

AIの活用と部品表生成の自動化による特型フォークリフト設計の効率化

Design Efficiency of Special-Design Forklift Truck Using AI and Automatic BOM Generation

雨宮 良之^{*1} 小紫 浩史^{*1} 鈴木 亮司^{*1} 杉浦 保彦^{*2}
 Yoshiyuki Amamiya Hiroshi Komurasaki Ryoji Suzuki Yasuhiko Sugjura

*1 トヨタL&Fカンパニー 製品開発センター CS開発部 *2 ITデジタル推進本部

要旨 顧客個別仕様のフォークリフト(以下、特型フォークリフト)は受注後に都度設計を行っている。お客様要望の納期で出荷していくためには、設計の効率化が必要である。我々はAIを用いて、設計の参考とすべき過去の設計案件の検索時間を短縮した。さらに、検索結果から部品表を生成するシステムを構築し、特型フォークリフト設計の自動化を実現した。

キーワード: 特型フォークリフト、設計効率化、AI、k近傍法、自動設計、基幹システム連携

Abstract Customer-specific forklift trucks (special-design forklift trucks) are designed each time after each order. Efficient Design of forklift trucks is necessary to meet requested delivery time. We have reduced design time by using artificial intelligence (AI) to search for previous related designs. Additionally, we have created a design system that generates BOM from related designs, and have realized automatic design.

Keywords: Special-Design Forklift Truck, Design Efficiency, Artificial Intelligence, K-Nearest Neighbor Algorithm, Automatic Design, Core System Cooperation

1 はじめに

1.1 特型フォークリフト

フォークリフトは物流現場で使用される車両である。物流現場の要望は様々であり、メーカー標準設定のオプションでは対応できないお客様もある。我々はそのご要望にきめ細かく応えるために、顧客個別仕様のフォークリフト(特型フォークリフト)の受注設計を行っている。

標準的なフォークリフトの設計情報は基幹システム上に部品表として存在し、部品はかんばん方式で製造現場に準備されている。これに対して、特型フォークリフトは、引合いの都度、お客様の要望内容を確認して、特別な仕様の車両を設計・生産する。このため、受注後出荷までの期間は標準的なフォークリフトに対して長い。お客様要望の納期で出荷していくために、設計・生産、それぞれの工程でリードタイム短縮の努力をしている^[1]。

1.2 特型フォークリフト設計の課題

図1に特型フォークリフト設計の業務フローを示す。

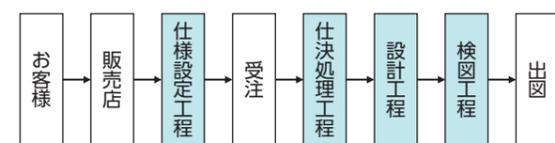


図1 特型フォークリフト設計の業務フローのブロック図
 Fig.1 Block Diagram of Special-Design Forklift Truck Design Process Flow

1) 仕様設定工程

まず、仕様設定工程でお客様の要望に対する対応可否を検討する。対応可の場合は、販売店から寄せられる依頼を、特型名称という仕様に分解して回答する。例えば、「お客様保有の他社機台と同じ仕様でお願いします。」という依頼に対して、「フォーク長さ2200mm」「マスト揚高6000mm」「黄色回転灯ウエイト上部取付」という標準車にオプションのない3つの特型仕様の設定を回答する。特型仕様は一つのこともあるが、複数の特型仕様の組合せとなることが多い。図2に特型フォークリフトのイメージを示す。

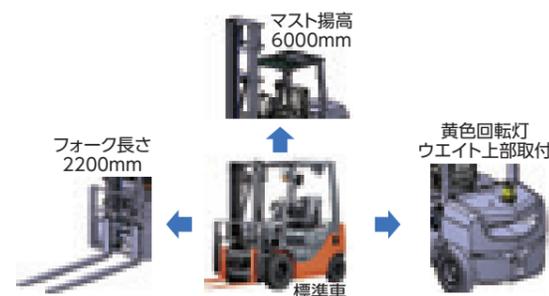


図2 特型フォークリフトの事例
 Fig.2 Examples of Special-Design Forklift Truck

2) 仕決処理工程

仕様、価格、納期が要望を満たして受注すると、仕決処理工程に入る。ここで仕決とは、機種やオプションや特型仕様など、受注案件に関する受注情報一式のことをいう。仕決処理工程では、受注案件の特型仕様を過去に設計したことがあるかどうか

を調査し、設計の難易度などを検討して、設計が必要な案件について設計着手を指示する。

3) 設計工程

それを受けて設計工程ではあらためて、今回の設計に流用できる過去の設計実績はないか、参考にできるものはないかを、それぞれの特型仕様ごとに検索する。流用できるものがあれば、図面を作成する必要はなく、部品表のみで必要部品を指示することができる。流用できるものがなければ、過去の案件を参考にして、新規に図面を作成することになる。それぞれの特型仕様ごとにこれを行い、それらを組み合わせることで設計作業は完了する。図面作成のない、部品表構成の組合せのみの案件も多いので、検索作業と部品表構成作業は、設計時間の中で大きな割合を占めることになる。

4) 検図工程

その後の検図工程でも検索作業は行われる。過去の設計実績は数万件と膨大であり、一つひとつの特型仕様に対して、多数の設計実績がある。それら設計実績の設計内容は一つだけとは限らない。機種やオプションなど、受注情報の様々な要素が複雑に影響を及ぼす結果、一つの特型仕様に対して設計の種類は複数存在することが多い。検索された多数の設計実績の中から、今回の設計に最適なものを選択するにはノウハウが必要である。最適なものが選択され、今回の設計が正しい内容となっていることをベテランの目で確認する。全ての特型仕様についてこの作業を繰り返す。

5) 課題

以上、4つの工程を経て、特型フォークリフトの出図は行われる。業務フローの中で検索作業が繰り返し行われ工数がかかっていること、検索にはノウハウが必要であること、設計時間の中で部品表構成作業に工数がかかっていること、これらが特型フォークリフト設計の課題である。

2 AIによる過去特型実績検索

特型フォークリフト設計の課題には、従来、ルールをベースにした論理的な手法で対応し、さまざまな改善をしてきた。しかしルールベースだと、この検索の課題に対しては、ルールが複雑になり過ぎて対応できない。そこで我々は実用化が進むAI/機械学習の活用を着想した。

過去の受注情報や部品表情報は、整理された形で基幹システムの中に膨大に蓄積されており、構造化されたビッグデータといえる。機種やオプションなどの受注情報を説明変数とし、設計実績である部品表情報を目的変数として機械学習することはできないかと考えた(図3)。

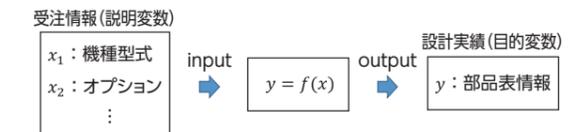


図3 説明変数と目的変数
 Fig.3 Explanatory Variable and Objective Variable

まず、主力車種の限定されたデータを使ってAIモデルを作成した。基幹システムより受注情報と部品表情報を抽出し、クレンジングして学習用データとして整備して、説明変数・アルゴリズムの検討、モデル製作、性能評価というサイクルを回してAIモデルを作成した。受注情報の中から、実際の設計作業で設計者が重視している項目の順に説明変数の候補として検討し、その組合せの最適化、各変数につける重み係数を最適化して、モデルの精度はクロスバリデーションで検証した。

最終的にAIのモデルは2つとなった。フォークリフトの部位により設計担当グループが異なっており、それぞれの設計の作業手順に対応したモデルとなった。説明変数はそれぞれに5つとなった。機種やオプションなど、ベテラン設計者が重視している項目が変数に選ばれた。実際の作業内容に対応した、ベテラン設計者の検索ノウハウが盛り込まれたAIモデルとなった。

2.1 AI手法

今回採用したAIの手法はk近傍法という。特徴空間中でインプットデータに最も近いものを探すというアルゴリズムである。受注情報を次元とする空間の中に、過去案件の設計実績である部品表情報がプロットされており、そこに新たに入ってきた今回設計する受注案件の最近傍となる過去案件を探す。その探索のイメージを図4に示す。図では3次元空間になっているが、実際には高次元空間である。k近傍法はディープラーニングなど他のAI手法と比較して、モデルの説明力が高い。ブラックボックスにならないので、モデルの改良がしやすく、検索結果を利用する設計者にとって心理的に受け入れられやすい手法といえる。

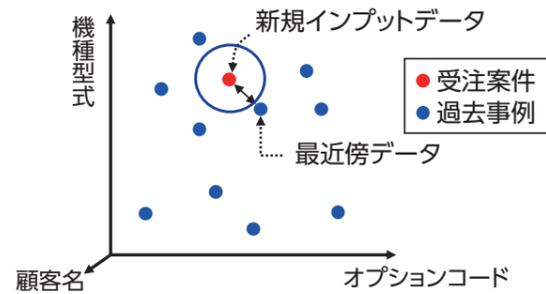


図4 k近傍法のイメージ
Fig.4 Image of k-Nearest Neighbor Algorithm

2.2 データ処理手法

さまざまなタイプのデータである業務情報を取り扱うには、適切なデータ処理が必要である。例えば、重要な情報の一つにオプションコードがある。特定の特型仕様を設計する際に特定のオプションコードが影響することがあり、同じ特型仕様でもオプションコードによって設計内容が異なることがある。それぞれの案件にはオプションコードが複数あるので、案件間のオプションコードの類似度を数値化するには工夫が必要である。この数値化にはジャカード係数を用いた(図5)。案件を集合、そのオプションコード一つひとつを集合に含まれる要素とみなし、2つの集合に含まれる共通要素の占める割合を計算して数値化した。

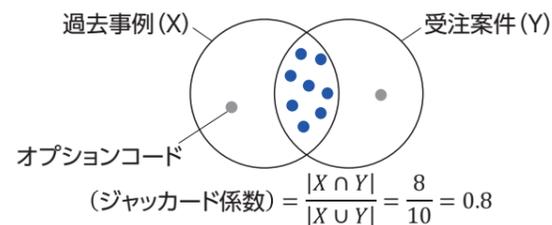


図5 ジャカード係数
Fig.5 Jaccard Index

顧客名もまた、重要な情報である。同じ特型仕様であっても、顧客違いで異なる設計になることがある。一方、顧客名のデータには表記にゆらぎがあり、完全には名寄せができていない。逆に、似た名前の関連会社向けに、同じ設計をしていることもある。文字列間の類似度はレーベンシュタイン距離を用いて数値化した。レーベンシュタイン距離とは、1文字の挿入・削除・置換によって、一方の文字列をもう一方の文字列に変形するのに必要な手順の最小回数として定義されるものである。

「豊田自動織機」から「トヨタ自動車」の距離算出

0. 豊田自動織機
1. ト田自動織機 (「豊」を「ト」に置換)
2. トヨ自動織機 (「田」を「ヨ」に置換)
3. トヨタ自動織機 (「タ」を挿入)
4. トヨタ自動車機 (「織」を「車」に置換)
5. トヨタ自動車 (「機」を削除)

レーベンシュタイン距離 = 5 (ステップ数)

図6 レーベンシュタイン距離
Fig.6 Levenshtein Distance

2.3 業務知識の活用

k近傍法で最近傍の候補となったものでも、業務知識から判断すると候補となりえないものもある。図7に部品表のイメージを示す。標準車の部品表情報は基幹システムの中に存在し、受注したタイミングでその案件の標準車としての部品表構成は既に確定している。都度設計である特型の部品表は、その標準車の部品表構成の一部を削除して、今回設計する特型部分を追加する形で構成する。同じ特型仕様の案件でも、標準車部品表から削除する部分の構成が異なるものは、追加する部分の構成も異なり、違う設計になることが多い。候補となったもののうち、削除対象部分の部品表構成が今回の受注案件と異なるものを、候補から除外するロジックを取り入れた。このように業務知識を活用することでモデルの精度を向上させることができた。

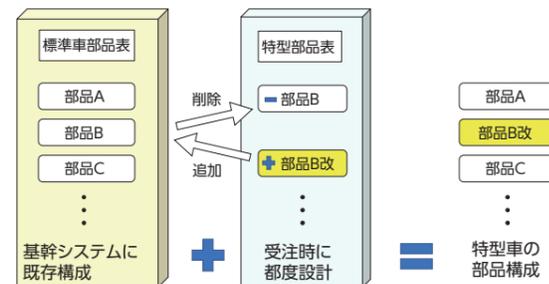


図7 標準部品表と特型部品表
Fig.7 BOM of Standard Parts and Special Design Parts

逆に、ある特型仕様で候補がなかった場合でも、似たような名称の特型仕様で候補があれば、その案件は設計する際の参考にすることができる。候補がない場合は、レーベンシュタイン距離を用いて類似した特型名称を選定して、その設計実績から参考にできる候補を検索するロジックを取り入れた。

2.4 検索精度

主力車種の限定されたデータで作ったAIモデルでコンセプトの正しさのあたりをつけ、その後、業務知識を活用した改良を加え、対象データを拡大して再度検索精度の検証を行った。最終的な精度検証結果を表1に示す。第1候補が正解となる確率は83~86%で、第5候補までに正解が存在する確率は95~98%となった。実用上十分な精度が得られることを確認した。

表1 AIモデルの検索精度
Table.1 Evaluation Results of AI Model

車種	検索精度					
	部位A			部位B		
	第1候補	第3候補まで	第5候補まで	第1候補	第3候補まで	第5候補まで
車種A	86%	96%	98%	84%	91%	96%
車種B	84%	92%	95%	83%	93%	98%

作成したAIモデルの検索精度が、将来にわたって維持されるかということも確認しておく必要がある。過去のある期間のデータでAIモデルを作成し、そのモデルの検索精度が、その過去6年間の期間でほとんど変化のないことを確認することで、将来の検索精度が維持されることを予測した。

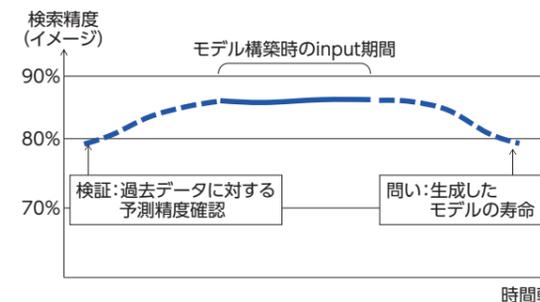


図8 将来の検索精度の予測
Fig.8 Prediction of accuracy of AI Model in the future

3 部品表生成の自動化

3.1 AIモデルのシステム実装

課題である過去データの検索工数や部品表構成工数の削減をねらいに、今回作成した過去特型実績検索のAIモデルを活用したシステムを開発した。AIモデルと基幹システムとの連携構成を図9に示す。

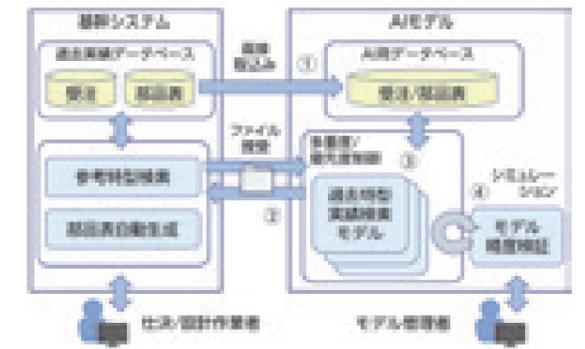


図9 基幹システムとAIモデルの連携構成図
Fig.9 Combination Structure of the Core System and AI Model

1) AI用データベースの構築

AIで利用する受注および部品表の実績データは、基幹システムのデータベースで管理されているが、今回必要となる情報のみを抽出しAIのために最適化した専用のデータベースを新たに構築した。基幹システムの実績データは日々蓄積されるため、検索精度を維持するにはAI用データベースも日々最新化し鮮度を保つ必要がある。対象のデータ量、更新頻度、開発費用や運用負荷等を総合的に判断し、今回は差分更新ではなく日次の全件データ洗い替え方式を採用した(図9.①)。

2) AIモデルと基幹システムとの連携

今回作成したAIモデルに対し、統計解析ソフトウェアおよびプロセス自動化ソフトウェアを組み合わせ、基幹システムから呼び出せるようにした。基幹システムとの連携はCSVファイルを使った授受で行い、システム間を疎結合とした。新規の受注情報を格納したファイルを基幹システム側で生成すると、それを自動検知しAIモデル側で過去実績検索結果を求め、基幹システムへ返すというプロセスになる。この一連のプロセスは通信ソフトウェアで処理制御できるため、基幹システムおよびAIモデルの影響や開発量を最小化した(図9.②)。

3) 多重度・優先度制御による検索レスポンス確保

業務ピーク時には過去実績より大量(60件/15分)の検索を処理する必要があるため、複数プロセスを同時に処理できるように多重度制御機能を実装した。検索レスポンスを一定以上確保するため、余裕率(1.5倍)を考慮した件数(90件/15分)に対し、1件あたりの処理時間と全体の処理時間を両立できる多重度数をシミュレーションにより求め

最適値を決定した。さらに、新規検索(システムが自動実行)と再検索(作業者が条件変更して手動実行)において、業務ピーク時でも作業者が再検索で長時間待たされずに処理されるよう優先度制御機能も実装した。これらにより全体の検索レスポンスをバランス良く確保できるよう工夫した(図9.③)。

4) モデル精度のシミュレーション

AIモデルの精度を維持するため、検索結果データと実際の設計データを比較し精度を算出する機能を実装した。算出結果の精度が低かった場合に、モデルに定義している説明変数の割合を変更しながら精度をシミュレーションできるようにした(図9.④)。

3.2 基幹システムの改修

従来の基幹システムでは、作業者は受注した特型仕様ごとに1件ずつ過去特型実績をデータベースより検索し、類似性や構成上問題がないかの確認をするという操作を繰り返すことで最適な候補を探していた。さらに仕様ごとに部品表を組み上げる操作も行う必要があり、大変多くの工数がかかっていた。そこで、参考特型検索機能と部品表自動生成機能を新たに実装した。

1) 参考特型検索機能

基幹システムにおいて仕決処理開始とともに、今回システム化したAIモデルを自動実行し、検索結果を画面表示する機能を実装した。検索結果画面のイメージを表2に示す。過去実績の検索結果として、新規受注した特型仕様ごとに確信度が高い順に1位から5位までの候補を参考情報として表示する。また、新規受注と検索結果である各候補の受注情報や部品表情報の詳細を比較・確認する画面も合わせて実装した。

作業者は、確信度の高い上位5位までの候補を自動で入手でき、詳細情報を比較・確認し効率的に正解を求めることができるようになった。

表2 基幹システムの参考特型検索結果表示
Table.2 Display of Search Results for Reference Special Design in the Core System

参考特型検索結果 凡例						参考案件No 確信度/採用率
No	特型仕様	1位	2位	3位	4位	5位
1	フォーク長さ 2200mm	AAAA 90%/90%	BBBB 80%/80%	DDDD 70%/70%	FFFF 60%/60%	HHHH 50%/50%
2	マスト揚高 6000mm	AAAA 85%/90%	BBBB 75%/80%	EEEE 65%/70%	CCCC 55%/60%	JJJJ 45%/50%
3	黄色回転灯ウエイト 上部取付	AAAA 90%/85%	CCCC 80%/75%	BBBB 70%/65%	GGGG 60%/55%	KKKK 50%/45%

2) 部品表自動生成機能

参考特型検索機能にて得られた結果をもとに、部品表構成情報を生成し、その論理的整合性のチェックも同時に自動実行する機能を実装した。作業者はシステムが1位の候補の組合せで自動生成した部品表を受け取り、5位までの候補と内容を比較・検討し、必要に応じ組み替えて部品表を構成する。また、部品表構成情報の詳細内容の確認・微修正や、設計上留意すべき特記情報を確認する画面も合わせて実装した。作業者は、システムが自動で収集・作成した部品表構成情報や特記情報を確認・微修正することで、効率的に部品表を完成させることができるようになった。

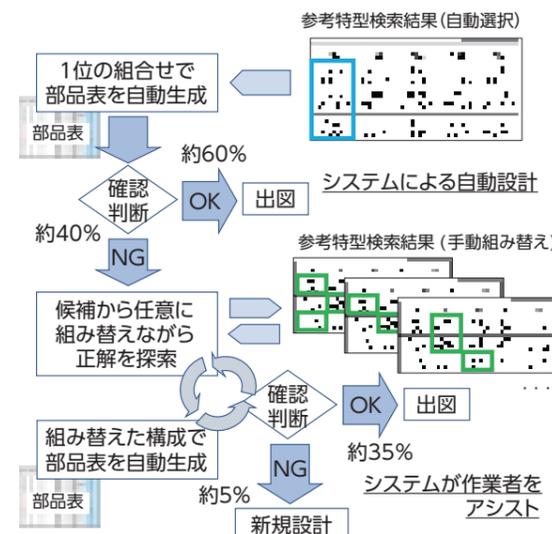


図10 部品表生成と設計自動化のイメージ
Fig.10 Image of BOM Generation and Design Automation

3.3 システム化による効果

基幹システム改修後の数か月間の運用において約3,000件の特型設計に適用され、過去特型実績検索結果(1位~5位)の正解率は95%以上となり、想定通りの精度を確認できた。その結果、仕決・設計・検図工程における検索工数や、部品表構成工

数など、付随効果も合わせて年間約20,000時間相当の工数削減効果を得ることができた。また、検索レスポンスについても多重度・優先度制御が有効に機能し、良好な結果であることを確認した。

約60%の受注については、1位の候補の組合せでシステムが自動生成した部品表で出図した。設計者はその内容を確認するだけで実際の設計作業はしておらず、システムによる自動設計を実現した。

4 まとめ

特型フォークリフトの設計作業で繰り返し行われる過去の設計実績の検索にAI/機械学習を活用し、誰でも簡単に高精度な検索ができるシステムを開発した。さらに、検索結果から部品表を自動で生成する機能を実装することで、設計の自動化を実現した。

今後は、モデル精度の維持向上を行うとともに、データの持ち方や業務の進め方そのものを見直すなどして、実装した機能の活用を推進していく。また、機能の応用や活用範囲の拡大、社内改善業務への展開なども検討していきたい。

最後に、本開発にご協力いただいた、(株)豊田自動織機ITソリューションズ、日本アイ・ビー・エム(株)、富士通(株)をはじめとする社内外の関係者の皆様に、厚くお礼申し上げます。

参考文献

- [1]小紫浩史、鈴木亮司、塚原俊英: 機械学習を活用した受注成否予測による特型フォークリフトのリードタイム短縮、豊田自動織機技報 No.71 (2020)
- [2]「特殊フォークAI活用」『日刊工業新聞』、2021年7月6日、1/28面

著者紹介



開発の経緯と開発者の思い

お客様が必要とする納期に特型フォークリフトをお届けするためには、設計リードタイムの短縮をすることがとても重要です。このリードタイム短縮を検討する中で、特型フォークリフトの中でも既に設計済みの部品を流用して組み合わせるだけで設計可能な点に着目しました。

既に金融関係のヘルプデスクや生産現場の検査工程等でデジタルトランスフォーメーション(DX)されておりますが、過去の膨大な設計情報の中から正確に必要な部品表を抽出するにあたり、それらの技術を応用できないかと考えて開発をスタートしました。しかし、言うは易く行うは難しで、高い精度で正しい部品表を抽出するには、単なるAIや機械学習の手法を用いるだけではなく、多くの設計者の設計手法の考え方を採り入れて精度向上に努めることにより、本システムの実現に至ることができました。

本システムは限定的な機能ですが、設計という創造的な業務をDXするという他には類がない新しい取り組みであったと思います。今後は部品表構成のみの設計は自動で部品表を生成し、設計者はよりクリエイティブな設計に注力できるようになることを期待しています。