

AIによる設計初期段階のデザイン検討支援システム「AiCorb®」

中 林 拓 馬 辻 芳 人
(設計本部)

Development of AiCorb to Streamline the Early Stages of Architectural Design Process

Takuma Nakabayashi Yoshito Tsuji

Abstract

In the early stages of an architectural design process, architects need to present multiple design proposals to clients to build consensus. However, creating a design proposal is a time-consuming and labor-intensive process. To streamline this process, we developed AiCorb, an Artificial Intelligence-based (AI) technology that automatically generates multiple facade designs. AiCorb is composed of two AIs: the first AI generates various facade images from sketches, and the second AI reflects the facade features from an input facade image to 3D models. In this study, we showed that recognition accuracy can be improved by adding synthesized images to training data. Additionally, we confirmed that AiCorb can efficiently generate facade designs and 3D models.

概 要

建築設計の初期段階では、設計者が複数のデザイン案を提示し、顧客と合意形成を進めるのが一般的である。しかしながら、デザイン案作成はアイデア検討や3Dモデル作成など、非常に手間と時間がかかる作業である。この合意形成プロセスの効率化を目的に、筆者らはAIを用いてファサードデザイン検討を支援するシステム「AiCorb®」を開発した。AiCorbは、スケッチなどから無数のファサードデザイン画像を生成するAIと、入力されたファサード画像を模した3Dモデルを生成するAIの2つの異なるAIで構成されている。本報では、学習データに人工的に生成したCGデータを加えることでAIの認識性能を向上できることを示した。加えて、それぞれのAIを用いることで、ファサードデザイン案の生成からその3Dモデル化までを効率よく実施できることを確認した。

1. はじめに

昨今、AI技術のうち特にDeep Learningに端を発する機械学習の発展により、建設業界でも様々な業務を対象とした省力化・自動化の取り組みが行われている。これらの取り組みのほとんどは、人間が実施している作業をAIに学習させ、人手を代替することを目的としている。例えばコンクリート表層の画像と不具合箇所を示すデータとを対にした学習データを用意し、AIにコンクリート表層の不具合を認識させる、などがその典型例である。現在のAIは、このように入力と出力がはっきりした判断基準に基づき対になったデータから特定パターンを見出し、データを分類することに長けている。一方、デザインが優れているか、などといった主観的な指標に関するAIの実用例はほとんどない。昨今では建築設計の効率化のためジェネレーティブデザイン²⁾など様々な手法が検討されているが、これらは基本的に距離に基づく動線の最適化や光・熱環境の最適化など、定量的な指標を用いる。

他方、近年ではAIなどを活用したデザイン検討・合意形成プロセスの効率化が検討されはじめている。その背景として、顧客との設計案に関する合意形成には膨大な時間がかかっていること、加えてよりよい設計案の提案は工事受注にも繋がることなどが挙げられる。

以上の背景のもと、大林組は建築設計の初期段階の合意形成プロセスの効率化や探索できる設計案の幅を広げ

ることを目的に、建築設計の意匠的側面を対象にAIを活用した設計支援システム「AiCorb®」を開発した。なお、AiCorbは大林組と米国の研究機関SRI International、建築設計向けWebプラットフォームを提供しているHyparの三社による共同開発である。本報では、AiCorbの技術概要と基礎的な検証実験の結果について述べる。

2. 設計業務でのAI技術の活用

2.1 システムの対象

設計には様々な段階があり、大別すると概念設計・基本設計・実施設計に分類される。本節では、各設計段階の位置づけと、AiCorbが対象とする設計段階について述べる。

まず、各種設計段階の位置づけであるが、概念設計では敷地条件等を満たす範囲で、いくつかの設計案を素早く検討し、施主の要求に応える案を提案することが優先される。ここでは一般的に、細かな納まりや寸法を検討する必要はなく、大まかな建物形状、間取り、外観のデザインが求められる。なお、本報では建物形状の検討をボリュームスタディ、建物表面の外観デザインをファサードデザインと呼ぶ。これに対して、基本設計以降は設計案を一つに絞り込んだ上で、徐々に各要素を具体化、仕様確定し、細部の検討へと移る。基本設計以降の段階では、建築法規や構法・各種材料や製品への知見の重要



Fig. 1 AiCorbを取り入れた設計業務の概念図
Concept Diagram of Architectural Design Workflow using AiCorb

性が高まり、法規や構法・製品などを参照しながら設計案を最終的に施工できる形まで具体化していく。

現在のAIは、いくつかの素案を素早く提示することが重要となる基本設計までの段階が適している。その理由として、現在のAIは未だ一つのタスクに特化したものが一般的であり、様々な条件を考慮する基本設計以降では適用が難しくなることが挙げられる。また、AIの出力は説明性が低く、なぜそのような解が得られたのか分からないことも課題の一つである。

以上から、設計者がAIの出力を取捨選択し、意味付けを行う形で素案作成プロセスに活用することで、品質や説明性の課題をカバーしながら運用すべきだと考えた。AiCorbの開発においては、AIシステムを設計者の補助ツールと位置付けた。また、設計部門へのヒアリング結果から、設計の初期段階で素早くいくつかの素案を提示できるようになれば、受注面だけでなく、設計の細部を検討するための作業時間の確保の面でも非常に有益だとの意見が多かった。なお、建物用途も設計に大きく影響を与える要素だが、まずはAIによる設計支援の実現可能性を検証するため、本報においては事務所ビルのみを対象としている。

2.2 AiCorbの概要

AiCorbはスケッチや3Dモデルのアウトラインから瞬時に無数のファサードデザイン案の画像を生成するAIと、入力されたファサード画像を模した3Dモデルを生成するAIの2つのAIで構成される。後者のAIは設計向けWebプラットフォームであるHypar³⁾と連携する形で実装した。Hypar上のAI機能に任意のファサード画像を入力することで、そのファサードの窓形状の特徴などをパラメーターとしてHypar上の3Dモデルに反映することができる。以上の2つのAIで構成されるAiCorbを取り入れた設計業務の概念図をFig. 1に示す。

2.3 AiCorbを利用するワークフロー

Hyparは建築設計用の簡易BIMツールとして開発されており、ユーザーが独自機能を開発・公開できるWebプラットフォームとしての特徴を持つ。また、Hyparは従来のCADと比較すると簡便なインターフェースで手軽




Fig. 2 Hyparのインターフェース
Interface of Hypar

に操作ができ、ボリュームスタディを効率良く実施することが可能である。HyparのインターフェースをFig. 2に示す。

Fig. 1に示したとおり、AiCorbを取り入れた設計業務においては、顧客からの要望を受けたのち、まずHyparにてボリュームスタディを行う。Hyparにてボリュームスタディが完了したのち、AiCorbを利用してファサードデザイン検討を開始する。詳細は次節で述べるが、AiCorbの一つ目のAIはスケッチや3Dモデルのアウトラインなどの画像を入力することで瞬時に無数のファサードデザイン案を生成する。これらのうち、任意の結果を選択し、二つ目のAIに入力することで、入力画像の窓の大きさや配置といったファサードの特徴がHypar上の3Dモデルに反映される。なお、Hypar上に反映されたのち、設計者は改めて各種パラメーターを手動で変更することが可能である。

以上の工程で設計案が固まった段階で、設計案を顧客に提案したうえで改めて要望をヒアリングし、合意形成を図る。一般的に、要望のヒアリングから設計案の提案のサイクルは何度も繰り返され、徐々に要望が具体化され、最終的に合意に至る。しかしながら、このサイクルでは通常、設計者がデザイン検討、設計案の可視化を何度も実施する必要があるほか、時には大きな手戻りが生じることもあるため、膨大な時間を要する。

本報で提案するAiCorbの目的は設計の自動化ではなく設計者の補助である。AIによりさまざまな設計の素案を迅速に作成することで設計者の検討の幅を広げ、より多くの案を検討できるよう手助けする。設計者が早期に顧

客からの具体的な要望を引き出せるようにすることで、品質の高い設計案の提案につながると考えられる。

3. システムの技術概要

3.1 ファサードデザインを提案するAI

本節では、AiCorbを構成する2つのAIのうち、1つ目のAIにあたるファサードデザイン案の画像を生成するAI（以下、ファサード生成AI）の技術概要と、学習に用いたデータセットについて述べる。

3.1.1 採用したAIモデルの概要 2014年にGoodfellowらが敵対的生成ネットワーク⁴⁾（Generative Adversarial Network, 以降GAN）を提案して以来、機械学習分野において生成モデルを利用した画像生成は非常に活発な研究が続けられている。近年では、Rameshらが提案したDALL-E⁵⁾によりテキストから生成された非常に高品質な画像生成結果が話題となったことも記憶に新しい。

本報では、ファサード生成AIにはGANベースの生成モデルを利用し、ファサードデザイン案の画像生成を試みた。GANは通常のAIモデルと異なり、1つのAIモデル内に2つのAIを備え、これらを競い合わせることで学習が進む。これらのAIは通貨偽造者とこれを取り締まる警察に例えられ、偽造者は警察を騙すためにより本物に近い偽札を、警察はこれを見抜くために真偽をより高精度に見分けることが必要となる。GANにおいては、上記例での警察の役割をDiscriminator、偽造者の役割をGeneratorと呼び、双方が切磋琢磨し合うことで最終的にGeneratorから高精度な生成結果を得ることを目的とする。

本報のGANベースのAIモデルでは、入力データはスケッチなどの線画画像、出力データはファサード画像を想定している。学習データに関する詳細は次項にて述べるが、このAIモデルの学習にはFig. 3のような線画画像とファサード写真とを用いた。学習過程では、Generatorが線画画像をもとに生成したファサード画像がDiscriminatorに入力され、Discriminatorはこの生成画像がファサード写真と見なせるかを判定する。この繰り返しの繰り返しにより、徐々に写真に近いファサード画像をGeneratorが生成できるようになる。

3.1.2 学習に用いたデータセットの概要 GANをはじめとする生成モデルは、一般的なAIモデルと同様に大量の学習データを必要とする。近年目覚ましい成果を上げている画像生成を対象とする生成モデルの多くは、インターネット上に存在する大量のデータをもとに学習を行っている。

一方、本報では入力データはスケッチなどの線画画像情報であり、生成対象もファサードデザインのみと非常に限定的である。特に建築物をスケッチした画像はインターネット上にもそれほど多くのデータは存在しない。加えて、本報の目的は設計者の設計案検討の意匠的な側面の手助けであるため、生成結果が設計者から見て魅力




Fig. 3 ファサード生成AIの学習データ例
Example of Training Data for Façade Generation AI



Fig. 4 ファサード写真からの線画画像生成例
Example of Image Processing

的な設計案でなければならない。このことから、生成結果と同様に、学習データは可能な限り多様性を持たせたい。設計者が魅力的だと感じるファサード写真にて構成すべきだと考えた。以上から、本報においては手動でデータセットを構築する方針とした。データ収集の際には設計者が意匠的な観点からデータを取捨選択する形で、数千枚のファサード写真のデータセットを構築した。また、本報で用いたAIモデルは学習にファサード写真だけでなくスケッチなどの線画画像も用いる。ファサード写真と線画画像は必ずしも同じ対象を写真・線画で表したペアとなっている必要はないが、数量としては同程度あることが望ましい。このため、画像処理によりファサード写真から生成した線画画像もAIモデルの学習に利用した。Fig. 4にその一例を示す。

3.2 入力画像のファサードを3Dモデルに反映するAI

本節では、AiCorbを構成する2つのAIのうち、2つ目のAIにあたる、入力されたファサード画像の窓の大きさや配置などといった特徴をHypar上の3Dモデルへ反映するAI（以下、3D変換AI）の技術概要と、学習に用いた学習データを述べる。

3.2.1 ファサード特徴の認識方法の概要 3D変換AIは入力されたファサード画像から、窓の大きさや配置などといったファサードの特徴をパラメーターとして抽出することが目的である。本報では、これを実現するため画像認識が得意なAIモデルであるResNet⁶⁾をそれぞれ

の処理ごとに別に用意した。

本報では、入力するファサード画像としてファサード生成AIで生成したファサード画像、あるいは実在の建築物のファサード写真を想定している。ただし、特にファサード写真では、基本的に透視投影歪みの発生は避けられず、加えてファサード面が複数面写っていることもあり、意図したファサード面以外からパラメーター推定してしまい、認識精度を妨げる要因となる。加えて、多くの建築物は窓の配置だけを見ても単一のパターンではなく、ほとんどの場合で一層目と上層部、あるいは部分的にパターンが異なり、これも本AIのパラメーター推定を困難にする要因である。以上から、Fig. 5に示すように、いくつかの段階でのパラメーター推定を試みた。以下に各ステップの詳細を述べる。

(1) 正対化処理 ほとんどの場合、ファサード写真は歩行者の目線の高さからの撮影となるため透視投影歪みが避けられない。これにより、同一寸法の要素であっても撮影地点からの距離によりその見え方が大きく影響を受けるが、これは窓の大きさや配置などを正確に認識するうえで課題となる。本報では、この課題を解決するために、3D変換AIに入力されたファサード画像内の主要なファサード面を認識し、歪み除去を行うこととした。画像内の主要なファサード面の認識は、ResNetによって主要なファサード面の四隅の座標を認識した。

(2) ファサードタイプ認識 ほとんどの場合、ファサード面は低層部や高層部などでいくつか異なるパターンにより構成されている。単一の認識モデルにて窓の形状や階高などといったパラメーターを認識することは難しいため、ファサードをいくつかのタイプに分類したうえでパラメーターを認識することとした。本報では、①窓などが規則的ですがすべての階がほぼ同様の階高を持つファサード、②窓などは規則的ながら、低層部で階高の異なるデザイン、③窓などが不規則かつ、低層部で階高の異なるデザインなどといった典型的ないくつかのタイプを設定した。正対化処理と同じくResNetにより、このファサードタイプを認識した。

(3) ファサードパラメーター推定 これまでの処理により、正対化処理がなされ、かつファサードタイプが認識された画像が本処理に入力される。本報では、ファサードパラメーターとして、建物幅・階高・窓形状・窓配置などの各寸法を認識し、得られたパラメーターをHypar上の3Dモデルに反映することとした。この認識にもこれまでと同様ResNetで、各パラメーターの値を推定した。なお、このAIモデルへの認識は二次元画像であり、正確なスケール情報は得られないため、各寸法については建物高さを基準とする比として出力している。

3.2.2 学習に用いたデータセットの概要 3D変換AIの各処理に用いたResNetも、一般的なAIモデルと同様にそれぞれ大量の学習データを必要とする。そのため、本報では手動でのラベリング作業とアルゴリズムによるデータの自動生成を併用し、数千枚の学習用データセッ

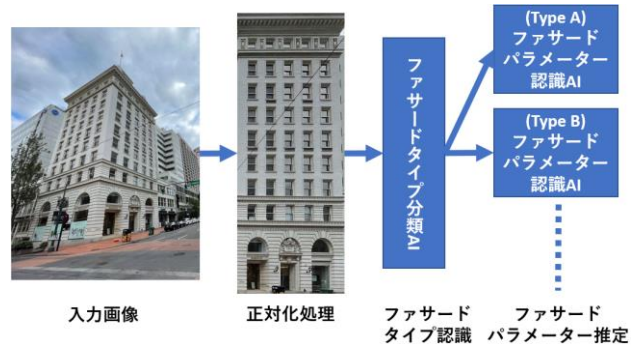


Fig. 5 3D変換AIの処理の流れ
Pipeline of Façade Feature Recognition



Fig. 6 正対化処理の学習データ例
Example of Training Data for Frontalization

トを構築した。

まず、正対化処理の学習データについて述べる。ラベリング作業には1つ以上の建物が含まれる画像が与えられ、作業者はこのうち最も主要だと思われる建物の1つのファサードの四隅を記録する。建物形状によっては四隅の設定は一意には決まらないが、本報においては、例えばあるファサード面の上層部が凸型になっているような形状の場合には、その面全体を包括するような四角形を描く形で四隅を設定することとした。学習データの一例であるFig. 6では、四色の十字マークの位置が作業者が設定したファサード面の四隅である。

続いて、ファサードタイプ認識とファサードパラメーター認識の学習データについて述べる。これらは、手動でのラベリングのほか、Fig. 7のような3DモデルをHypar上で自動生成し、学習データに追加した。これらの3Dモデルは、3D変換AIのプロセス内でAIによって認識されるファサードタイプや階高・窓形状などのパラメーターを用いて生成した。学習時には、3Dモデルを生成する際に利用したパラメーターを画像データと対することで、そのまま学習データとして利用することができる。なお、CGなど仮想環境を用いて学習する際には、Data Randomization⁷⁾と称される、実用時に入力されないようなデータを含め、ランダム性を持ってデータを生成する手法を用いることで、実用時の入力データに対する頑健性を高めることが知られている。本報ではこの手法を採

用したため、Fig. 7のように生成した3Dモデルのマテリアル・テクスチャに対し、現実にはほぼ見られないような色・質感を含め多様なものを設定し、学習に用いた。

4. システムの検証実験

4.1 ファサードデザインを提案するAIの検証実験

本報で開発したファサード生成AIの性能を確認するため、様々なデータを入力した際のファサード画像生成結果を検証した。スケッチ入力と、Hypar上で作成した3Dモデルのファサード面を入力した場合の2つの検証結果をFig. 8に示す。なお、Fig. 8では左端の画像が入力画像である。本検証ではスケッチ画像・3Dモデルのアウトライン画像を計100枚程度用意し、複数の評価者にて主観的な品質評価を実施した。

結果から、入力画像に空白が少なく、ある程度の情報量を持っている場合にはFig. 8のように写実的な結果が得られることが確認できた。一方で、特にスケッチ入力のように書き込みの少ない空白箇所が多い入力画像の場合、破綻した生成結果となりやすいことがわかった。また、Fig. 8の下段に示したように、Hypar上で作成した3Dモデルのファサード面を学習データと同様に画像処理によって線画画像化した場合には、良好な生成結果を得やすいことがわかった。これは人間がスケッチを作成する際に省略して書いてしまうような細部の繰り返しのパターンであっても、機械的に均一な品質で描画する3Dモデル表示の特徴が寄与していると考えられる。

4.2 画像を3Dモデルに反映するAIの検証実験

3D変換AIの性能検証のため、ラベリング済みのファサード写真を用意して精度検証を実施した。ここでは、3D変換AIを構成する3つの処理それぞれに対して定量的な評価を試みた。正対化処理には375枚、ファサードタイプ認識には3375枚、ファサードパラメーター認識には369枚の評価用データを用意し検証を行った。また、精度指標として、ファサードタイプ認識は正答率を、正対化処理とファサードパラメーター認識は以下で定義されるL1errorを用いて評価した。

$$L1_{error} = \frac{1}{n} \sum_{i=1}^n |gt_i - pred_i| \quad (1)$$

N : 検証に用いたデータ数量

gt : データに付与されている真値

pred : 各AIの予測値

また、各検証では、学習データとして手動でラベリングした写真データの場合と、自動生成したCGデータを含めて学習した場合の精度比較を実施した。なお、検証データ内の各画像は画素数が異なるため、L1errorの算出時には画素数ではなく、正対化処理の検証においては画




Fig. 7 アルゴリズムにより自動生成した学習データ例
Example of Synthesized Training Data

Table 1 正対化処理の検証結果
Quantitative Result of Frontalization

データセット	L1 error
写真データのみ	0.10
写真+自動生成データ	0.06

Table 2 ファサードタイプ認識の検証結果
Quantitative Result of Façade Type Recognition

データセット	正答率
写真データのみ	70%
写真+自動生成データ	81%

Table 3 ファサードパラメーター認識の検証結果
Quantitative Result of Façade Parameter Recognition

データセット	L1error
写真データのみ	0.087
写真+自動生成データ	0.080

像高さを1、ファサードパラメーター認識においては主要ファサードの高さを1と仮定した上で、予測値と真値とのずれをそれら基準長さに対する比として算出した。また、L1errorは真値との距離にあたるため、小さいほど高精度と見なせる。

Table 1に正対化処理の検証結果を、Table 2にファサードタイプ認識の検証結果を、Table 3にファサードパラメーター認識の検証結果をそれぞれ示す。評価結果から、いずれもある程度の誤差・誤認識は生じたものの、良好な精度で認識できたことが確認できた。また、いずれの結果においても、自動生成したCGデータを加えた場合のほうが高い性能を示すことを確認できた。Fig. 9に3D変換AIにて3Dモデルに入力画像の特徴を反映した結果を示す。いずれの例も、右上の枠内の画像を入力した結果である。なお、ここでは3Dモデルの表面材質の色は手動で調整している。

5. まとめ

本報では、AIを活用した建築設計初期段階の合意形成を支援するシステムを開発し、技術構成とそれぞれのAIの検証実験について報告した。本研究を通して得られた




Fig. 8 ファサード生成AIによる生成例
Results of Façade Image Generation




Fig. 9 3D変換AIにより入力画像を反映した3Dモデル
3D Models Reflected Façade Features by 2D to 3D conversion AI

知見を以下に示す。

- 1) GANベースの生成モデルを用いることで、スケッチ等の線画画像から実写のようなファサード画像を生成することができた。
- 2) 畳み込みニューラルネットワークをベースとしたAIモデルにより、ファサード画像から窓形状や配置、階高などのパラメーターを抽出できた。
- 3) 学習データ量が少ない場合に、画像処理による線画化や、3Dモデルの自動生成など、目的に応じて人工的にデータを生成することで学習効果を高めることができることを確認した。

今後は、さらにシステムの性能を改善し、より効率的に魅力的な設計案の提案ができるように継続して開発に取り組みたい。

参考文献

- 1) 青島, 他: 深層学習による画像認識を用いたコンクリート構造物の変状検出に関する研究, 土木学会論文集E2 (材料・コンクリート構造), Vol. 74, No. 4, pp. 293-305, 2018

- 2) Dieter Vermeulen: From Design Automation to Generative Design in AEC, Autodesk University, 2019, <https://www.autodesk.com/autodesk-university/class/Design-Automation-Generative-Design-AEC-2019-0> (accessed 2022-09-20)
- 3) Hypar, <https://hypar.io/> (accessed 2022-09-20)
- 4) Ian Goodfellow, et al.: Generative adversarial nets, NIPS'14: Proceedings of the 27th International Conference on Neural Information Processing Systems, Vol. 2, pp. 2672-2680, 2014.12
- 5) Aditya Ramesh, et al.: Zero-Shot Text-to-Image Generation, arxiv, <https://arxiv.org/abs/2102.12092>, (accessed 2022-5-30)
- 6) Kaiming He, et al.: Deep Residual Learning for Image Recognition, Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition, pp.770-778, 2016.6
- 7) Josh Tobin, et al.: Domain randomization for transferring deep neural networks from simulation to the real world, 2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), pp. 23-30, 2017