

# 深層学習を用いた内外の曖昧さの記述に関する基礎的研究

可視領域を入力とした内外判別機の誤判別

## A Basic Study on Description of Ambiguity of In-Out Using Deep Learning

Where the classifier that reads visible regions fails in discrimination?

○安田 溪<sup>\*1</sup>, 口羽 雄太<sup>\*2</sup>, 三浦 研<sup>\*3</sup>

Kei Yasuda<sup>\*1</sup>, Yuta Kuchiba<sup>\*2</sup> and Ken Miura<sup>\*3</sup>

- \*1 京都大学大学院工学研究科建築学専攻 研究員・修士（工学）  
Researcher, Department of Architecture, Kyoto University, M. Eng.
- \*2 京都大学大学院工学研究科建築学専攻 修士課程  
Master's Student, Department of Architecture, Kyoto University
- \*3 京都大学大学院工学研究科建築学専攻 教授・博士（工学）  
Professor, Department of Architecture, Kyoto University, Dr. Eng.

**Summary:** The object of this paper is to describe the sense of being inside or outside in buildings. As moving through buildings, the sense changes delicately. Architects have their own thoughts on the relationship between inside and outside, but those are always ambiguous. In this study, the sense of being inside or outside can be shown on the plan view by using the classifiers. The classifiers are made by convolutional neural network that has the information of visible area in buildings. This approach may allow architects and others to share their senses, and help architects design buildings.

キーワード：可視領域；アイソビスト；視深度ベクトル；判別機；深層学習；曖昧さ

**Keywords:** visible region; isovist; sight depth vector; classifier; deeplearning; ambiguity

### 1. 研究の背景と目的

建築空間は壁などによって領域が囲まれることにより、屋内・屋外、共用部・専用部といった内外に空間が分けられる。しかし内でも外のように感じられる場所や、逆に内のような外となる場所のように、内外の曖昧な場所が存在する。そのような内外の曖昧さはどのように記述できるのか。この問題にたいして、内外を機械的に判定できれば、それを平面図上に記述しながら共有し、設計を行うことができる。

本研究では、Figure 1のように建築空間の可視領域を入力とした畳み込みニューラルネットワークによる内外の判別機を構成することで、建築空間の内のような場所・外のような場所を平面図上に記述できることを示す。最終的な研究目標としてはこのような内外の曖昧さを評価し建築空間設計を支援することであるが、本研究はその端緒として仮想的なモデル空間を設定する。

内外が曖昧となり織り交ざるように空間が設計された例として「情緒障害児短期治療施設生活棟」（藤本壮介設計、北海道伊達市、2006年）を挙げることができる




Figure 1. 可視領域を入力とした内外判別機。

<sup>[1]</sup> 正方形の箱とそれらに囲まれた領域で構成されるが、囲まれた外部的な領域が場所によっては「隠れられる場所」となる。深層学習の設計への応用可能性を考えると、このように設計者個人の主観で判断していた空間の性質を図面上に可視化できれば、他者とその価値を共有するためのよいツールとなり、また設計者自身にとってもフィードバックを得ながら設計作業をするための支援ツールとなるだろう。

### 2. 研究に用いる手法

#### 2.1. 可視領域

可視領域とは、空間内である視点から見える領域である。ここではのちに可視領域をニューラルネットワークに入力するために、可視領域を視深度<sup>[2]</sup>（可視長）のベクトルとして表現する。すなわち、視点周りに  $n$  分割して光線を射出し、それぞれの光線が壁・障害物とはじ

めて交差した点までの距離で構成された  $n$  次元のベクトルを視深度ベクトルとして得る。例えば、半径 1 の円形の空間の中心を視点として可視領域を観測するとき、視深度ベクトルは  $[1, 1, 1, \dots, 1]$  と表現できる。

## 2.2. ニューラルネットワークによる判別機

ニューラルネットワークとは脳神経系を模擬した数理的モデルである<sup>[3]</sup>。例えば、手描きのアラビア数字 0 から 9 の 10 通りの数字が描画された画像を入力とし、その画像が 0 から 9 のどれであるか判別するような判別機を、ニューラルネットワークの機械学習により得ることができる。このときの手描き数字の画像とその正解ラベルのペアの集合をデータセットと呼ぶ。本研究では、このように判別機としてニューラルネットワークを用いる<sup>[4]</sup>。このとき入力が視深度ベクトルであり、出力が内か外かの 2 値のラベルとなる。

## 3. データセットの生成と判別機の学習

### 3.1. モデル空間の設計と空間の生成

判別機の学習に必要なデータセットは、モデル空間を作成し、視深度ベクトルと内外のペアを得ることとした。モデル空間は Figure 2 のようにいくつかのパラメータを設定して生成した。まず箱とその残余によって内部と外部に分割した。箱の中は内部であり、残余空間を外部とした。

箱の形態について説明する。基本は縦横寸法 1 の正方形とし、この箱に変形を適用する (t) か変形を適用しない (n) かの 2 タイプを考える。変形は回転と拡大縮小を両方適用したものからなる。回転は 0 から  $2\pi$  ラジアンまでの一様分布乱数のパラメータで回転させた。拡大縮小は正方形の中心を拡大縮小の中心として、面積の

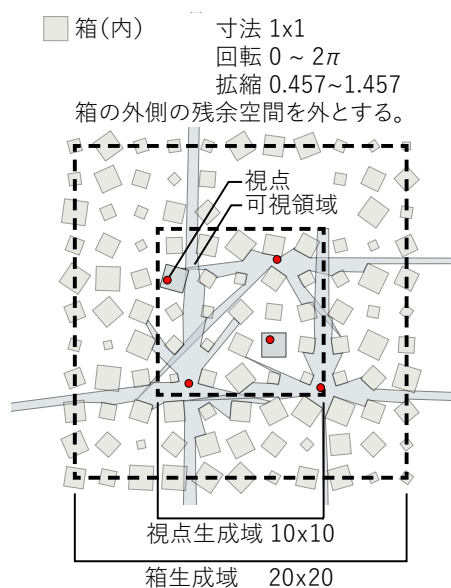


Figure 2. モデル空間の定義。

平均が 1 になるように、相似比の拡大縮小率が一様分布乱数で約 0.457 倍から 1.457 倍の間となるように設定した<sup>注1</sup>。もし箱同士が重なることがあれば結合した。

箱の配置については、グリッド配置 (G) とランダム配置 (R) の 2 タイプを設定した。まず 1 辺が 10 の正方形領域を視点を置く視点生成域とし、1 辺が 20 の正方形領域を箱が生成する箱生成域とした。グリッド配置については、箱生成域を自然数  $m$  に対して縦横  $2m-1$  分割し、その交点となる  $(2m-1)^2=M$  個の点を中心として箱を生成した。ランダム配置は箱生成域内を一様分布乱数によりグリッド配置と同数の  $N^2$  の点を配置し、同様に箱を生成した。本実験では  $M = 121, 169, 225, 289$  の 4 通り用意した。

したがって、モデル空間のタイプは、箱の変形の有無 (t-n) と配置のグリッドかランダムか (G-R)、箱生成数  $M$  によって設計した。例えば「箱の変形あり」で「グリッド配置」で「 $M=11^2=121$ 」のときのタイプは  $Gt(121)$  と表現することとする。このそれぞれのタイプの乱数パラメータを動かすことによって、それぞれのタイプについて 100 通りのモデル空間を生成した。ただし  $Gn(M)$  は乱数パラメータがないので変化しない。

### 3.2. 視点の配置と可視領域の計算

ひとつのモデル空間に対して、 $10 \times 10$  の視点生成域に点を一様分布乱数によって 100 点配置した。したがってひとつのタイプに対しては 10000 点の視点を配置したことになる。

視深度ベクトルを生成するには、視点座標の他に分割数・開始ベクトル・最大長を設定する。分割数については 128 分割とした。開始ベクトルとはすなわち頭の向き

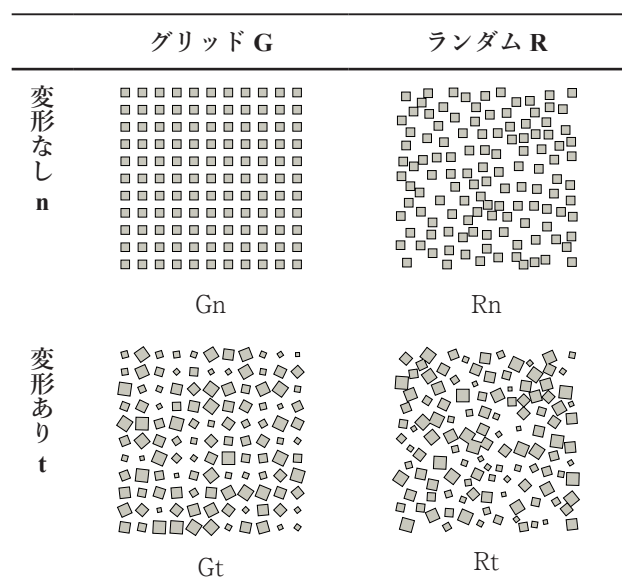


Figure 3. モデル空間の生成例。図は箱生成数  $M=121$  の場合。変形や配置のパラメータは乱数によって与え、乱数パラメータの無い  $Gn$  タイプ以外は 100 通りのモデル空間を生成している。

であるが、これは0から $2\pi$ ラジアンまでの一様分布乱数で定めた。空間の方位・方向性を考慮せずに内外を判別したいがためである。最大長は箱生成域より十分に大きい100とした。

これらによって、ひとつのモデル空間に対して10000の128次元視深度ベクトルを得ることができた。

### 3.3. 視深度の正規化

ここで、視深度を正規化することを考える。視深度はとくに障害物に当たらない場合は値が設定した最大値である100となる。するとこのような大きい値が、10以下の微妙な視深度の変化より効いてしまい、大きい量に結果が左右されやすくなると予想するからである。視深度の1と2の差は重要であるが、99と100の差は比較的問題とならないことが、実際の人間の空間認知からも想像できる。そこで、Figure 5のように視深度が0のときに1、視深度が無限大のときに0をとるように以下の数式(1)によって視深度を正規化する。dを視深度、r




Figure 4. (左) 正規化された視深度の意味。  
Figure 5. (右) 視深度の正規化関数のグラフ。視深度(距離) $d=0$ で最大値1を取るようになっている。

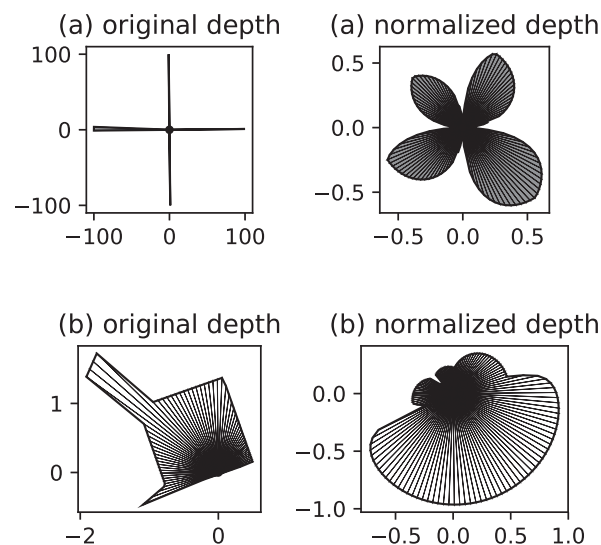


Figure 6. 可視領域(左)と視深度を正規化した可視領域(右)。(a)の可視領域(original depth)は障害物と当たらない場所があり、最大値として設定した100を上下左右でとっているが、正規化することでその部分はほぼ0となり、視点から近い壁の部分の変化がわかりやすくなっている。

を正規化した視深度とする。これは長さ1の棒の中心から垂直にd離れて見たときの視野180度に占める割合rを意味する(Figure 4)。正規化の式は(1)以外にも考えうるが、2次元空間において近いものと遠いものの意味の量を考えると、このように定義するのは妥当である。

実際にこれを用いて可視領域を正規化したものがFigure 6である。

$$r = \frac{2}{\pi} \arctan \frac{1}{2d} \quad (1)$$

### 3.4. データ分割

視深度ベクトルと内外の正答データのペアの集合からなるデータセットについて、学習に用いるtrainデータセット、学習の汎化性能を測るためのtestデータセット、空間評価に用いるvalidationデータセットの3つに分割する。ひとつのタイプに対してモデル空間は100生成しているため、これをtrain : test : validation = 80 : 10 : 10となるように分割した。すなわち、データセットの数でいえばtrain : test : validation = 8000 : 1000 : 1000となる。

### 3.5. データ拡張

判別精度をより高めるために、データ拡張を行う。128次元の視深度ベクトルは、これを1から128ずらして開始ベクトルを回転させても、空間の内外判定は変わらないことから、元のtrainデータセットからランダムに選択し、それを1から128のうちでランダムにずらすことでデータを増やした。ここでは合計で10倍に増やし、80000のtrainデータセットを得た。

### 3.6. ニューラルネットワークのモデルの定義と学習

ここではニューラルネットワークのモデルは畳み込み層を用いたもので画像判別で高い精度をもつAlexNetを基にして定義した。視深度ベクトルが1次元であるため、畳み込みフィルターも1次元になるように調整している。

学習エポック数は200まで行い、精度および損失のグラフから過学習が少なく十分に学習したと判断した。各モデル空間の検証データに対する精度は以下のTable 1の通り。

モデル空間	test データセットに対する判別機精度			
タイプ	121 箱	169 箱	225 箱	289 箱
Gn	1.0	1.0	1.0	1.0
Gt	1.0	0.9969	0.9700	0.9769
Rn	1.0	0.9879	0.9649	0.9819
Rt	0.9800	0.9720	0.9430	0.9580

## 4. 判別機の性能評価と内外判定

### 4.1. 判別機が誤判別する場所と内外の曖昧な場所

どのようにして内外が曖昧な場所を記述できるのか。そのような場所は「内部なのに外部のような場所」「外

部にいるのに内部のような場所」と表現できるものとして措定したい。例を挙げると、藤本壮介は「house N」の設計趣旨として次のように記している<sup>[5]</sup>。

…東京の小さな路地、立て込んだ木造の2階建てできた都市というものに対して、自分の6畳のワンルームから一步出ても、やはり何か大きな内部空間の中にいるような感覚を覚えたことに始まっている。…

「house N」は3重の入れ子の空間構成をもつ住宅であり、内部のような外部、外部のような内部を設計しようとしている。このように内外の曖昧な場所は、内外を取り違える場所と解釈可能である。内外を取り違える場所は判別機にとっては誤判別する場所である。そこで、本研究では判別機の誤判別に焦点をあてる。

#### 4.2. 各モデル空間自身で誤判別する場所

前章で得た判別機の誤判別する場所を分析する。ここではそれぞれのモデル空間タイプの validation データセット (10 モデル空間分、合計 1000 データ) に対してそのモデル空間の train データセットで学習した判別機によって内外判定を行った。内外別の誤判別数、誤判別割合は Table 2 に示す通り。

モデル空間タイプ Gn に関しては、全てに対して誤判別がない (Figure 7)。これらは、箱同士が重なって新たな広い箱になることがないため、内部が正方形で均一であり、外部は囲まれた場所がない。すなわち内部と外部を間違えようがなく、あいまいではない空間であるといえる。Gt(121), Rn(121) も同様である。

Gt(169), Gt(225), Gt(289) において誤判別する場所を見る (Figure 8)。外を内と誤判別する場所は、四方箱に囲まれたような場所であることがわかる。内を外と誤判別する場所は、箱同士が結合している部分を通して隣の箱を見通せるような場所であることがわかる。これらは箱の密度が 169 から 225 に上がることによって増す




Figure 7. 左から Gn(121), Gn(169), Gn(225), Gt(121)。どれも誤判別なし。




Figure 8. 左から Gt(169) の外での誤判別 (赤), Gt(225) の外での誤判別 (赤), 内での誤判別 (青), Gt(289) の内での誤判別 (青)。




Figure 9. 左から Rn(169) の外での誤判別 (赤), 内での誤判別 (青), Rn(225) の誤判別, Rn(289) の誤判別。




Figure 10. 左から Rt(121)・Rt(169)・Rt(225)・Rt(289) での誤判別。

ため、誤判別割合は Gt(169) の 0.4% から Gt(225) の 2.3% へと増している。しかし Gt(289) になると外部空間が細かくなり、小さい外部空間を外として学習したおかげで内の小さい正方形の箱の内部を外と誤判別するようになっていく。ただし誤判別割合は Gt(225) から減少しており、内外のあいまいさはこのうちでは Gt(225) が極大であることがわかる。

Rn(169), Rn(225), Rn(289) において誤判別する場所を見る (Figure 9)。誤判別の仕方は Gt の場合と同様であ

Table 2. validation データセットに対する各モデル空間自身での内外別の誤判別数, データ数, 割合, 割合の差

model space types		whole	in		out		diff in-out			
G - R	t - n boxes	wrong/all	wrong	all	wrong/all	wrong	all	wrong/all	wrong/all	
grid (G)	trans	121	0.0000	0	231	0.0000	0	769	0.0000	0.0000
		169	0.0040	2	389	0.0051	2	611	0.0033	0.0019
		225	0.0230	9	431	0.0209	14	569	0.0246	-0.0037
		289	0.0200	14	593	0.0236	6	407	0.0147	0.0089
	notrans	121	0.0000	0	227	0.0000	0	773	0.0000	0.0000
		169	0.0000	0	386	0.0000	0	614	0.0000	0.0000
		225	0.0000	0	426	0.0000	0	574	0.0000	0.0000
		289	0.0000	0	652	0.0000	0	348	0.0000	0.0000
random(R)	trans	121	0.0090	9	259	0.0347	0	741	0.0000	0.0347
		169	0.0230	11	372	0.0296	12	628	0.0191	0.0105
		225	0.0510	26	500	0.0520	25	500	0.0500	0.0020
		289	0.0320	11	603	0.0182	21	397	0.0529	-0.0347
	notrans	121	0.0000	0	267	0.0000	0	733	0.0000	0.0000
		169	0.0110	4	380	0.0105	7	620	0.0113	-0.0008
		225	0.0490	21	513	0.0409	28	487	0.0575	-0.0166
		289	0.0250	7	644	0.0109	18	356	0.0506	-0.0397



る。ここでRn(225), Rn(289)になると、空間をみても箱同士が結合して内外があいまいになっていることがわかる。また箱より狭い路地のような外部が多数発生していることが見て取れる。誤判別割合はRn(225)で4.9%まで増加しているが、Rn(289)ではまた2.5%まで減少している。これはほとんどの外部が内部より狭い空間で占められるが、内部は箱の寸法より狭くなることのないため、また内部と外部の違いがはっきりとしてきているからであると推測する。たしかにRn(289)で外部を内部と誤判別するところは箱のような広場ができていているところである。

Rtにおいて誤判別する場所をみる (Figure 10)。Rt(121)は内を外と誤判別しているところのみで、外を内と誤判別していない。これはRt(121)の密度は比較的 low、視線が範囲外まで抜けてしまうことが多いからではないかと推測できる。これがRt(169), Rt(225)になると視線が範囲外まで抜けることはなくなり、外を内を誤判別する場所が増える。内外での誤判別の割合の差も小さくなる。この視線が外部まで抜けると外部を内部と判定しないということは、Gnにおいてどの場所でも外部は視線が抜けるため誤判別しないということと矛盾しない。また逆に、内部でも外部に視線が抜ける場所をつくること、たとえば窓を設けるといったことは内部空間において外部的な場所をつくることに貢献すると考えられる。またRt(289)では内部を外部と誤判別するところはそこまで見通しがよくないところであることがわかる。これもRn(289)と同様にここまで密度が増加すると外部空間の見通しは悪く狭小になるため、121や169のときと内部、外部の見通しについては逆転するからであると推測する。

以上からまとめると、誤判別する場所と、内外の曖昧さの極大値をとる箱の密度に関して言及できる。誤判別する場所については、内部が基本的に箱で構成されているため、外では四方箱に囲まれたような場所を誤判別する。内の誤判別する場所は外部の密度によって異なる。箱の密度が低く外部で見通しがきく場合は、箱同士が結合している部分を通して隣の箱を見通せるような内の場所を外と誤判別する。箱の密度が高く外部の見通しがきかない場合は、内部の狭い場所、アルコーブのような場所を外と誤判別する。

内外の曖昧さの極大値をとる箱の密度については、本実験の121, 169, 225, 289の密度においては誤判別割合が225で極大となった。このときの内部と外部の面積の比率は、外部を直接計測することができないがランダムに配置された視点の内外の数から読み取ることができる。Table 2の視点数in allとout allをみると、誤判別の発生したGt, Rn, Rtでは225箱のときが最も面積の割合が1:1に近いことが読み取れる。例えばRt(225)は

内・外の視点数がどちらも500である。121だと外の視点数が多いが、289だと内の視点数が多くなる。すなわち、本モデル空間においては内外の面積割合が等しいときに誤判別しやすくなり、内外の曖昧さが極大となる。

## 5. 議論

### 5.1. 研究の位置付け

本研究は可視領域を分析する研究のひとつであるが、可視領域研究についてはBenediktによるisovist<sup>[6]</sup>がその後の研究の骨格をなしているといえる。Benediktが提案したのは、図形として得られるisovistをその体積および面積である可視量をはじめとした何らかの尺度に計算し直し、量として扱えるようにした方法である。このように量として扱うことで異なる空間や場所同士の比較や、行動や心理量との相関の検討を行うことができる。これはその後のTurnerらによるVisibility Graph<sup>[7]</sup>でも、空間の可視性を捉える道具が図形であるisovistからグラフであるVisibility Graphに変わったものの、クラスター係数や平均最小経路長といった何らかの量の尺度として特徴を抽出しているという点は同様である。

もちろん、このように量の尺度に変換しないと、図形やグラフのままでは空間の特徴を論じることは難しいため、量の尺度として捉える手法は強力である。しかし、今回のように可視領域の内外を判定するのに適切な量の尺度はどのようなものだろうか。モデル空間の定義方法によっては、単純に平面の可視領域の面積である可視量の大小で決定できるだろうが、単に可視量では判定できないモデル空間もある。例えば本研究のモデル空間のGn(121)は内は可視量が必ず1であることが利用できる。しかしRt(225)では可視量を使用した判定法では難しいことがわかる。さらにいえば、可視量以外にも多数考案されている尺度のどの尺度がいいのか決定することも難しい。このように本研究のような問題では可視領域を何かしらの量の尺度に変換するような手法に限界があることがわかる。

可視領域を何かしらの量の尺度に変換せずに空間を捉えられないか。その意味では、早瀬らが提案する視深度グラフ<sup>[2]</sup>は、視深度グラフが可視領域の形態に復元可能である点で意義のある手法である。ただし、心理量との相関を論じるために、グラフから読み取れる不連続点数や不連続長さ最大値といった量の尺度に変換せざるを得ない。

ここで、本研究のように可視領域の形態に復元可能な視深度ベクトルを量の尺度となる特徴量を設定せずにニューラルネットワークの入力とすることが有意義であるといえる。筆者らが以前提案した手法<sup>[4]</sup>に基づくが、内外の判別のように、モデル空間の定義次第で判別機内部の重み係数が変化するような、特徴量を先に決定できない問題において特に有効であるといえる。

視深度をそのまま扱う研究としては、Takizawaらが仮想都市空間内の視深度画像を入力に加えた深層畳み込みニューラルネットワークにより、その視点からの印象評価を予測する手法<sup>[8]</sup>を示している。視深度情報のある方が人間の印象を正確に予測できることから、少なくとも視深度は人間の印象評価に影響していることがわかる。本研究では機械学習で得られる判別機が人間の印象を表しているとは言えないが、先の研究に基づけば、関係ないわけではないと予想できる。実際に本研究の内外判別が、人間の抱く印象を予測することができるかどうかは、この判別機を用いて設計した空間において評価実験をする必要がある。これは今後の課題である。

## 5.2. 完璧な判別機または完璧な曖昧な空間は存在するか

もし完璧な判別機、すなわちどの空間でも内外が判別できる判別機をつくることのできたらこの手法は成立しないのではないかと考えられる。しかしそれに対しては内外が全く同じ空間形態をもつように設計する場合が反論材料となる。すなわち内部と外部が同じ形態のため判別不可能である。ただしこれは仮想空間上はできるが、実際に建築設計することを考えると、操作可能な範囲の外側（例えば敷地外）やはそのように作ることができない。内外を分ける建築のさらに外側が広がっているため、全ての場所を経験・学習しない限り内外を完璧に判別することはできない。

また、完全に内外が曖昧な空間は作れるのか。それはすなわち内をすべて外と判別し、外をすべて内を判別するような空間である。これは異なるモデル空間（とくに内外の定義を入れ替えたもの）で学習した判別機を用いれば可能であることがわかる。しかしここで登場する完全に内外が曖昧な空間を判別機が再学習することで、判別精度が上がり曖昧ではなくなるのが予想できる。

## 6. 結論

内部と外部の判別機を用いることで、空間の内部的な外部と外部的な内部を評価するための基礎的研究を示した。以下に成果を挙げる。

- 可視領域を視深度ベクトルに変換し、それを入力とした畳み込みニューラルネットワークによる判別機を構築する手法を示した。
- 無限遠の登場する視深度を扱うためにそれを正規化する関数を示した。
- 空間の内外の判別機の誤判別を利用して内外の曖昧さを記述するアイデアを考案し、モデル空間ごとに内外の曖昧な場所の特徴を論じた。
- モデル空間のパラメーターを変化させることによって、本モデル空間においては内外の面積割合が等し

いときに誤判別しやすくなり、内外の曖昧さが極大となることがわかった。

本研究は仮想的なモデル空間を題材としているため、実際の建築空間において適用可能かどうか、また実際に人間の印象と相関するかどうかについては今後の課題である。

本論文は2019年建築学会大会発表論文「深層学習による可視領域の内外判別を用いた空間評価のための基礎的研究」を発展させたものである。

## 謝辞

この研究は公益財団法人大林財団の助成によって遂行された。

## 注

注1 拡大縮小率が約0.457倍から1.457倍であることの説明。1辺xの正方形について、xがaからa+1までの値を一様分布乱数で取るときの面積の期待値 $E(x^2)$ は

$$E(x^2) = \int_a^{a+1} x^2 dx = [x^3/3]_a^{a+1} = (3a^2 + 3a + 1)/3$$

である。したがって、これが1となるようにすると

$$3a^2 + 3a - 2 = 0 \wedge a > 0 \Rightarrow a = (\sqrt{33} - 3)/6 \approx 0.4574 \dots$$

となり、面積の期待値を拡大縮小しない場合と等しくすることができる。

## 参考文献

- [1] 藤本壮介（設計）：情緒障害児短期治療施設生活棟，北海道伊達市，2006年  
新建築2006年9月号 pp.174-187 参照
- [2] 早瀬幸彦，田中理嗣，近藤正一，若山 滋：「視深度」による建築平面記述・評価の研究，日本建築学会計画系論文報告集，vol.484，pp.123-128，1996
- [3] 人工知能学会監修：深層学習 -Deep Learning-，近代科学社，2015.10
- [4] 安田溪，三浦研：ニューラルネットワークによる空間の可視領域の判別，第40回情報・システム・利用・技術シンポジウム2017，2017.12
- [5] 藤本壮介（設計）：house N，大分県，2007年  
新建築2008年9月号 pp.106-123 参照
- [6] Benedikt, M. L.: To take hold of space: isovists and isovist fields, Environment and Planning B, vol.6, pp.47-65, 1979
- [7] Turner, A., Doxa, M., O'Sullivan, D., Penn, A., : From isovists to visibility graphs: a methodology for the analysis of architectural space, Environment and Planning B: Planning and Design 2001, vol. 28, pp. 103-121, 2001
- [8] Takizawa, A. and Furuta, A. : 3D Spatial Analysis Method with First-Person Viewpoint by Deep Convolutional Neural Network with Omnidirectional RGB and Depth Images, Proceedings of the 35th eCAADe Conference - Vol. 2, Sapienza University of Rome, Rome, Italy, 20-22 September 2017, pp. 693-702, 2017