外観検査の自動化に向けた AI 技術開発

Development of AI Technology for Automated Visual Inspection

加納正晃　M. KANO　マキシム・モレヨン　M. MOREILLON　荒井雄貴　Y. ARAI
中瀬晶詳　A. NAKASE　近藤永治　E. KONDO　山下雄也　Y. YAMASHITA　日比大貴　D. HIBI

Automated visual inspection requires accurate detection of tiny defects. However, deep learning-based image classification methods often struggle with low accuracy for small anomalies. To solve this problem, we propose a novel approach that integrates image partitioning with data cleansing based on defect locations. Our experimental results demonstrate that this method significantly improves classification accuracy, particularly for defects located near the center of an image. To facilitate practical deployment in manufacturing environments, we have developed an in-house, no-code platform for building and utilizing AI models. This report presents the key features of our platform and discusses its potential for widespread adoption in real production settings.

Key Words: visual inspection, image classification, image partitioning, software KARAKURI

1．はじめに

日本では少子高齢化の急速な進行によって 1995 年をピークに生産年齢人口が減少しており，製造業における人手不足の深刻化が懸念されている．この問題に対し，当社ではデジタルを活用したモノづくりの競争力強化を成長戦略の重点施策に掲げており，現場作業の省人・自動化を推進している．例えば，当社製品である自動車用ステアリングの検査工程で熟練作業者によるラック割れなどの欠陥（**図１**）の目視検査に対し，自動化を進めている．本検査は欠陥の検出に磁粉探傷法を採用しており，被検体を磁化し蛍光磁粉を塗布すると磁粉が欠陥の周囲に集まるため，**図２**に示すとおり欠陥の視認が可能となる[1)]．この欠陥の判断を検査員ではなく，ディープラーニングを用いた画像分類手法で実施した．現場作業の中でも特に検査工程は経験を積んだ検査員の感覚に依存する作業が多く，自動化によって属人化の防止だけでなく検査品質も安定する．

一般的にディープラーニングによる画像分類では画像全体の特徴量を用いる．しかし，微小な欠陥を見逃す場合があり，品質管理上の課題であった．そこで，本開発では画像分割と欠陥位置に応じたデータ選別方法を構築し，微小な欠陥の検出率を向上させた．本報の**第２章**で

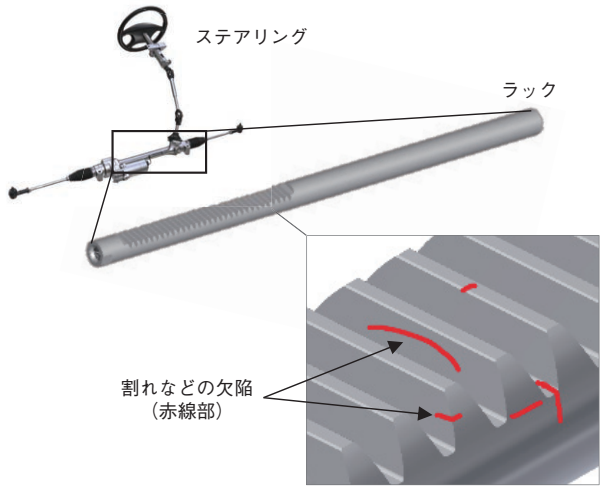

図１　ステアリングとラック
Steering and rack

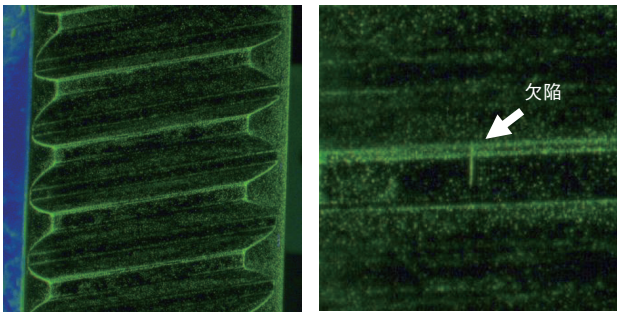

図２　ラックの磁粉探傷検査画像
Magnetic particle inspection image of rack (Left: Entire image with no defect/Right: Enlarged image of defect)

は本手法の内容と検証結果を述べる.

また，現場の要求を満たす手法を開発しても AI 判定モデルの適用にはプログラムの更新や再構築が必要となり，それを実施できるのは AI やソフトウェア開発に精通した人材に限られる．そこで，ノーコードで AI 判定モデルを構築・運用可能な AI 画像認識プラットフォームを内製し，提案手法を実装した．**第３章**ではこの AI 画像認識プラットフォームのコンセプトおよび機能を紹介する.

2．微小欠陥の検出精度向上[2)]

磁粉探傷検査では，画像の局所的な特徴の検出に適した CNN（Convolutional Neural Network）による画像分類手法を採用し，各画像を「欠陥あり」「欠陥なし」の 2class で分類した.

2.1　開発技術

2.1.1　画像分割による学習精度の向上

ラックの割れ検査では，最小幅 5 μm の欠陥の検出が必要である．磁粉探傷法の場合は付着した蛍光磁粉の発光により，50 μm 程度の幅として識別できる．そこで，本報では 29 mm × 28 mm のエリアの画像を画素数 1 080 × 1 050 の高解像度で取得した．これにより，1 画素が 30 μm 以下となり，最小幅の欠陥の検出が可能となった．欠陥サイズ（割れの長さ）と検出可否のヒストグラムを**図３**に示す．欠陥の多くは 150 ～ 400 画素のサイズに分布しており，100 画素以下のサイズは検出できない欠陥が多くなっていた.

この理由として，微小な欠陥は画像全体に占める面積が小さいため，CNN の GAP（Global Average Pooling）層の平均で欠陥を示す特徴も小さくなった可能性がある．そこで，画像をブロックに分割し，微小な欠陥が画像全体に占める面積を大きくして分類する方法を試した．また，後述する理由により各ブロックはオーバーラップさせて分割している（**図４**）．なお，分割後のブロックのサイズは縦 400 ×横 400 画素である.

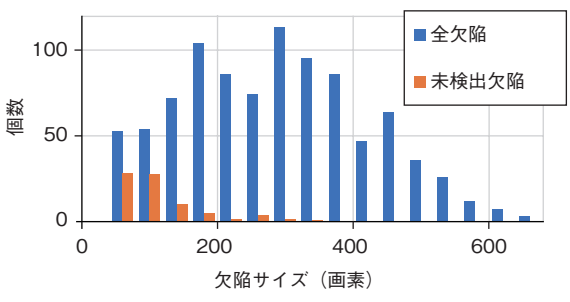

図３　欠陥サイズの個数分布
Defect size distribution

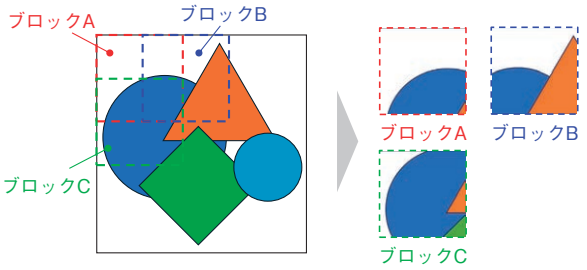

図４　画像分割
Image division

2.1.2　データ選別による学習精度の向上

CNN に学習させる画像は，欠陥の位置を各ピクセルにラベル付けするアノテーションを手作業で実施した後，ブロックに分割している．画像の数は汎化性能の向上，過学習の防止，ロバスト性向上などの理由から多いほうが望ましい．そのため，Data Augmentation（データ拡張）によって画像を増やしている．データ拡張には各種の方法を使っており，そのうちの一例を**図５**に示す.

ここで，ブロック画像の端部のみに欠陥がある場合，データ拡張で回転させた**図６**のように欠陥がブロック外となり，欠陥を含まない画像が生成される．したがって，アノテーションで分類された「欠陥あり」のラベルと相違が生じる．このようなラベルミスのあるデータを学習に使用すると分類性能が低下する可能性がある.

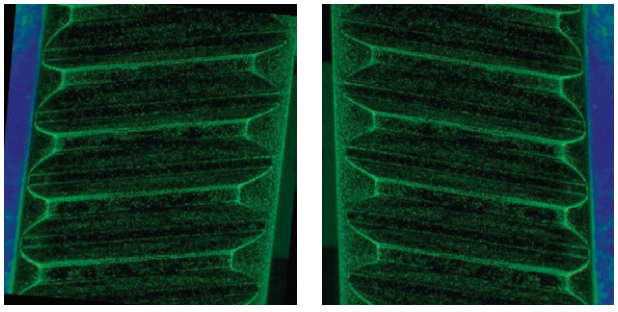

（a）回転画像　　（b）反転画像

図５　データ拡張画像の例
Data augmentation example

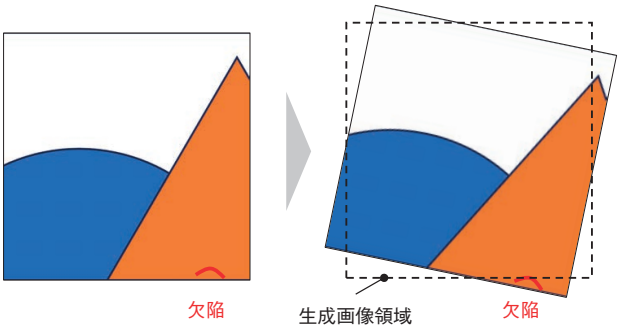

図6　回転による欠陥喪失
Loss of defects due to rotation

この問題を解決するため，画像分割後のブロック端のみに欠陥があるデータを自動で取り除き，ブロック中に存在する欠陥の位置を制限した．本報ではこの操作を欠陥位置制限とよぶ．

データを制限するときの問題は欠陥がブロック端のみに存在する学習データが減ることである．Isram らの研究によれば，CNN は分類時に画像の位置情報も利用している[3] ことが示されている．また，Biscione らの研究によれば，CNN は位置不変ではなく学習時に位置不変性を獲得する[4] ことが示されている．これらの研究結果から，ブロック端に欠陥がある学習データが少ない場合，CNN はブロック端を分類において重要でないと学習する可能性がある．

この対策として，オーバーラップさせた分割方法を導入した．すなわち，あるブロックの端部に存在する欠陥は，隣接ブロックでは中央付近に位置しているため，CNN がブロック端を重要でないと学習しても影響はなく，分類性能が低下しないと考えられる．

2.2　学習効果の検証

画像の分割，欠陥位置制限による学習効果を検証するため，**表1** に示す 3 種類の手法で欠陥検出性能を比較した．手法 B，C では 1 枚の画像を 16 ブロックに分割しているため，全ブロックで「欠陥なし」の場合のみ「欠陥なし」と判定し，それ以外の場合は「欠陥あり」と判定した．これにより，画素サイズの異なる手法 A と学習性能の比較が可能となる．

表1　画像ごとの分類結果算出方法
Method to derive results for each image

手法	学習用画像の条件			欠陥有無の判定	
	画像分割	画素サイズ	欠陥位置制限	欠陥あり	欠陥なし
手法 A	なし	1 080 × 1 050	なし	—	
手法 B	16 分割	400 × 400	なし	1 ブロック以上	全ブロックなし
手法 C	16 分割	400 × 400	あり	1 ブロック以上	全ブロックなし

分類性能の指標は二値分類に使われることが多い ROC-AUC とし，10 回の試行で最も 1 に近いときの評価結果を採用した．また，評価指標は欠陥の見逃しを意味する「未検出率」と，正常な部位を欠陥と誤認識する「過検出率」を使用する．なお，欠陥の有無を判定するしきい値は，未検出率と過検出率の調和平均である F1 スコアが最大となる値とした．

2.2.1　評価環境

評価の CNN は EfficientNet b0[5] を使用した．入力層のサイズを手法 A では縦 1 080 ×横 1 050 とし，手法 B と C では縦 400 ×横 400 に設定した．なお，入力画像はリサイズせずに使用し，学習は**表2** に示す設定値を使用した．

表2　ハイパーパラメーター一覧
List of hyperparameters

パラメーター	値
エポック数	50
バッチサイズ	32
検証用データの分割	0.1
早期終了：待機エポック数	10
データ拡張	ランダム反転 ランダム回転（± 5°） ランダムコントラスト（± 10%） ランダムガンマ補正（± 10%）
最適化手法	Adam
学習率	0.001

2.2.2　データ選別の効果

学習と評価に使用した画像枚数を**表3** に示す．欠陥ありの画像データが手法 C では手法 B の約 60% に減少している．これは，ラベルミスの可能性が高いブロック端のみに欠陥がある画像データが約 40% 存在していたことを意味する．

表３　画像枚数
Number of images

画像データ	学習用			評価用
	手法 A 1 050 × 1 080	手法 B 400 × 400	手法 C 400 × 400	
欠陥あり	2 248	14 232	8 733	932
欠陥なし	3 954	85 000	85 000	1 667
合計	6 202	99 232	93 733	2 599

2.2.3　評価結果

３種類の手法の未検出率と過検出率を**図７**に示す．数値はどちらも小さいほうが望ましく，特に未検出率は不良品を市場へ流出させないために重要な指標である．手法 A に対し，手法 B，C は未検出率が減少しており，画像をブロックに分割した効果が確認できた．また，手法 B と C を比較すると，未検出率，過検出率ともに，ほぼ同等となり欠陥位置制限の効果は確認できなかった．この理由を明確にするため，欠陥の画像位置と大きさで整理した結果を**図８**に示す．**図８**(a) の画像中央では手法 C の未検出率が向上しており，特に小さな欠陥の見逃しが手法 B の５分の１に抑制されている．一方，**図８**(b) の画像端部では手法 C の未検出率が高くなっている．これは，欠陥位置制限によって画像端の欠陥を学習させていないことが原因であり，評価前に想定した結果となった．この結果を基に画像撮影時にもオーバーラップさせる手法を採用し，画像間で欠陥位置制限を実施する．これにより，欠陥の多くが画像の中央付近に位置するため，未検出率の向上が期待される．

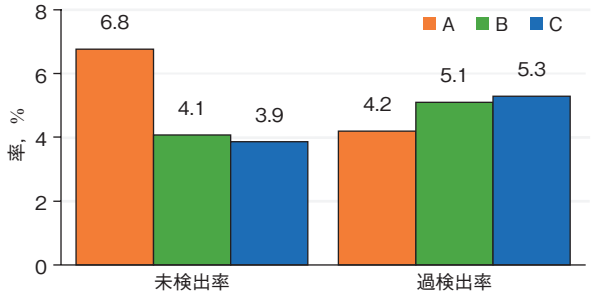

図７　未検出率と過検出率
False negative and false positive rates

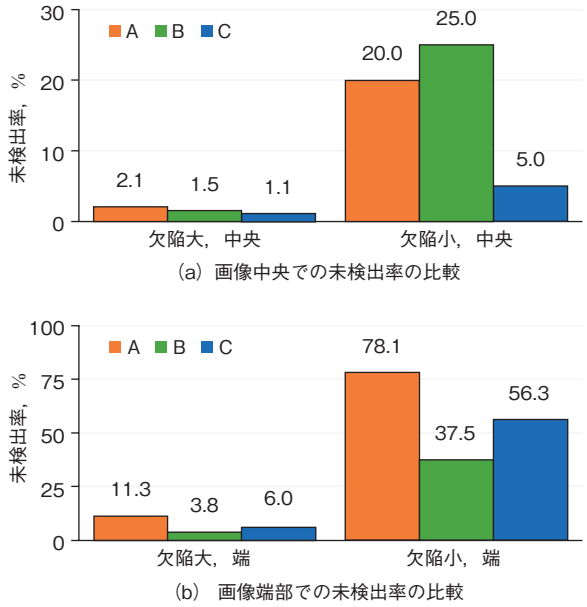

図８　欠陥サイズと位置による未検出率
False negative rate by defect size and location

2.3　量産工程への導入

上記の考え方に基づいて構築した検査装置をラックの量産工程に適用したところ，欠陥の見逃しゼロを達成できた．

本手法を社内で広く利用するため，後述の AI 画像認識プラットフォームに実装した．

3. AI 画像認識プラットフォーム[6)]

3.1　AI 画像認識プラットフォームの開発

生産ラインで新しい品番が追加された際，構築した AI モデルでは対応できず，新品番に適したモデルの再構築や再学習が必要となる場合がある．また，AI モデルは時間の経過や製造プロセスの変更で入力データの特性が変化すると検出性能に悪影響を及ぼす「ドリフト」の発生が知られている[7)]．したがって，量産工程で運用開始した後も AI モデルの性能劣化が検査結果に影響を与える前に再評価や再学習によって AI モデルの更新が必要となる．それには，プログラミングなどの専門スキルを持つ人材が必要であるが，生産現場でこのような人材は限られることが課題であった．そこで，プログラミングが不要で容易に AI 判定モデルの構築や運用を実施できる AI 画像認識プラットフォームを構築した．これにより，各生産現場で AI モデルを迅速に更新できるようになった．

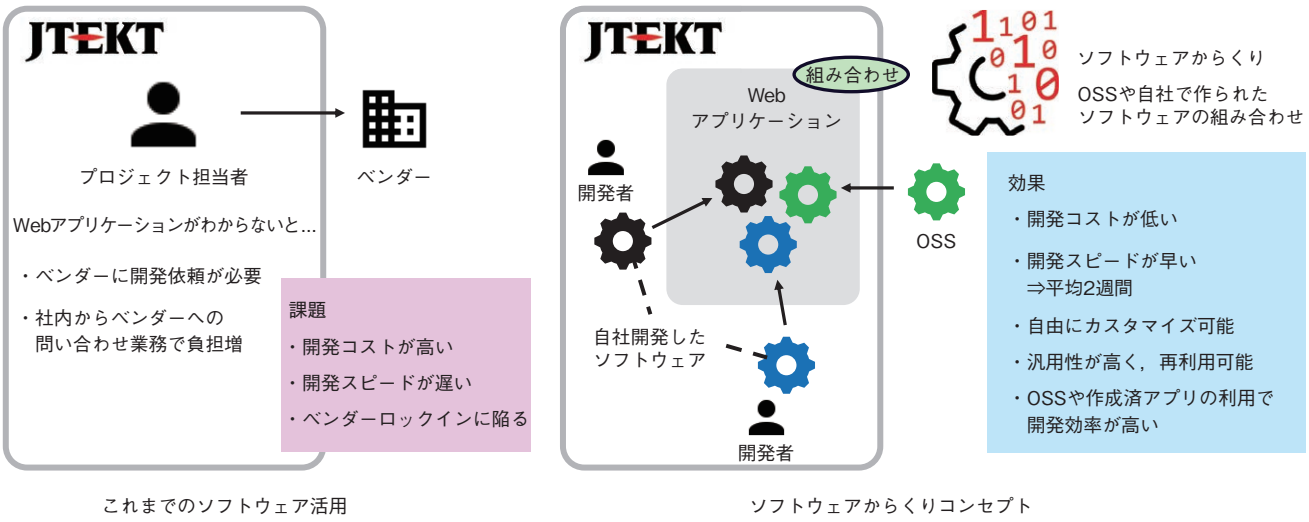

図9　ソフトウェアからくりコンセプト
Advantages of Software KARAKURI Concept

3.2　AI 画像認識プラットフォームの特長

構築した AI 画像認識プラットフォームの特長は，ソフトウェアからくりのコンセプトである専門スキルがなくても活用できる使いやすさと，使いたい機能を自由に組み込めるカスタマイズ性の高さである．**図9**に示すとおり，ソフトウェアからくりは，OSS（オープンソースソフトウェア）や社内開発した独自機能を活用し，必要な機能を組み合わせて一つのアプリケーションを作成できる．このアプローチにはいくつかの利点がある．まず，ベンダーへの依存が減り，開発コストを抑制できる．また，自社開発のためアプリケーションを自由にカスタマイズできる．さらに，マイクロサービス（小さな機能に分割して開発する手法）として機能を開発するため，別の新しいアプリケーションに利用でき，ほかの開発効率の向上にも寄与する．したがって，PDCA サイクルを短周期で回し，必要に応じて迅速な改善ができる．

なお，ソフトウェアからくりはノーコード・ローコード，つまりプログラミングの知識が少なくてもアプリケーションを開発できる．さらに，プロコードを組み合わせることで専門的なプログラミングを活用したソリューションを提供できる．したがって，AI 画像認識プラットフォームは当社だけでなく，グループ会社や社外などの同様の困りごとを解決するソリューションとして活用できる．

3.3　用途別機能の紹介

AI 画像認識プラットフォームは，**図10**のブロック図に示すとおり，AI 判定による外観検査に必要な三つの機能を備えている．これらの機能はモデルの構築，検査の運用，検査結果のモニタリングを通じて判定精度を向上させるサイクルを形成している．以下に，各用途の具体的な機能を説明する．

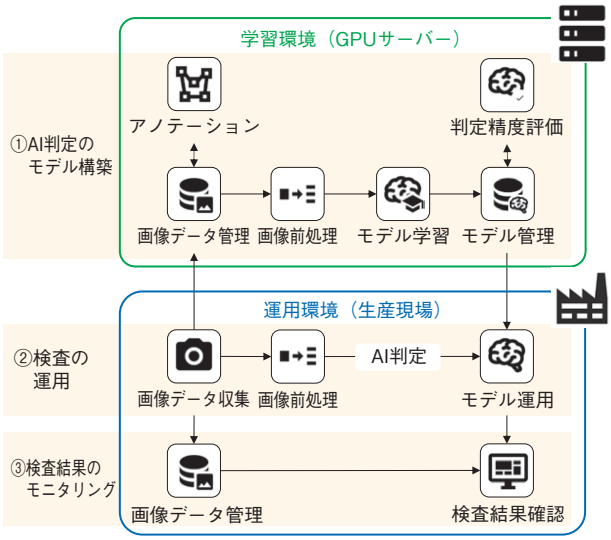

図10　AI 画像認識プラットフォームのブロック図
Block diagram of AI image recognition platform

① AI 判定のモデル構築

データ管理，画像前処理，モデルの学習・管理，判定精度評価など，AI 判定モデル構築に必要な一連の機能を備えており，評価結果やバージョンの管理が可能である．AI 判定モデル構築アプリケーションを**図11**に示す．本アプリケーションでは学習の進捗状況や，学習状況グラフで AI 判定モデルの精度推移を視覚的に確認しながら AI 判定モデルを構築できる．

図11　AI 判定モデル構築
AI model building

② 検査の運用

作成した AI 判定モデルは，生産現場で運用するため，GPU を搭載したパソコン上で実行できる．カメラなどで取得した画像データを判定し，結果を PLC などへ出力できる．なお，検査結果や設備の状態はリアルタイムでメイン画面に表示される．また，社内で汎用的に使用できるよう，各種カメラや各社 PLC に対応しており，GUI 上で検査フローを設定すると簡単に検査を始められる．

③ 検査結果のモニタリング（**図12**）

判定結果の推移や実際の検査画像，NG 判定箇所などは可視化され，社内ネットワークに接続されたパソコンで常に確認できる．これにより，判定結果に異常な傾向が認められた場合，早期の対策が可能となる．また，発生した NG 判定の要因を特定できるよう，期間別や検査部位別に NG 判定の数を集計する機能も備えている．

図12　検査結果の集計
Result monitoring and aggregation

4. おわりに

本報では外観検査の自動化に向けた微小欠陥の検出技術および AI 画像認識プラットフォームを紹介した．

微小欠陥の検出技術では画像の分割による検出精度向上（未検出率が 6.8% から 3.9% へ低下）を確認した．本手法を量産工程に適用し，画像撮影時にオーバーラップさせることで非常に高い判定精度を達成している．なお，本技術は AI 画像認識プラットフォーム上でノーコードにて活用可能である．

今後もソフトウェアによるデジタル活用で業務効率化や現場作業の省人化を実現し，将来の生産年齢人口減少への対応を進めていく．

＊ソフトウェアからくりは，株式会社ジェイテクトの登録商標です．

参考文献

1）荒井雄貴，房安浩二，杉原　億：磁粉探傷検査工程の自働　化，JTEKT ENGINEERING JOURNAL，No. 1018 (2021) 99-104.
2）加納正晃，中瀬晶詳：画像分割とデータクレンジングによる外観検査の判定性能向上，精密工学会ビジョン技術の実利用ワークショップ 2024 (ViEW2024) 講演論文集，(2024) 229-233.
3）M.A. ISLAM, S. JIA, N.D.B. BRUCE：How Much Position Information Do Convolutional Neural Networks Encode?, The Eighth International Conference on Learning Representations (2020).
4）V. BISCIONE, J.S. BOWERS：Convolutional Neural Networks Are Not Invariant to Translation, but They Can Learn to Be, Journal of Machine Learning Research 22 (2021).
5）M. TAN, Q.V. LE：EfficientNet：Rethinking Model Scaling for Convolutional Neural Networks, Proceedings of the 36th International Conference on Machine Learning (2019).
6）株式会社ジェイテクト：ノーコードで AI を活用できるプラットフォームを内製〜生産現場でのデジタルモノづくり改革を推進〜，ニュースリリース，2024-10-10, https://www.jtekt.co.jp/news/2024/004124.html (参照 2025.05).
7）J. LU, A. LIU, F. DONG, F. GU, J. GAMA, G. ZHANG：Learning under Concept Drift: A Review, IEEE Transactions on Knowledge and Data Engineering, Vol. 31, No. 12 (2019) 2346-2363.

筆　者


加納正晃*
M. KANO


マキシム・モレヨン*
M. MOREILLON


荒井雄貴**
Y. ARAI


中瀬晶詳*
A. NAKASE


近藤永治**
E. KONDO


山下雄也**
Y. YAMASHITA


日比大貴**
D. HIBI

*　イノベーション本部　データアナリティクス研究部
**　生産技術本部　工程革新部