rent-prediction models,” *Proc. 2020 Joint. 11th Int. Conf. on Soft Comput. and Intell. Syst. and 21st Int. Symp. on Adv. Intell. Syst.*, pp.1–3, online, Dec. 2020. DOI:10.1109/SCISISIS50064.2020.9322769
- [21] 服部凌典, 岡本一志, 柴田淳司, “賃料予測モデルにおける間取り図の影響分析,” *知能と情報*, vol.33, no.2, pp.640–650, May 2016. DOI:10.3156/jsoft.33.2_640
- [22] 古川泰隆, “不動産画像データセットを利用したディープ多形態画像対応学習,” *人工知能*, vol.32, no.4, pp.542–546, July 2017. DOI:10.11517/jjsai.32.4_542
- [23] T. Narahara and T. Yamasaki, “Subjective functionality and comfort prediction for apartment floor plans and its application to intuitive online property search,” *IEEE Trans. Multimedia*, pp.1–14, Oct. 2022. DOI:10.1109/TMM.2022.3214072
- [24] 田中駿成, 秦野 亮, 西山裕之, “VisionTransformer を用いた屋内画像分類,” *信学総大*, p.82, March 2022.
- [25] G. Algan and I. Ulusoy, “Image classification with deep learning in the presence of noisy labels: A survey,” *Knowl.-Based Syst.*, vol.215, pp.106771, March 2021. DOI:10.1016/j.knsys.2021.106771
- [26] T. Xiao, T. Xia, Y. Yang, C. Huang, and X. Wang, “Learning from massive noisy labeled data for image classification,” *Proc. 2015 IEEE Conf. on Comput. Vis. and Pattern Recognit.*, pp.2691–2699, Boston, MA, USA, June 2015. DOI:10.1109/CVPR.2015.7298885
- [27] 豊原 優, 門 洋一, 山崎俊彦, 藤森 進, 太原育夫, “Bottleneck 特徴量を用いた不動産画像の分類,” *人工知能学会全国大会論文集*, vol.JSAI2018, pp.2C3OS1705–2C3OS1705, 2018. DOI:10.11517/pjsai.JSAI2018.0_2C3OS1705
- [28] 李 石映雪, 野村眞平, “不動産情報ポータルサイト SUUMO でのデータ活用,” *人工知能*, vol.32, no.4, pp.547–552, 2017. DOI:10.11517/jjsai.32.4_547
- [29] J. Cohen, “A coefficient of agreement for nominal scales,” *Educ. and Psychological Meas.*, vol.20, pp.37–46, 1960. DOI:10.1177/001316446002000104
- [30] L.J. Richard and G.G. Koch, “The measurement of observer agree-

ment for categorical data,” *Biometrics*, vol.33, no.1, pp.159–174, 1977. DOI:10.2307/2529310

- [31] J. Alshehri, M. Stanojevic, E. Dragut, and Z. Obradovic, “On label quality in class imbalance setting – a case study,” *Proc. 2022 21st IEEE Int. Conf. on Mach. Lear. and Appl.*, Nassau, Bahamas, pp.1666–1671, 2022. DOI:10.1109/ICMLA55696.2022.00256
- [32] J.L. Fleiss, “Measuring nominal scale agreement among many raters,” *Psychol. Bull.*, vol.76, no.5, pp.378–382, 1971. DOI:10.1037/h0031619
- [33] A. Krizhevsky, I. Sutskever, and G.E. Hinton, “ImageNet classification with deep convolutional neural networks,” *Adv. in Neural Inf. Process. Syst.*, vol.25, Jan. 2012.
- [34] K. Simonyan and A. Zisserman, “Very deep convolutional networks for large-scale image recognition,” *Proc. 3rd Int. Conf. on Learn. Represent.*, May 2015. DOI:10.48550/arXiv.1409.1556
- [35] K. He, X. Zhang, S. Ren, and J. Sun, “Deep residual learning for image recognition,” *Proc. 2016 IEEE Conf. on Comput. Vis. and Pattern Recognit.*, pp.770–778, Las Vegas, NV, USA, June 2016. DOI:10.1109/CVPR.2016.90
- [36] M. Tan and Q.V. Le, “EfficientNet: Rethinking model scaling for convolutional neural networks,” *Proc. 36th Int. Conf. on Mach. Learn.*, vol.97, pp.6105–6114, Long Beach, CA, USA, June 2019.
- [37] C.G. Northcutt, L. Jiang, and I. Chuang, “Confident learning: Estimating uncertainty in dataset labels,” *Journal of Artif. Intell. Res.*, vol.70, pp.1373–1411, 2021. DOI:10.1613/jair.1.12125
- [38] C. Marco, “Sinkhorn distances: Lightspeed computation of optimal transport,” *Adv. in Neural Inf. Process. Syst.*, vol.26, pp.2292–2300, 2013.
- [39] C. Frogner, C. Zhang, H. Mobahi, M. Araya-Polo, and T. Poggio, “Learning with a wasserstein loss,” *Adv. in Neural Inf. Process. Syst.*, vol.28, Dec. 2015.

(2023年6月27日受付, 11月14日再受付,
2024年1月9日早期公開)



市原 大也

2022 電気通信大学情報理工学域卒。現在、同大学大学院情報理工学研究科情報学専攻在学中。



岡本 一志 (正員)

2006 高知工科大学工学部情報システム工学科卒。2008 同大学院工学研究科基盤工学専攻修士課程了。2011 東京工業大学大学院総合理工学研究科知能システム科学専攻博士後期課程了。同年、千葉大学アカデミック・リンク・センター特任助教。2015 電気通信大学大学院情報理工学研究科総合情報学専攻助教。2020 同大学院情報理工学研究科情報学専攻准教授。現在に至る。博士(工学)。データサイエンスの研究に従事。IEEE、情報処理学会、人工知能学会、日本知能情報ファジィ学会各会員。



柴田 淳司

2009 青山学院大学理工学部電気電子工学科卒。2012 東京工業大学大学院総合理工学研究科知能システム科学専攻修士課程了。2015 同大学院総合理工学研究科知能システム科学専攻博士課程了。同年、岐阜大学電気電子情報学科産官学連携研究員。同年、東京都立産業技術大学院大学助教。現在に至る。博士(学術)。データサイエンス研究に従事。人工知能学会、情報処理学会、日本知能情報ファジィ学会各会員。