

# 複雑な建築図面における部屋のセマンティクス情報の抽出

田中 福治<sup>1</sup> 水本 旭洋<sup>1</sup> 山口 弘純<sup>1</sup> 東野 輝夫<sup>2</sup>

**概要:** 建築図面には部屋の構造を含め様々な情報が含まれており、その解析（フロアプラン解析）を行うことで、フロアプランの 3D モデルの生成やレイアウトが類似する家屋の検索など、多様な用途に活用できる。しかし、既存のフロアプラン解析手法はいずれも部屋の構造抽出に注力しており、それらの部屋がどのような使われ方をするかの用途の理解は行われていない。一方で、部屋用途の情報は、センサを用いた宅内行動推定の補助情報提供などにも有効である。本稿では、画像として与えられた建築図面から部屋の構造情報と宅内設備情報を抽出し、それらを用いて各部屋の種別（用途）を推測する手法を提案する。提案手法では、我々が以前に提案した部屋構造と電気設備を抽出する手法から得られた情報をもとに、各部屋をノード、部屋間の接続をエッジとしたグラフを構築する。そのもとで GNN（グラフニューラルネットワーク）により、寝室、ホール、収納といった各部屋の用途を示す種別を推定する。電気設備情報を含む建築図面は非常に複雑であり、情報密度が高いことから、情報が図面上で重畳しており、例えば部屋名が記載されていてもその抽出精度を高めることは極めて困難である。これに対し、我々は高精度な部屋構造情報と電気設備情報を組み合わせ、さらに部屋の接続関係に基づく推測が可能な GNN を活用することでその目的を達成する。協力企業との提携により入手した住宅 352 邸、合計 719 枚の電気平面図を用いた評価実験の結果、宅内設備を平均 F 値 99% で検出でき、部屋の役割を平均 F 値 95.4% で推定することができた。

## 1. はじめに

建築図面には部屋の構造を含め様々な情報が含まれている。一般住宅の建築図面は CAD データとして作成されているものの、一方でソフトウェアや住宅ビルダ間でのデータフォーマットや記述仕様は共通化されておらず、それらの情報を抽出することは容易でない。さらに、CAD データは作成した建築士が保持することが多く、物件保有者が一般に利用可能なフロアプラン情報は意味情報が喪失された図面のみであることが多い。したがって、画像化された建築図面から上記のような情報を抽出できることが望まれる。建築図面の解析（フロアプラン解析）を行う研究は活発に行われており、近年の画像認識の精度向上とともに、対象とする建物の壁の位置や部屋領域、ドア位置などの構造情報が抽出できるようになってきている。これらの研究によって抽出された情報はフロアプランの 3D モデルの生成やレイアウトが類似する物件検索などの用途に活用できる。

しかし、建築図面の中でも電気設備情報が含まれている建築図面（電気設備図あるいは電気平面図）は、電力配線

や電気設備記号に加え、設計者情報や建築素材、防火仕様、外壁の配色など、部屋構造とも電力情報とも直接関係しない様々な情報が数多く含まれている。その結果、線同士を重ねたり線と文字の重ねが多くなり、情報の欠損が生じる。そのため一般の図面を対象とした既存の図面認識手法による情報抽出は困難であると考えられる。一方で、既存の 3D モデルの生成において用いている壁の位置や部屋領域、ドア位置などの構造情報に加えて、コンセントの位置や洗濯機、冷蔵庫などの特定の家電の位置などの電気設備情報が得られれば、家具・家電配置のシミュレーションや最適化などのアプリケーションや電力消費に基づく在室推定の精度向上なども期待できる。

我々は文献 [1] において、電気平面図において確実に抽出できる構造情報を用いた平面図に特有の描画規則に基づく補間を適用することで、電気平面図に含まれる様々な情報を抽出する手法を提案している。この手法では、電気平面図から構造情報として壁、ドア・窓、部屋領域、部屋の接続関係を抽出し、部屋名称ならびに電気設備情報（コンセント位置）を抽出する。しかし、部屋の用途推定に最も重要な情報である部屋名称の検出については、文字列領域の正確な特定が情報の図面上での無秩序な混在により非常に困難であり、結果として OCR (Optimal Character Recognition) の適用が難しいことがわかっている。また、

<sup>1</sup> 大阪大学大学院情報科学研究科  
Graduate School of Information Science and Technology, Osaka University

<sup>2</sup> 京都橘大学  
Kyoto Tachibana University

収納部屋や浴室、トイレには部屋名称が記載されないことも多いため、部屋名称の記載に依存する手法は適さないことも明らかになった。一方で、部屋の用途は部屋の接続関係や部屋面積、窓の大きさ、コンセント数やシンク、バス・タブのような宅内設備の有無などと一定の相関があることが想定されるため、そういった情報を活用することで部屋の用途を推定できる可能性がある。

本研究では部屋の種別を部屋の構造情報や宅内設備情報から推測する手法を提案する。提案手法ではまず、文献 [1] で提案した我々の情報抽出手法を用い、部屋構造を抽出するとともに、宅内設備を示す記号をオブジェクト認識手法 (YOLOv4) で検出し、検出した各記号がどの部屋に属するかを判別する。次に、各部屋をノード、部屋間の接続をエッジとしたグラフで表現し、各部屋の構造情報や宅内設備の有無を特徴量とし、GNN (グラフニューラルネットワーク) によって各部屋の種別を推定する。協力企業との提携により入手した住宅 352 邸、合計 719 枚の電気平面図を用いた評価実験の結果、宅内設備を平均 F 値 99% で検出でき、部屋の役割を平均 F 値 95.4% で推定できることがわかった。

## 2. 関連研究

### 2.1 建築図面の解析

これまで文書分析のための自動化システムの実現や平面図解析の前処理を目的として、平面図のような図や表を含んだ画像から文字列を抽出する研究が行われている。文献 [2] では、文書画像を対象に、黒ピクセルで繋がったもののグループ化とそれらの並びに Hough 変換を適用することによって、文字列のフォントと大きさの変更、および文字列の向きに比較的依存しない自動文字列分離のアルゴリズムを提案している。文献 [3] では、平面図に壁の抽出による除去やスミアリングによる線分の除去などの前処理を行いテキスト以外のノイズを除去することで、建築用平面図からの文字列の抽出を行なっている。文献 [4] では機械学習を含む複数の手法を合わせることで従来の一連の画像処理による文字抽出の精度を上回ることを達成している。

フロアプランの 3D モデルの生成や対応する CAD ファイルの生成を目的として、建築図面から壁やドア、窓、部屋領域などの構造情報を抽出する手法の研究が行われている。文献 [5] ではセグメンテーション、ベクトル化、アークの検出、ループの検出などを用いて、建築用平面図からドアや窓、壁の抽出を行っている。文献 [6] ではオブジェクト検出と属性推定を組み合わせた建築図面からの壁の検出に焦点を当てた手法を提案している。文献 [7] では従来の Hough 変換と画像ベクトル化を合わせた壁の抽出と円弧抽出を用いたドア検出によって得られる壁とドアによって、長方形の部屋領域が得られるまで画像を再帰的に分解することで建築平面図から部屋を検出している。文献 [8]

では建築図面で使用可能な情報を壁やドアなどの構造情報と部屋名や部屋の面積表記などの意味情報へ分離し、また外壁の外側のコンポーネントを除去するなどの前処理を行うことで、不要な情報が与える悪影響を減らし、部屋の検出精度を上げる手法を提案している。文献 [9] では建築図面を壁などの構造情報と文字列やドアなどの意味情報に分離し、構造情報からは部屋を検出し、意味情報には OCR を適用して、部屋とそのラベル付けを自動で行うシステムを提案している。文献 [10] では統計的パッチベースのセグメント化アプローチによる部屋の境界要素認識と境界要素をグラフに見立てた構造パターン認識技術により部屋の位置を特定している。[11] では平面図からのテキスト抽出と SURF 特徴のマッチングによるドアの検出によってドアと部屋の位置を確認し、部屋間の接続関係を理解している。

上記の手法では建築図面にある予測可能な描画表記、例えば壁は黒く太い線で描かれていることや、壁が水平か垂直に描かれていることを元に、モルフォロジ変換や Haugh 変換などの画像処理アルゴリズムを用いて建築図面の解析を行っていた。しかし、実際には壁が黒塗りではなく斜線で描かれてあることや、真っ直ぐではなくカーブを描いていることもある。そこで近年、一連の低レベルの画像処理やヒューリスティックに依存しない学習ベースのアプローチにより図面上の部屋や壁、ドアなどを認識する研究 [12] [13] が行われている。文献 [12] では CNN を用いて建築図面から壁やドアの端点などの低レベルの構造情報を抽出して、それらから壁線やドア線などの高レベルの構造情報を復元して部屋を抽出する手法を提案している。文献 [14] では標準の建築ドキュメントよりも解像度が低い平面図に対して壁の抽出を行う完全なたみ込みネットワーク (FCN) を提案している。文献 [15] ではディープニューラルネットワークを用いて、平面図内のドアや窓だけでなく、家具オブジェクトを認識している。文献 [13] では部屋の境界要素を予測する DNN と部屋の種類を予測する DNN の 2 つを設計し、壁や部屋に加えて、ドア、窓、部屋の種類など建築図面上にある様々な要素を認識している。文献 [16] では YOLO (You-Only-Look-Once) アーキテクチャに基づいたオブジェクト検出フレームワークを適応することで、オクルージョンやクラッタがあっても、クラス内の類似性が低く、グラフィカルな複雑さが変化する建築シンボルを検出している。文献 [17] ではセマンティック・ニューラル・ネットワークと後処理の部屋分割を組み合わせた農村住宅のフロアプランを解析するための新しいフレームワークを紹介している。文献 [18] では重ね合わせたグラフィックスや不規則な表記を含む、不明瞭なパターンに囲まれた部屋や開口部を認識することができるロバストなモデルを提案している。条件付き生成敵対ネットワークを用いて、様々な平面図のフォーマットを簡潔で統一的なスタイルに統合し、容易にラスタ情報からベクトル情

報へ変換できるようにしている。

## 2.2 建築図面の解析結果を用いた研究

上記の研究を通して取り出せたフロアプラン構成要素を利用する研究にも様々あり、インドア位置推定や3Dの内装の再構築、類似のフロアプラン検索などが挙げられる。文献 [19] ではWiFiと慣性センサの情報を、対象となる屋内空間の地図による制約と組み合わせることで、歩幅などの他の変数と同時に位置を推定している。文献 [20] では屋内のフロアプランやWi-Fi APの位置、APから得られるRSSI値から屋内のユーザの位置情報を取得している。文献 [21] ではフロアプランの情報と位置が不明な信号強度の測定値のみに依存する教師なし学習アプローチを提案している。文献 [22] では2Dのフロアプランの境界要素が作る内部ループと外部ループ、開口部を認識し、これを元に3Dのフロアプランを再構築している。文献 [23] では深層学習（ディープラーニング）の手法を用いて、建築図面から低レベルと高レベルの意味的特徴を抽出し、取り出した特徴をもとに間取り間の類似度を計算し、似たような間取りを見つけている。文献 [24] では不動産推薦のためのアルゴリズムを紹介しており、コンテンツベースのフィルタリングとフロアプラン解析によって得られる部屋数や部屋種類の情報を組み合わせて、ユーザーの物件に対する嗜好を予測している。

## 2.3 本研究の位置付け

我々の研究の目的は、電気平面図に含まれる部屋の構造情報や宅内設備の存在と位置、ならびに各部屋の用途を得ることで、様々な家庭における在室・行動推定を高度化することにある。これに対し、本研究では、文献 [1] で提案した我々の構造解析手法を活用し、部屋の「種別」を推定する手法を提案している。構造情報の取得に関しても、既存手法のほとんどは電気設備情報を含まない建築図面を対象としており、なかでも部屋の用途を推定する研究はほとんど存在しない。

本研究では、多様な情報が雑多に記載されている複雑な電気平面図に対し、部屋構造・宅内設備ならびに部屋の用途を極めて高精度に推定できることを示した点で前例がないと考える。

## 3. 手法概要

本稿では、建築図面の1種である電気平面図の画像データ上にある各部屋の種別を推定する手法を提案する。推定する部屋の種別としてはLDK、寝室、ホール、収納、トイレ、洗面室、浴室の計7種類である。

図1に示すように、提案手法では電気平面図を入力として、先行研究 [1] で提案した電気平面図解析手法を用いて、ドア・窓、壁、部屋領域、部屋の接続関係、コンセント位置

を抽出する。さらに、オブジェクト認識手法（YOLOv4）を用いて宅内設備情報を示す記号を検出する。そして、抽出した部屋の接続関係をグラフとして扱い、各部屋の構造情報、電気設備情報、宅内設備情報を特徴量としてGNNに入力し、部屋の種別を推定する。

## 3.1 電気平面図

提案手法では、図面上の文字が読み取れる程度の解像度に画像化された電気平面図を入力として用いる。提案手法で扱う電気平面図のイメージを図2に示す。

図2に示すように、電気平面図では、画像中央に対象住宅の間取り図（フロアプラン）と電気設備情報、画像左上に家の方位、画像右方に設計者情報や建築素材、防火仕様、外壁の配色などの情報がそれぞれ表記されている。フロアプランでは、壁は一般的に黒い太線で、窓やドア、電気設備情報などはアークや二重線などの専用の記号で記載されている。また、部屋名は対応する部屋の中にそれぞれ記載されている。宅内設備情報は、図3に示すように、それぞれに対応した記号で示される。図2に示されるように、電気平面図は情報の密度が高く、文字と他の線や記号が重なって描かれることがあるため、文字列領域抽出をもとにした部屋の名称識別も困難である。さらに、ここでは協力企業との契約上、仮想的かつ簡略化したものを表記しているが、実際の電気平面図では、壁の素材やドアの部品IDなど、図2に表示されているものより多くの情報が雑多に含まれている。

## 4. 提案手法

本章では3章で述べた手法の詳細を述べる。ドア・窓、壁の抽出や部屋領域抽出、コンセント検出の処理詳細については文献 [1] で述べていることから、ここでは宅内設備情報の抽出と部屋の種別推定処理についてのみ説明する。

### 4.1 宅内設備情報の抽出

宅内設備情報は図3に示すような、各設備に対応した記号を用いて表されている。トイレやシンクの記号などは形状が複雑であり、冷蔵庫や洗濯機の記号などは宅内に類似のパターンが出現することがあるため、単純な画像処理による規則ベースの手法の適用は難しい。また、これらの記号は家屋によって形状や大きさが異なるため、クラス内での類似度も高くはならない。さらに、電気平面図のように情報の密度が高い建築図面は、宅内設備記号と他の線分、文字列、記号が重畳していることが多く、SIFT、SURF、A-KAZEのような特徴点マッチングやテンプレートマッチングによる検出も困難である。

そこで、提案手法では、物体認識手法であるYOLOv4 [25] を用いて宅内設備記号の検出を行う。しかし、例えば電気平面図を5000×7000ピクセルとした場合でも、トイレ記

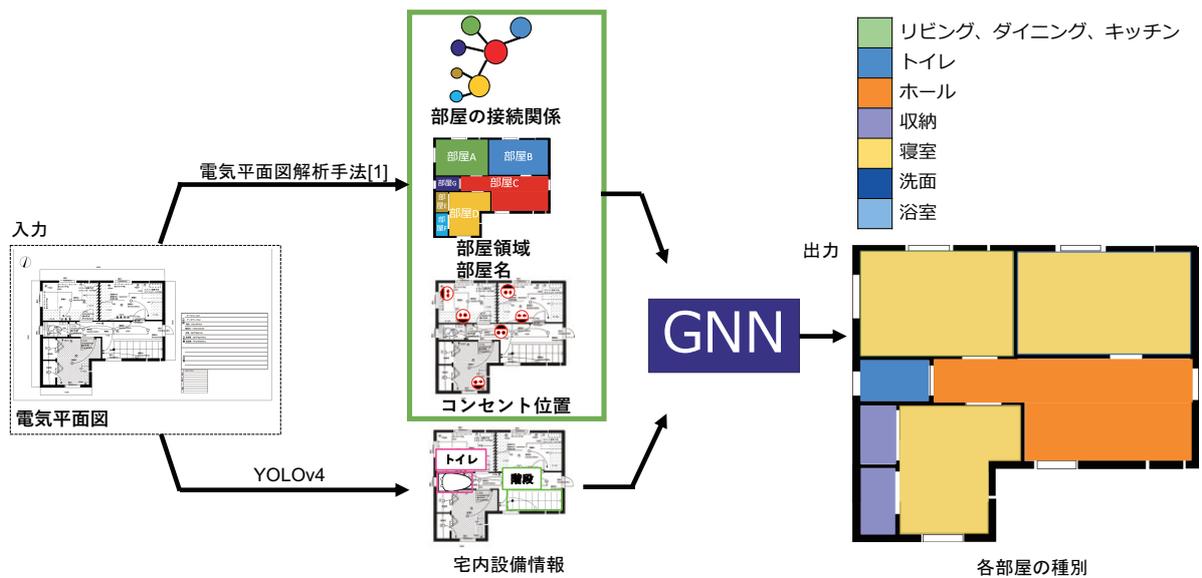


図 1 手法概要

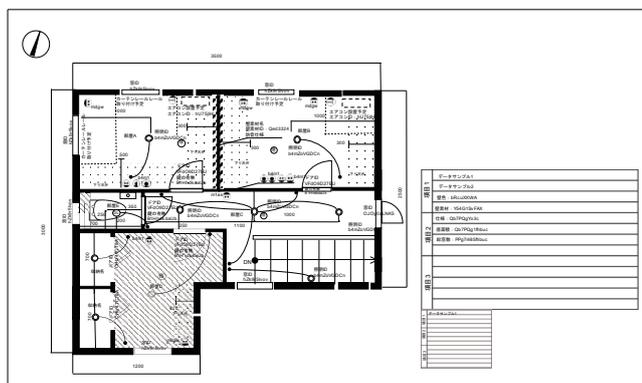


図 2 電気平面図の例

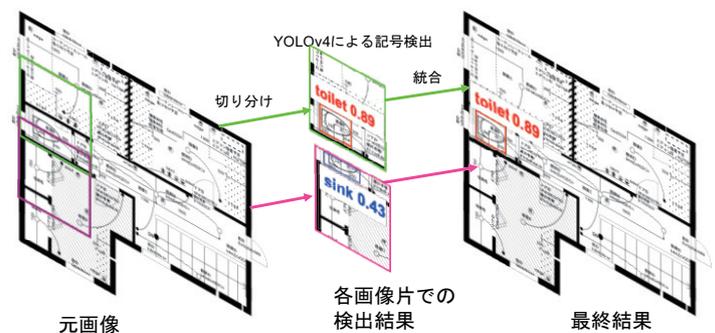


図 4 宅内設備記号の検出の流れ

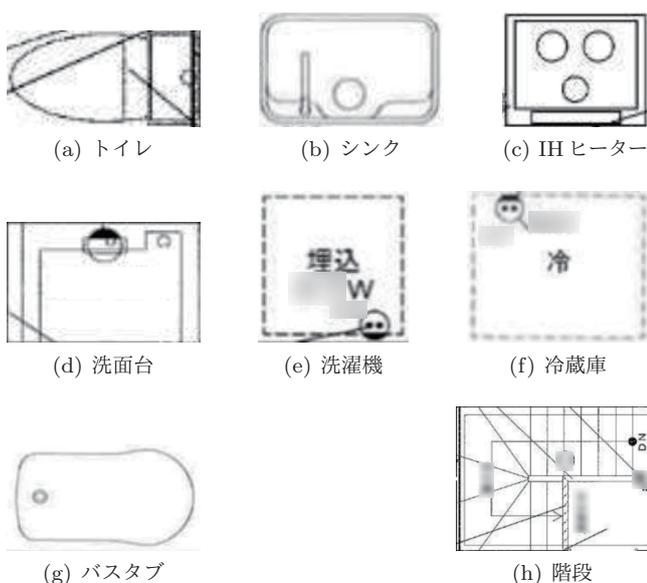


図 3 検出する宅内設備記号の一例

号は  $120 \times 180$  ピクセル程度であるように、電気平面図に対する記号のサイズ比が極めて小さいため、電気平面図を

直接入力すると記号の特徴量発見精度が低下する。また、前述のように洗濯機や冷蔵庫に関しては類似の特徴が出現しがちであるため、偽陽性率も増加する。これらの問題に対して、提案手法では、図 4 のように、電気平面図を宅内設備記号の特徴が残る大きさに保ちながら分割した領域に対して、YOLO をそれぞれ適用し、最後に各画像片における検出結果を統合することで、電気平面図から宅内設備記号を検出する。また、領域分割においては、全ての記号が少なくとも一つの画像片において完全な状態で収まるように、領域境界付近に多少の重複を持たせて分割を行う。画像片の中には、領域内に収まらず欠損した記号が含まれている可能性があり、これらの画像片を基に推定を行うことは誤検出に繋がる。そこで、結果の統合時に、同一箇所検出された記号のうち confidence が最大であるものを残すことで誤検出を防ぐ。さらに、一般的な住宅であれば 1 家屋あるいは 1 フLOOR に対する各宅内設備数は限られており、階段数もフロア数から推定できることから、1 フLOOR に同一クラスの宅内設備が検出された場合、双方の

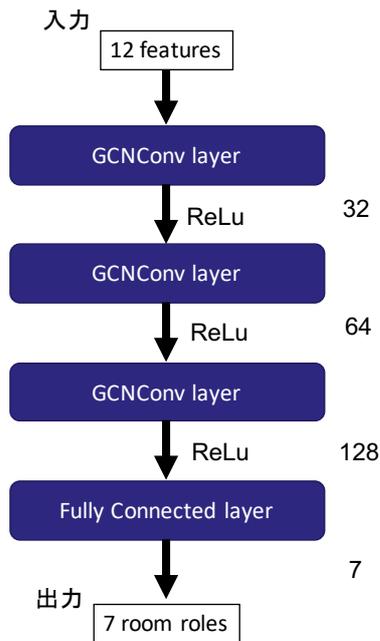


図 5 部屋の用途を推定する分類器の構成

confidence が高い場合を除き、低い confidence の検出結果を除去することで誤検出を防ぐことができる。

#### 4.2 部屋の種別推定

前述のように、本研究では、部屋の用途を部屋の接続関係や部屋の大きさ、窓の大きさ、コンセント数やシンク、バスタブのような宅内設備の有無から推定する分類器を構成する。例えば、日本では建築基準法において、居室には採光が確保できる窓の面積（=有効採光面積）を部屋の床面積の 1/7 以上設けるよう定められている。また、シンクや IH ヒーターは LDK にあり、トイレ記号はトイレに、バスタブは浴室にあるといったように宅内設備記号の有無と部屋の種別の間には高い相関がある。また、他の部屋との接続数が多い部屋はホールである事が多く、浴室と洗面室が隣同士になる事も多い、浴室と浴室が、寝室と寝室が隣にならないといったように、分類器においては部屋の接続関係を活用することが重要となる。そこで、提案手法では、このような地理的依存関係を考慮できる学習モデルである GNN (Graph Neural Network) を訓練することで、部屋の種別を推定する。

提案手法で用いる部屋の種別推定を行う多クラス分類器の構成を図 5 に示す。入力には 12 個の特徴量と部屋の接続関係であり、特徴量として、部屋の大きさ、部屋にある窓の大きさの総和、部屋の接続数、部屋にあるコンセント総数、4.1 節で抽出した 8 つの記号の有無を用いる。GNN は 3 層の GCNConv 層と 1 層の全結合層からなり、活性化関数としては ReLU 関数を用いる。

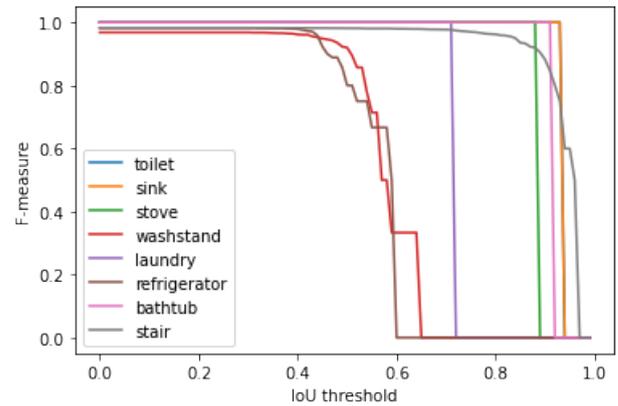


図 6 IoU に対する F 値

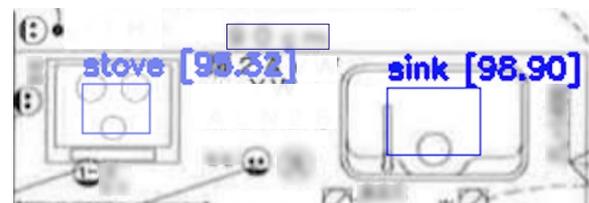


図 7 宅内設備記号の検出例

## 5. 性能評価

### 5.1 評価環境

提案手法の宅内設備情報の検出精度、および、部屋の役割の識別精度を評価するため、協力企業である住宅会社より提供された住宅 352 邸、合計 719 枚の電気平面図を用いて評価を行った。この内 605 枚を YOLOv4 と GNN の訓練データとして、残りの 114 枚をテストデータとして用いた。

評価指標としては、正と予測したデータのうち実際に正であるものの割合である Precision と、実際に負であるもののうち負であると予測されたものの割合である Recall、Precision と Recall の調和平均である F 値に加えて、宅内設備記号抽出に関しては検出できた領域の大きさも含めて評価できるように、IoU (Intersection over Union) という検出領域と正解領域の共通領域を領域の和集合で割った値を用いた。

部屋の種別推定に関して提案手法が有効であることを確認するために、既存のモデルを用いた場合との比較を行った。比較手法としては文献 [13] にて提案されている手法を用いた。

### 5.2 宅内設備情報抽出の精度評価

宅内設備情報の抽出については、検出した設備記号のバウンディングボックスと正解の設備記号のバウンディングボックスとの IoU が閾値以上であるかを正答判断基準とし

表 1 IoU0.3 以上を正解とした場合の精度

	Precision	Recall	F-measure
トイレ	100%	100%	100%
シンク	100%	100%	100%
IH ヒーター	100%	100%	100%
洗面台	96.8%	95.3%	96.1%
洗濯機	100%	100%	100%
冷蔵庫	98.2%	98.2%	98.2%
バスタブ	100%	98.2%	99.1%
階段	98.3%	99.1%	98.7%
マクロ平均	99.2%	98.9%	99%

表 2 部屋の種別推定の精度

	Precision	Recall	F-measure
LDK	91.7%	96.5%	94%
寝室	94.4%	94.4%	94.4%
ホール	87.7%	89.2%	88.4%
トイレ	96.7%	100%	98.3%
洗面室	98.2%	93.3%	95.7%
浴室	98.3%	100%	99.1%
収納	98.4%	97.1%	97.8%
マクロ平均	95.1%	95.8%	95.4%

た. IoU を 0 ~ 1 まで変更した時の F 値の変化を図 6 に示す. 図 6 から, 洗面台や冷蔵庫, 洗濯機に関しては IoU の閾値を 0.7 とした場合に, F 値が 0 となるのがわかる. 理由の一つとして, 洗面台や冷蔵庫, 洗濯機の記号が他の記号と比べて特徴が乏しく, 類似のパターンが出現しがちであることが考えられる. また, 図 7 の宅内設備記号の検出例のように, 検出結果の多くで正解領域より小さいバウンディングボックスが検出された. これは, YOLOv4 の学習によるものだと考えられるが, 本手法では, 各設備が属する部屋の検出を目的としており, 記号の大きさまでを正確に検出する必要はないため, 正解のバウンディングボックスに収まる形で宅内設備を検出できていれば正常に検出できているものとする. 表 1 は, IoU の閾値を 0.3 以上とした場合の各クラスの Precision, Recall, F 値を示しているが, マクロ平均で F 値 99% のように, 非常に高い精度で宅内設備記号を検出できることが分かる.

### 5.3 部屋の種別推定の精度評価

まず, 純粋な部屋の種別推定のみ性能を評価するために, 正解の接続関係, 電気設備記号位置, 宅内設備記号位置に, 4.2 節に示す種別推定手法を適用した. 各部屋の種別毎の精度を表 2 に, 部屋の種別推定の内訳を図 8 示す. 表 2 に示すように, マクロ平均で Precision 95.1%, Recall 95.8%, F 値 95.4% を達成した. また, 図 8 を見ると, 特に収納と寝室の間違い, ホールと寝室の間違いが多いことがわかる. ホールと寝室の間違いに関しては, ホールが玄関としての役割を持っているときに間違えていることが多

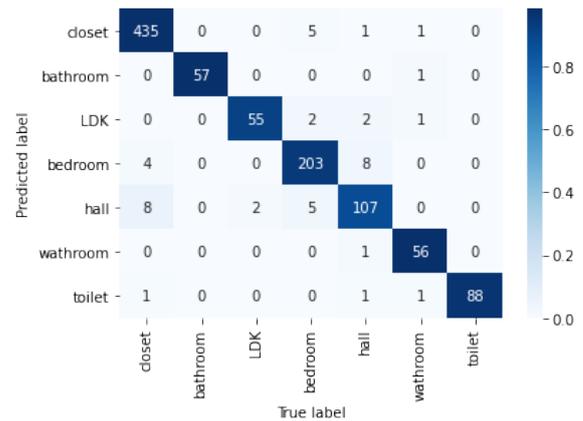


図 8 部屋の種別推定の内訳

い. この理由として, 現状玄関と窓を区別せずに全て窓として扱っており, 大きな窓面積を持ってしまふことと, 他のホールと比べて隣接数が少なくなる傾向があることが挙げられる. また, 収納と寝室に関しては, 納戸のような収納の中でも大きな部屋には大きくはなくても窓があり, 寝室に特徴が似ていたために誤分類してしまったことが原因として挙げられる. これらの誤分類の改良案としては, 玄関と窓の区別をつけることが挙げられる. 玄関の場合は外に特徴的な表記がなされるために窓の周り一帯を入力として ResNet などで分類することで玄関と窓の区別ができると思われる. また, 文字列抽出により得られた部屋名の中でも信頼できるものを以って推定結果を修正することも改良案として考えられる.

次に, 建築図面解析手法によって得られた構造情報や電気設備・宅内設備情報を用いて部屋の種別推定を行った. 本研究では, 先行研究 [1] にて示される手法を用いて取り出したドア・窓, 部屋領域, 接続関係, コンセント位置と節 4.1 にて示した手法で取り出した宅内設備情報を用いて部屋の種別推定を行なった. 正解のドア位置や部屋位置を用いているわけではないため, 前述の結果とは異なり対応する部屋が一つに定まらない事がある. そこで, 部屋領域を役割毎に決めた色で着色し, 各座標の色の正誤を基に Precision, Recall, F 値を計算した. その結果, 表 3 に示すように, 提案手法ではマクロ平均で Precision 87.6%, Recall 90.8%, F 値 88.8% を達成した. ホールの精度が低い結果となっているが, この理由としてはホールが多数の部屋と隣接する部屋でありドアの検出漏れによって他の部屋と融合する可能性が高く, 比較的部屋領域が正しく取れなかったためだと考えられる. また, トイレや収納の精度が低くなっているが, これらに関しては部屋の元々の面積が小さいために, 部屋の領域を正しく取れていない場合や, 種別推定を間違えたときに他の部屋以上に影響を受けるためだと考えられる. 提案手法が既存手法と比べて精度が高くなった理由として, 部屋領域をより正しく認識できている

表 3 部屋領域抽出を含めた部屋の種別推定の精度

	提案手法			Zeng et.al [13]		
	Precision	Recall	F-measure	Precision	Recall	F-measure
LDK	91.6%	91.9%	91.8%	83.6%	97.6%	90.1%
寝室	93.7%	89.8%	91.7%	89.5%	84.2%	86.8%
ホール	80.7%	84.7%	82.6%	70%	70.9%	70.5%
トイレ	68.2%	98.3%	80.5%	80.4%	71%	75.4%
洗面室	97.1%	87.3%	91.9%	95.1%	45.8%	61.9%
浴室	96.1%	96.2%	96.1%	87.7%	63.1%	73.4%
収納	86.1%	87.2%	86.6%	72.1%	70%	71%
マクロ平均	87.6%	90.8%	88.8%	82.6%	71.8%	75.6%

からだと考えられる。部屋の種別が正しく推定できたとしても、部屋領域が正しく認識できていないと、余分に抽出した領域の分だけ偽陽性が、不足した領域の分だけ偽陰性が増加する。加えて、部屋の接続関係を学習に明示的に与えたことも理由の1つとして考えられる。浴室と浴室、寝室と寝室が隣にならないように部屋の接続関係が部屋の役割に与える影響は大きく、提案手法が既存手法と比べて、特に洗面室と浴室の認識精度が高くなったのも、接続関係を与えたことによる効果だと考えられる。他に、洗面室と浴室の認識精度が高くなった理由としては、宅内設備記号を検出できている事も挙げられる。洗面室は隣接数が多いことからホールに似ており、浴室に関しては隣接数が少なくあまり大きくないことから収納にそれぞれ似ており、これらはバスタブや洗面台、洗濯機などの宅内設備記号によって主に見分ける必要がある。しかし、電気平面図全体に対して宅内設備記号は小さく、既存手法のように全体の画像をそのまま入力として学習、推定に用いると記号の特徴が消えてしまい、設備記号を種別推定に用いる事ができない。それゆえ、分割、統合のアプローチにより設備記号を検出できた提案手法の洗面室と浴室の認識精度が高くなったのだと考えられる。

## 6. おわりに

本稿では、建築図面の一種である電気平面図の画像データ上にある各部屋の種別を推定する手法を提案した。提案手法では先行研究 [1] の手法を適用して、ドア・窓、壁、部屋領域、部屋の接続関係、コンセント位置を取り出す。さらに、オブジェクト認識手法 (YOLOv4) を用いて宅内設備情報を示す記号を検出する。最後に取り出せた部屋の接続関係をグラフとして扱い、各部屋の構造情報、電気設備情報、宅内設備情報を特徴量として GNN に入力し、部屋の種別を推定する。

提案手法の精度評価として、住宅会社の協力により入手した住宅 352 軒、合計 719 枚の電気平面図を用いて、ネットワークの学習と解析を行なった結果、宅内設備を平均 F 値 99% で検出でき、部屋の役割を平均 F 値 95.4% で推定することができた。

今後の課題として玄関と窓の区別をつけることや文字列領域抽出を元にした部屋名識別手法と組み合わせて種別推定の精度を上げることを予定している。

## 謝辞

本研究成果は国立研究開発法人情報通信研究機構 (NICT) の委託研究「ウイルス等感染症対策に資する情報通信技術の研究開発 (課題番号 222)」により得られたものです。

## 参考文献

- [1] 田中福治, 石津紘太郎, 水本旭洋, 山口弘純, 東野輝夫ほか. 建築図面の解析によるフロアプランと電気設備の情報抽出. マルチメディア, 分散協調とモバイルシンポジウム 2148 論文集, Vol. 2020, pp. 882–891, 2020.
- [2] Lloyd A. Fletcher and Rangachar Kasturi. A robust algorithm for text string separation from mixed text/graphics images. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 10, No. 6, pp. 910–918, 1988.
- [3] Sheraz Ahmed, Markus Weber, Marcus Liwicki, and Andreas Dengel. Text/graphics segmentation in architectural floor plans. In *Proceedings of International Conference on Document Analysis and Recognition*, pp. 734–738, 2011.
- [4] Jason Ravagli, Zahra Ziran, and Simone Marinai. Text recognition and classification in floor plan images. In *2019 International Conference on Document Analysis and Recognition Workshops (ICDARW)*, Vol. 1, pp. 1–6. IEEE, 2019.
- [5] Christian Ah-Soon and Karl Tombre. Variations on the analysis of architectural drawings. In *Proceedings of the fourth international conference on document analysis and recognition*, Vol. 1, pp. 347–351. IEEE, 1997.
- [6] Lluís-Pere de las Heras, Joan Mas, Ernest Valveny, et al. Wall patch-based segmentation in architectural floor-plans. In *Proceedings of International Conference on Document Analysis and Recognition*, pp. 1270–1274, 2011.
- [7] Sébastien Macé, Hervé Locteau, Ernest Valveny, and Salvatore Tabbone. A system to detect rooms in architectural floor plan images. In *Proceedings of IAPR International Workshop on Document Analysis Systems*, pp. 167–174, 2010.
- [8] Sheraz Ahmed, Marcus Liwicki, Markus Weber, and Andreas Dengel. Improved automatic analysis of architectural floor plans. In *Proceedings of International*

- ence on *Document Analysis and Recognition*, pp. 864–869, 2011.
- [9] Sheraz Ahmed, Marcus Liwicki, Markus Weber, and Andreas Dengel. Automatic room detection and room labeling from architectural floor plans. In *Proceedings of IAPR International Workshop on Document Analysis Systems*, pp. 339–343, 2012.
- [10] Lluís-Pere de las Heras, Sheraz Ahmed, Marcus Liwicki, Ernest Valveny, and Gemma Sánchez. Statistical segmentation and structural recognition for floor plan interpretation. *International Journal on Document Analysis and Recognition (IJDAR)*, Vol. 17, No. 3, pp. 221–237, 2014.
- [11] Obadijah Lam, Feras Dayoub, Ruth Schulz, and Peter Corke. Automated topometric graph generation from floor plan analysis. In *Proceedings of the Australasian Conference on Robotics and Automation 2015*, pp. 1–8. Australian Robotics and Automation Association, 2015.
- [12] Chen Liu, Jiajun Wu, Pushmeet Kohli, and Yasutaka Furukawa. Raster-to-vector: Revisiting floorplan transformation. In *Proceedings of IEEE International Conference on Computer Vision*, pp. 2195–2203, 2017.
- [13] Zhiliang Zeng, Xianzhi Li, Ying Kin Yu, and Chi-Wing Fu. Deep floor plan recognition using a multi-task network with room-boundary-guided attention. In *Proceedings of IEEE International Conference on Computer Vision*, pp. 9096–9104, 2019.
- [14] Samuel Dodge, Jiu Xu, and Björn Stenger. Parsing floor plan images. In *Proceedings of International Conference on Machine Vision Applications (MVA)*, pp. 358–361, 2017.
- [15] Zahra Ziran and Simone Marinai. Object detection in floor plan images. In *IAPR workshop on artificial neural networks in pattern recognition*, pp. 383–394. Springer, 2018.
- [16] Alireza Rezvanifar, Melissa Cote, and Alexandra Branzan Albu. Symbol spotting on digital architectural floor plans using a deep learning-based framework. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*, pp. 568–569, 2020.
- [17] Zhengda Lu, Teng Wang, Jianwei Guo, Weiliang Meng, Jun Xiao, Wei Zhang, and Xiaopeng Zhang. Data-driven floor plan understanding in rural residential buildings via deep recognition. *Information Sciences*, Vol. 567, pp. 58–74, 2021.
- [18] Seongyong Kim, Seula Park, Hyunjung Kim, and Kiyun Yu. Deep floor plan analysis for complicated drawings based on style transfer. *Journal of Computing in Civil Engineering*, Vol. 35, No. 2, p. 04020066, 2021.
- [19] Anshul Rai, Krishna Kant Chintalapudi, Venkata N Padmanabhan, and Rijurekha Sen. Zee: Zero-effort crowdsourcing for indoor localization. In *Proceedings of the 18th annual international conference on Mobile computing and networking*, pp. 293–304, 2012.
- [20] Chengwen Luo, Long Cheng, Mun Choon Chan, Yu Gu, Jianqiang Li, and Zhong Ming. Pallas: Self-bootstrapping fine-grained passive indoor localization using wifi monitors. *IEEE Transactions on Mobile Computing*, Vol. 16, No. 2, pp. 466–481, 2016.
- [21] Jens Trogh, Wout Joseph, Luc Martens, and David Plets. An unsupervised learning technique to optimize radio maps for indoor localization. *Sensors*, Vol. 19, No. 4, p. 752, 2019.
- [22] Junfang Zhu, Hui Zhang, and Yamei Wen. A new reconstruction method for 3d buildings from 2d vector floor plan. *Computer-aided design and applications*, Vol. 11, No. 6, pp. 704–714, 2014.
- [23] Divya Sharma, Nitin Gupta, Chiranjoy Chattopadhyay, and Sameep Mehta. Daniel: A deep architecture for automatic analysis and retrieval of building floor plans. In *2017 14th IAPR International Conference on Document Analysis and Recognition (ICDAR)*, Vol. 01, pp. 420–425, 2017.
- [24] Naoki Kato, Toshihiko Yamasaki, Kiyoharu Aizawa, and Takemi Ohama. Users’ preference prediction of real estate properties based on floor plan analysis. *IEICE Transactions on Information and Systems*, Vol. 103, No. 2, pp. 398–405, 2020.
- [25] Alexey Bochkovskiy, Chien-Yao Wang, and Hong-Yuan Mark Liao. Yolov4: Optimal speed and accuracy of object detection. *arXiv preprint arXiv:2004.10934*, 2020.