

深層学習と最適化を組み合わせた木漏れ日を感じるデザインの生成

A Creation Method of Komorebi Design Using Deep Learning and Evolutionary Algorithm

○鳥羽 潤*1, 加戸 啓太*2
Jun TOBA *1, Keita KADO*2

*1 千葉大学大学院 融合理工学府 博士前期課程

Graduate Student, Graduate School of Sci. and Eng., Chiba University.

*2 千葉大学大学院工学研究院 助教 博士 (工学)

Assistant Prof., Graduate School of Engineering, Chiba University, Ph.D.

キーワード : 深層学習; 進化的アルゴリズム; パラメトリックデザイン

Keywords: deep learning; evolutionary algorithm; parametric design

1. はじめに

建築分野では、しばしば自然物の引用によるデザインの創出が試みられ、人工物においても自然を感じられることに価値が置かれている。形状を生み出すアルゴリズム (以下、形状生成アルゴリズム) に自然物の持つ曲線や成長規則、再帰などの性質を引用することもしばしば行われている。他方、進化的アルゴリズムにより建築部位を最適化することも行われている。進化的アルゴリズムでは、形状生成アルゴリズムに対し、設定した評価軸のスコアを最大化 (ないし最小化) するパラメータの探索が行われる。現在、ここでの評価軸には日射取得や制作コストなど定量的な評価軸しか扱えず、デザイン性の最終的な決定は最適化によるスコアが良いものの中から選択するというアプローチになる。このような評価軸に「自然を感じることを加えることで、新しい設計手法が提案できないかと考えた。本研究では深層学習に自然物の形状情報を学習させ、そ


の結果を最適化の評価軸に用いて形状生成を行うシステムの開発を試みる。具体的には、自然物を理解するよう学習した深層学習モデルを作成し、進化的アルゴリズムによる最適化においてこの深層学習がどの程度自然物を理解するかを評価の軸に加えた最適化を試行し、その結果について報告する。自然物としてはしばしば建築デザインにおいて引用される「枝葉による心地よい光の漏れ (本研究ではこれを木漏れ日と呼ぶことにする)」を対象とすることにした。

2. 研究概要

本研究は、図 1 に示す深層学習と進化的アルゴリズムによる最適化を組み合わせたシステムを提案する。システムは以下のステップに整理できる。

- ①木漏れ日らしさを理解する深層学習ネットワークの開発
- ②深層学習による評価を取り入れた最適化システムの開発

① 木漏れ日らしさを理解する深層学習ネットワークの開発



② 深層学習による評価を取り入れた最適化システムの開発




図 1 深層学習を用いた形状最適化システム

この試行を通し、進化的アルゴリズムを用いた最適化の評価軸に人工知能（深層学習のネットワーク）が「木漏れ日を感じるか」を加えることで、自然物を新しいかたちで引用するデザイン手法の実現を試みる。

2-1. 関連する研究

深層学習では、入力した画像が何であるか認識する画像の分類タスクが良く知られる。従来、このような分類タスクは色の分布など画像解析的な特徴を求め、それを設定したルールに沿って評価することが行われていたが、深層学習による画像の分類タスクでは、その分類ための特徴を自動的に学習することが行われる。建築、特にデザイン分野でも深層学習を用いた研究が報告されており、吉村ら¹⁾は、深層学習による建築の理解に関して、建築作品の写真から建築家を推定するよう学習を行い、抽出された特徴（量）を分析している。抽出された特徴量が近い建築家は「ハイテック建築」や「プレーリースタイル」などデザインに共通するキーワードが見いだせることが示されている。あくまで複雑な関数による処理に過ぎないが、深層学習のネットワークは抽象的な情報を理解したよう振る舞うとも説明できる。また山田ら²⁾は画像生成タスクに代表されるGANを用い「サン・ピエール教会風サヴォア邸」といったデザイン性を継承した建築ファサードのような画像が生成できることを示し、生成された画像はインスピレーションの起点としてデザインの発想や拡張に寄与すると報告されている。

本研究は、従来のルールベースと呼ばれる手法では扱いきれない「木漏れ日らしさ」を深層学習に学習させることを行い、さらにそれを、進化的アルゴリズムの評価軸として適用することで「木漏れ日らしさ」のあるデザインが生まれ出せるか試みるものである。

3. 木漏れ日らしさを理解する深層学習ネットワーク

木漏れ日らしさの理解は、深層学習ネットワークに木漏れ日を含めた多クラスの分類タスクを学習させることで

行う（図2）。学習データとなる画像は深度画像を用いる。深度画像を用いる利点としては、色情報によらず形状における最適化が行える、最適化時の入力データと学習データの乖離がない少ない、また他クラスの画像としてImageNet^{注1)}などのデータセットが利用可能という点が挙げられる。木漏れ日以外のクラスは人工物の画像を採用し、深層学習が人工物と比較した自然形状を学習するようにする。ネットワークは画像分類タスクにおいて代表されるCNNにAttention Branch Network³⁾（以下ABN）を併用したネットワークを用いる。ABNを用いることにより分類において注視すべき領域(Attention Map)を学習し、推論時においてAttention Mapを確認することにより、深層学習がどこを注視して推論しているかを理解できる。人の印象評価において重要な特徴と注視領域が合致していることを確認することによって木漏れ日らしさを学習していることを目的とする。

3.1. 学習データの作成

学習データとなる深度画像は深度推定モデル⁴⁾を用いて単眼カメラで撮影した画像を深度画像に変換したものを用いる。木漏れ日の画像については自前で撮影したものを、人工物の画像として外構、ファサード、家具に相当する「金網フェンス」、「ダイニングテーブル」、「図書館」、「修道院」、「引き戸」、「石垣」の全6クラスをImageNetから選んだ。木漏れ日の画像は深度変換した後に木の葉の形状や抜けが認識できるサイズにクロップし（図3）、深度値の正規化を行う。深度変換後にクロップする理由は深度推定の都合上、高解像度の画像ほど深度推定の精度が高いためである。正規化後、ノイズやぼやけが目立つなど、深度推定の精度が低いものを省き学習データとする。図4に他のクラスについて学習用に深度画像に変換した例を示す。

3-1. 学習

図2の深層学習ネットワークで学習を行った。クラス数7、各クラス1000枚程度（訓練用:700枚、評価用:150枚、テスト用150枚）、画像サイズは300×300で学習を行った。




図2 深層学習ネットワーク

図 5 は学習後のモデルより得た Attention Map の一例である。Attention Map は判定に大きく寄与したところほど赤く表示されるため、図 5 を見ると画像の周辺部の葉の茂りが判定に大きく寄与していることがわかる。これは他クラスの画像と比較したときに、木漏れ日のクラスは画像周辺部に深度値が近い値を持つ画像が多い傾向にあるからと考えられる。一方で下方から中央にかけての葉の茂りの部分も赤く表示されているため、周辺部以外の葉の茂りも寄与していることもわかる。池田ら⁵⁾は、実際の木漏れ日に対する印象評価から、葉の密度や葉の輪郭といった葉の形状の特徴が良い印象と認識されると報告しており、主観的ではあるがこの学習モデルもこういった特徴を木漏れ日と認識していると判断でき、最適化に用いることとした。学習モデルの評価や改善については考察の余地があり、引き続き検討する予定である。




図 3 木漏れ日の学習データの作成




図 4 他クラスの深度画像




図 5 学習モデルによる Attention Map の一例

4. 深層学習による評価を取り入れた最適化

3次元モデルの作成は Rhinoceros, Grasshopper で行うため、Grasshopper に、深層学習を行う Python と TCP で通信を行うコンポーネントを作成した。具体的には Rhinoceros 上で作成したモデルの深度画像を入力されると、入力された画像 TCP 経由で Python 環境に渡される。

Python 環境では受け取った深度画像のターゲットとなるクラスの損失を算出し、TCP にて返す。連携コンポーネントはこれを受け取り、Grasshopper 上で最適化アルゴリズムに現在の適応度として渡すことで最適化を行う。また損失 L は次式(1)による予測値 (Y) と正答ラベル (Y_t) によるクロスエントロピー誤差とした。

$$L(Y, Y_t) = -\sum_k Y(k) \log(Y_t(k)) \quad (1)$$




図 6 コンポーネントの設定の様子

4-1. アルゴリズム

検証用の形状生成アルゴリズムとして 2000m×2000m、3層の範囲内にポロノイ状の多角形のパネルを配置するものを作成した。パネルの数、パネルの密度及び配置のパターンを変化させるオフセットをパラメータとして設定した。手法の検証として変化を観察しやすいように、木の葉の重なりのようなデザインを意図したアルゴリズムとした。また、深度画像の撮影設定はカメラ位置がパネルの中央より 2m 手前、高さを 1.5m、ターゲットをパネル奥 2m、高さ 1.5m、レンズ長さを 30mm、パネルより 5m 先にバックパネルを配置した。なお、Rhinoceros の設定上取得できる深度画像の画素値が学習データと反転しているため、画像を受けた Python 環境上で画素値を反転してから損失を算出している。




図 7 アルゴリズムによる形状の一例と設定環境

4-2. 最適化の結果

図 8 は目的関数を 1 つとする単目的最適化による形状の変化を示したものである。世代数が進むと損失が 0 に収束していき、深層学習が木漏れ日と判断する、つまり子も例日のような特徴を持つ形状に変化していくことが確認できた。

形状を観察すると損失が大きいものは、図 8 左は一層目の開口が少なくかつ大きさも小さいものが多いあるいは、開口が極端に大きいものが多い傾向にあった。加えて、開口が三層分重なり背後へ抜ける部分が少ない傾向も確認できた。損失が 1.0 を下回り始めると図 8 中のように背後への抜けが多数ある形状がみられるようになる。さらに損失が低下し、深層学習が 99% を超える確率で木漏れ日とはんだんするようになると、図 8 右のように背後への抜け以上に、各層が複雑に重なり合う箇所が多数あらわれるのが確認できる。これは、2.2 において Attention Map を用いて確認した木漏れ日らしさと合致しているとも言える。

目的関数を他クラスの損失に設定した最適化についても試行した。引き戸と判断されるよう最適化を行うと、木漏れ日の時と同様に損失が収束されることが確認できた。形状を確認すると損失が小さくなるほど単純な開口のある形状が多くあらわる傾向にあった。同様に修道院や図書館など外装、内装にあたるクラスの損失を目的関数に設定して最適化を行ったが、今回のアルゴリズムの性質上、修道院や図書館のような形状にはなりにくいためか、損失の収束が観察出来なかった。また、今回用いた分類ネットワークは小さな形状の変化による損失の変化が起きにくい可能性もあり、距離学習などを用いることでパラメータの変動による損失の変化が観察しやすい深層学習ネットワークに改良するなどの課題も挙げられる。

5. まとめ

本研究では深度画像による自然物の深度情報の特徴を深層学習に学ばせ、その結果を用いて形状最適化を行った。最適化の結果、木漏れ日のような深度を持つ形状に変化できることが確認できた。今回は手法の検証用としてのアルゴリズムに適用させたが、今後はスクリーンやフォーリーなど製作を意識したアルゴリズムへの適用を検証したい。

【注釈】

注1 深層学習用の画像データセット。1000 クラス、1400 万枚ラベル付き画像が使用可能。 <https://www.image-net.org/>

【参考文献】

- 1) Yoshimura Y., et.al., Deep Learning Architect: Classification for Architectural Design Through the Eye of Artificial Intelligence, Computational Urban Planning and Management for Smart Cities (CUPUM) 2019.
- 2) 山田、他、Deep Learning を用いたデザイン AI の作成と検証 -街並みと建築物外観の画像生成を対象に-、日本建築学会 計画系論文集、第 85 巻 第 770 号、pp. 987-995、2020.
- 3) Fukui et.al., Attention Branch Network: Learning of Attention Mechanism for Visual Explanation, Conference on Computer Vision and Pattern Recognition (CVPR), 2019.
- 4) S. Mahdi H. Miangoleh et.al., Boosting Monocular Depth Estimation Models to High-Resolution via Content Adaptive Multi-Resolution Merging, Conference on Computer Vision and Pattern Recognition (CVPR), 2021.
- 5) 池田、他、木漏れ日に対する認識と印象評価に関する研究、日本建築学会大会講演梗概集（九州）、pp. 65-68、2007




図 8 木漏れ日の損失を最適化した際の深度画像の損失と形状の変化の一例