

豊田自動織機-産総研 アドバンスト・ロジスティクス連携研究ラボ TICO-AIST Cooperative Research Laboratory for Advanced Logistics

横町 尚也^{*1} 前伸一^{*1} 菊池 駿介^{*1} 岡本 和也^{*1} 松浦 慶伍^{*2}
Naoya Yokomachi Shinichi Mae Shunsuke Kikuchi Kazuya Okamoto Keigo Matsuura

*1 先行開発部 *2 ITデジタル推進部

要旨

先進的なロジスティクスソリューションの実現を目指し、2016年10月に産業技術総合研究所(産総研)内に設立された豊田自動織機-産総研 アドバンスト・ロジスティクス連携研究ラボ(ALラボ)の取組み概要を紹介する。

キーワード:産総研、インスタンスセグメンテーション、転移学習、MaxSAT

Abstract

TICO-AIST Cooperative Research Laboratory for Advanced Logistics (AL Laboratory) has established in October 2016 for realization of advanced logistics solutions.

Keywords: AIST, Instance segmentation, Transfer learning, MaxSAT

1 はじめに

物流業界ではe-コマース(電子商取引)の普及により多頻度・小口配送での荷役量が増加する一方、少子高齢化に伴う労働力人口の減少により輸送能力の不足が懸念されている。ITデジタル技術の進展を背景に、高度に智能化・自動化された機器やビッグデータを活用した効果的なオペレーションなど新しいソリューションの提案が求められている。その実現には社内外の技術を融合し新しい価値を生み出すオープンイノベーションの取組みが必要である。当社の製品開発力、導入実績に基づくデータノウハウに加えて産総研の持つ高度なロボット技術、情報技術を融合させ先進的なロジスティクスソリューションの実現を目指しALラボを設立した。表に産総研とALラボの概要を示す^[1]。

表1 産総研の概要
Table1 AIST overview

名称	国立研究開発法人産業技術総合研究所 National Institute of Advanced Industrial Science and Technology
創立	2001年4月1日
人員	研究職員 2188名 (2023年7月現在)
拠点	全国12か所
研究領域	7領域 エネルギー・環境、生命科学、エレクトロニクス・製造、情報・人間工学、材料、地質、標準・計測

表2 ALラボの概要
Table2 AL Laboratory overview

名称	豊田自動織機-産総研 アドバンスト・ロジスティクス連携研究ラボ (ALラボ) TICO-AIST Cooperative Research Laboratory for Advanced Logistics
設立	2016年10月
人員	42名 うち出向者8名
拠点	2拠点 (つくば、 臨海副都心)



図1 ALラボの研究領域
Fig.1 Research area

データ取得/解析/活用を基盤とし智能化/自動化、ソリューション/サービス、システム化/コネクテッド化を研究領域としている(図1)。本稿では3テーマの概要を紹介する。

1) 深層学習を用いた荷姿異常検出

荷干渉など荷姿異常を荷役作業前に検出し荷崩れを防止する技術。数式ドリブン教師あり学習により高精度で商用利用可能な手法を構築した。

2) FC寿命予測

FC(Fuel cell: 燃料電池)フォークリフトのロガーデータを用いて寿命予測を行い予防保全に寄与する技術。ベクトル自己回帰モデルと転移学習を組み合わせることで高精度な予測を実現した。

3) 仕分け・積み付けアルゴリズム

物流センターで使用される仕分け機・積付機の制御を最適化しスループットを向上させる技術。最適化計算を数理モデル適用により短縮した。

2 深層学習を用いた荷姿異常検出

物流現場では運搬時の振動などにより隣接荷物同士の干渉や荷物がパレットからはみ出すなどの通常の荷役動作では荷役が困難な状況(荷姿異常)が発生する(図2)。自動運転フォークリフトが荷姿異常の荷物を正常な荷物として荷役を行うと荷崩れが発生する可能性があり、事前に荷姿異常を検出し適切な処置を取る必要がある。



図2 荷姿異常の例
Fig.2 Examples of Load Anomalies

そこで我々は深層学習を用いて個別に検出した荷物・パレットの領域情報を用いて荷姿異常を検出する荷姿異常検出手法を開発した。本手法ではフォークリフト前方に取り付けたカメラとLiDAR (Light Detection and Ranging) で取得した画像と点群による入力画像から検出した荷姿前方領域とLiDAR点群を組み合わせることで干渉とはみ出しの荷姿異常を検出する。

1) 荷姿認識モデル

荷姿領域検出モデルは入力画像から検知対象物をピクセルレベルで検出可能な技術であるインスタンスセグメンテーションを用いて構築した。一般的に産業利用可能な高精度なインスタンスセグメンテーションモデル構築には図3に示すような検知対象物の個別領域に対しアノテーションして作成した数万枚単位の画像データを学習に用いる必要があり、モデル構築のコストが高い^[2]。

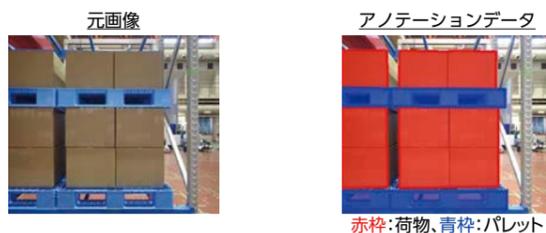


図3 アノテーションデータ
Fig.3 Annotation Data

こうした学習データの不足を補う手法として事前学習がある。一般的に、深層学習における事前学習は目的とするタスクの学習の前にImageNet^[3]などの大規模データセットによる画像分類タスクを事前に学習しておくことで目的タスクの性能を向上させる手法である。しかし、ImageNetなどの公開されているデータセットの多くは、個人情報保護・公平性担保の観点から商用利用を禁止しているものが多く、製品に実装するモデルの事前学習に用いるには慎重な判断が必要である。

そこで、大規模データセットが抱える問題に対して共同研究をしている産業技術総合研究所の片岡らは数式から生成した画像を事前学習に用いる数式ドリブン教師あり学習(FDSL: Formula-driven Supervised Learning)を提案した^{[4][5]}。FDSLは数式から画像を生成するため、著作権などが発生せず商用利用が可能である。また、数式のパラメータに基づき画像とそれに対応したラベルを自動で生成することができるためデータ作成コストがかからず、数式やパラメータを変更することが可能である(図4)。

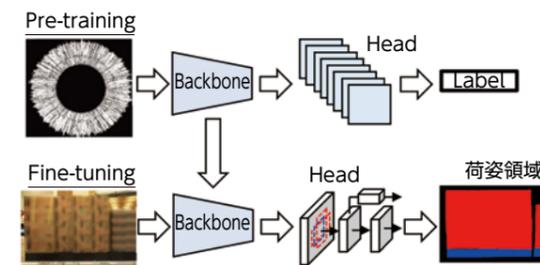
	Fddb	ImageNet[2]
商用利用	可能	不可
アノテーション	不要	必要
画像分類精度	82.4% ^{*1}	81.8% ^{*2}
画像例		

*1 RCDB-21kで事前学習、ImageNet-1kで転移学習
*2 ImageNet-21kで事前学習、ImageNet-1kで転移学習

図4 事前学習データセット
Fig.4 Pre-training Dataset

荷姿認識モデル構築では事前学習にFDSLの一種であるRCDB-21kを、ファインチューニングでは荷物・パレット前面のみをアノテーションした3664枚の画像データセットを学習させた(図5)。

構築したモデルにおいて未学習の100枚の画像にて検出精度を評価するとmAP@90 (Mean Average Precision) で98.3%という高い検出精度を確認した(図6)。



3664枚の画像データセット
図5 荷姿領域検出モデル構築
Fig.5 Construction of a Load Recognition Model

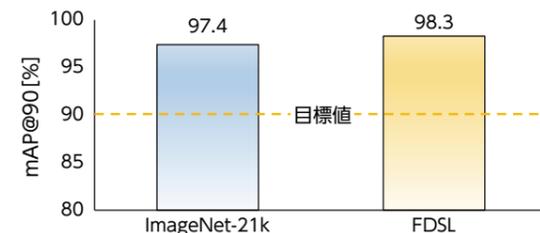


図6 荷姿領域検出精度
Fig.6 Accuracy of Load Region Detection

2) 荷姿異常検出

荷姿異常検出部では事前のキャリブレーションで取得した外部パラメータを用いて検出した荷物・パレット前面領域とLiDAR点群との対応を取り、荷物・パレット前面領域点群を切り出し、検出したパレット平面に他の点群を射影することで荷物・パレットの2次元点群を取得する。

この荷物・パレットの2次元点群を用いて干渉検出では事前に設定したリフトアップ量にて荷役対象荷物をリフトアップした際に通過する領域を干渉判定領域とし、干渉判定領域内に荷役対象以外の点群が含まれる場合に干渉異常と判定。はみ出し検出では下段パレットの左右端と荷物の左右端の座標からはみ出し量を算出し、はみ出し量がしきい値以上の場合にははみ出し異常と判定する(図7)。

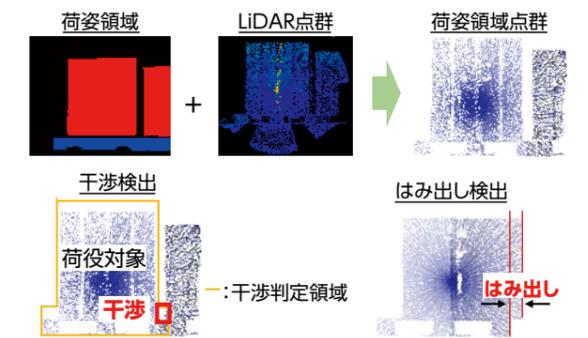


図7 荷姿異常検出
Fig.7 Palletized Load Anomaly Detection

この手法を用いて正常荷姿:76、干渉荷姿:12、はみ出し荷姿:12から構成される合計100枚の評価データにおいて荷姿異常検出精度を評価したところ目標である適合率・再現率:90%以上を達成した(図8)。今後は開発した荷姿異常検出手法を自動運転フォークリフトに実装し実際の物流現場で実証予定である。

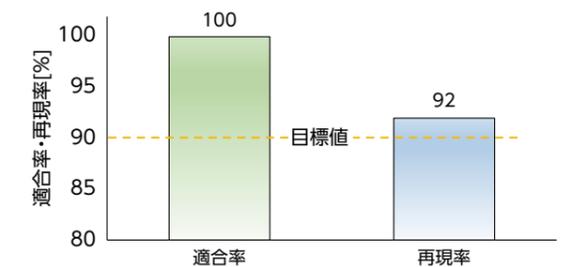


図8 荷姿異常検出精度
Fig.8 Precision and Recall of Load Anomaly Detection

3 FC寿命予測

FCユニットの主要部品であるFCスタックは、積層セル総電圧(以後、FC電圧)が一定値を下回ると寿命と判定され交換のため使用停止期間が生じる。精度よく寿命予測ができると予測時期に合わせてあらかじめ部品手配等の交換準備を行うことができるため停止期間の低減が期待できる。

FC電圧は右肩下がりのトレンドを示すため、傾きからある程度の予測は可能だが数%の電圧誤差が数か月単位の誤差となるため高精度な予測は困難である。ベンチ試験結果を元にした予測手法は一定条件下で精度は高いが、市場での使い方の影響により精度が低下する場合がある。使い方の影響とは負荷や速度等の運転条件、気温等の環境条件により生じる数か月から年単位のトレンド変化である(図9)。そこで使い方の影響を考慮した高精度な予測手法構築に取り組んだ。

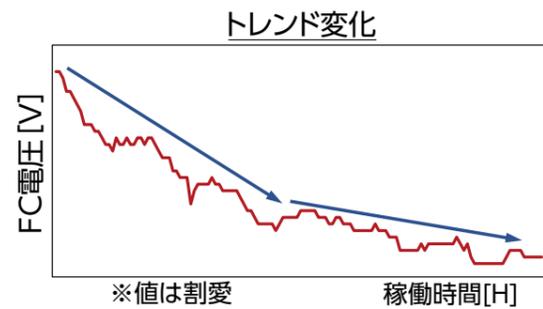


図9. FC電圧変動、トレンド変化の例
Fig.9 Example of FC voltage fluctuation and trend

1) システムの概要

使い方の影響を考慮するためフォークリフトに搭載されたロガーにより収集された実測定データを用い機械学習モデルによる予測手法構築を行った。予測モデルは、多変量ベクトル回帰モデル (VAR-X: Vector Auto Regressive model with Exogenous Variables) をベースとし、使い方が類似したフォークリフト間 (以後、同属性) で標準化偏回帰係数の転移学習を行った。機械学習では対象全データを学習させる方法が多いが、予測結果が平均的となり個体差や使い方の影響による精度悪化の課題がある。一方個別データで学習を行う方法ではデータ数不足による精度悪化、使い方のパターンへの許容度が狭まる懸念がある。そこでリフトごとの個別データの学習に加え、転移学習を適用することでデータ数不足を補完し、使い方のパターンへの許容度も高める手法とした (図10)。

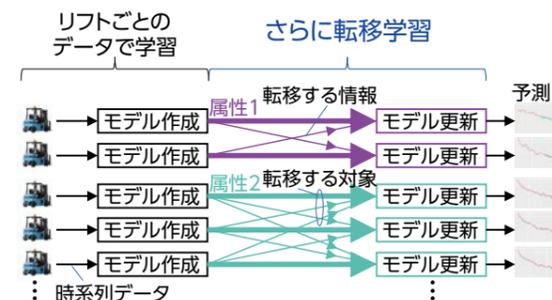


図10 属性を揃えた転移学習によるモデル構築
Fig.10 Model Construction through Transfer Learning with Aligned Attributes

2) 転移学習

転移学習は、新規タスクの仮説を効率的に見つけるために、1つ以上の別のタスクで学習された知識を得て、それを適用する問題^[6]が広く使われる定義である。①過去知識の積み上げ②タスク間の類似構造の把握③獲得した知識の適用の3要素で構成される。人が犬種を学習する場合、秋田犬の認識という新たなタスクに対し柴犬を認識するタスクで得た犬の類似構造の知識 (例えば4本足、毛皮、しっぽ等) が秋田犬の学習に役立つ。このような学習過程を機械学習に適用するのが転移学習の考え方である (図11)。

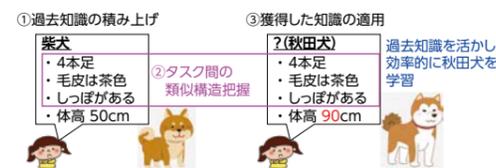


図11 転移学習の概念
Fig.11 Concept of Transfer Learning

転移学習を寿命推定に適用する手順は、①リフトAの観測データからモデルを作成する。具体的には標準化偏回帰係数を求める。②リフトAと他リフトの類似性を比較・分類し、同属性のリフトを選定する。③リフトAと同属性のリフトのデータを用いて、リフトAのモデルを更新する。これにより単独観測データで作成したモデルよりも精度の良いモデルが期待される。転移学習の課題は、同属性が取り扱う問題設定ごとで異なり形式的に定義できず個別に定義が必要な点である。我々は観測データ波形の類似性に着目し動的時間伸縮法 (DTW: Dynamic Time Warping) により得た類似度を階層クラスタリング手法により分類し同属性の定義を行った。この手法で同属性の自動判別が可能になった。DTWはペアとなる時系列データの類似度を測定する手法で、時間軸方向にずれが生じている場合にも類似と判断できる点に特徴がある。ある変数を例にリフトA対C、リフトA対BでDTWの類似度を計算した結果を示す (図12)。DTW計算値が小さいほど類似度が高いことを意味し、A対Cの方がA対Bより類似度が高く、目視で波形を比較した感覚と一致している。

リフトA 対 リフトB DTW計算値=4600 類似度小
リフトA 対 リフトC DTW計算値=8 類似度大

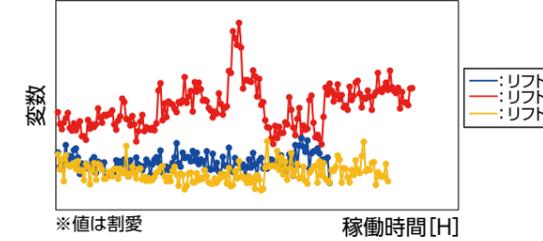


図12 DTWの概要
Fig.12 Example of DTW

次にDTWで計算したペア間の類似度の結果を元に階層クラスタリングにより、同属性のグループを作成した。同属性グループを作成するメリットとして1対1のペアで転移学習を行うと知識の偏りによる精度悪化が懸念されるがグループ内の複数データにより偏りを低減できる。同属性のリフトのデータを用い転移学習を行った結果を図13に示す。予測精度改善が確認された。

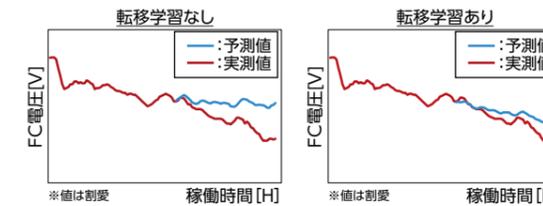


図13 転移学習の効果
Fig.13 Effect of Transfer Learning

今後は、本構築手法をクラウド上の解析環境へ実装し、実証を進める予定である。

4 仕分け・積み付けアルゴリズム

物流センターでは製造元などの仕入先から入荷した商品を顧客の注文に応じ、品目、数量ならびに仕向け先ごとに商品を組み合わせ、梱包して出荷を行っている (図14)。

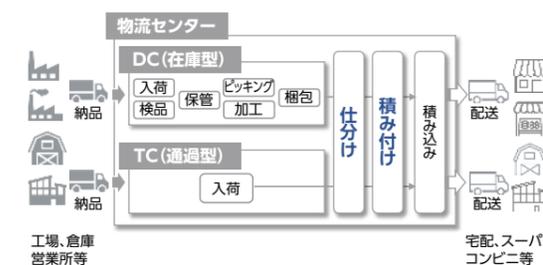


図14 物流センターの工程
Fig.14 Logistics center Process

物流センターには商品の保管機能を持つDC (Distribution Center) と持たないTC (Transfer Center) があるが、いずれの形態でも顧客ごとの商品組合せを決める仕分け・積み付け工程は必要な重要工程である。

物流ソリューション事業室では物流センターで扱う荷物量の増加に対応するため、効率的な仕分け・積み付け作業を自動で行う垂直搬送機と積付機の適用を検討している (図15)。物流センターの単位時間あたりの荷物処理量 (以下、スループットと記載) を高めるためには、システム全体の最適化とともに使用される各機器の能力を最大限に引き出す制御が重要である。ALラボでは垂直搬送機と積付機を最適に制御するアルゴリズムを構築した。

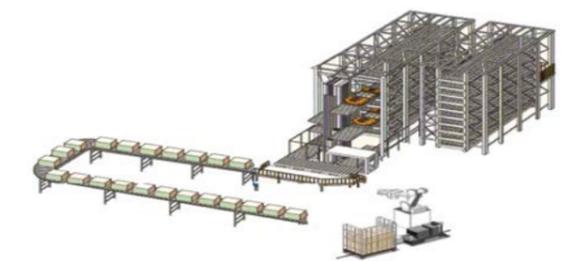


図15 垂直搬送機と積付機の運用例
Fig.15 Example of Vertical Transport Machine and Stowage Machine

1) 垂直搬送機の最適化

多階層型の自動倉庫では、搬入コンベアにより運ばれてきた荷物を保管棚へ格納するために、垂直搬送機を設置するケースがある。荷物は、垂直搬送機を通してあらかじめ決められた階の棚へ搬送される。垂直搬送機は、交互作動式で、図16のように左右と上下移動を繰り返すことで、複数の荷物を同時に動かせるため、高い搬送能力を期待できる設備である。ただし、高い搬送能力を実現するためには、垂直搬送機内の荷物位置および搬送先の階を考慮した上で、膨大な左右と上下移動の組合せの中から、最適な組合せを導出することが求められる。

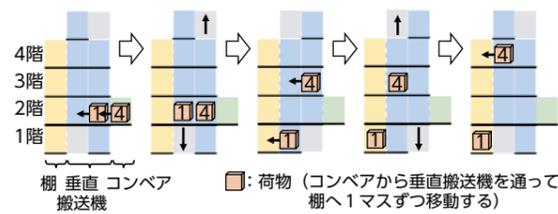


図16 荷物搬送の動作例
Fig.16 Example of container transfer operation

多くの組合せ問題は、SAT (Satisfiability) 問題として表現できることが知られている。SATは与えられた命題論理式を真にする値割当てが存在するか否かを判定する問題となる。SATを最適化問題に拡張したMaxSAT (Maximum satisfiability)^[7]を用いて、左右と上下移動の移動組合せを求める。世界初(当社調べ)となる搬送機の荷物移動を命題論理式で記述して、最適な組合せを高速に算出可能な手法を開発した。^{[8][9]}

高速性を評価するために、計算時間を従来手法のA*アルゴリズム^[10]と比較した。図17の結果を確認すると、荷物数1から3までは従来手法の方が高速に算出できる。しかし、荷物数4以上では、MaxSATの方が高速に算出でき計算時間の増加が大幅に抑えられている。

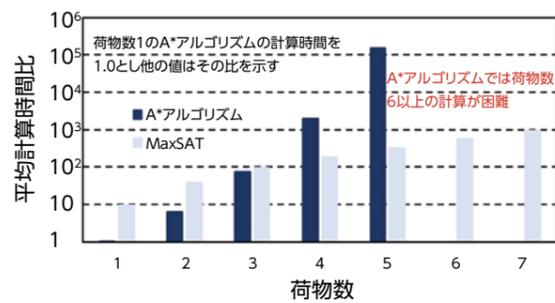


図17 計算時間の比較結果
Fig.17 Comparison results of computation time

2) 積付機の最適化

積付機は垂直搬送機から出された荷物をロールボックスと呼ばれる棚付き台車(以下、RBと記載)に積み付ける装置である(図18)。



図18 荷物積付の動作例
Fig.18 Example of container stowage operation

積付機は複数の荷物を、RBの棚に1段ずつ入れる動作を繰り返すため、1つの棚に入る荷物数を最大化して棚段数を最小化することがスループット最大化につながる。そこで、1つの箱に複数荷物を入れて箱数を最小とする組合せ最適化問題の1つのビンパッキング問題を解くこととした。RBに荷物を積み付ける全組合せは、(RB数×棚数)²(荷物数)となり荷物数が増えれば計算量は膨大となる。計算時間も実運用上重要であるためビンパッキング問題のヒューリスティックな解法であるFirst Fitの適用を検討した^[11]。

解の精度と高速性を評価するため、厳密解の分枝限定法と準最適解の列生成法の2手法と比較した。分枝限定法は、本問題をすべて定式化した整数計画問題を解く解法で、厳密解が得られる。列生成法は、整数計画問題から制約を緩めた線形緩和問題の解法で、準最適解が得られる。^[12]

提案のFirst Fitは厳密解の97%のスループットを達成できるとともに高速に算出できる可能性を示した(図19)。

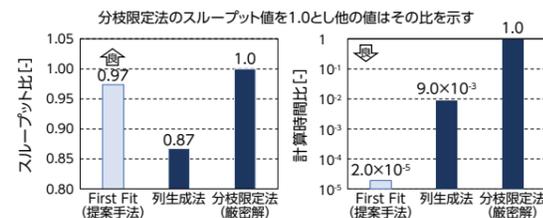


図19 スループットと計算時間の比較結果
Fig.19 Comparison results of throughput and computation time

今後もさまざまな物流機器に対し、機器に適した最適化手法の適用を検討していく予定である。

参考文献

[1]産総研ホームページ
 [2]Marius Cordts, Mohamed Omran, Sebastian Ramos, Timo Rehfeld, Markus Enzweiler, Rodrigo Benenson, Uwe Franke, Stefan Roth, and Bernt Schiele. The cityscapes dataset for semantic urban scene understanding. In IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pages 3213-3223, 2016. 1, 6, 12
 [3]Jia Deng, Wei Dong, Richard Socher, Li-Jia Li, Kai Li, and Li Fei-Fei. Imagenet: A large-scale hierarchical image database. In IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), pages 248-255, 2009. 1
 [4]Hirokatsu Kataoka, Kazushige Okayasu, Asato Matsumoto, Eisuke Yamagata, Ryosuke Yamada, Nakamasa Inoue, Akio Nakamura, and Yutaka Satoh. Pre-training without natural images. International Journal of Computer Vision (IJCV), 130(2):990-1007, 2022. 2
 [5]Hirokatsu Kataoka, Ryo Hayamizu, Ryosuke Yamada, Kodai Nakashima, Sora Takashima, Xinyu Zhang, Edgar Josafat Martinez-Noriega, Nakamasa Inoue, and Rio Yokota. Re- placing labeled real-image datasets with auto-generated contours. In IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), pages 21232-21241, June 2022. 2,3,4,5,7,8,11
 [6]NIPS 2005 workshop — inductive transfer: 10 years later.http://iitrl.acadiau.ca/itws05/
 [7]Biere A., Heule M., Maaren v. H., and Walsh T., eds.: "Handbook of Satisfiability - Second Edition," Frontiers in ArtificialIntelligence and Applications 336, IOS Press (2021)
 [8]越村三幸, 野田五十樹: "垂直搬送機の MaxSAT による最適スケジューリング", スケジューリングシンポジウム 2022
 [9]岡本和也, 小出幸和, 越村三幸, 野田五十樹, 垂直搬送機のスケジューリング問題に対するMaxSATの適用, 人工知能学会論文誌, Vol.39, No.2, (2024)
 [10]加納政芳, 山田雅之, 遠藤守: "人工知能原理", コロナ社 (2017)
 [11]久保幹雄: "Pythonによる実務で役立つ最適化問題 100+(3)", 朝倉書店
 [12]宮本裕一郎: "初めての列生成法", 日本オペレーションズ・リサーチ学会機関誌, Vol.57, No.4, (2012)

著者紹介



横町 尚也 前 伸一 菊池 駿介 岡本 和也



松浦 慶伍

開発の経緯と開発者の思い

荷姿異常検知はさまざまなお客様の環境で荷姿が大きく異なり安定して荷役するためには事前に荷物状態を把握する必要があることがわかり開発が始まりました。荷姿を高精度に検出することは困難でしたが、数式画像による事前学習を取り入れることで解決できました。

寿命予測技術は精度向上に対して手持ちの全データを学習させる試みが多いですが、今回は様々なお客様のデータを混ぜてしまうと精度悪化する点が困り事でした。設計者と議論を行い使い方が類似なデータの存在に気づくことができ属性の定義へとつながりました。

仕分け・積み付けアルゴリズムは最適な動作を実現するために設計者・研究者と実物見学、動画や図面を基にした議論を重ね目的関数や制約の定式化を行うことで最適化手法を構築することができました。

TICO/産総研と連携し、製品サービスに貢献できる研究開発を進めてまいります。