

故障診断へのAI適用による 修理サービスの効率化

Efficiency Improvement of Repair Services by Applying AI to Failure Diagnosis

● 日下治久

● 宗意幸子

あらまし

製造業においては、自社製品の製造・販売だけではなく、販売後に故障した製品の修理を行うことも重要である。富士通の大手製造業のお客様では、顧客から年間数十万件から百万件程度の出張修理の依頼があり、修理サービスの効率化が経営課題となっている。この効率化に向けては、故障診断の際にできる限り過不足なく補修部品を選定することが特に重要である。しかし、そのための修理ナレッジの整備は、技術員のノウハウに依存した属人的な色合いが濃いため非常に困難である。そこで筆者らは、修理情報システムに大量に保存されている修理実績データに機械学習を適用し、AI(人工知能)化させることによって、故障の症状に応じた適切な部品を高い精度で推定できる故障診断用の学習モデルを構築した。そして、実証実験で精度を検証した結果、最頻出の主要10部品中6部品において、人間による平均選定精度を上回る正答率を得ることができた。

本稿では、今回の実証実験によって確認した故障診断のAI化手法と適用効果、およびAIの更なる精度向上に向けた取り組みについて述べる。

Abstract

In the manufacturing industry, repairing failures of products caused after their sale is also important in addition to the production and sale of the products. Fujitsu's major customers in manufacturing receive over several hundred thousand to a million requests for on-site repairs from customers annually. Improving the efficiency of repair services is a business issue. To improve efficiency, identifying required repair parts to fix the problems at the time of failure diagnosis is the key. However, gathering and organizing repair knowledge is extremely difficult because the knowhow tends to depend on the skill of individual engineers and has unique characteristics. We have developed a learning model for failure diagnosis that enables suggesting which parts are required to fix the problems with great accuracy in response to detected failures by applying machine learning to the large volume of historic repair data saved in the repair information system and turning it to artificial intelligence (AI). As a result of a verification test for accuracy, we have achieved a higher percentage of accuracy with AI on six out of ten major parts, which were most frequently repaired, than the average of accuracy suggested by the engineers. This paper describes the technique how to adopt failure diagnosis information, which has been verified by the demonstration test, to AI, the effect of the application, and an approach for further improvement of AI accuracy.

ま え が き

製造業においては、製品の修理サービスが不可欠である。富士通の大手製造業のお客様も、製品の出張修理件数が年間数十万件から百万件程度に及び、多くの人的資源の投入や非常に多種の補修部品調達を必要とされている。このため、製造業では修理サービスにおける品質向上および業務の効率化が求められる。修理サービスは、初回訪問で対処を完了することが理想であり、そのためには訪問前に故障診断による最適な部品・手配が重要となる。この故障診断の精度を高めることが鍵となる。

製造業各社は、長年にわたって修理ナレッジの構築などを行い、故障診断の精度向上に取り組んできた。しかし、過去の膨大な修理実績データの中から、人間が故障の症状と対処を的確に抽出することは困難である。加えて、故障には想定外の事象が発生するケースもあり、修理ナレッジの整備と鮮度維持は非常に負荷が高い。

そこで筆者らは、修理実績データに機械学習を適用し、AI（人工知能）化させることによって、故障の症状に応じた適切な部品を高い精度で推定できる故障診断用の学習モデルを構築した。

本稿では、修理サービスにおける故障診断用学習モデルの実証実験結果およびAIの更なる精度向上に向けた取り組みについて論じる。

修理サービスの課題

修理サービスの効率化は、製造業の共通な課題となっている。一方で、修理サービスはお客様満足度や企業イメージへの影響が大きく、サービス品質の向上も必要である。修理サービスの効率化とサービス品質向上の観点においても、初回訪問における対処完了が求められる。しかし、初回訪問時の対処完了を重視しすぎると、使われる可能性が低い部品を余分に手配することになり、部品の返品コストや在庫の増加によって逆に非効率化を招いてしまう。

出張修理では、初回訪問で対処が完了する割合の「初回解決率」と、手配した部品のうち実際に使った部品の割合の「部品利用率」が評価の指標になる。この二つは、重要なKPI（Key Performance

Indicator）であるが、相反する関係にあるため両立が非常に難しい。そのため、両指標を考慮した最適な部品選定、すなわち上述した故障診断の精度を高めることが重要である。

製造業の修理サービスでは、故障診断における部品選定精度の向上に向けて各社がナレッジの構築・整備に取り組んできた。しかし、修理ナレッジの整備においては、症状に応じた適切な部品選定が必要であることから、組み合わせのバリエーションが非常に多く難易度が高い。例えば、修理ナレッジの整備には高度な故障診断ノウハウに基づく対応事例の作成や、多数のマスタデータ（症状マスタ、処置マスタなど）のメンテナンスに多くの工数がかかってしまう。その結果、修理ナレッジは陳腐化し、故障診断ノウハウの属人化といった悪循環に陥ってしまう。

故障診断にAIを適用するための仕掛け

修理情報システムには、修理実績として故障診断の正解が記録に残っているが、従来はこの情報を活用することが非常に困難であった。その理由は、症状コード（故障箇所の症状を表す項目）の粒度がネックとなっていたからである。症状コードの粒度が荒過ぎるとデータ構造の関係もあり、必要部品を絞り込めない。また、症状コードの粒度を判定できるレベルにすると症状コードの種類が膨れ上がってしまう。

そこで筆者らは、修理実績データには、症状コードのほかにいくつかの項目に症状に関する情報がテキストで入力されていることに着目した。全ての修理案件の実績は、修理を担当する技術員の修理完了報告という形で記録されている。この中に部品選定に必要な情報（特徴的なワードなど）があれば、機械学習を適用して故障診断の部品選定に活用できるのではないかと考えた（図-1）。これにより、部品選定精度を高いレベルで平準化し、属人性を排除した持続的な修理ナレッジの鮮度維持も実現できる。次章以降で、AIを用いて修理に必要な部品を推定するために構築した故障診断用の学習モデル（以下、故障診断AI）の実証実験について述べる。





図-1 修理サービスの概略



DARPAの「Explainable Artificial Intelligence (XAI)」⁽¹⁾に掲載の図を基に作成

図-2 機械学習の概要

予備調査の実施

故障診断AIの実証実験の前に、予備調査を行った。予備調査の目的は、使用データとして想定している修理実績データが、機械学習の教師データとして有効であることをお客様に説明し、故障診断AIの実現性・有用性を納得いただくことである。

そのため、予備調査で用いる手法は、少量のサンプルデータでも実行可能で、判定結果の説明可能性が高いことが重要となる。つまり、図-2に示すように、ディープラーニングのように予測精度は高いが、何を特徴量として学習したか分からず説明可能性が低い手法は、予備調査には不向きであると考えた。そこで、推定結果の精度よりも推

定プロセスの説明可能性を優先し「決定木」という手法を採用した。この手法はディシジョンツリーとも呼ばれ、データを分類する質問をノード（節）とし分類結果をリーフ（葉）とする木構造の図を作り出し、部品推定に寄与する項目を可視化できる。

予備調査の詳細を以下に示す。

(1) 分析用オリジナルデータの作成

修理情報システムのデータは、修理受付から部品手配、技術員による修理対応内容まで、一連の業務プロセスの情報が複数テーブルに蓄積されている。このデータ一式から、分析の入力となるデータを作成する前処理が必要である。キー項目により複数テーブルを結合し、全ての項目の位置付け

と内容を理解した上で、分析に不要な項目を削除し、必要最小限の分析用オリジナルデータを作成した(図-3)。

(2) データ観察

分析前に、サンプルデータに対して簡単な集計と基本的な統計処理を行い、データの傾向を確認しなければならない。また、機械的な処理だけではなく、人の目でデータを俯瞰し、形式と内容の両観点でデータをチェックする必要がある。今回のデータ観察では、データの仕様書上は各項目に合った値が入っていることになっているが、実際には空白の項目や、指定以外の値が入っている項目が発見された。「補足」「備考」のような自由に記入できる項目は、テキストで書かれている内容の記載レベルや表現形式などにより、活用可否や活用の仕方が決まってくるため、集計や統計処理だけでなく、人の目によってデータ全体を確認することが重要になる。

(3) 故障診断における部品推定処理

AIが出力すべき項目を目的変数(今回は必要部品に当たる)と言い、その目的変数と相関があり推定処理の入力となる項目を説明変数と言う。予備調査では、必要部品を推定する際、どの項目が有用な説明変数になるかを検討しながら、説明変数を入れ替えて繰り返し推定処理を実行した。これは、推定結果の精度が高いときの説明変数のデータセットを探すというプロセスである。

上記(2)で述べた「補足」「備考」のようなテキストで記入された項目に、修理受付時に製品を購入・使用されたお客様からヒアリングした情報が含まれていることを確認した。それらの項目には、お客様が目撃された動作・状態、聞かれた音、異臭などの気づきが記述されており、故障原因や故障箇所を推定する際の有用な情報であると考えた。

これらの記述が、修理に必要な部品推定処理に利用できるのではないかと仮説を立てた。しかし、記述されているテキストは、修理受付時にお客様からヒアリングした表現がそのまま文字になっている。例えば、異常音が発生したという現象でも「ジージー」「パチッ」「パチパチ」「パーン」など、表現は様々である。そこで、お客様が視覚・聴覚・嗅覚によって気づいた故障現象に関するテキスト部分に対して、「音」「臭い」「煙」「錆」「剥がれ/はげ」「割れ/ひび」などの分類ラベルを付与し、それを説明変数として使用できる形式にした。

商品コード、現象コード(現象を表す項目)、部位コード(故障部位を表す項目)を説明変数とした推定結果をベースラインとし、説明変数に有用と思われるそのほかの項目を追加して推定した結果と比較した。その結果、テキスト部分に対して、「音」「臭い」「煙」「錆」「剥がれ/はげ」「割れ/ひび」などの分類ラベルを説明変数に追加して推定したものが、最も高い精度を示した。

この予備調査により、修理受付時に製品を購入・使用されたお客様から、聞き取った症状から必要な処置や部品を推定する手法を修理サービスの関係者に示すことができた。このプロセスを自動化してシステムに組み込むことにより、これまで属人的なノウハウに頼ってきた仕組みを改善できる。

実証実験の概要

実証実験では、説明変数(症状コードと症状が記述されたテキスト)と、目的変数(使用部品)を組み合わせ、機械学習による予測を行った。故障診断AIの予測モデルの構築は、FUJITSU Human Centric AI Zinraiのプラットフォームサービスの目的別APIで提供しているFAQ検索⁽²⁾に適用されている機械学習技術を用いた。

AIの精度の評価指標としてF値を用いた。F値と




図-3 分析用オリジナルデータ

は、適合率（モデルが正と予測したデータのうち、実際に正であるデータの割合）と、再現率（実際に正であるデータのうち、正であると予測されたデータの割合）の調和平均である。故障診断精度のKPIとした初回解決率と部品利用率は、相反する関係にあると述べた。評価指標にF値を採用することにより、KPIとして採用した初回解決率と部品利用率に当てはめて評価することが可能となる。適合率と再現率の関係は、適合率を重視すると部品利用率が高くなり、再現率を重視すると初回解決率が高くなる。つまり、重視しなかった方の割合は低くなる。F値を用いると、このトレードオフ状態を考慮した評価が可能となる。故障診断業務のAI化は、業務として解決すべき課題をKPIとして表現することが重要である。⁽³⁾

図-4に示すとおり、今回の実証実験において比較対象とした平均的な人間が行う故障診断の精度は、初回解決率が85.4%、部品利用率が64.8%となっている。これをAIの精度（F値）との比較の目安とした。

実証実験のポイントは、機械学習アルゴリズムの選定とチューニングの2点である。機械学習アルゴリズムは、ディープラーニングをはじめとする複数のアルゴリズムの実験結果を基に、最も高い精度が得られたアルゴリズムとパラメーター値を採用した。




図-4 人間の診断精度を表すKPIの関係

各チューニングの種類は、以下のとおりである。

- ・チューニング1：説明変数選択（説明変数のうち重要な変数のみの特徴量として選択）
- ・チューニング2：学習アルゴリズムのパラメーター調整
- ・チューニング3：適合率と再現率のバランス調整
- ・チューニング4：チューニング1から3の組み合わせ

AIによる部品選定の実証実験期間中において、各チューニングを検証し、最終的に得られた結果を図-5に示す。頻出度トップ10の部品のうち6部品において人間が確認する故障診断精度を上回る結果を示すことができた。チューニング4を調整するほどに精度が向上する傾向が認められた。

故障診断AIの適用評価

前述したとおり、故障診断精度のKPIは初回解決率と部品利用率である。故障診断においてはこの相反する二つの要素を可能な限り最適化することが求められる。そして修理サービスは、必要な補修部品を選定した上で、一度の訪問で完了することが求められる。これにより、余分な補修部品の手配やそれに伴う返品コストの減少といったメリットにつながる。

今回の検証では、このKPIに当てはめて評価した結果、作成した学習モデルが平均的な人間が行う故障診断と同じ程度の精度が得られることを確認した。また、故障診断AIが修理サービスに対するお客様の要望に応えられることを証明できた。

故障診断AIの精度向上に向けて

故障診断AIの精度向上に当たっては、教師データの質が重要である。信頼性に欠けるデータ（不適切な症状記述内容）を繰り返し学習させると正答率が低下する恐れがある。そのため、日々の業務を通じて質の高い教師データ生成する仕組みを確立していかなければいけない。そのポイントは、「症状を正確に聞き取ること」「十分な情報を記録に残すこと」である。

(1) 症状を正確に聞き取る

通常、正確な症状の聞き取りには、要員のスキルアップのための教育や豊富な経験が必要である。しかし、これには人材育成へのコスト・期間が必

部品ごとの要否予測




図-5 最頻出トップ10部品のチューニング前後のAI正答率(F値)

要となるため、問診のシステム化が効果的である。お客様からのコンタクトがあった際に、お客様に何を確認すれば最適な修理サービスが実現できるかが重要となる。そのために、問診システムにAIを適用し、大量の修理実績データから問診に必要な要素を抽出することも有効であると考えられる。

(2) 十分な情報を記録に残す

現場で担当した技術員が行った処置を正確に情報として残すことがノウハウの蓄積であり、AI化する上で必要なプロセスである。しかし、出先で作業の詳細を入力することはオペレーションの負担にもなり、運用が難しい。また、お客様とのFace to Faceのコミュニケーションを阻害することにもつながる。そのため、音声を入力してテキストに変換するといったUIの工夫も求められる。AIを活用した音声データから教師データを生成することが有効ではないかと考える。

む す び

本稿では、製造業における故障診断業務へのAI適用の方法論と実証実験について述べた。故障診断AIを適用することによって、修理サービス全体の業務効率化とサービス品質の向上、および属人性の解消に効果があることが確認できた。

今後、製品ライフサイクルの短縮化やマスカスタマイゼーションといった施策により、故障診断も今までにないような場面での対応が求められる。富士通は、様々な場合を想定し、故障診断AIの精度向上や機能追加などに取り組んでいく。そして、人の持つ業務ノウハウや経験とシステムとをつなぎ、更なる業務の変革に貢献していく。

参考文献

- (1) D. Gunning : Explainable Artificial Intelligence (XAI). DARPA (Defense Advanced Research Project Agency), p.4, 2016.
[https://www.cc.gatech.edu/~alanwags/DLAI2016/\(Gunning\)%20IJCAI-16%20DLAI%20WS.pdf](https://www.cc.gatech.edu/~alanwags/DLAI2016/(Gunning)%20IJCAI-16%20DLAI%20WS.pdf)
- (2) 富士通：FAQ検索－FUJITSU Human Centric AI Zinrai.
<http://www.fujitsu.com/jp/solutions/business-technology/ai/ai-zinrai/services/platform/faq-search/>
- (3) 有賀康顕ほか：仕事ではじめる機械学習. オライリージャパン (2018).

著者紹介



日下治久（くさか はるひさ）

（株）富士通クオリティ&ウィズダム
第六プロフェッショナルサポート事業部
製造業向けシステムインテグレーション・業務システム開発に従事。



宗意幸子（もとい さちこ）

富士通（株）
サービステクノロジー本部
自然言語処理，機械学習などに関する
技術調査・支援に従事。