

特集：DX/AIの活用

04

メカニズム解明を支援する AI 技術の基盤創発と実践

Creation and Practice of AI Technology to Support Mechanism Clarification

目良 貢^{*1} 足立 崇勝^{*2} 本田 正徳^{*3}
Mitsugu Mera Takamasa Adachi Masanori Honda
小平 剛央^{*4} 釘持 寛正^{*5} 近藤 俊樹^{*6}
Takehisa Kohira Hiromasa Kemmotsu Toshiki Kondo

要 約

機械・人・社会に関わる多様な大規模データに対し、メカニズム解明を支援して価値創出や効率化の促進につなげるための分析基盤となる AI 技術・プロセスの確立を目指している。本稿では、人が理解しやすい処理・可視化とともに重要な特徴・関係性を積極的に抽出できるよう構築した、幾つかの独自の AI 技術とその適用事例について報告する。

Abstract

For a wide variety of large-scale data related to machines, people, and society, we are aiming to establish AI technologies and processes that will serve as an analysis platform to support mechanism clarification and promote value creation and efficiency. In this paper, we report on some of our own AI technologies that we have developed and applied to actively extract important features and relationships, along with processing and visualization that are easy for humans to understand.

Key words : Vehicle development, Large-scale data, Artificial intelligence, Machine learning, Bayesian network, Random forest, Sparse modeling, Visualization

1. はじめに

近年、社会全体で AI (人工知能)・機械学習に対する注目が集まり、あらゆる商品・サービスの領域で、多様なデータから潜在価値を抽出してビジネスに活かそうとする動きが活発化している。自動車業界では、カーボンニュートラル実現に向けて、自動車の軽量化などによる燃費性能向上を通じた CO₂ 削減が求められている。一方で、顧客ニーズの多様化に対応し、構造・制御・安全性・快適性などに関わる他の性能も満たすよう、個々のシステムは一層複雑化している。それらを結集し、商品としての性能向上に資する開発の効率化が重要となっている。そのため、自動車の開発においては、実機試作を極力削減して効率的に開発する「モデルベース開発」⁽¹⁾ が重視されている。一方で、モデルベース開発やデジタル化が進むにつれ、機械・人・社会に関わる種々の場面で、多量・多次元・非線形性といった複雑さを伴う大規模データが生み出される。実際、多点で同時に計測したデー

タ、シミュレーション結果のデータ、カメラ映像のデータなど複数存在する。このようなデータを無駄にせず、競争力の確保に向け、複雑な現象の理解を促して設計やメカニズム解明を支援できる AI 技術の重要性が増している。

これまでマツダでは、車体構造に関わる設計因子と性能との間をデータに基づいて近似する予測モデル化(応答曲面法)の活用を進めてきた。そして、衝突や車体剛性などシミュレーションで定量化される対象の性能を満たしながら軽量化構造を探索する車体構造最適化(Multidisciplinary Design Optimization)技術⁽²⁾を AI 技術の一環として開発した。更にそれを拡張し、デザインや製造方法などの要件も踏まえて設計者が構造を検討できるよう、最適仕様の結果だけでなく性能に対する設計因子の影響度を定量的に示し、軽量化と性能のトレードオフ関係を可視化する設計支援技術⁽³⁾も開発した。上記の技術は、複数の仕様がデータのサンプルとして蓄積された下で、車体構造の設計支援を目的として効果を発揮する。

一方で、現象に対するメカニズム解明支援の目的にお

*1~6 技術研究所
Technical Research Center

いては、特定の限られた仕様において出現する動的・力学的な特性を詳細に分析し、直接観測できない潜在的な事象に関わる知識を獲得することに対応可能なAI技術が求められる。より具体的には、例えば自動車の空力・衝突・NVHなどの車両性能に関連付いている多点の時刻歴や周波数の波形をはじめとした連続値からなるデータを基に、因子同士の関係性（カラクリ）や未知の因子を推察する手掛かりを導くことが必要となる。それらを促すためには、予測モデル化する機能だけでは十分でなく、因子同士の関係性を構造的に可視化できること、また、構造化された関係性に従って強弱を可視化できることが求められる。更に、未知の因子の存在可能性を考慮し、現象に対する深い洞察や改善策を得るために、情報量が豊富な画像を直接対象として特徴的な部位を可視化することも求められる。これらを代表的な機能としてカバーできるAI技術・プロセスの手の内化はメカニズム解明を加速する上で極めて重要である。

そこで、マツダでは創発すべきAI技術の基盤として、単に予測することに留まらず、Fig. 1の特に緑の枠内に示すとおり、予測の根拠がセットで得られる説明可能性（ホワイトボックス性）の確保に軸足を置くコンセプトを掲げた。これに従い、データに潜む特徴や関係性の抽出に寄与する幾つかの独自のAI技術を構築した。具体的には、向きをもつネットワーク構造として因子間の支配的な依存関係を推定・可視化するグラフ構造化分析技術⁽⁴⁾、因子の連鎖的な構造に対応した関係性の強弱を定量的に可視化する連鎖的ランダムフォレスト因子構造分析技術^(5,6)、画像に基づき設計指針導出のための重要な部位を理解しやすく可視化するスパースモデリング技術⁽⁷⁾を構築した。本稿では、上記の技術の概要を適用事例と合せて報告する。

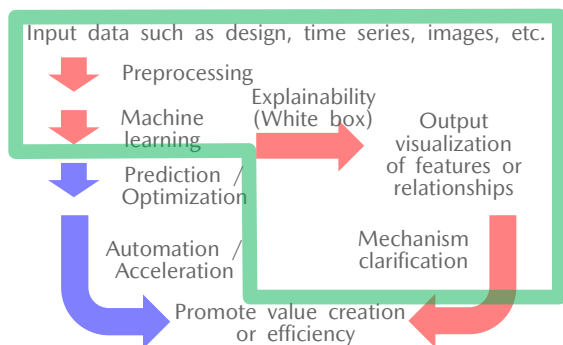


Fig. 1 Our AI Technology Concept to Support Mechanism Clarification

2. グラフ構造化分析技術

2.1 技術の概要

本節では、構築したAI技術（教師なし機械学習技術）の一つ「グラフ構造化分析」（Graph Structured Analysis）⁽⁴⁾について概要を述べる。詳細な数式を含めた記述は文献⁽⁴⁾を参照されたい。

本技術は、離散値をもつ複数の変数（ノード）間に潜む支配的な依存関係（向きをもつエッジ）を確率的な親子関係のネットワーク構造（グラフ構造）として学習する「ベイジアンネットワーク」の一般的な方法論を拡張する。より詳細には、時系列データをはじめとした連続値をもつ変数の場合においても応用できるように拡張することを含み、幾つかの独自の処理を定式化して織り込んだ技術である。具体的には、Fig. 2のフローチャートに示すとおり、プリ処理、メイン処理、ポスト処理の3つのプロセスから構成される。プリ処理では元のデータを多水準系の離散値にカテゴリ化する処理を、メイン処理ではネットワーク構造全体をBDeu (Bayesian Dirichlet equivalence uniform) と呼ばれる確からしさを表すスコアの最大化に基づき推定する処理を、ポスト処理では着目したい変数（子ノード）に向かって辿り着く因子（親ノード）の階層構造を過不足なく自動抽出する処理を、それぞれ実現する。これらのプロセスを通し、特に時系列データを対象とした時、従来のベイジアンネットワークのみでは支援できない、時間に関する知識発見を支援し、時間の概念が明示的に与えられていなくてもそれらを部分的に内包するような依存関係を推定・可視化する独特の効果を発揮する技術となっている。

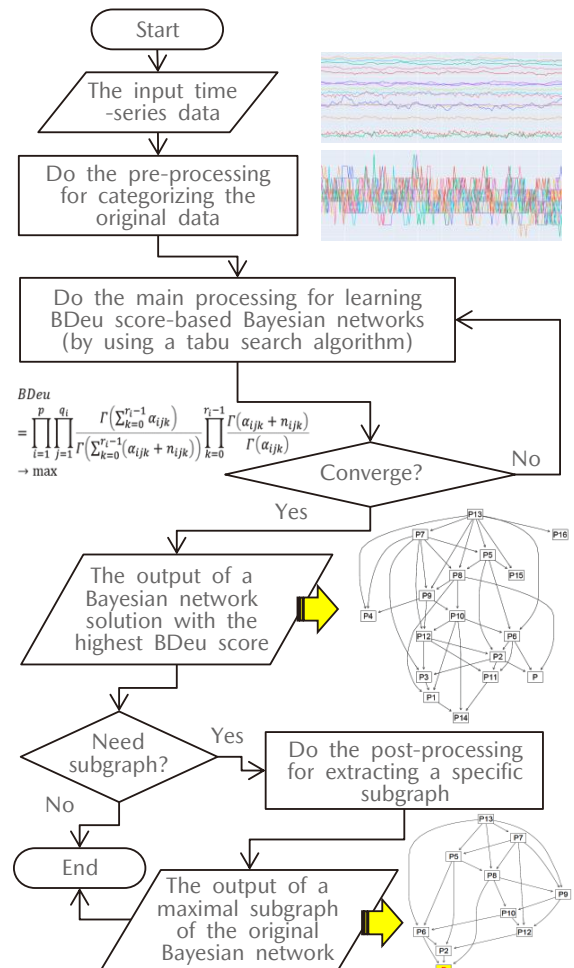


Fig. 2 The Flowchart of “Graph Structured Analysis”, A Kind of Unsupervised Machine Learning

2.2 適用事例

本節では、自動車の空力性能を評価する風洞実験で得られる、車体表面圧力の多点同時計測（時系列長：5750、計測点数：70）に基づく時系列データを題材に、グラフ構造化分析を適用した事例を述べる。

各計測点と幾つかの時系列データの概観を Fig. 3⁽⁴⁾ に示す。車両周りの空気の流れ場においては、先行研究を通して空気抵抗に影響する重要な渦の知見が知られており、それを踏まえて構成された計測車両には二つの仕様がある。一つは、空気抵抗が大きい複雑な流れ場（トランクデッキ上の流れがボディサイドからの流れの影響を受ける三次元的流れ）をもつベース仕様車である。もう一つは、ベース仕様車における流れ改善対策により空気抵抗が小さくなる比較的シンプルな流れ場（トランクデッキ上の流れがルーフからの流れに沿った二次元的流れ）をもつ空力改善仕様車である。ここでは、これら二つの仕様に対応する非線形性の強い流れ場で得られた時系列データを基に、グラフ構造化分析を適用して多点間での支配的な依存関係を構造化し、古典的な相関分析などではとらえることが難しい“向き”を見出すとともに、各仕様と整合する傾向が示唆されるかどうかを検証した。




Fig. 3 Measurement Points (Nodes) of Aerodynamic Pressure Fluctuations on the Car Body Surface and Some Images of their Time Series Data⁽⁴⁾




Fig. 4 Results of Analyzing and Visualizing the Relationships among Nodes⁽⁴⁾

結果を Fig. 4⁽⁴⁾ に示す。共通の傾向として、ボディサイドの前方から後方へと向かう関係性が見られ、時間の概念を内包するような自然な流れの方向が示唆された。差異の傾向として、ベース仕様車ではボディサイドか

ら背面へと向かう関係性（薄い紫の最も太い矢印）や、背面から床下へと向かう関係性（薄い紫の少し太い矢印）が見られ、複雑な流れ場が示唆された。一方で、空力改善仕様車ではそれらが全く見られず、ベース仕様車と比べてシンプルな流れ場が示唆された。このように、恣意的な方向付けがなくても妥当な傾向が示唆されることを検証できた。また、時間に関する知識発見だけでなく、依存関係を表す一部のエッジ（例えば、背面における上段と中段の間のエッジのうち、中段から上段へと逆向きに向かうもの）の本数の割合に着目する発想に至ることができた。これにより、流れ改善対策の効果を計測車両の時系列データのみから直接定量化する表現を獲得し、本事例では約 2 倍の改善効果があったと評価できた。

3. 連鎖的ランダムフォレスト因子構造分析技術

3.1 技術の概要

本節では、構築した AI 技術（教師あり機械学習技術）の一つ「連鎖的ランダムフォレスト因子構造分析」（Chained Random Forest Factor Structure Analysis）^(5,6) について概要を述べる。詳細な数式を含めた記述は文献⁽⁵⁾を参照されたい。

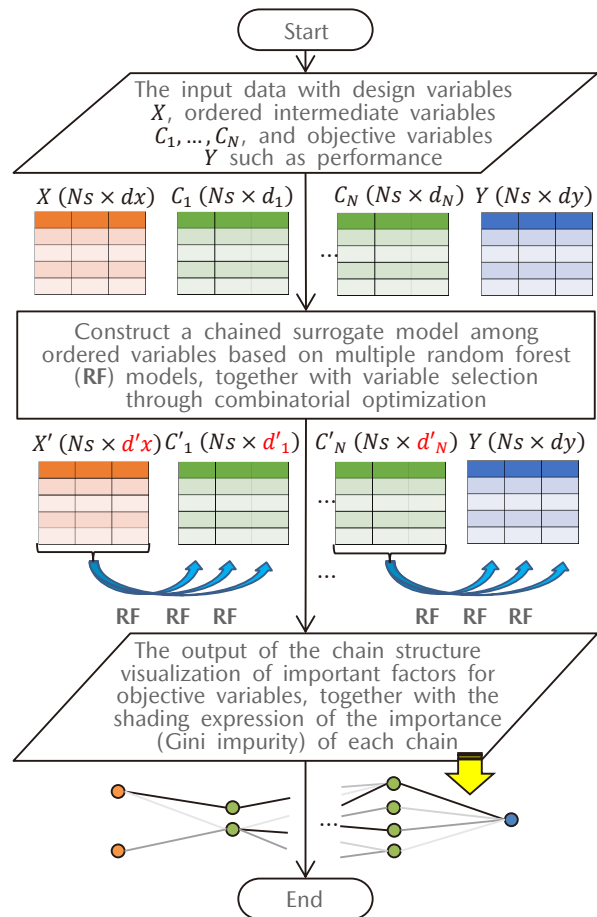


Fig. 5 The Flowchart of “Chained Random Forest Factor Structure Analysis”, A Kind of Supervised Machine Learning

本技術は、設計変数（入力）と目的変数（出力）のデータを一つの関数で直接結び付けて近似する基本的なサロゲートモデル（代理モデル）の方法論を拡張する。より詳細には、入出力の変数の間に位置する中間変数が出現順序を含めて別途定義される場合、それらを無視せず扱い、複数のサロゲートモデル構築とともに各変数間の重要な連鎖構造を表現しようとする技術である。具体的には、Fig. 5のフローチャートに示すとおり、設計変数・中間変数・目的変数が順序付きで与えられた前提の下で、目的変数から設計変数へと順序を遡って複数のランダムフォレストに基づくサロゲートモデルを逐次的に構築する独自のプロセスを実現する。その際、変数の個数が膨大でも対応できるよう、組合せ最適化に基づく変数選択も可能にしている。これらを通し、目的変数にとって重要な因子のみに絞り込まれた形で関係性の連鎖構造が出力され、因子の重要度（ジニ不純度）を関係性の強弱として扱って閾値とともに濃淡表現に反映して可視化できる技術となっている。

3.2 適用事例

本節では、自動車のロードノイズ性能を対象として、周波数応答解析に基づくデータセット（サンプル数： $N_s=211$ ，構成因子数： $dx=28$ ， $d_1=d_2=23625$ ， $dy=225$ ）を題材に、連鎖的ランダムフォレスト因子構造分析を適用した事例を述べる。ただし、設計変数 X ($N_s \times dx$)，中間変数 C_1 ($N_s \times d_1$)，中間変数 C_2 ($N_s \times d_2$)，目的変数 Y ($N_s \times dy$) はそれぞれ、ボディー主要骨格部品やフロントサスペンションクロスメンバーを含む部品板厚、P/I（ポイントイナータンス：加振点応答特性を表す）、A/F（振動伝達特性を表す）、SPL（Sound Pressure Level：乗員耳位置での騒音音圧レベルを表す）とする。




Fig. 6 Evaluation Points for P/I and A/F⁽⁶⁾

題材とした計 $N_s=211$ 組のサンプルからなるデータの詳細として、設計変数 X においては、0.5~2.9mmの範囲内で3水準系の値をもつ部品板厚に基づく、計 $dx=28$ 個の構成因子からなるデータを用いた。中間変数 C_1 ， C_2 においては、Fig. 6⁽⁶⁾の赤色のドットで示した共通の105個の評価点から得られるP/I，A/Fをそれぞれ指定の下、何れも各点において2~450Hzの範囲内で2Hz刻みに取得した225個分の値を全て横並びにした、計 $d_1=d_2=23625$ 個の構成因子からなるデータを用いた。目的変数 Y においては、2~450Hzの範囲内で2Hz刻みに取得したSPLの値に基づく、計 $dy=225$ 個の構成因子からなる

データを用いた。また、変数選択の過程では、P/I，A/Fともに $d_1=d_2=23625$ 個から $d'_1=d'_2=150$ 個に絞り込み、部品板厚は変更なしの $d'_x=28$ 個とした。これらに対し、連鎖的ランダムフォレスト因子構造分析を適用し、指定した中間変数とその順序に沿った確からしい連鎖構造を導けるかどうかを検証した。

結果を Fig. 7⁽⁶⁾ に示す。連鎖構造として現れたP/I，A/Fの各因子について、各評価点名を青色、赤色、緑色のテキストで示している。また、それらに対応する実際の評価点の位置をドットの色を統一して Fig. 8⁽⁶⁾ に示す。部品や評価点の位置が互いに近いものが線で接続されていることから、確からしい連鎖構造が可視化されていると判断できた。また、特に重要度が高い連鎖構造として、薄い赤色の太線でハイライトしたとおり、カウルの板厚~フロントウィンドウP/I~フロントヘッダーA/F~100HzのSPLが可視化されている。従って、例えば、カウル板厚を増大させることで、フロントウィンドウ下部やダッシュロアパネル部のP/Iが増大し、また、フロントウィンドウ部、トップシーリング部、フロントヘッダー部のA/Fが増大もしくは減少することで、乗員耳位置のSPLが低減する、という解釈に基づくメカニズムの仮説立案につながった。ここでは割愛するが、文献(6)の中で、上記仮説は実際にカウル板厚を変更して周波数応答解析を追加で行った結果とともに妥当性も検証できた。

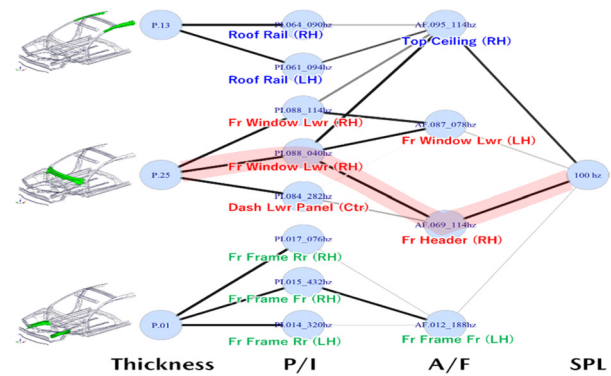


Fig. 7 Chain Structure of Important Factors⁽⁶⁾




Fig. 8 Evaluation Points Appearing in Fig. 7⁽⁶⁾

4. スパースモデリング技術

4.1 技術の概要

本節では、構築したAI技術（教師あり機械学習技術）の一つ「スパースモデリング」(Sparse Modeling)⁽⁷⁾ に

ついて概要を述べる。詳細な数式を含めた記述は文献(7)を参照されたい。

本技術の背景となる方法論においては、一般的なアプローチである「正則化法」を採用している。すなわち、通常の線形回帰モデルをデータに基づき推定することにおいて、サンプル数よりも変数の個数が多い（つまり、解が一意的に求まらない連立方程式を解く必要がある）場合でもモデルの係数の解を求められるよう、係数の大きさに制約を課した条件下で推定するというアプローチを採用している。制約を課す代表的な方法は二つある。一つは、全ての係数の二乗和を課す「Ridge 回帰」と呼ばれる方法である。もう一つは、全ての係数の絶対値の和を課す「Lasso 回帰」と呼ばれる方法である。更に、これら二つの制約のバランスを $(1-\alpha):\alpha$ に配分する $0 \leq \alpha \leq 1$ のパラメータ α を与えて調整する方法もあり、これは「Elastic net 回帰」と呼ばれる。 $\alpha=0$ の時は Ridge 回帰に、 $\alpha=1$ の時は Lasso 回帰にそれぞれ相当し、 α は「Elastic net 混合比率パラメータ」と呼ばれる。特に、 $\alpha=1$ の Lasso 回帰の場合には、本質的に必要な変数だけを取捨選択、つまり、不要な係数を完全に「0」とする特性が最大発揮されることになる。

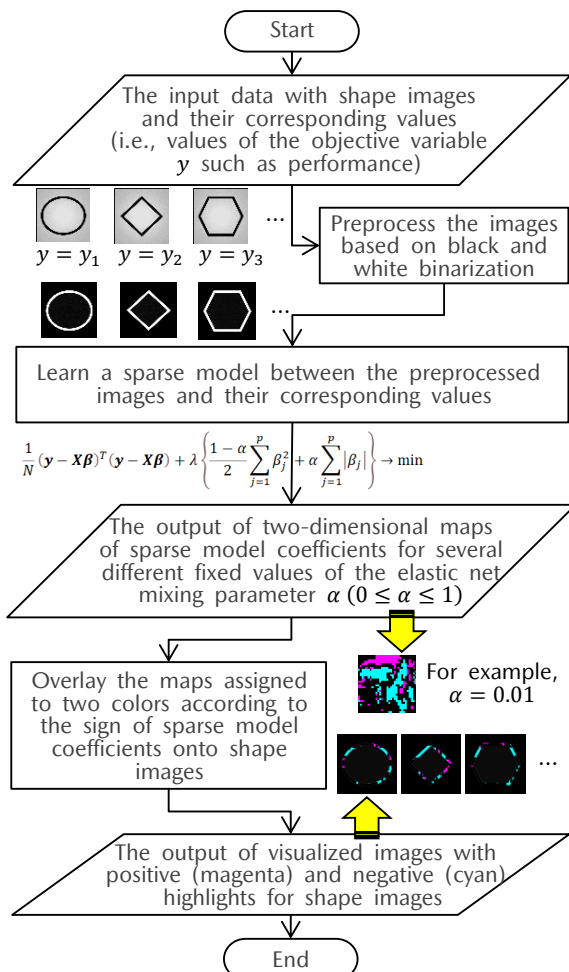


Fig. 9 The Flowchart of “Sparse Modeling”, A Kind of Supervised Machine Learning

本技術は上記を踏まえ、例えば構造物の形状設計において、設計者が想定できていない未知の因子の存在可能性を考慮し、新しい設計指針導出につなげることを支援できるような独自の可視化プロセスを実現する。具体的には、Fig. 9 のフローチャートに示すとおり、情報量が豊富な形状画像データを直接対象とし、それらを二値化処理した上で全ての画素値を説明変数として扱う。そして、Elastic net 混合比率パラメータ α を幾つかの異なる値に固定した下で、目的変数に当たる性能を推定し、偏回帰係数の値を獲得する。それらを正負の符号に基づく二色（正：マゼンタ、負：シアン）の二次元マップとしてシンプルにハイライトしながら元の形状画像の上に重ね合わせる。これらのプロセスを通し、形状画像を基にその重要部位を性能向上に対する正または負の効果の可能性と合せて直感的に理解しやすく可視化できる技術となっている。

4.2 適用事例

本節では、自動車の車体フレームの断面形状を表す画像における全画素（説明変数）の値と、それらに対応する有限要素法で取得したフレーム質量当たりの曲げ強度質量効率（目的変数）の値を組合せたデータセット（サンプル数：1041、画素数：64×64=4096）を題材に、スパースモデリングを適用した事例を述べる。







Fig. 10 Evaluation Model of the Bending Stiffness of the Frame⁽⁷⁾

フレームの曲げ強度は Fig. 10⁽⁷⁾ に示すような 3 点曲げの非線形有限要素解析に基づく結果を市販ソフトウェア LS-DYNA を用いて算出し、それを単位質量当たりに換算した曲げ強度の質量効率を目的変数として設定した。また、形状画像（説明変数）の設定としては、Fig. 11⁽⁷⁾ に示すようなフレームの断面形状の各候補において、何れも $x=0$ で線対称であるため右半分のみに絞った。その上で、重要部位が明瞭に可視化されるように断面線に 3 画素以上の太さを持たせた。更に、断面線の部分が材料配置箇所を表すため白（正の画素値）に割り当てられるよう白黒の二値化を施した。これらの設定に対し、Elastic net 混合比率パラメータ α を例えば 3 条件 $\alpha \in \{0.01, 0.1, 1.0\}$ で固定してスパースモデリングを適用し、重要部位の結果を可視化し、薄板座屈理論や主成分分析を通じた従来までの先行研究の知見（縦板に関わる高さ・角度・形状変化点・圧子側の形状などの観点）と照らして妥当性をもつかどうかを検証した。

Fig. 11 Pre-Processing of Cross-Sectional Images⁽⁷⁾

各画素に対して得られる係数を二次元マップとして可視化した結果を Fig. 12⁽⁷⁾ に示す。係数の正負はその領域に材料を配置すべきか否かに対応する。何れの図からも、曲げ強度の質量効率を高めるためには、上板形状の中央部分 A は低く、端部 B は高くすること、また、縦板形状の上部 C は垂直とし、下端部 D も広げすぎない形状が有効であると示唆された。一方で、上面中央部 E を高くすること、縦面上部 C を断面中央側に寄せること、断面下端部 F を広げすぎないことは、何れも質量効率を低下させる可能性が高いことが示唆された。以上の結果から、先行研究の知見と照らして妥当性をもつことが検証できた。

更に、質量効率の比較的高い形状の代表的な集団に対して、Fig. 12 の (c) のマップと重なる部位をハイライトした例を Fig. 13⁽⁷⁾ に示す。ここでは割愛するが、文献(7)の中で、質量効率の比較的低い形状でも同様にハイライトしている。これらの結果から、上板 a の断面高さを確保することで曲げ剛性を高めるとともに面内圧縮座屈を抑制すること、右上部部 b を直角形状とすることで曲げ荷重に対して縦板の面内力を発揮させること、縦板上側 c の形状変化点を断面内側に寄せることで断面変形を抑制することが示唆された。これらを通して、上板、縦板の薄板座屈を効果的に抑制して曲げ強度を高められると解釈できた。一方で、縦板下端部 d を内側に配置することで質量を小さくし質量効率を高めるといふ、従来にはなかった設計指針の発想も得られた。

Fig. 12 Visualization Results of Critical Areas⁽⁷⁾Fig. 13 Visualization Results of Critical Areas (High Performance Clusters)⁽⁷⁾

5. おわりに

本報告では、メカニズム解明を支援するコンセプトの下、独自の AI 技術として構築したグラフ構造化分析、連鎖的ランダムフォレスト因子構造分析、スパースモデリングについて、概要と適用事例を報告した。グラフ構造化分析では、空力に関する時系列データを題材に流れ場の理解を深める上で時間の概念を内包するような依存関係の知識発見や改善効果の定量化の支援ができることを述べた。連鎖的ランダムフォレスト因子構造分析では、ロードノイズに関わる順序付けされたデータを題材に中間状態や膨大な個数からなる変数を見逃さず扱った上で重要な連鎖構造へと縮約して仮説立案の支援ができることを述べた。スパースモデリングでは、車体フレームの形状画像と質量効率のデータを題材に重要部位の可視化を通して設計指針につなげる支援ができることを述べた。今回扱っているデータは車（機械）を対象としているが、今後は、適用領域の拡大を通して人や社会に直接関わるデータも扱うことや、データの種類の問わず効果的な支援につなげられる AI 技術の更なる基盤創発に取り組んでいく。

参考文献

- (1) 脇谷伸ほか：自動車エンジニアを対象としたモデルベース開発 (MBD) 基礎研修の実践と評価, 工学教育, Vol.66, No.1, pp.60-66 (2018)
- (2) 小平剛央ほか：複数性能を扱う車体構造最適化手法の開発, [マツダ技報, No.29, pp.104-109 \(2011\)](#)
- (3) 鈿持寛正ほか：自動車車体構造の設計支援技術の開発, [マツダ技報, No.36, pp.272-276 \(2019\)](#)
- (4) 目良貢ほか：時系列データを解析するためのベイジアンネットワークの活用法に関する研究, 日本応用数理学会論文誌, Vol.31, No.2, pp.76-104 (2021)
- (5) 足立崇勝ほか：機械学習を用いたロードノイズ予測手法およびメカニズム解明支援技術の開発, 自動車

技術会学術講演会予稿集 (秋), No.108-21,
20216123, pp.1-6 (2021)

- (6) 足立崇勝ほか：機械学習を用いたロードノイズ予測
手法およびメカニズム解明支援技術の開発，自動車
技術，Vol.76, No.10, pp.74-80 (2022)
- (7) 本田正徳ほか：スパースモデリングを用いた構造物
の設計形状における重要部位の抽出手法に関する研
究，日本機械学会論文集，Vol.88, No.905, p.21-
00289 (2022)

■著者■



目良 貢



足立 崇勝



本田 正徳



小平 剛央



釘持 寛正



近藤 俊樹