

鉄鋼生産プロセスにおける画像処理活用

Applications of Computer Vision in Steel Production Processes

平野 弘 二*
Koji HIRANO

石谷 紗知
Sachi ISHITANI

枚田 優人
Yuto HIRATA

兵頭 雅士
Tadashi HYODO

抄 録

国内の少子高齢化による労働力不足やグローバルでの競争激化に対応すべく、画像処理技術を活用して作業の自動化、生産性向上を進めている。本稿ではまず、画像処理を活用したオペレータの作業分析支援技術開発について述べる。次に、オペレータによる各種監視・確認業務の自動化について述べる。これらの開発では近年発達した著しい深層学習を活用している。深層学習活用にあたり重要となる、画像認識モデルの精度を維持管理する仕組みの構築について、最後に述べる。

Abstract

In order to adapt to labor shortages due to the declining birthrate and aging population, as well as intensified competition world-wide, we are transforming our steel production processes in terms of automation and productivity by using computer vision technologies. This article first explains computer vision based application which supports the analysis of videos captured during work by operators. We next explain automation of various monitoring and confirming works by operators. Development of these applications utilizes fast growing deep learning technology. We then describe the development of a framework to maintain the performance of image recognition tasks, which is important in the deployment of deep learning vision systems.

1. 緒 言

日本製鉄(株)(以下、当社)の鉄鋼製品は、高炉・電炉、精錬、連続鋳造、圧延、表面処理といった多数の工程を経て製造される。仕上がった製品は、表面や内部に欠陥がないか検査され、各種機械試験を実施した上で、梱包され、船やトラックで出荷される。当社では長年にわたり、各種センサや自動制御技術の適用等により、製造プロセスの省力化・自動化を図ってきた。今では、全長1kmに及ぶような長大な工程(製造ライン)であっても、ごく少数のオペレータで操業している。しかし、国内の少子高齢化による労働力不足やグローバルでの競争激化を背景として、さらなる省力化・自動化、労働生産性の向上が求められている。本稿ではこうした課題に対し、画像処理技術を活用し業務変革を進めている取り組みについて述べる。近年は、高精細なカメラの安価化、深層学習の登場や画像処理関連のオープンソースソフトウェアの進展を背景として、画像処理技術の開発ハードルが下がり、鉄鋼業においても様々な展開が可能となっている。

本稿ではまず、画像処理技術を活用した“オペレータの作業分析”を取り上げる。各種業務のさらなる効率化を目指す上でスタートポイントとなる現状業務の分析において、作業の動画撮影がよく用いられるが、撮影後の動画解析作業が高負荷になるという課題がある。これに対し、画像処理を用いて支援・効率化する技術を開発した。現状業務分析の負荷を下げ、その工期を短縮し、結果的にスピーディーに業務改革につなげる意義がある。なお、画像によりオペレータの作業を捉えるという観点で、当社では他にも、作業者の安全確保を目的として安全見守りくん[®](製鉄所構内での一人作業の安全確保のため、管理者等が遠隔から見守り・遠隔作業支援を行うツール)プラットフォームの開発、全社展開を進めているところであるが、本稿では触れない。

次に、オペレータによる監視・確認業務の自動化について述べる。上述のように、当社は操業の省力化・自動化を図ってきたところであるが、オペレータに残された業務として、操業や品質の監視・確認業務がある。当社はこれら業務の自動化に取り組んでおり、本稿では、操業監視の例として“製品搬送状態異常の予兆監視”，製造後の各種検

* プロセス研究所 インテリジェントアルゴリズム研究センター 生産マネジメント研究室長 Ph.D. 千葉県富津市新富 20-1 〒293-8511

査の例として“衝撃試験の破断面識別”，“薄板コイル製品梱包後の確認”，そして，半製品・製品の取り違い防止に向けて重要な現品確認作業における“鋼材 ID 認識”，を取り上げる。なお，製品外観検査については，次稿“鋼板表面検査装置の開発と DX 化への取り組み”を参照されたい。これらはオペレータが目視で行う確認・判断を自動化する開発であり，近年発達の著しい深層学習を活用している。鉄鋼分野では，例えば昼間・夜間での明るさの違いや錆といった外乱があるため，従来の画像処理技術だけでは，様々な局面で安定的に高精度に判定できるモデルを作成することは，画像処理の専門家をして難しかった。深層学習を用いると，そうした外乱を含む大量の画像とそれらに対応する正解データを与えさえすれば，安定的に高精度なモデルが得られるようになってきている。一方で，数値系の機械学習技術と比較すると，深層学習ではより厳密かつ高度な精度維持管理が必要である。対応する取り組みとして，画像認識モデルの精度を維持管理する仕組みの構築について，最後に説明する。また，以上の画像認識モデルの開発から運用は，NS-DIG® や AIRON-EDGE® 等を活用している。これら共通基盤については，本誌別稿“DX を実現するプラットフォーム群”も参照されたい。

2. “動画分析ツール”の制作と展開

2.1 生産現場の作業観測における課題

“インダストリアル・エンジニアリング (以下，IE)”とは，生産管理の最適化を狙いとす一連の分析・改善の技法として広く知られており，製鉄業含めた製造業全般で高度経済成長期から継続して活用されている。とりわけ IE 技法の中でも“作業観測”の手法は，生産現場における実際の事象を漏れなく測定・記録し，課題解決に向けての問題点を抽出するための重要な手段である。“作業観測”の伝統的なやり方は，現場へ“ストップウォッチ”と“記録用紙”

だけをもって作業を測定・記録するというシンプルな方法であるが，一回限りの観測で真の課題解決へ導くには，観測者に IE 技術者としての高い知見が必要となる。近年の“作業観測”では，人の目による直接観測だけではなく，ビデオカメラ等で記録した動画を用いることが試みられている。動画を用いる理由としては，①録画データを何度も見返すことができる，②必要に応じてスロー再生を活用できる，③安全上の立ち入りが制限されている場所での観測が可能，等の様々な利点があげられるが，現時点において本格的な実用化には至っていない。“作業観測”で動画を実用化するための課題を以下に述べる。

人が動画を見て，後に作業分析するための記録表にするには，相当な時間と手間がかかる。文献 1) に動画を用いた市販の作業分析ソフトウェアが紹介されているが，本件は限られた範囲での特定の作業を前提としており，製鉄業の生産現場のような広域での記録には必ずしも適さないと考えられる。

2.2 “動画分析ツールの開発”

上記課題を解決するため，生産現場の“作業観測”に適した手法として，新たに“動画分析ツール”の制作に取り組んだ (図 1)。本ツールの制作にあたっては，上記課題を解決するための対策として以下に示す内容を取り込み，それぞれの機能について，実際の生産現場で検証しながら各仕様を詰めていった。

対策 1：効率的かつ精密な作業記録の収集

“①複数のオブジェクト (撮影場所，人，設備・器具) の連合作業を正確に読み取る機能”，“② ①の情報に付随した時間情報等を，自動で読み込む機能”，“③同時刻に撮影された複数動画を同時に視聴できる機能”を有する。

対策 2：“動画自動判定機能”

動画情報から，オブジェクト毎の作業状態 (開始～終了)

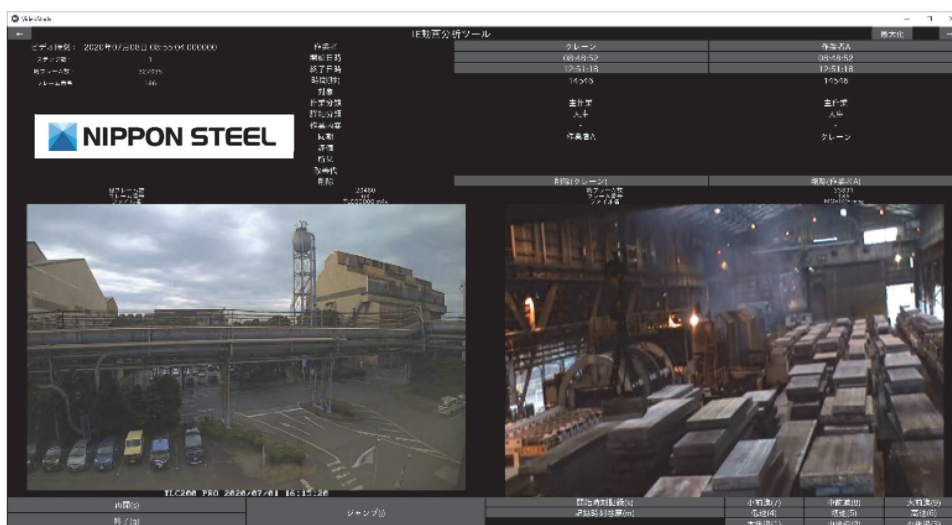


図 1 “動画分析ツール”の画面
Screen of the video analysis tool

を自動取得できる動画判定機能として、“コンピュータビジョン”の手法を用いた動画の色彩・輝度の変化、オブジェクトの動き（“オブティカルフロー”）、特徴量の変化などを総合的に判断して、“作業観測”の記録へ変換する機能を考案した(表 1)。また分析内容を画面で閲覧する利用者は、プログラミング等の知識や経験のない者であっても、ツール画面での設定作業で利用できるようにしており、製鉄業の生産現場に従事するオペレータ操作が可能となっている。

2.3 “動画分析ツール”の適用効果

上記対策の適用結果について、実施例を紹介する。

効果 1：従来から約 4 倍の作業記録速度向上を達成

ある作業の動画データをもとに①“動画ビューアと表計算ソフト”での作業記録、②“動画分析ツール”の作業記録を比較した。結果、表 2 のように約 4 倍の作業記録速度の向上がみられた。

効果 2：特定の作業観測についてほぼ全自動化

“マシンスカーフ作業観測”の事例より“動画自動判定機能”の効果を説明する。この作業は、鋼片の表面に生じ

た疵や不純物を熱化学的に溶削する作業であり、“予熱”、“溶削”、及び“消火”の 3 工程からなる。これらの作業時間を統計的に評価するため、作業員が常時見ている 2 つのモニタを後方からビデオカメラで長時間撮影して、これを“自動判定機能”を用いて作業記録のほぼ全自動化を図り、大幅に作業観測の効率化を実現できた。この自動判定方法について図を用いて説明する。まず、判定領域を座標で定義し、各判定領域で判定手法、判定条件を定義画面上で設定する(図 2)。

次に 2 つの判定領域それぞれの判定を複合して、“予熱”、“溶削”、“消火”の判定を行った(図 3)。

現在、本ツールは各製鉄所において実用化されており、能力検証や生産課題の抽出に活用され、それぞれの分析結果に基づく改善施策によって生産性向上、安全対策に展開できている。また、本ツールは DX 人材育成の観点からも、現場スタッフの業務支援ツールとして有用な位置づけとなっている。今後は、導入・適用箇所を増やし、実績を積み重ねることで、さらなるツールの改善を行う予定である。

3. 製品搬送状態異常の予兆監視²⁾

3.1 製品搬送における課題

鉄鋼業には、生産性向上を目的に、複数のコイルを溶接し、ベルトのような形態で連続処理する設備がある(図 4)。

表 1 製鉄業での動画自動判定機能の実施例
Use cases of automatic video scene recognition in steel manufacturing

Recognition target	Applied recognition function
① Busy/idle durations of a coiler	Optical flow
② Busy/idle durations and moving direction of an overhead crane	Optical flow
③ Arrival/departure of palettes in a pit	Feature matching
④ Human intrusion into a restricted area	Color recognition or combined recognition

表 2 従来の記録方法との比較
Comparison with a conventional recording method

Method	Recording speed	Improvement ratio
① A video viewer and a spreadsheet software	20 records/hour	Approx. 4 times
② The developed video analysis tool	81 records/hour	



Examined regions	Examined parameters	Recognition conditions
① Light blue frame	Brightness	If [Brightness] ≥ 100, luminescence; otherwise, darkened.
② Green frame	Brightness	If [Brightness] ≥ 200, luminescence; otherwise, darkened.

図 2 判定領域毎の設定例
Examples of recognition conditions for multiple examined regions




図 3 複合条件での判定例
Examples of decisions by multiple conditions




図4 連続処理設備の一例²⁾
An example of continuous processing line²⁾




図5 搬送中の板寄り現象²⁾
An example of moving steel strip²⁾

コイルの搬送には多くの搬送ロールを使用しており、コイル板の形状が板幅方向で不均一な場合や搬送ロールのアライメント状態等の操業条件によっては、板が搬送（以下、通板）する方向に直角な方向に寄り、最悪の場合は設備に衝突し、コイルが破断（板破断と呼ぶ）することがある（図5）。板破断の頻度は少ないが、破断発生時の操業への影響は大きい。これまではカメラ画像を人が監視し、板寄り発生時は通板速度を下げるアクションを取っていた。人による検知は可能だが、常時監視が困難であることが課題であった。

3.2 製品搬送状態異常の予兆監視システムの構築

既設のITV（Industrial Television、監視カメラ）画像を毎秒30枚の静止画に分解し、1枚ごとに深層学習モデルを用いて板寄りの発生確率を予測し、予測結果をリアルタイム処理し、グラフ化して現場のモニタに表示する仕組みを開発した（図6）。板寄り発生時の3-5分前に予兆を検知できるなど、現場オペレータと同じレベルで検知可能と評価を得ている。

4. 衝撃試験の破断面自動識別技術

4.1 衝撃試験の破断面算出における課題

鉄鋼製品の品質を評価するための種々の試験には、試験者が試験片の目視観察に基づいて試験結果を導出するものが存在する。そうした試験では、目視による判断に熟練が求められる場合が多く、試験者によるばらつき抑制が重要となる。当社では目視観察に高いスキルが求められる試験について、結果の自動取得、品質管理システムへの自動取



図6 板寄り予兆検知の一例²⁾
An example of predictive detection of moving coil²⁾




図7 シャルピー衝撃試験の概要
Schematic of Charpy impact test

り込み化を推進し、品質管理レベルの向上を図っている。ここでは一例として、衝撃試験における破断面自動識別技術の開発について述べる。

シャルピー衝撃試験、DWTT試験（Drop Weight Tear Test）等の衝撃試験は、鉄鋼製品等金属の靱性を評価する試験である³⁾。図7に概要を示す通り、棒状の試験片に予めノッチを入れておき、ハンマーを振り下ろすなどして衝撃を加えることで試験片をノッチから破断させ、破断面（図8(a)に例示）から延性破面と脆性破面を判断し、破断面全体の面積に対する延性破面の割合である延性破面率、もしくは、脆性破面の割合である脆性破面率を求めるものである（延性破面率、脆性破面率をまとめて破面率とも呼ぶ）。

上記の通り破面率の導出には、破断面のどこが延性面でどこが脆性面かを判断する必要があるが、その判断には熟練を必要とし、人に依るばらつきが発生する。加えて、延性部と脆性部との境界領域が複雑な形状であるため、破面率の正確な算出には多くの時間を要する。具体的には、従来手法の一例としては、破断面の画像に方眼状のマスを重ね合わせ（図8(b)赤枠）、破断面内で延性面もしくは脆性面に相当する領域のマスを数えて、破断面における占有割合を破面率として算出することが行われている。これら作業の負荷が課題である。

4.2 破断面自動識別技術の開発

そこで、深層学習による破断面自動識別技術を開発した。類似研究として、文献4)には破断面の走査型電子顕微鏡（SEM）画像を入力として、ディンプル、ファセット、スト




図8 シャルピー試験片破断面 (a) に対し、人がつけた脆性面の正解 (b) と深層学習モデルによる推論結果 (c) の例
An example of original Charpy fracture surface image (a), groundtruth of brittle surface given by a person (b), and output of deep learning (c) with respect to the same image (a).

ライエーションといった破壊組織の種類⁹⁾を出力する深層学習モデルが提案されている。本開発は、よりマクロな光学顕微鏡画像を用いる点、破壊組織の種類でなく破面率を出力したい点が異なっている。

深層学習タスクの設計として、文献4)と類似した形で、画像から直接破面率を出力する深層学習モデルを構築する方法が考えられたが、破面率の精度を追求するために、破断面内のどこが脆性破断部かを画像の1画素毎に判定し、脆性領域を塗り絵のような形で出力させる深層学習モデル⁹⁾を開発することとした。

深層学習モデルの学習には大量の正解データを準備する必要がある。本タスクの正解データは、破断面の画像とその破断面内のどこが脆性破断部を示す領域情報の組合せであるが、後者は基本的には、人が画像に塗り絵をして作成(マーキングと呼ぶ)する必要があり、このマーキングの作業負荷が大きい。

そこで、本開発においては、大量の画像及びマーキングデータが出揃ってから深層学習モデルを作成するのではなく、ある程度の画像及びマーキングデータが作成できた時点で、そのデータを用いて仮の深層学習モデルを作成し、以降に収集される画像に対しては、仮の深層学習モデルで仮ラベルを付与し、その仮ラベルを人が適宜修正する方法⁹⁾で、マーキングの作業負荷を軽減した。

また学習において、画像を上下・左右反転させることで学習データの水増し効果が得られるように、破断面の上からカメラで撮像する際には、破断面に垂直な軸(カメラの光軸と一致)に沿って軸対称となる光学系を用いた⁶⁾。

加えて、深層学習モデルの設計ではReceptive Field⁷⁾を最適化した。Receptive Fieldはある1画素が脆性部かどうかを判定する際、深層学習モデルが画像内で当該画素からどれくらい離れた画素の情報までを考慮して判定しているかを示す、領域の大きさである。現状業務においても人は、ある点が脆性部か否かをその周辺の領域を見ながら判定していることに対応した最適化である。

以上の工夫点を織り込み深層学習モデルの精度向上を進めた結果、試験片本数ベースで99%以上の試験片で、人

と同等の判定が可能なレベルに到達した(図8(c)に深層学習モデルによる推論結果例を示す)。間もなくプロパー化され、破断面読み取り作業の効率化に貢献していく予定である。

5. 薄板コイル製品梱包後の確認業務支援

5.1 薄板コイル製品の梱包における課題

薄板コイルなどの鉄鋼製品は、製造・検査手入れの工程を通過後、梱包を行い、出荷している。梱包は、金属や紙、バンドなどで製品全体を覆った上で、製品の情報や運搬時の注意事項等を記載した複数のラベルの貼付を行っている(図9)。

これらの梱包の内容は、製品の特性や顧客の要望等に合わせて決めているため、梱包のパターンは様々であり、製品に貼付するラベルも梱包のパターンごとに数十種類存在する。そのため、製品一つ一つに対して変わる梱包とラベル貼付のパターンに応じて、正しい梱包が行えているかを確認している。梱包とラベル貼付内容のミスの見落としは、契約と異なる製品の出荷に繋がるため、慎重な確認が必要であり、作業者一人だけの確認では、仮に緊張感を持って対応しても見落としを完全に防ぐことはできないため、二人以上での目視確認を行ってきた。しかし、複数人での確認を前提としても、作業者が集中力を維持したまま確認し続ける業務の負荷は高いという課題認識があった。




図9 コイルの梱包例
Coil packaging

5.2 梱包確認業務の支援の仕組み構築

当社では、設備に取り付けたカメラや端末カメラ等で撮影した梱包後の製品の画像を用いて、梱包内容を自動で確認する技術を開発した。画像認識を行う上での課題は、梱包及びラベル貼付パターンとの組合せ数が多いことに加え、鉄鋼製品の重量は数トンから数十トンまでのバリエーションを持つため、大きさの異なる製品への対応、カメラの設置条件に伴い変化する撮影角度の変化への対応など、多くの条件に対応した画像認識モデルの整備を行うことである。一般に画像から物体を識別するには、フィルタ等の前処理の後に、検出したい物体を特徴付ける特徴量を決め、その特徴量の分布に対するルールを設定する手法が考えられる。しかし、検出対象やそれ以外の背景など画像にバリエーションが多い場合、そのような特徴量やルールを設計・設定することは長大な時間と手間を必要とすることが多い²⁾。そこで、梱包内容の識別モデルの開発に深層学習を用いることとした。さらに、当社が開発した識別モデルでは、製品認識精度を向上させる前処理等の工夫を行うことで実用可能な精度への改善を行い、製品梱包後の確認業務の支援ができるシステム構築を実現した。その結果、従来は二人以上で確認していた作業について、第二の目として深層学習モデルを用いることで、一人で梱包確認をすることが可能となった。

今回構築した前処理や認識処理等の周辺機能については、他の様々な業務に適用できることから、共通部品化を行い、業務に合わせて組み合わせ活用できるように整備を行った。これらの部品を他の業務にも展開することで、別の画像認識モデルの実用化までの工期を短縮することができる。

6. 鋼材ID認識技術²⁾

6.1 鋼材 ID 読み取り作業における課題

当社の鉄鋼製品は、社内の製鉄所で製造後、船舶等で出荷され、適宜中継地を間に挟みながら顧客に届けられる。この一連の物流において、製品を正確にトラッキングし、注文仕様通りの製品を顧客にお届けする必要がある。このため製品には、その表面や側面に製品を識別するための ID が印刷、刻印、ラベルなどの形態で示されている。ID に基づく個体識別は、多工程に亘る鉄鋼の製造プロセスにおいては、製鉄所内での半製品（スラブ、ビレット、コイル等）を正しく処理、運搬するためにも重要である。

従来、ID の認識は人の目視により行われてきた。図 10 には一例として、厚板製品の中継地での確認作業の様子を示す²⁾。製品の側面に印字された ID を一枚ずつ人が目視で読み取り、製品山毎のリストと突き合わせる作業を行っている。この写真のように作業しづらい姿勢を取る必要がなかったとしても、正しく読むべく集中力を切らさずに長時間読み取り作業を継続することが求められ、作業負荷が課




図 10 製品 ID 読み取り作業の一例²⁾
写真中央の人が製品の側面に印字された ID を読み取っている。
An example of work to read IDs²⁾
The person in the center is reading ID printed on the side of each plate.

題であった。

6.2 鋼材 ID 自動認識技術の開発

そこで、スマートフォンのカメラ等で製品や半製品の ID を撮影し、撮影画像から製品 ID を自動認識する技術を開発している。

この ID 認識のタスクは、文字や数字の認識であるが、通常の紙資料の電子化に利用される OCR (Optical Character Recognition/Reader) の利用環境と異なり、影が映りこむ、明るさが足りず文字の有無を確認できない、屋外の場合は朝日や夕日によってハレーションが起こるなど撮影環境上の課題がある。また鋼材に直接印字する場合は、錆など鋼材表面性状の影響も受ける。画像処理の工夫によって ID 印字部分を顕在化する処理を開発することも考えられるが、上述したような環境からの外乱も含めた多様な条件全てに適用可能なアルゴリズムを開発することは容易ではない。

そこで、深層学習モデルの適用を進めている。深層学習を用いると、多様な条件に対応する学習データの準備ができれば、それら多様な条件に対応可能なアルゴリズムを一つずつ人手で設計する必要がなくなり、自動で学習できるという利点がある。一方で、精度の高い深層学習モデルを作成するためには、一般的に何万枚もの画像データを準備する必要がある。学習するためには、画像だけでなく、それぞれの画像内でどこに何の文字が映っているかの情報を紐付ける（アノテーション）必要がある。この人手で行われるアノテーション作業の負荷と工期が課題となる。加えて、当社が提供する多様な品種毎に製品や半製品の ID の種類が異なっており、100 を超える種類毎に何万枚ずつ学習データを準備せねばならないため、トータルとしての作業負荷・工期は膨大になる。

以上の課題に対応するために当社では、鋼材 ID 認識に共通的な基盤モデルを構築している。これは図 11 に示すように、先行して開発が進められた 10 程度の文字種について画像とアノテーション情報を集約し、それら全てを学習したモデルである。データは全社解析基盤 NS-DIG[®] に

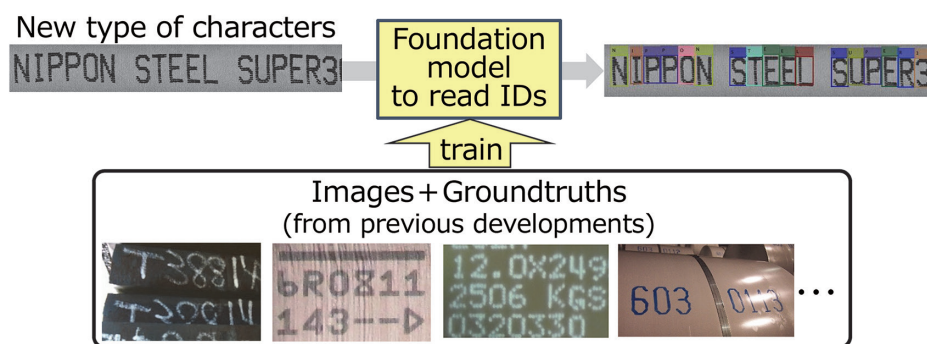


図 11 鋼材 ID 認識基盤モデル
A foundation model to read IDs on steel

集め、NS-DIG® 上の KAMONOHASHI® にて実行した。10 程度とはいえ、図 11 にある通り、様々な品種の製品・半製品の文字種を学習している。

他の新規文字種への展開にあたっては、基盤モデルをベースに当該新規文字種のデータを追加学習（転移学習）することで、ある精度まで到達するのに必要な当該新規文字種の学習データ量を減らせる効果を確認している。また、この基盤モデルは当該新規文字種のアノテーションにも活用可能である。すなわち、当該新規文字種が映った画像を基盤モデルに通すことで、部分的にアノテーションされる。その後、人がその結果の修正や、アノテーションできなかった残りの部分のアノテーションを進めることで、アノテーションの作業負荷・工期を大幅に低減することができる。

7. 画像認識モデルの精度維持管理

7.1 運用中の画像認識モデルにおける課題

深層学習等の AI モデルは、膨大なデータを元に特徴を見つけ、ルールを学習し、それに従い推論を行う。しかし、学習データの範囲から外れたデータが予測対象となった場合には、対応するルールが見つからず、誤った答えを出す可能性が高い。例として、屋内にカメラを設置して、コイルの梱包内容を認識する AI モデルの学習について述べる。様々な梱包パターンを撮影した画像で AI モデルの学習を行い、実用化したとする。しかし、運用中に屋内に設置された照明が劣化し交換した場合、明るさ等の見え方が変わる可能性がある。このような環境変化が生じると、学習時のデータとは異なるデータが与えられたことになるため、一般的には認識精度が落ちる（図 12）。このように、AI モデルは運用中にデータの特徴が変化すると、精度が低下する傾向にある。しかし、精度低下に気づかずに利用すると、利用者は実績と乖離した答えを出す AI モデルを、次第に利用しなくなる可能性がある。AI モデルが実用化した後も継続的に効果発揮をするためには、致命的な精度低下が発生する前に AI モデルの精度を回復することが必要である。



図 12 AI モデルの精度変化
Changing accuracy of AI model in operation

7.2 AI モデルの精度維持管理の仕組み構築

AI モデルの持続可能な効果発揮に向けては、“AI モデルの精度を監視し、精度低下を早期に検知し、精度低下の要因の特定と再学習を行う”改善サイクルを回す基盤整備が重要である。しかし、画像認識モデルの精度維持管理は、数値データを用いた AI モデルに比べて難易度が高いため、モデルを構築する部門は、適用先の業務部門とよく連携しながら仕組みを構築することが必要である。例えば、数値データを用いた AI モデルの場合は、センサデータ等から実績データを取得でき、予測と実績の乖離を自動で管理することができる一方で、画像データを用いた AI モデルは、人の視覚情報に基づいた合否判定が実績データとなることがある。具体的には、人の存在を検知する AI モデルにて、AI モデルが“人がいる”と推論したとしても、本当に人が映っているかどうかは、結果を確認した作業者にしか評価できない。このように、画像認識については、人を介さずに自動で予測と実績の乖離を管理することが難しい場合がある。実用化した AI モデルの精度を管理する方法として、例えば日別に精度を算出し、直近の精度傾向を手で分析するという方法も考えられるが、様々な AI モデルを全て監視する場合は人手での管理には限界がある。

そこで、AI モデルの結果をデータとして蓄積しそのデータを元に精度監視を行う仕組みと、精度低下を検知し精度回復を支援する仕組みを構築し、画像認識モデルの精度管理の容易化に取り組んだ。これらの仕組みは、エッジコンピューティング基盤 AIRON-EDGE® に構築しており、画像認識モデルでの利用拡大を行っている。今まで人を中心の

精度維持管理であったが、自動での仕組みを導入することで運用保守の業務効率化が図れている。


8. 結 言

本稿では、画像処理技術を活用して作業の自動化、生産性向上を進めている取り組みについて説明した。ここで取り上げた、動画を用いた業務分析を画像処理で支援する技術、そしてオペレータの視覚的判断を自動化する技術としての、製品搬送異常の予兆監視、破断面識別、薄板コイル製品梱包後の確認、鋼材 ID 認識、いずれも各業務の省力化・効率化に貢献している。これらの実業務運用は、次いで述べた画像認識モデルの精度を維持管理する仕組みで下支えている。画像系 AI 技術は現在も日々進展を続けている。


当社は今後も最先端の技術をいち早く取り入れ、業務改革を推進していく。

参考文献

- 1) 作業分析／業務最適化ソフトウェア OTRS ((株)ブロードリーフ) <https://www.broadleaf.co.jp/products/other/otrs/>
- 2) 伊藤 ほか：ふえらむ. 26 (2), 69-74 (2021)
- 3) 例えば, JIS Z 2242, ASTM E23, ISO 148-1, API 5L3, など
- 4) 山際：材料. 69 (9), 644-649 (2020)
- 5) 駒井謙治郎 編：機械材料学. 9 版. 京都, (社)日本材料学会, 1999, p.173-182
- 6) 日本特許出願公告 2023-42445. 2023 年 3 月 27 日
- 7) 岡谷：人工知能. 31 (2), 169-179 (2016)



平野弘二 Koji HIRANO
プロセス研究所
インテリジェントアルゴリズム研究センター
生産マネジメント研究室長 Ph.D.
千葉県富津市新富20-1 〒293-8511



枚田優人 Yuto HIRATA
情報システム部 情報システム企画第二室
AIソリューション課長



石谷紗知 Sachi ISHITANI
情報システム部 情報システム企画第二室
AIソリューション課 主査



兵頭雅士 Tadashi HYODO
日鉄ソリューションズ(株)
鉄鋼ソリューション事業本部 鉄鋼ソリューション事業部 瀬戸内システムソリューション部 広畑システムセンター 生産管理・IEコンサルグループ 主査