

3 次元形状への AI の取り組み

Initiatives of AI for Three-dimensional Geometry

三 村 崇 晃

要 約 画像や言語モデルに対する AI が隆盛している一方、学習の対象に 3 次元の形状データを扱った事例は広く知られていない。3 次元データの利活用促進が活発な複数の業務領域において、点群の深層学習の適用範囲と有効性を実証した。設計製造フィーチャの認識では、CAD の面形状から生成した点群データの学習で自動認識が可能になる。類似形状検索は非 AI の技術がソリューションとして有効でありつつも、全体形状検索において点群 AI による特徴量が匹敵する性能を持っており、非構造データへの注目すべき AI の適性を示唆している。歯科臨床では、点群 AI によるランドマーク点の推定という新手法を開発し実用化を進めている。

Abstract While AI for images and language models highly develops, practices of learning of three-dimensional geometric data are not well common. In several business domains in which utilization of three-dimensional data is actively promoted, we showed the effectiveness and applicable region of deep learning for point clouds. In recognizing manufacturing design features, learning of point clouds data generated from CAD shapes enables automatic recognition. In similar shape search, whereas non-AI technologies provide the effective solution, our research has showed that the feature generated by the point cloud AI for global shape search yielded comparable result, which implies the suitability of AI to non-structured data is remarkable. In clinical dentistry, we developed a new AI-assisted method for estimation of landmark points and have been pushing forward the implementation.

1. は じ め に

BIPROGY 株式会社およびグループ会社（以降、BIPROGY および BIPROGY グループ）では長年にわたり製造業向けエンジニアリングソリューションの開発に取り組んでいる。人手不足を背景に DX や AI による生産性向上が社会課題としてうたわれる中、生産工程のみならず、設計工程までの全体最適化を視野に入れた技術開発は重要である。エンジニアリングプロセスにおいて製品の形状は非常に多くの要素を左右するものでありながら、設計者の判断材料の中でも特に情報の抽出が難しく活用が進んでいないデータ源となっている。

AI が 2010 年代から注目を浴びるようになったきっかけが深層学習技術の躍進である。機械学習のアプローチが浸透しつつあり、IT に期待される事柄や関心は大きく変化した。データ駆動の課題解決にはデータ基盤の整備が不可欠である。しかし形状データは CAD のデータとして保持され、コアなデータのフォーマットは CAD ベンダーによって異なるため、ユーザにとって利活用のシナリオ想像が難しい領域となっている。本稿では 3 次元形状の深層学習技術を取りあげ、いくつかの検討事例を紹介する。

本稿は序章と終章を含む 6 章構成である。2 章では導入として AI の活用ターゲットを例示

する。3章では注目している3次元データにおけるAIとして点群の深層学習について述べる。4章で設計製造における形状検索、5章で医療分野におけるランドマーク推定について述べる。

2. 設計へのAI適用検討

AIを活用するにはまずどのような場面に適用するか検討することが重要である。本章では金型設計への検討例を簡単に紹介する。

設計工程のデジタル化では、標準化と自動化をテーマとして、さまざまな場面で設計/加工データ作成をAIで支援する機能が期待されている。蓄積されたデータ資産からノウハウを抽出して、経験の浅い設計者に技能を継承していくことが経営上の課題となっている。こうした背景を踏まえて、どのような機能に需要が見込まれるかを検討し具体化したプランを表1に示す。この分析では形状認識や類似形状検索を中核の要素技術として想定している。製品に対して特定の形状部位があるかどうかという情報が設計者の意思決定に深く関わっており、部分形状の認識ができるかどうかでAI設計支援が果たす役割は大きく異なる。

表1 要求分析

雛型・型費の見積もり	製品の形状から過去の類似の設計事例を参照した見積もりの自動判断
加工工程組の自動決定	類似の形状にひもづく工程組の割り当て、部位の標準手順の割り当て
自動モデリング	形状の修正すべき箇所を自動検出して修復する
自動部品配置	製品の特徴的な加工部位に応じた最適な部品の自動配置

3. 点群の深層学習

本章では、点群の深層学習による3次元形状の認識技術について述べる。

3.1 点群の深層学習

点群とは3次元データを点の集合で表すデータ形式である。3次元形状のデータ表現はさまざまな形式があるが、点群の構造は非常に単純で、3次元座標(x, y, z)の数値を任意の数並べたデータである。表現力は低いものの単純さゆえに低コストで得られるため、物体を計測したデータとしてはよく用いられる。点の座標だけでなく、法線という情報を付加したデータを処理することも多い。法線とは形状面に定義される情報であり、面上の点での面の外向きを表す単位ベクトルである。

機械学習ではデータから物事を推論する数理モデルを作成する。扱うデータの形式が違えばモデルの特徴も異なる。AIで扱う3次元データの種類として、点群の他にボクセルやメッシュがよく研究されている。2次元データ、すなわち画像に対する深層学習が非常に発展していることから、3次元の物体を多視点からの画像や深度の画像にして適用する手法も有効である。点群特有のメリットとして、ホワイトノイズにより座標値の摂動を加えるデータの水増しができる。これは計測による誤差や数値誤差を加味でき、モデルの安定性が向上する。機械学習は推定であるので、ロバストな推定ができるモデルは強みとなる。一方で、点群は点の順番が空間的な位置関係とは無関係に与えられる。深層学習の基本のモデルの一つ、畳み込みニューラルネットワークでは、画像の規則的な空間配置であるグリッド構造を利用して、畳み込みと

プーリングによって局所的な特徴を階層的に捉える手法をとる。点群ではこれと異なるアプローチが求められた。ブレイクスルーとなった点群の深層学習が、Standford 大学の研究チームから発表された PointNet^[1]である。点群のデータの順番の不定性に対応するアイデアとして点群全体のプーリングによって全体特徴量を抽出する。後発の研究では、このモデルをベースに局所的な構造を抽出する手法が数々考案されている。

3.2 形状認識の検証

深層学習モデルは論文によって性能、特に与えられたタスクの解決度合いが実証されているものが数多くある。公開されたデータセットに対するベンチマークとして論文は非常に参考になるものの、独自のデータに適用する場合にはタスクの解決に十分な精度が得られるか、検証を要する。本節では、設計 CAD データへの適用を意識して、点群の深層学習による形状認識の検証実験について紹介する。

CAD によるモデリングでは、部品種によらず頻出する操作がある。これをフィーチャという。設計データの形状はモデリングという形状操作の結果によって創成され、一般に複数の面から構成される。面の創成に使用されたフィーチャを、各面の属性としてデータに付与することがある。フィーチャは CAD ソフトウェアに特異な属性であり、流通の過程でデータを変換すると失われる情報である。形状からフィーチャ属性を推定できれば、属性の復元や設計の再利用の際に参考になる。本節のテーマとして、操作後の面の形状のみからフィーチャ属性の自動認識を試みる。フィーチャは径や寸法のパラメータを持つが、定量的な情報は測定によって得られるため推定の対象とせず、フィーチャ種類の推定を目的とする。

設計 CAD データでは形状の面を B-Rep に代表される曲面が表現可能なデータ形式で扱うものの、データ構造としては扱いにくい。単純なデータ形式で処理できることには実用的な価値がある。曲面を点群によって表現すると、曲がり具合の情報は失われるものの、密度が高ければ元の面の情報を一定程度保つことができる。深層学習においては学習で獲得できる情報量が大きく、形状情報を失っても認識というタスクにおいては不利にならないと仮定した。認識性能は深層学習のモデルの設計以外にも、学習するデータセットに依存するため、独自に用意したデータで検証することが肝要である。

検証にあたりデータセットとしてトイモデルを準備した(図1)。直方体をベースの形状に何種類かのフィーチャ操作をランダムな回数・パラメータで実行し、すべてのデータを自動生成した。作成したデータセットは、表面に点群を一様にサンプリングすることで、点群データに変換した。1データの点群の点数は10,000点とし、各点に法線情報を付加した。設計データの面に付与されたフィーチャ属性を各点にラベルとして転写した。ラベルは穴やボス、フィレットの凹凸、無属性の5種類とした。点群データセットはトレーニング用3,383個とテスト用383個を使用し、トレーニング用データのラベルを推定するよう学習した。深層学習モデルには PointNet++^[2]を利用した。学習したモデルにテスト用データを用いてラベルを推定させ、推定が一致した点の割合(適合率)を評価した結果、平均して99%という推定結果を得た。さらに点群に詳細な幾何的計量の情報を付加することで、推定の精度がより高まることを確認している。

つづいての検証として、実データに対する評価を行った。はじめにトイモデルから学習したモデルでターゲットデータに対する推定を試みたが、フィーチャによって推定率にばらつきが

生じた。ターゲットデータには製品形状があり、意匠的な曲面形状があった。複雑な曲面形状は自動生成が困難で、データの量・質ともに確保が難しい。データセットを全自動生成する方針を捨て、意匠形状を含む少数の製品面のみデータを準備し、そのデータの一部をもとに部品に近い形状を生成するようにした。7種類の少数データから5,430個のデータを生成してトレーニングに使用した。トレーニング用とは異なるデータに対して定量的に評価したところ89%の点で推定が一致した。

推定した情報をCADオペレーターにとって分かりやすい形に提示するよう、点群から面に対する推定結果に変換して、元のCADデータにフィードバックする。面ごとに採取された点における推定フィーチャの多数決をとって面のラベルとすれば実現できる。推定ラベルを面の色として表示した。図2に加工用部品データに対する認識結果を面色で示す。製品の形状が局所的な曲面形状と区別されて認識しており、深層学習によってフィーチャが高い精度で復元された。




図1 トイモデルのデータ作成手順（上）と最終形状例（下）




図2 実部品データのフィーチャ認識

4. 形状検索

本章では形状の検索技術について述べる。

4.1 情報検索の概論

情報検索技術は AI の出現によりこの 10 年近くで目覚ましい進歩を遂げてきた。文書検索では自然言語解析の発展によって、キーワードによるマッチング検索を超えて、語句の意味合いの抽象的な数値表現を対象にできるようになった。深層学習の取り込みは Word2Vec から始まり、ChatGPT のように自然な対話ができるまでに表現力を獲得できている。AI で大量データを学習したモデルでは、類似のデータを数値的に近くなるようベクトル化する構造を持っている。この性質を利用して、ベクトルを索引の代用とし、ベクトル同士の「近さ」で語句や文章の類似性を判断することができる。こうした AI 組み込みの文書検索や類似画像検索サービスは一般的なものになりつつある。本節では AI ベースの検索^{*1}の性質について議論する。

AI ベースでの検索技術はデータドリブンである。大規模言語モデルのような汎用モデルが存在する領域を除いて、ユーザでデータセットを用意して学習したモデルを作成するケースが考えられる。学習モデルを構築するメリットとして、特定の業界や、社内のみに通じる用語や知識をモデルに反映することができる。モデルの学習はコストがかかり、頻繁な更新はシステムに高負荷がかかる。運用を想定したシナリオとしては、標準とするデータセットを定めて、特徴ベクトルの生成器としてモデルを学習し、モデルを一定期間固定する案が考えられる。検索対象データに対してベクトル埋め込みで特徴ベクトルを作り、これを検索対象データの追加・更新に合わせてインデックスとして管理する。モデルは標準データセットの見直しとともに定期的なスパンで再学習し、評価してデプロイする。更新したシステムが良くなっているかは定量的であれ定性的であれ評価が難しい。特に深層学習ではブラックボックスとなるため、更新前は似ていたケースが更新後は似ていないと判断される危機が起こる可能性があり、制御が難しい。後退を防ぐよう標準データの質の確保や検証の仕組みの整備が重要である。

また、AI をベースにした検索技術と比べて従来の検索技術が劣るとは言い難い。検索ロジックが人間の判断に似た結果を返すよう設計されていれば、既存ロジックの魅力は失われない。例えば、システム全体での利用シーンを考えると、古いドキュメントより最近できたドキュメントの方が参照されやすい傾向にある。また、特定の期間に作成されたデータを探したいという要求は常にある。検索とは複合的な尺度から総合して判断するものであり、データセットにはよらず決定論的なロジックやアルゴリズムで算出される基準は変わらず重要である。AI の新規性は画像、音声という非構造化データの類似性が基準の一要素として加わったことにある。実際の利用シーンでは既存ルールとのハイブリッドな検索が多く想定される。

形状も非構造化データの一つであり、形状検索というソリューションも同様な議論が展開できる。次節では従来技術も踏まえながら AI による形状データの特徴抽出の適用可能性について紹介する。

4.2 類似形状検索

2023 年、BIPROGY グループでは、金型設計向け CAD/CAM/CAE ソフトウェア「CAD-meister」の付属機能として類似形状検索機能をリリースした。BIPROGY グループは既存の形状検索技術を持っており、設計ノウハウの再利用を目的として、形状検索エンジン「エンジ

ニアリングサーチ」^[3]を提供していた。類似形状検索機能はその精神を引き継ぎながら、CAD ソフトウェアに直結することで、ハイエンド CAD に備わる形状処理技術や設計情報との高度な連携を図っている。

4.2.1 対象データ

類似形状検索では特定の種類の形状に特化した機能を提供する。製法によって設計者の関心が異なり、多種のニーズに合わせて技術開発するためである。2024 年現在、プレス金型で加工される部品を対象としている。プレス加工部品は薄い板を変形させた形状であり、設計データには板厚というパラメータを持たせて形状データ自体は厚みのないサーフェスとしてモデリングする。一般に知られている 3 次元 AI ではコンピュータビジョンへの応用に適した立体的なモデルを対象としていることとは対照的である。CAD データは形状が B-Rep 形式で定義されているものを扱う。

4.2.2 検索機能

形状指示は面で行い、検索は面を対象とする。範囲指示のオプションとして、全体検索と部分検索の機能を搭載している。全体検索では形状全体としての類似性を判断してスコアリングして並べ替える。部分検索では形状の一部を指示して検索データベースの中から指示箇所に類似した部分を探し出す。全体検索と部分検索では異なるロジックを採用している。

検索タイプによらず、直接形状を比較せず、特徴を抽出し高次元のベクトルとして情報を圧縮する。2024 年現在、特徴抽出手法には AI を用いない決定論的な従来型ロジックを採用している。

4.2.3 全体検索技術

全体検索の 3 次元特徴量抽出としては、点群ベースの特徴量を採用している。点群は形状表面から採取し、そこから計測した情報の統計を特徴量化した。点群の採取方法はプレス部品のような板形状でも立体と変わらず、表面から一様にサンプリングした。

形状全体の特徴量として、Point Feature Histogram^[4]および Viewpoint Feature Histogram^[5]をベースとしている。両方に共通して、2 点間の長さや法線との角度を測定した統計を特徴量として計算する。プレス部品には型抜き方向という設計上重要な座標軸があり、その方向に沿っての計量が重要な意味を成す。Viewpoint については計測するカメラの視点にあたるものの代用として、点群を主成分分析で型抜き方向が Z 軸となるよう回転させ、XYZ 軸のそれぞれの視線に沿った角度の統計量を測定した。

得た特徴ベクトルに対して、距離を測れば類似度が計算できる。類似度スコアが高いものを上位とするランキングを検索結果とした。

この検索方法では、点群 AI による特徴ベクトルでの代替が容易である。プレス部品に対して点群 AI を採用した場合との比較検証実験を実施した。データセットは A 社のプレス加工のパネルの部品で、12 種類 217 データからなる。それぞれの部品種においてベース部品を一つ選び、検索の実行結果を比較して、特徴量算出アルゴリズムによる差異を評価した。点群 AI の特徴量算出には PointNet の中間層をベクトルとして抽出している。ここで、PointNet は部品種を教師ラベルとした分類の学習を行い、データセットに適合するようにした。評価には二

つの尺度を用いた。一つは適合率である。結果の上位9種の内、検索した部品と同じ部品種のデータが占める割合で評価した。全種平均では点群AIと従来型特徴とで同等の割合だった。部品種別では12種中5種で従来型特徴が良く、4種で点群AI特徴量が良く、残り3種が同等の結果となり、部品種別によって得手不得手が分かれた。もう一つの尺度として、各種のベース部品に似ているデータを4位まで設計者が順位付けし、実際の結果とのmAP（適合率平均）を測った。従来型が0.71、点群AIが0.64となり、従来型の方が人間の評価に近い結果となることが分かった。点群AIは学習方法やデータの増量によって改善する可能性があるが、従来型のロジックでも一定の性能を得られると現時点では結論付けている。

4.2.4 部分検索技術

部分検索では形状の一部を指示して、登録された形状データの中から類似の部分を探し出す。検索用途によって興味のある一部の切り取り方は異なるが、表面形状の曲面的なパターンを重視している。部品の各所に設計意図が込められているため、特定のパターンに限定しない。部分検索は、全体検索と同じく、姿勢や位置によらず類似性を判断することが期待される。違いとしては、特徴的な領域を発見し抽出するところである。特徴量指示される領域が不定であるため、全体検索に比べて探索空間が膨大になり、技術的難度は高い。3次元のまま形状を処理すると計算コストが高く、データを2次元の画像に変換し画像処理によって類似性を判断する手法を有力視している。

部分検索ではプレス加工部品の平面展開可能性に着目し、画像処理手法によって検索を行うべく、形状処理技術によって部品を平面に展開し、曲率から彩色した画像を作成する技術を開発した。CADmeisterの既存の展開機能は、材料の機械的性質からシミュレーションによる解析を行うものであった。今回開発した技術は形状のみから計算するため、板厚や材質の属性設定は不要であり、解析の知識なしに利用できる利点がある。

パネルを展開して得られた画像を図3に示す。平面形状は曲率0であり、グレーの中間色として表現している。濃い部分や薄い部分は曲率変化の大きい箇所を表し、白と黒はフィレット（稜線に丸みをつけた形状）によく表れている。元形状と画像の対応関係は分かりやすく、部品の構造が画像によく反映されている。




図3 パネル部品（左）の曲率展開画像（右）

画像特徴量技術を用いれば、局所的な特徴領域および画像特徴量を抽出できる。SIFT 画像特徴量技術^[6]は古典的だが、マッチング検出においてはいまだ有力なアルゴリズムである。特徴領域を代表する点は幾何的に検証することができ、どの部分にどのような向きでヒットしたかを明確に表せる。画像上でマッチング箇所が分かれば、3次元上に位置を引き戻して詳細に位置合わせすることも可能である。部分検索の類似度は、マッチング箇所を3次元的に検証して、その整合率から判断している。

4.3 今後の展望

形状の全体検索には前節で紹介した手法以外にもさまざまな手法が考案されている。検索結果の良し悪しは検索の状況や主観に左右され、一概にどの手法が優れているとは言い難い。ユースケースに応じて適した手法を選択できるよう拡張していく予定である。また、ユーザ期待値が既知であれば、ユーザの選好に合わせるよう順位を学習する Learning to Rank の手法により直接結果を改善することもできる。

部分検索については技術的な課題がある。位置合わせによる評価は発想として理解を得やすい一方で、ユーザの意図する類似パターンはその範疇に収まらないケースが多い。誤検出を防ぐために整合性の検査を厳しくすることで、一致する形状の検索には一定の効果がある一方、類似の検索が柔軟にできなくなる欠点がある。画像特徴量の抽出とマッチングに AI を適用する方法を一案として検討中で、画像の局所特徴量を教師なし学習する技術^[7]に注目している。他に、画像のアプローチとは異なった切り口による柔軟な検索を検討している。

また、対象データの拡大として、樹脂成型品への検討を進めている。

5. ランドマーク推定

BIPROGY は「産学連携・クロスイノベーションイニシアティブ」^[8]に参画している。これは、健康医療分野のオープンイノベーションの創造を目的に大阪大学大学院医学系研究科および医学部附属病院が設立した組織である。歯科臨床では3次元医療データを使って診療の質を高める取り組みがなされており、事例として CT 画像から作成した3次元モデルで骨の変形の度合いを評価している。相同性を評価するには計測データ上の特定位置の情報をランドマークとして同定するが、専門家による解剖学の知見が欠かせない。68 点のランドマークの同定には 30 分ほどの時間がかかり、3次元による定量的な評価を日常の診療に導入する際の課題となっていた。作業を補助するため、X 線 CT から取得された上顎骨・下顎骨データに対して AI により自動的にランドマーク（特徴点）を求める手法を研究した。本技術を用いて、平均的な形態との偏差を3次元的に視覚化すれば、医師の的確な診断に寄与できる。

ランドマーク推定の素となるデータは3次元の CT 画像から生成したポリゴンである。上顎骨・下顎骨は非常に複雑な形状であり、形状処理的な特徴検出のロジックでは認識し難い。またポリゴンのスキヤナの読み取り品質のばらつきが処理に与える影響も無視できない。点群に変換すると、形状の詳細は失われるもののポリゴンの品質の影響は緩和され、その情報の損失は深層学習ならば補える精度で認識できることが期待される。

紹介するランドマーク推定の手法の流れを図4に示す。点群はポリゴンの表面を成す三角形のフェイス上から、面積あたり一様にサンプリングして作成した。モデルは PointNet++ をベースに構築した。PointNet++ は識別モデルであり、大きくは特徴抽出層と分類層から構成され

る。特徴抽出層では 20,000 点の座標および法線を入力にとり、1,024 次元の特徴ベクトルを抽出するよう変更した。分類層は回帰用に改造し、3 段の全結合層によるニューラルネットワークを構築し、特徴ベクトルを入力としてランドマークの個数分の 3 次元座標を出力するよう設計した。損失関数には二乗誤差平均を用いて推論した。上顎骨と下顎骨それぞれにおいて上述のモデルで学習した。トレーニング用データとテスト用データは上顎骨に対してそれぞれ 139 個および 33 個、下顎骨に対して 152 個および 66 個を用いた。




図4 ランドマーク推定

ランドマーク点はポリゴンの表面にのる点であるのに対し、推定した点が面上にあるとは限らない。ポリゴン上に各ランドマークの最近点を射影し、補正したランドマーク推定点とした。人手で同定したランドマーク点とのユークリッド距離で平均誤差を評価した。補正前の推定点については上顎骨に対して 3.7(2.1)mm、下顎骨に対して 2.7(1.4)mm であり、補正した推定点についてはそれぞれ 3.2(2.2)mm、2.4(1.5)mm であった（カッコ内は標準偏差）。この結果は点群の深層学習による回帰モデル推論の有効性を示している。

学習したモデルはプラットフォームの影響を受けずに推論モデルとして利用できる。BIPROGY グループ提供のポリゴン編集ソフトウェア「POLYGONALmeister」に組み込み、ポリゴンメッシュと重ね合わせて 3D 上に推定したランドマークを表示する機能を提供している。本件は大阪大学との共同特許を取得している^{*2}。

6. お わ り に

本稿では、3次元形状データに対して AI を適用するアプローチとして、点群データへの深層学習 AI を基礎技術とする取り組みを議論した。産業用データに対する検証事例をあげ、有効性を示した。3次元 CAD データの形状検索技術を紹介し、AI の展望を議論した。実用の事

例として歯科臨床における AI をベースとしたランドマーク推定を紹介した。

本稿では形状の AI, その中でも点群の深層学習に焦点を絞った。扱ったモデルは深層学習の分野では古典的だが実績があるといってよい。本稿では取り扱わなかった Transformer モデルを点群 AI に対して適用したモデルが知られており、導入による改善を検討している。また、形状の特徴だけでなく、3D アノテーションをはじめとして他の情報と合わせたマルチモーダルな推論が実業務で重要である。3次元データに対しての研究は発展途上であり、大規模言語モデルに相当するような汎用のデータセットが公開されるにはまだ時間がかかるだろう。データおよびナレッジの蓄積が十分あれば AI を適用できる段階に移行しつつある。

-
- * 1 本稿執筆時点では AI ベースの検索については検討中である。
 - * 2 特許第 7895143 号, 2023 年 12 月 11 日「三次元ランドマーク自動認識を用いた人体の三次元表面形態評価方法及び三次元表面形態評価システム」, 国立大学法人大阪大学, BIPROGY 株式会社。

- 参考文献**
- [1] Charles R. Qi, Hao Su, Kaichun Mo, Leonidas J. Guibas, “Pointnet: Deep learning on point sets for 3d classification and segmentation”, In Proceedings of the IEEE conference on Computer Vision and Pattern Recognition, 2017.
 - [2] Charles R. Qi, Li Yi, Hao Su, Leonidas J. Guibas, “PointNet++: deep hierarchical feature learning on point sets in a metric space”, In Advances in Neural Information Processing Systems, 2017.
 - [3] 石橋 研二, 「形状の検索・分類の技術と類似形状検索エンジン “エンジニアリングサーチ”」, ユニシス技報, 日本ユニシス, Vol.32 No.4 通巻 115 号, 2013 年 3 月, P51 ~ 61
 - [4] Radu B. Rusu, Zoltan C. Marton, Nico Blodow, Michael Beetz, “Learning Informative Point Classes for the Acquisition of Object Model Maps”, In Proceedings of the 10th International Conference on Control, Automation, Robotics and Vision, 2008.
 - [5] Radu B. Rusu, Gary Bradski, Romain Thibaux, John Hsu, “Fast 3D Recognition and Pose Using the Viewpoint Feature Histogram”, In 2010 IEEE/RSJ International Conference on Intelligent Robots and Systems, 2010.
 - [6] David G. Lowe, “Distinctive Image Features from Scale-Invariant Keypoints”, International Journal of Computer Vision, Vol.60, No.2, 2004.11, P91-110.
 - [7] Jiaming Sun, Zehong Shen, Yuang Wang, Hujun Bao, Xiaowei Zhou, “LoFTR: Detector-Free Local Feature Matching with Transformer”, In Proceedings of the IEEE conference on computer vision and pattern recognition, 2021.
 - [8] 「産学連携・クロスイノベーションイニシアティブ」, 大阪大学大学院医学系研究科・医学部附属病院, <https://www.med.osaka-u.ac.jp/pub/xii/> (2024 年 7 月 22 日確認)

執筆者紹介 三 村 崇 晃 (Takaaki Mimura)

2016 年 日本ユニシス・エクセリューションズ株式会社 (現 UEL 株式会社) 入社。CAD/CAM/CAE ソフトウェアの開発に従事。

