
論 文

空間構造物の設計支援統合環境の開発 ～情報の一元管理・効率的運用が可能なプラットフォームの 開発と機械学習による分析手法の提案～

Development of an Integrated Design Support
Environment for Spatial Structures
～Development of a platform for centralized management and
efficient operation of information, and proposal of
analysis methods using machine learning～

宮崎 崇 Takashi MIYAZAKI
都市インフラセクター 建築本部
設計技術部 鉄構設計室

抄 録

近年、情報処理技術が発達し設計デザインの自由化が進んでいる。特に空間構造においては、構造骨組み自体がデザインとなることが多々あり、意匠的要求を満たすために構造・製作・施工的に難易度が高くなることが多い。そのため、設計段階で構造検討だけでなく製作・施工性も検討することが重要であるが、製作・施工性を検討するために必要となる3DモデルやBIMモデルは作成に時間を要する。また、架構形状が複雑であるため、構造合理性の定量的判断が困難なことから経験則や過去例に倣った形状を選択することが慣例的であった。本論文では、上記課題の解決を目的とした設計支援統合環境の開発とその効果を述べる。具体的には、構成要素である構造解析プログラムやBIMソフト等の各種ソフトウェアを連携させ情報を一元化した設計プラットフォームの開発と、機械学習を活用した架構形状の定量的評価を行う分析手法について述べる。

Abstract

In recent years, with the development of information processing technology, the freedom of design has increased. In particular, in spatial structures, the structural framework itself is often the design, and the degree of difficulty in terms of structure, fabrication, and construction is often high in order to satisfy the design requirements. Therefore, it is important to consider not only the structure but also the fabrication and workability at the design stage, but the 3D models and BIM models required to consider the fabrication and workability are time-consuming to create. In addition, it is difficult to make quantitative judgments on the structural rationality because of the complex shape of the structure, so it has been customary to select a shape that follows empirical rules and past examples. In this paper, we describe the development of a design support integrated environment to solve the above problems and its effects. Specifically, we describe the development of a design platform that unifies information by linking various software such as structural analysis programs and BIM software, which are components of the platform, and an analysis method for quantitative evaluation of the shape of the structure using machine learning.

1 緒言

近年、建築設計における情報処理技術が発達し、これまで建築業界で使用されていなかったツールの使用やプログラミングを活用したデジタルな設計手法が急速に構築されつつある。こうしたデジタル技術の発展背景には、ビジネスと生活を変革するDX (Digital Transformation) や第四次産業革命等が影響している。そのため、建築分野についても活用を模索する動きが出てきており活用事例の報告が増えつつある。特に建築分野でのデジタル活用では、BIM (Building Information Modeling) を用いた生産設計プラットフォームの構築が広がりを見せており、活用事例は年々増加している。

BIM 活用の最大のメリットは、建物情報を設計段階から製作・施工段階まで一元化したモデルで管理できることであり、そのような利用方法が当初は想定されていたと思われる。しかし、設計デザインにBIMを活用する設計BIMと生産性の向上を目指す施工BIMとで使用用途が異なり情報が一元化されておらず、メリットを活かしきれていないのが現状である。これは、建築家は形状生成といったプロジェクトのフロント部に重心を置く傾向があり、製作・施工者は、デザインの大枠が決まった状態から如何に効率的に生産・施工に結び付けるかというエンド部に重心を置いているため、役割の重心位置が異なることが要因と考えられる¹⁾。そのため、情報が一元化されず各々独自に発展しており、それぞれの活用方法の違いから、設計から製作・施工への情報伝達が効率よく機能していない場合が多い。如何に設計情報を製作・施工に情報漏れなく繋げるかが重要で、現在の構造エンジニアは、この両方を結び付ける重要な役割を担っている。特に構造骨組みがデザインとなる空間構造物では、多様な骨組形状が採用されるため、製作・施工の難易度が高くなり情報を結び付ける構造エンジニアの果たす役割は大きい。併せて、空間構造物では建築家の意匠的要求を満たすため、複雑な架構骨組みとなることが多々ある。これまでは、構造的に架構骨組みが有利かを定量的に説明することが難しく経験則による判断あるいは過去例に倣うことが慣例的であった。そのため図1-1に示すように、目的変数と架構形状

ケースから構成される非線形な関係の中で、選択した形状がどこに位置しているのかを把握することは困難であり、選択した形状よりも高性能な形状が存在する可能性は十分にあり得る。また、デザイン変更や設計を進めていく中で形状調整することが多く、形状の変更が繰り返される傾向にある。そのため、設計者の発想力を用いた提案よりも作業の方に時間が掛かる場合も多い。

上記、現状の課題点をまとめると、

- 1) 設計段階でデータがまとめられておらず製作・施工等への情報伝達が非効率
- 2) デザイン変更や形状調整により、形状変更が多く手戻り作業が増加
- 3) 形状選定が構造合理性の定量的判断が困難なことから経験則や過去例に倣うことが慣例化が挙げられる。

これらより、本論では課題点1)～3)を解決するために設計者の設計支援を目的とした設計支援統合環境(以下、統合環境)の開発とその効果を述べる。統合環境を構成する要素としては、以下3点が挙げられる。

- ・設計プラットフォームの構築
- ・機械学習による学習モデルの生成および検証
- ・説明支援機能の生成

2章では、情報を一元管理可能なデータベースを中心とした設計プラットフォームの概要について実施例を踏まえながら述べる。3章では、設計プラットフォームを用いて得られる大量の架構形状データ




図1-1 最適形状の探索
Fig. 1-1 Finding the optimal shape

を活用して、デザイン変更に伴う構造解析結果の予測が行える機械学習モデルの生成および検証方法について述べる。併せて、大量の架構形状データから設計者の任意の制約条件を満たす最適形状の探索に多次元グラフと機械学習手法を用いた最適形状の選定方法および選定理由を定量的に説明する手法について実施例と合わせて述べる。4章では、3章の分析を簡易に行うことが可能なツールの運用方法について述べる。

2 設計プラットフォームの概要

設計段階から製作・施工段階までの膨大な情報管理・運用していくためには、情報をひとつのデータベースに集約し一元管理することが効果的である²⁾。従来の設計フロー(図2-1)では、デザイン変更や形状調整をする場合の手戻りが設計終盤になるにつれ多くなる。また、使用するアプリケーション間の変換を自動で行っているため、さらに膨大な時間も要することとなる。この手動で行っている動作をプログラムによって自動化することも可能であるが、アプリケーション間の変換を自動化するプログラムはアプリケーションの組み合わせの数必要となり制御が煩雑となる。そこで図2-2のように設計段階で情報を逐次データベースに集約し、そのデータベースを参照して各アプリケーションと連動する設計プラットフォームを構築した。こうしたデータベースを中心としたプロセスに移行することにより各フェーズで生じる情報を失うことなく蓄積・運用することができる。また、本設計プラットフォームでは、設計終了時データベースの情報をそのままBIMモデルに変換することが可能となる。図2-3に本設計プラットフォームを活用した変換例を示す。図2-3(a)~(e)の順に各アプリケーションとの変換を行い、形状の変更や調整があった場合に即時BIMモデルや一般図までの作成が可能となった。これにより、設計の効率化や建築家への迅速なレスポンスができ設計付加価値の向上にも繋げることが可能になる。

データベースは、テーブルデータとして整備しアプリケーション間の移行がし易いように型変換を行っておく等の前処理を行っている。アプリケー

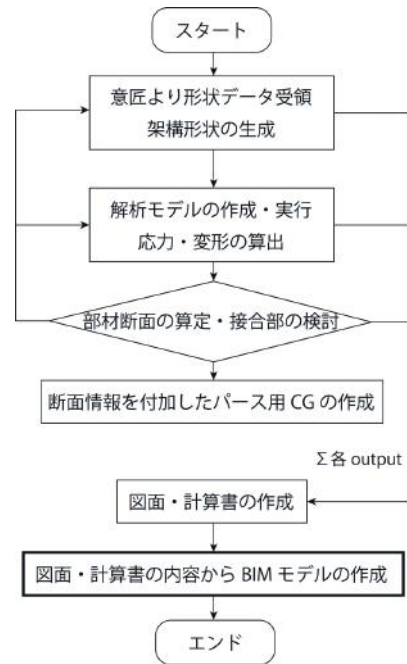


図2-1 従来の設計フロー
Fig. 2-1 Conventional design flow




図2-2 設計プラットフォーム
Fig. 2-2 Design platform

ションへの変換には、アプリケーション側にAPI (Application Programming Interface)が用意されている場合には、直接プログラムと連携することとしている。一方、用意されていない場合には、アプリケーションへの入力形式を確認した上で変換プログラムを実装することとしている。そうした使い分けにより最小限のプログラム実装でデータベースとの連携ができ、新たなアプリケーションが登場しても柔軟に機能の拡張・シミュレーションが可能となる。

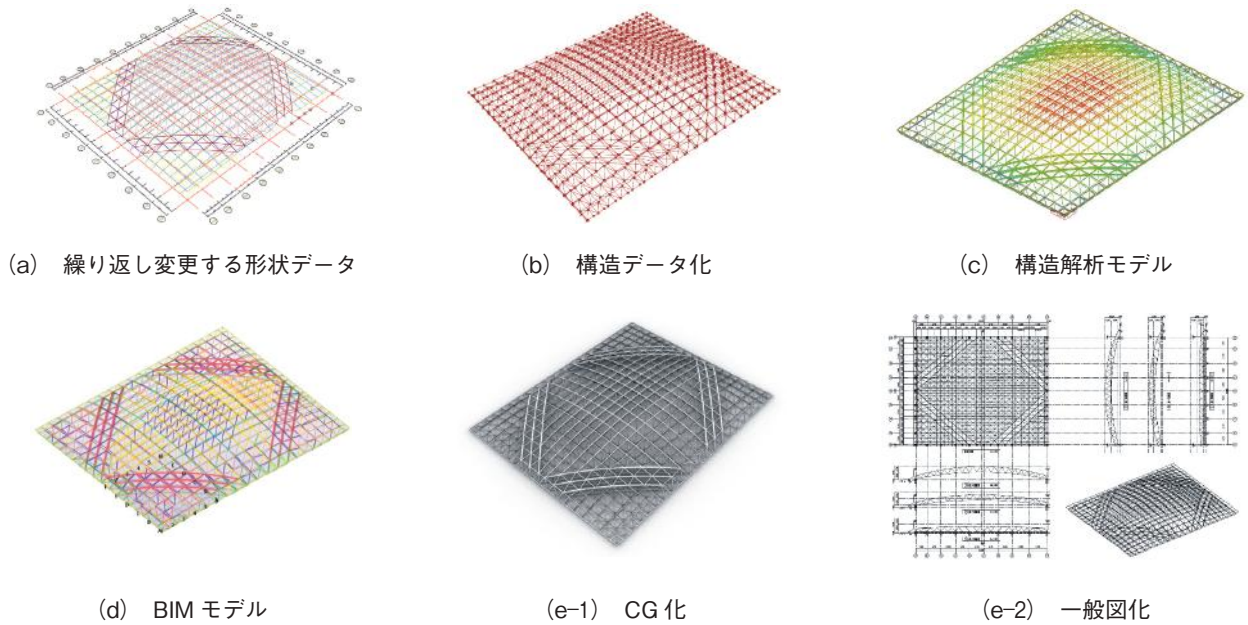


図2-3 各種アプリケーション間の変換例
Fig. 2-3 Examples of conversion between various applications

3 架構特徴の分析・運用方法

設計者の要望に応じた最適な形状を提案できるように、形状の構造的特徴の把握や形状を選択した理由を機械学習で説明できるプロセスを構築した。図3-1に全体のフローを示す。

本章では事例を踏まえながら、機械学習を用いた分析から運用までの内容及びプロセスを説明する。

3-1. データセット・学習モデルの生成

2章の設計プラットフォームにて瞬時に架構形状の構造計算まで連携することが可能であるため、架構形状のパラメトリックスタディにも使用できる。これを活用し、所定の設計制約条件を満たす中で考えられる架構の形状アルゴリズムを生成する(図3-2)。実案件でのデータセット作成事例として、形状変数(以下、特徴量)として図3-3に示す *depth* (デプス), *rise* (ライズ), *divide* (トラス本数), *divide2* (繋ぎ材本数), *type* (繋ぎ材の斜材有無), *radius* (中央リングの半径)とし、構造解析結果(以下、目的変数)として総歪エネルギー, 最大鉛直変位, 総重量を設定し本事例を用いて分析を行うこととする。なお、総歪エネルギーは式(1)に示すように、第1項の軸歪エネルギー, 第2項の曲げ歪エネルギー,

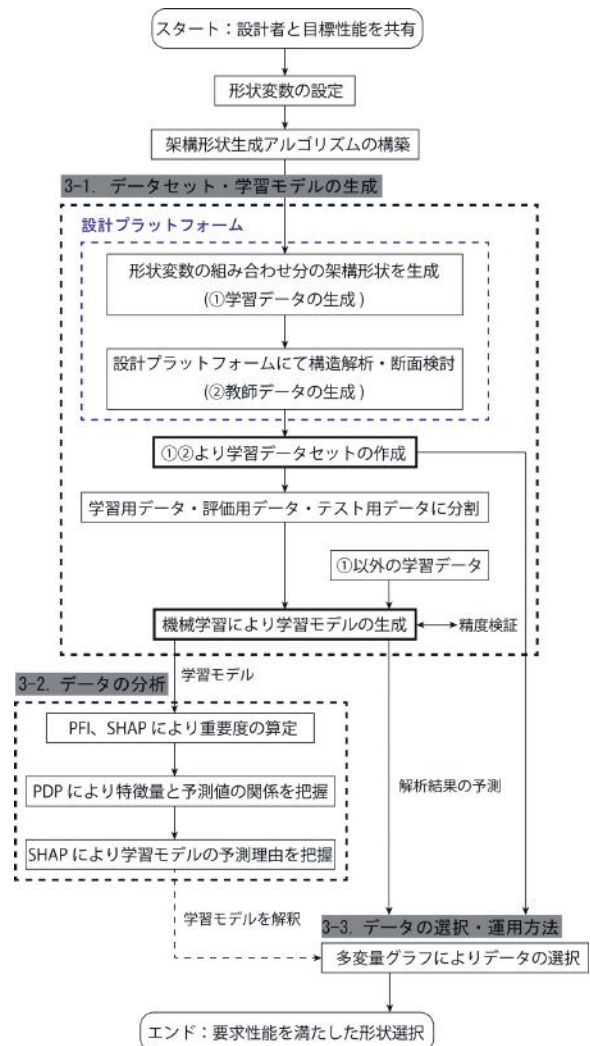


図3-1 架構特徴の分析フロー
Fig. 3-1 Analysis flow of structural characteristics

第3項のせん断歪エネルギーから算定する。

$$W = \frac{1}{2} \sum_i^n \left(\int_0^l \frac{Ni^2}{EAi} dx + \int_0^l \frac{Mi^2}{EIi} dx + \int_0^l \frac{\kappa_i Qi^2}{GAi} dx \right) \quad (1)$$

$$\kappa = \frac{A}{I^2} \int \frac{S^2}{b^2} dA \quad (2)$$

ここで、

n : 部材の本数, l : 部材長, N : 軸力, M : 曲げモーメント, Q : せん断力

E : 弾性係数, G : せん断弾性係数, b : 部材の幅, A : 部材の断面積, I : 部材の断面二次モーメント, S : 部材の断面一次モーメント

架構形状の構成イメージとして、図3-4に架構形状のCGを示す。表1に設定した各特徴量の最大最小値および刻み(step)の値を示す。これより、組込んだ特徴量の組み合わせ数分の形状を生成(図3-5)・構造解析を行い学習データ(各特徴量)と教師データ(構造解析結果)のデータセット生成を行う。データセットを自動で生成できることにより、データ収集および前処理の必要がなく、機械学習の入力形式に合わせたデータセットとできるため即時学習に回すことが可能である。

構造計算する際に、別途実装した日本規準の許容応力度設計用の関数にて断面の算定することが望ましい。しかし、収斂計算を伴うこともあり時間が膨大に掛かる。ここでは、架構形状の各特徴量が与える影響の分析を行うため、断面は仮定断面で進めることとする。

3-1-1 データセットの準備

ここでは、作成した形状アルゴリズムおよび設計プラットフォームを用いて約1万の架構形状の学習データおよび教師データを作成し、そのデータを用いて分析を行う。

未知のデータに対する予測能力(以下、汎化性能)の検証を行うために評価用データ、テスト用データを用意する。具体的には、図3-6に示すようにhold-out法を用いて学習用(trainデータ)と評価用(validデータ)、テスト用(testデータ)の生成を行った。hold-out法とは、図3-7に示すようにデータセットをtrainデータ validデータ, testデータに任意の割合で分割し、trainデータで学習を行い、

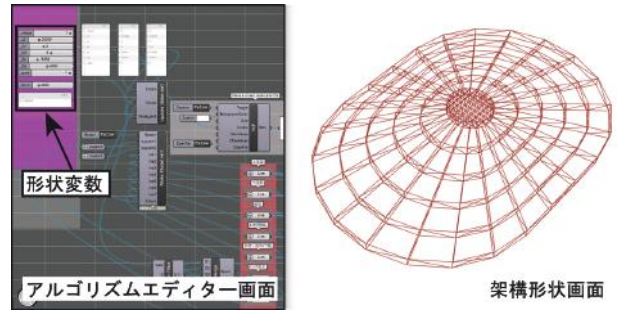


図3-2 アルゴリズムエディター
Fig. 3-2 Algorithm Editor




図3-3 形状変数凡例
Fig. 3-3 Shape Variable Legend

表1 各特徴量の値
Table1 Value of each feature

| | radius (mm) | divide | divide2 | rise (mm) | depth (mm) | type |
|------|----------------|--------|---------|--------------|---------------|------|
| min | 25000 | 4 | 6 | 6000 | 4000 | 0 |
| — | ~ | ~ | ~ | ~ | ~ | ~ |
| max | 40000 | 7 | 10 | 10000 | 8000 | 1 |
| step | @5000 | @1 | @1 | @500 | @500 | @1 |



図3-4 実案件の架構CG
Fig. 3-4 CG of the actual project

validデータ, testデータで精度の確認を行う評価用データの分け方の手法である。



図3-5 変数の組み合わせ数分の形状データ(イメージ)
Fig. 3-5 Variable shape data



図3-6 hold-out 法
Fig. 3-6 hold-out method

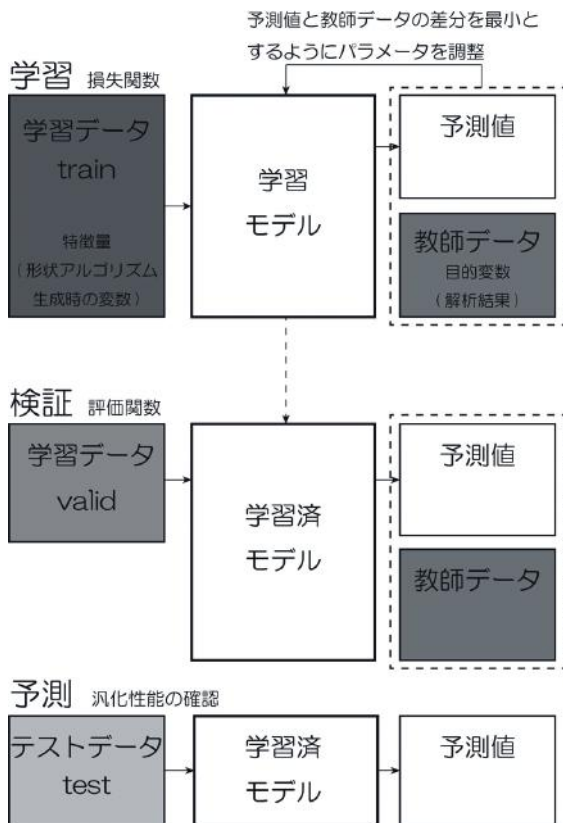


図3-7 学習・検証(評価)・分析の流れ
Fig. 3-7 Flow of learning, verification (evaluation), and analysis

各データの役割をまとめたものを以下に示す。

- ・学習用データ：パラメータ(重みやバイアス等)の調整(学習に使用)
- ・評価用データ：ハイパーパラメータの調整(性能評価に使用)

・テスト用データ：学習済みモデルの汎化性能を確認

一方で hold-out 法は、train データで使用されるデータ数が少なくなる欠点もあり、これを解消した Cross validation でデータの分割を行っても良い。しかし、ここでは hold-out 法で十分な精度が得られたことから計算コストを鑑み hold-out 法で評価を行うこととした。

また、学習データ全体は2次元の行列と見なすことができ、行列の行は「インスタンス」、行列の列は「特徴量」と呼ぶこととする。今回は、インスタンスは約1万行、特徴量は6列となる。

3-1-2 学習モデルの選定・学習方法

学習モデルには Tree Ensemble 系の LightGBM を選択した。理由は、回帰予測のみであれば線形回帰や多項式回帰、Neural Net 系等も考えられるが、LightGBM が最も高精度を示したためである。

モデルの学習および評価を行うため、損失関数(Loss Function)はRMSE(Root Mean Squared Error: 二乗平均偏差)、評価関数(Evaluation Function)は自由度修正済み決定係数式(3)を設定した。決定係数は、学習データに対する予測された回帰式の当てはまりの度合いを0から1で表現する。1に近いほど予測された回帰式がデータに当てはまっていることを示す。

図3-8より train データと valid データの学習曲線に差はなく overfitting は見られず汎化性能は高いことが読み取れる。併せて図3-9からも読み取れるように評価関数である決定係数 R^2 は目的変数に依らず0.99という高い精度を示した。これは、特徴量と予測値間には非線形性が存在するが、特徴量を入力とした構造解析から算定した値を教師データとしているため、構造解析の関係性を上手く機械学習が読み解けていると考えられる。

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - y_{pred_i})^2}{n - k - 1} \bigg/ \frac{\sum_{i=1}^n (y_i - y_{ave_i})^2}{n - 1} \quad (3)$$

ここで、

y : 目的変数 y_{pred} : 予測値 y_{ave} : 目的変数の平均値

n : 目的変数の数 k : 特徴量の数

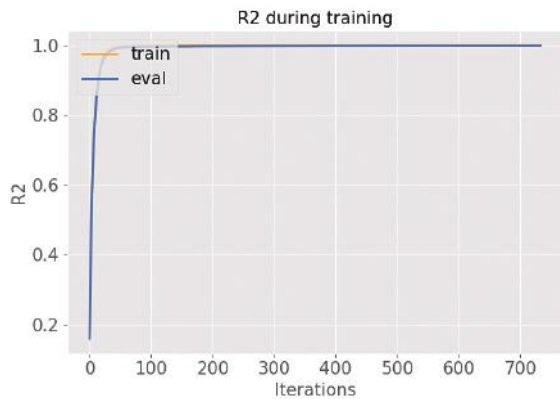


図3-8 総歪エネルギーに対する学習曲線(縦軸：決定係数, 横軸：学習回数)
Fig. 3-8 Learning curve for total strain energy (Vertical axis: Coefficient of determination, Horizontal axis: Number of learning)




図3-9 総歪エネルギーに対するテストデータと予測値の比較(縦軸：テストデータを構造解析した結果, 横軸：予測値)
Fig. 3-9 Comparison of test data and predicted values for total strain energy (Vertical axis: results of structural analysis of test data, horizontal axis: predicted values)

3-2. データの分析

架構形状や部材の最適化について、これまで多くの研究がなされているが最適化結果の理由を説明できていないケースが多々ありブラックボックス化している。ほとんどのユーザーはブラックボックスから算定している結果を理由もなく運用しているのが実情である。実務で用いる場合、設計者に対して結

果の理由を説明できない場合には、信頼を得にくい、かつ提供する側としても根拠を持って提案することができない。裏を返せば、結果について解釈性・説明性を把握できれば、信頼の獲得、積極的な提案、提案内容の付加価値向上等に期待することができる。

そこで本節では、機械学習を用いることで結果の解釈性・説明性を把握可能な手法について述べる。

3-2-1. モデルの解釈

作成した学習データと教師データを用いて、各特微量(架構形状生成のアルゴリズムを構築した際に組み込んだ変数)の重要度、予測値との関係性、予測理由が得られることで任意条件に適合する架構形状の選定やモデルの解釈性・説明性の把握³⁾が可能になる。具体的な手法として、まずモデルの解釈性が高い統計手法を用いた線形回帰を用いることが挙げられる。各特微量の回帰係数の大きさや比較により重要度や予測値との関係性を評価できる。また、学習済みモデルにて回帰係数とインスタンスの特微量の値から式(4)を分解することで予測理由を解釈・説明することが可能となる。しかしながら、線形回帰は目的変数と特微量の関係を線形でモデリングしており、関係が非線形な場合には予測精度が低くなる。多項式回帰や特微量エンジニアリングにより非線形な関係を学習させることも可能であるが、解釈性が低下する。対して、複雑な関係を予測できるNeural Net系やTree Ensemble系は学習モデルがブラックボックスとなりモデルの解釈性が低い⁴⁾。

そこで、ブラックボックスモデルの高い予測精度を保ちながらモデルの振る舞いを解釈する手法としてPFI(Permutation Feature Importance)⁵⁾、PDP(Partial Dependence Plot)⁶⁾、LIME(local interpretable model-agnostic explanations)⁷⁾、Anchors⁸⁾、SHAP(Shapley Additive exPlanations)⁹⁾等が挙げられる。

ここでは、PFI、PDP、SHAPを用いて分析を行う。

$$f(x_1, x_2, x_3) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 \quad (4)$$

ここで、

x : 特微量 $i = \{1, 2, \dots, M\}$,

β : 回帰係数 $i = \{1, 2, \dots, M\}$

3-2-2. 特徴量の重要度算定

PFIあるいはSHAPを用いて各特徴量の重要度の算定を行う。重要度は、目的変数に対して各特徴量がどの程度寄与しているのかを相対的に示すためドメイン知識に照らし合わせながら調整することができる。Tree Ensemble系でも特徴量の重要度の算定が可能であるが、一般的にTree Ensemble系で得られた重要度は、人間の感覚とは一致していないように感じる場合があり、一貫性が満たされないことが文献¹⁰⁾により指摘されている。そのため、PFIやゲーム理論で用いられているSHAP値(ゲーム理論で使用される場合にはShapley値)を主に用いる方針とした。

PFIとは特徴量の値をシャッフルした時の予測誤差の増減率から重要度を算定する手法である。

学習済みモデルを f 、特徴量の行列を X 、目的変数を y 、損失関数を $E(y, f)$ 、全ての特徴量 $M = \{1, 2, \dots, M\}$ とすると、

- 1) 特徴量の行列 X の特徴量 M を並べ替えて特徴量の行列 X_M を算定
 - 2) 並べ替えた後の損失関数 $E(y, f(X_M))$ を算定
 - 3) $PFI_M = E(y, f(X_M)) / E(y, f(X))$
- 1)~3)よりPFIを算定することができる。

SHAP値とは、ある予測値に対する各特徴量の貢献度を示す。式(5)にSHAP値の算定式を示す。第1項が特徴量の組み合わせの出現のし易さ、第2項が S にプレイヤー j (特徴量 j) が参加したときの限界貢献度を示す。式(6)のようにSHAP値を全インスタンスに対して絶対値の平均をとることでSHAPにて特徴量の重要度を算定することができる。図3-10にモデルとの関係を示す。

$$\varphi_j = \sum_{S \in M \setminus \{j\}} \frac{|S|!(|M| - |S| - 1)!}{|M|!} \times (v(S \cup \{j\}) - v(S)) \quad (5)$$

$$I_{SHAP} = \frac{1}{N} \sum_{i=1}^N |\varphi_{i,j}| \quad (6)$$

ここで、
 M : 特徴量 $M = \{1, 2, \dots, M\}$, S : M からプレイヤー j (特徴量 j) を除いた組合せ
 $v(x)$: 予測値を表す関数, I_{SHAP} : SHAPから算定された重要度






図3-10 モデルとの関係
 Fig. 3-10 Relationship diagram with the model

図3-11(a)(b)に目的変数「総歪エネルギー」に対するLightGBMの学習済みモデルを関数として設定したPFI, SHAP値から算定した重要度を示す。Tree Ensemble系のLightGBMから算定した重要度については参考までにAppendix Aに記載する。これより、PFI, SHAP値から算定した重要度は、順位は多少前後するが、同様の重要度を示していることが分かる。また、*divide* や *type*, *depth*, *rise* といった架構の剛性に与える影響の大きい特徴量が、総歪エネルギーが特に重視している変数で



(a) PFIの重要度



(b) SHAPの重要度

図3-11 総歪エネルギーに対する各手法の重要度比較
 (縦軸：各特徴量, 横軸：各手法から算定された重要度)
 Fig. 3-11 Comparison of importance for total strain energy
 (Vertical axis: each feature, horizontal axis: importance calculated from each method)




図3-12 各特微量間の相関関係(相関係数)
 (縦軸：各特微量，横軸：各特微量)
 Fig. 3-12 Correlation between each feature (correlation coefficient)
 (Vertical axis: each feature, horizontal axis: each feature)

あることが読み取れ、ドメイン知識と照らしても乖離がない。よって、異なる手法から算定した重要度がほぼ一致していること、ドメイン知識との照らし合わせから本重要度の確からしさを判断できる。

ただ、特微量同士の相関係数を確認し、特微量同士で強い相関がある場合には、相対的な評価であるが故に重要度の食い合いが発生することがあるため、特微量を1つのグループにまとめる等を行うことが望ましい。図3-12は、縦軸横軸共に特微量とした場合の特微量間の相関関係を示す相関関係図である。ここでは、特微量間の相関係数は小さいためそのまま使用することとする。


3-2-3. 特微量と予測値の関係

各特微量が予測にどう影響しているのかを把握するためにPDPを用いて分析する。対象とする特微量のみを一定の範囲にて増減させた際の予測値の分布を確認することで、対象とした特微量と予測値の関係性を知ることができる。(式(7))この手法はどんな機械学習モデルに対しても有用であるため、ブラックボックスモデルでも高い精度を保ちながら特微量と予測値の関係を知ることができる。またPDPはあくまで各インスタンスの平均的な関係を示すことから、交互作用を持つ特微量かつインスタンス毎の異質性には気づくことはできない。交互作用やインスタンスの毎の異質性が考えられる場合にはICE(Individual Conditional Expectation)を用いることでPDPではうまく解釈できない振る舞いを


解釈できる。

図3-13(a)(b)に学習モデルをLightGBMとした目的変数「総歪エネルギー」に対してPDPで得られた各特微量と予測値の関係を示す。これから各特微量の値の増減により予測値がどのように推移するのかを把握することができる。例えば、図3-11にて重要度の高かった *depth*、*divide* とPDPとの関係を確認すると(a)の *depth* (デプス)との関係では、デプスが大きくなるほど総歪エネルギーは小さくなる傾向にあり、(b)の *divide* は本数や分割数が増えるにつれ総歪エネルギーは増加する傾向にあることが分かる。(Appendix B にその他の特微量とPDPとの関係を示す。)

また図3-13-2(a)~(c)に *depth* と *divide* の2つの特微量と各目的変数との関係を示す。本図は縦軸に *depth*、横軸に *divide* を配置し、等高線は各目



(a) depth 関係



(b) divide 関係

図3-13 総歪エネルギーに対するPDP(赤点線)およびICE(青線)と各特微量の関係
 (縦軸：総歪エネルギー，横軸：各特微量の変数値)
 Fig. 3-13 Relationship between PDP (red dotted line) and ICE (blue line) and feature values for total strain energy
 (Vertical axis: total strain energy, horizontal axis: variable value of each feature)




図3-13-2 各目的変数に対する depth, divide の特徴量と PDP 関係
(縦軸: depth, 横軸: divide, 等高線: PDP)

Fig. 3-13-2 depth, divide and PDP relationship for each objective variable
(Vertical axis: depth, horizontal axis: divide, contour line: PDP)

の変数の PDP を示す。(a) (b) の最大鉛直変位、総歪エネルギーと特徴量との関係から *depth* は大きく、*divide* は小さいほど最大鉛直変位は小さくなる傾向が読み取れる。(c) の総重量と特徴量との関係からは *depth* は小さく、*divide* も小さいほど総重量は小さくなる傾向と読み取れる。ここから、*divide* は目的変数に対して小さい値の方が有利に働き、*depth* に関しては目的変数に依ってよし悪しが変わることから予測値やその他条件から選択することが望ましい。

$$f_s(x_s) = \frac{1}{N} \sum_{i=1}^N f(x_s, X_{Ci}) \quad (7)$$

ここで、

f : 学習済みモデル, x_s : ターゲットとする特徴量, X_C : x_s 以外の特徴量


3-2-4. 学習モデルの予測値解釈

機械学習モデルの予測値を算出する理由を解釈するために SHAP を用いて分析を行う。ドメイン知識との比較が行い易いように図3-14に目的変数「最大鉛直変位」に対するあるインスタンスの SHAP 値(式(5))と特徴量毎の貢献度の関係を例に示す。縦軸に各特徴量、横軸に SHAP 値(この場合、鉛直変位)を示す。本図はインスタンス毎の予測値と全インスタンスの最大鉛直変位の予測平均値(式(6)) 173.4mm の差分を特徴量毎の貢献度に分解したものである。これにより、平均値に対して選択したインスタンスの予測値の大小を確認すると共に、どの

特徴量が平均値に対して予測値の増減に貢献しているかを定量的かつ視覚的(赤: 平均より鉛直変位を大きくしている要素, 青: 平均より鉛直変位を小さくしている要素)に把握することができる。


図3-14(a)のインスタンスは式(5)から求まる SHAP 値は219.4mm で予測平均値173.4mm よりも最大鉛直変位が約45mm 大きい値となっており、特徴量毎の貢献度を確認すると *depth* や *rise* の特徴量が平均値に対して計60mm 程度大きくしていることが読み取れる。*depth* と *rise* は全学習データの中で最も小さい組み合わせであり、ドメイン知識と照らしても最大鉛直変位は大きくなると予測できる。図3-14(b)は(a)と比較し、*rise* が大きいインスタンスであり、式(5)から求まる SHAP 値は156.2mm で予測平均値173.4mm よりも最大鉛直変位が約17mm 小さい値となっている。特徴量毎の貢献度を確認すると *rise* の特徴量が平均値に対して40mm 程度小さくしていることが読み取れる。これによりインスタンス毎に何故このような値を予測しているのかを説明することができた。

図3-14はインスタンス毎に特徴量の貢献度を示しており、全インスタンスの貢献度の分布を可視化したものを図3-15(a)~(c)に示す。縦軸に各特徴量、横軸にインスタンス毎の予測値と全インスタンスの最大鉛直変位の予測平均値との差分を示す。本図は要素の色が赤いほど特徴量の値が大きく、青いほど小さいことを示している。また、特徴量毎の線幅が広い部分は要素の頻度が高いことを示している。



(a) インスタンス1

(radius : 25000, divide : 4, divide2 : 6, rise : 6000, depth : 4000, type : 1)



(b) インスタンス1833

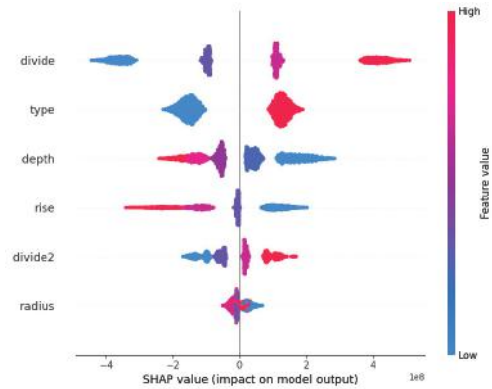
(radius : 25000, divide : 5, divide2 : 8, rise : 10000, depth : 4000, type : 1)

図3-14 インスタンス毎の SHAP 値と貢献度の関係 (縦軸: 各特徴量, 横軸: SHAP 値(鉛直変位))
Fig. 3-14 Relationship between SHAP value and contribution for each instance (Vertical axis: each feature, horizontal axis: SHAP value (vertical displacement))

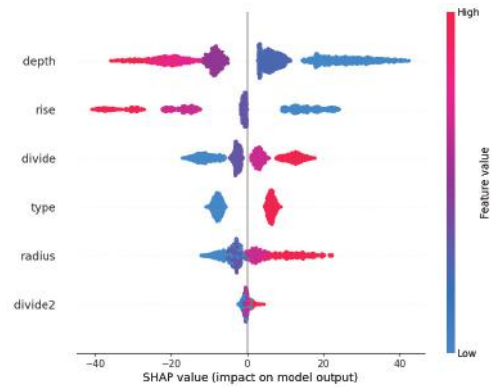
図3-15(b)の目的変数「最大鉛直変位」では, *depth* や *rise* が大きいほど最大鉛直変位は小さくなり, *divide* や *radius* が大きいほど最大鉛直変位が大きくなる傾向があることが読み取れる。その他目的変数も同様に分析を行うことで予測の理由をマクロ的に把握することが可能となる。

3-3. データの選択・運用方法


図3-16は各特徴量および各目的変数の数分縦軸を生成・並列させ, あるインスタンスの各特徴量, 各目的変数の値を並列した各縦軸の値にプロットし結んでいくことで多次元の定量データを1本の線として表示することができる。図3-16に示すように, 構成する線1本1本が各架構形状データを示しており,



(a) 総歪エネルギー



(b) 最大鉛直変位 (mm)



(c) 総重量 (kN)

図3-15 SHAP 値と各特徴量の関係 (縦軸: 各特徴量, 横軸: 各インスタンスの予測値と全インスタンスの予測平均値との差分)
Fig. 3-15 Relationship between SHAP values and each feature value (Vertical axis: each feature, horizontal axis: SHAP value (impact on model output))

条件を満たしているデータのみ表示させることで分かり易い表現が可能となる。そのため, グラフ上で直接値の範囲を絞れるようにインタラクティブな構成をし, データをフィルタリングすることを可能とした。また, フィルタリングした範囲で, 任意に選

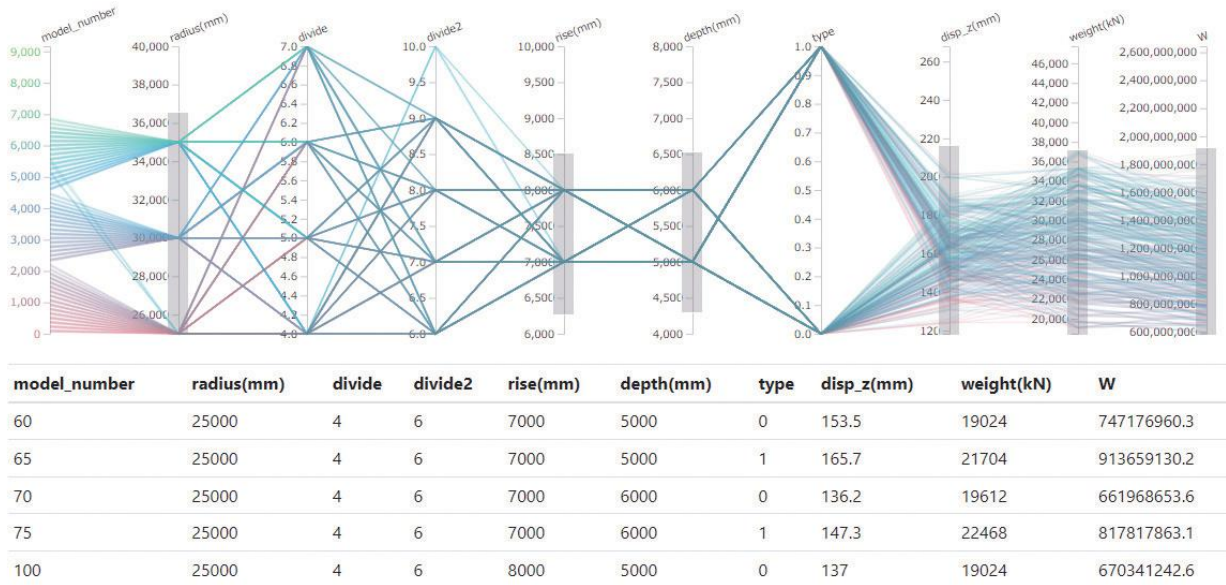


図3-16 多次元グラフ
Fig. 3-16 Parallel Coordinates graph

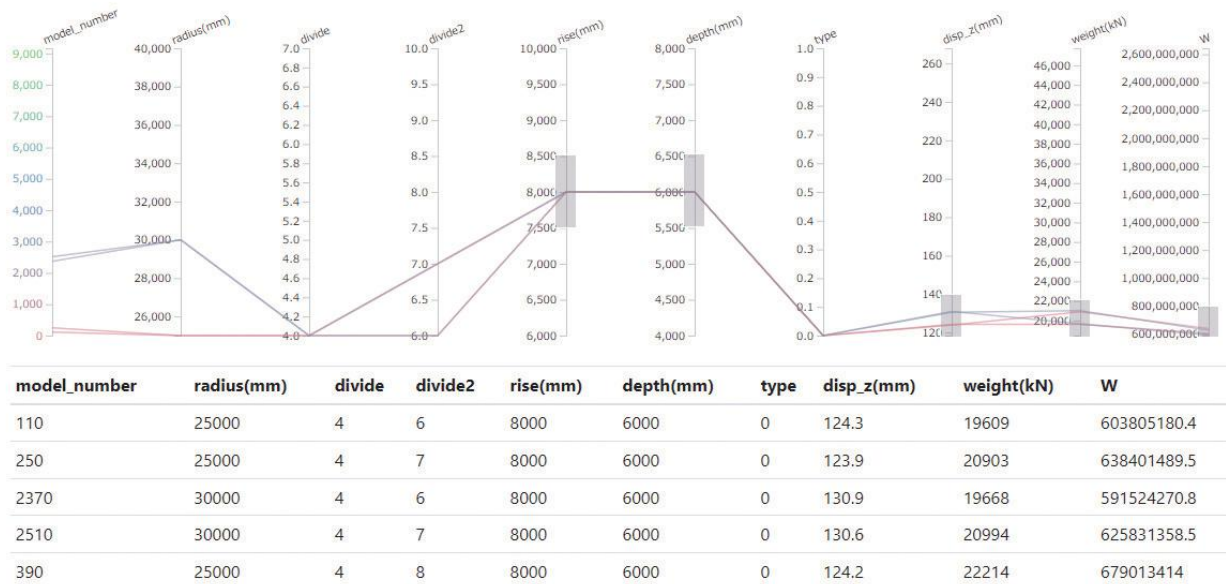


図3-17 多次元グラフ(実案件適用例)
Fig. 3-17 Parallel Coordinates graph(Example of the actual project)

択した目的変数中の結果が良いインスタンス5つを表形式で表示するようにした。これにより、任意の条件を満たす形状の探索が容易になった。

本案件では、3-2節より *rise* や *depth* は変数値が大きいほど最大鉛直変位や総重量は小さくなる傾向があり、*divide* や *divide2*, *type* は変数値が小さいほど目的変数は小さくなる傾向が見られる。また、*radius* については、特に目的変数に対する顕著な影響は認められない。これらの結果と意匠的な

制約(今回は、ライズとデプスを合わせて14000mm以内かつ中央リングはなるべく小さくする制約を設定)から多次元グラフで結果を絞ると図3-17のようにインスタンス110(*radius* : 25000, *divide* : 4, *divide2* : 6, *rise* : 8000, *depth* : 6000, *type* : 0)が今回の制約条件内では最適な形状であると選択した。

これにより、意匠設計者の優先すべき項目(重量(コスト)>デザイン>耐震性能等)と照らし合わせ

ることで形状の合意形成を迅速に図ることができた。併せて、3-2節の分析から架構形状の特徴を定量的に説明することが可能となった。こうした分析により架構形状の選択や架構形状の解釈性・説明性だけでなく新たな構造システムの探索にも使用することが可能である。具体的には形状アルゴリズムの変数を多数用意しておくことで、重要度から変数の絞り込みを行い、効果的な特徴量の把握を行うことで構造合理性の高い形状の選択が可能となった。

図3-18に新たな構造システムを構築した実施例を示す。本例は、意匠・構造の制約条件が厳しく、従来の方法では成立しなかった案件であったが、本システムで分析を行うことで、成立する架構構成や効果的な変数の値を見出すことができ形状の採用に至った。

これらの分析はあくまで、設計者がこれまで見ていなかった設計の可能性や付加価値を拡張する支援として考えている。そのため、出た結果をそのまま運用するのではなく自らの経験則や工学的な判断と織り交ぜながら運用していくことが望ましい。特に因果関係としての解釈は、因果推論の視点から判断することが望ましい¹¹⁾。




図3-18 新構造システム(リングトラス構造)
Fig. 3-18 A new structural system(Teusion ring structure)

4 分析の環境構成

任意データの入力を行うことで3-2節の分析が可能なツールを作成した。学習モデルで構成される分析ツールは、提案された学習モデルを設計者が直接利用することが難しいため、Webアプリケーションに集約した¹²⁾。アプリケーション環境構成の全体像を図4-1に示す。構成は、IaaS(Infrastructure as a Service)の場合には、データベース、AP サー

バー(Gunicorn), Webサーバー(Nginx)をクラウドの仮想環境上で構築する方針とした。また簡易に構築したい場合には、PaaS(Platform as a Service)でも十分と思われる。しかし、データ数が多くなるにつれ学習済みモデルの容量も比例して大きくなるためPaaSの場合には容量の空きに注意が必要である。

図4-2にアプリケーションのフローを示す。基本フロントエンドはhtml/css, javascript, バックエンドをpythonで構築した。構成は、シンプルにフロントエンド上で学習データと教師データのデータセットを入力し、データベースとして機能させる。フロントエンド上でグラフを表示させる場合にリクエストすることで、バックエンド側で処理したグラフをフロントエンド側で表示させている。

これらより、案件毎に対応したアプリケーションを簡易に作成することができ、手持ちのデバイスか

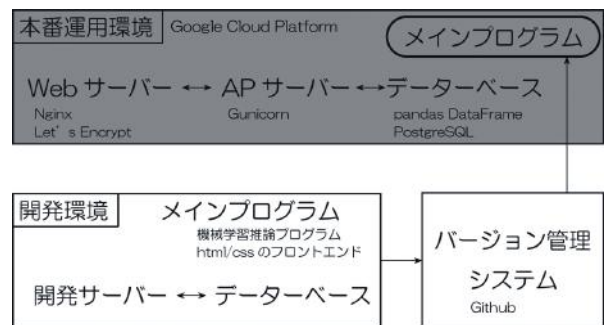


図4-1 運用環境構成
Fig. 4-1 Operational environment configuration

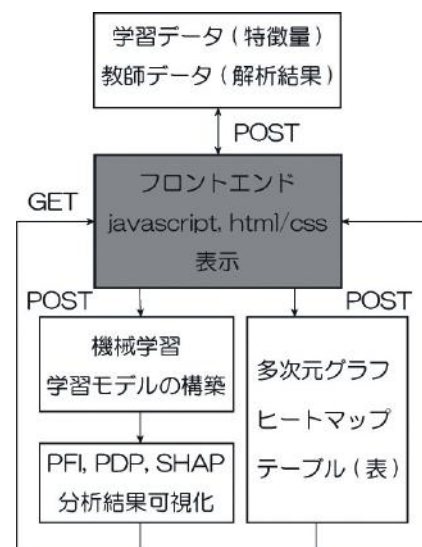


図4-2 アプリケーションの構成フロー
Fig. 4-2 Application Configuration Flow

らアクセスすることで場所に依らず、3-2節の分析をシミュレーションしながら説明することが可能となった。

5 結言

本論から得られた結論を以下に示す。

- 1) 設計プラットフォームでは、如何に情報を効率的に漏れなく伝達するかを考慮し設計した。その結果、シンプルな構成で、各アプリケーションとの変換や拡張性に配慮したものにでき、設計検討の効率化、設計内容の付加価値向上かつ製作・施工段階へのシームレスな情報移行が可能となった。
- 2) データ分析・運用については、これまで空間構造で扱うような複雑な架構形状に対しては経験則に基づいて検討を進めることが多かったが、機械学習を活用することで定量的に説明することが可能となった。併せて、考え得るパターンの架構形状を先にデータベース化しておくことで、設計進捗状況に応じて分析の材料として使用でき、意匠設計者の望む架構形状の構造性能や重量等を瞬時に提示することが可能となった。これらを実案件にて実施し、合意形成を円滑にできたことを実証した。

本論にて統合環境の構成要素について実施例を踏まえて論じ有用性を確認することができた。特に設計プラットフォームでは設計検討の効率化や情報移行だけでなく、各種検討の自動化による大量のデータ生成が可能になったことで、データ分析の技術を適用し設計付加価値の向上に繋げることができた。

データ分析に用いた機械学習等の技術は日進月歩であり、素早い実装および PoC (Proof of Concept) 等の開発におけるアジャイル型(図5-1)の取り組みが今後は非常に重要であると思う。ここで紹介した統合環境は、他分野への応用も十分可能である。また、構成要素である設計プラットフォームや分析手法、アプリケーションも完成形ではなく、日々使用しながら「建築家や現場が求めるもの」に対し、より良い提案ができるように適用範囲の拡大および進化させる所存である。

参考文献

- 1) 金田充弘, “デジタルデザインと空間構造設計の現状” 2016年度日本建築学会大会(九州)構造部門(シェル・空間構造)パネルディスカッション資料(pp20-29)
- 2) Takashi Miyazaki & Norihisa Kawamura. “Proposed Computational Design method for spatial steel structures—with engineering integration through design to production” In *IASS Annual Symposium 2019*
- 3) speakerdeck.com/dropout009/dgtalk5
- 4) Molnar Christoph (2019). “Interpretable Machine Learning. A Guide for Making Black Box Models Explainable.” <https://christophm.github.io/interpretable-ml-book/>
- 5) Aaron Fisher, Cynthia Rudin & Francesca Dominici (2019). “All Models are Wrong, but Many are Useful: Learning a Variable’s Importance by Studying an Entire Class of Prediction Models Simultaneously.” In *Journal of Machine Learning Research* 20(177), 1-81
- 6) Friwdman, Jerome H. “Greedy function approximation: a gradient boosting machine.” In *Annals of statistics* 2001 (pp. 1189-1232)
- 7) Ribeiro, M. T., Singh, S., & Guestrin, C. (2016, August). “Why should I trust you?: Explaining the predictions of any classifier.” In *Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining* (pp. 1135-1144). ACM
- 8) Ribeiro, M. T., Singh, S., & Guestrin, C. (2018, April). “Anchors: High-precision model-agnostic explanations.” In *Thirty-Second AAAI Conference on Artificial Intelligence*. (pp. 1527-1535)
- 9) Lundberg, S. M., & Lee, S. I. (2017). “A unified approach to interpreting model predictions.” In *Advances in Neural Information Processing Systems* (pp. 4765-4774)
- 10) Scott M. Lundberg, Gabriel G. Erion, and Su-In Lee (2019). “Consistent Individualized Feature Attribution for Tree Ensembles”
- 11) 安井翔太, 効果検証入門～正しい比較のための因果推論/計量経済学の基礎, 技術評論社(2019)
- 12) Tomoki Asai, Yuki Terazawa, Takashi Miyazaki, Pao-Chun Lin & Toru Takeuchi “First mode damping ratio oriented optimal design procedure for damped outrigger systems with additional linear viscous dampers” In *Engineering Structures* 247(2021)113229 <https://doi.org/10.1016/j.engstruct.2021.113229>




図5-1 アジャイル開発
Fig. 5-1 Agile development

Appendix

Appendix A

LightGBM で重要度を算定する場合には、各特徴量で不純度(ジニ不純度あるいはエントロピー)をどれだけ改善できたかという指標式(1)(2)で評価できる。付図A-1に総歪エネルギーに対するLightGBMから算定した重要度を示す。


$$G(k) = \sum_{i=1}^n p(i) \times (1 - p(i)) \quad (1)$$

$$I(j) = \sum_{i=1}^{n \in F(j)} (N_p(i) \times G_p(i) - (N_l(i) \times G_l(i) \times N_r(i) \times G_r(i))) \quad (2)$$

ここで、

$G(k)$: あるノード k におけるジニ不純度 n : ターゲットラベルの数 $p(i)$: あるノード k におけるターゲットラベル i の頻度

$I(j)$: ある特徴量 i における重要度 $F(j)$: ある特徴量 (j) が分割対象となるノードの集合 $N_p(i)$: あるノード i におけるサンプル数 $N_l(i)$: あるノード i の子ノードの内左側のノードのサンプル数 $N_r(i)$: あるノード i の子ノードの内右側のノードのサンプル数 $G_p(i)$: あるノード i におけるジニ不純度 $G_l(i)$: あるノード i の子ノードの内左側のノードにおけるジニ不純度 $G_r(i)$: あるノード i の子ノードの内右側のノードにおけるジニ不純度



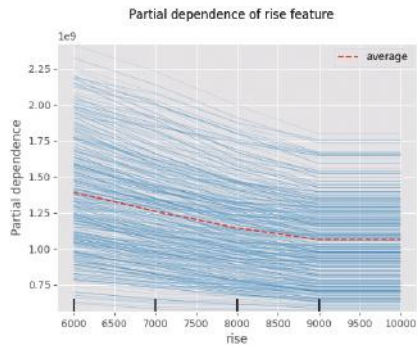
付図A-1 総歪エネルギーに対するLightGBMの重要度 (縦軸: 各特徴量, 横軸: 各手法から算定された重要度)
Appendix Fig.A-1 Importance of LightGBM for total strain energy
(Vertical axis: each feature, horizontal axis: importance)

図3-11(a)(b)のPFI, SHAP値から算定した重要度と比較すると重要度の順番は同様であるが、重要視している特徴量の重要度比率が大きく異なっている。


Appendix B

付図B-1に学習モデルをLightGBMとした目的変数「総歪エネルギー」に対してPDPで得られた各特徴量と予測値の関係を示す。(a)のrise(ライズ)との関係からは9000mmまでは増加するにつれ単調に総歪エネルギーは減少しているが、以降は横ばいであることが分かる。(b)のdivide2は本数や分割数が増えるにつれ総歪エネルギーは増加する傾向にある。また(c)のradius(中央リングの半径)はほぼ横ばいで総歪エネルギーに与える影響はないことが分かる。(d)のtypeは0か1の2通りであるが、1の繋ぎ材の斜材が有る方が総歪エネルギーは増加する傾向にある。


本編では、図3-13-2のように縦軸と横軸に特徴量、等高線でPDPを表現した2次元図となっているが、PDPと特徴量の関係が複雑な場合には等高線が見づらくなることもある。そこで、付図B-2のようにX, Y軸(横軸)に特徴量、Z軸(縦軸)にPDPとした3次元図とすることで視覚的に理解がし易くなる場合もあるため、用途に応じて可視化方法を変えることが望ましい。




(a) rise 関係



(b) divide2関係




(c) radius 関係

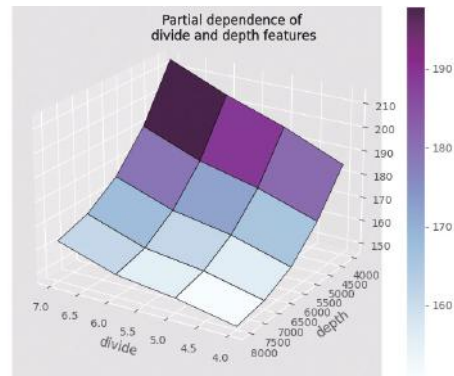


(c) radius 関係

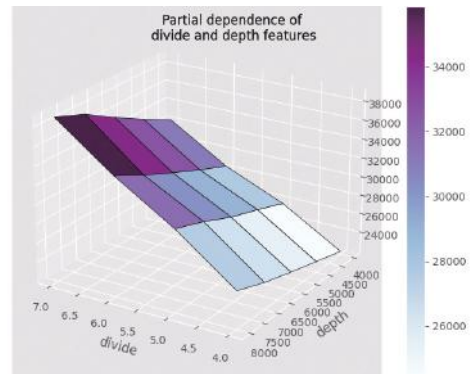
付図 B-1 総歪エネルギーに対する PDP (赤点線) および ICE (青線) と各特徴量の関係 (縦軸: 総歪エネルギー, 横軸: 各特徴量の変数値)
 Appendix Fig.B-1 Relationship between PDP (red dotted line) and ICE (blue line) and feature values for total strain energy
 (Vertical axis: total strain energy, horizontal axis: variable value of each feature)



(a) 総歪エネルギー関係



(b) 最大鉛直変位関係



(c) 総重量関係

付図 B-2 各目的変数に対する depth, divide の特徴量と PDP 関係
 (X 軸: depth, Y 軸: divide, Z 軸: PDP)
 Appendix Fig.B-2 depth, divide and PDP relationship for each objective variable
 (X axis: depth, Y axis: divide, Z axis: PDP)