

修理サービスの改善に向けた AI による不具合原因特定の支援

Failure Cause Classification for Repair Service Utilizing Artificial Intelligence

住設機器メーカーでは、訪問修理サービスでの顧客満足度の向上や、コスト削減が課題となっている。訪問修理では、受付時のヒアリングや訪問時の状況確認により不具合の内容を把握し、それをもとに不具合の原因を特定する。しかし、現状では修理エンジニアの経験に依存しているため、原因を特定できず、処置を行わないで完了となるケースが問題となっている。本稿では、AI により不具合の原因の特定を支援するシステムを提案する。住設機器メーカーのデータを用いて既存の AI 技術の精度を評価した結果、76.8% の正解率で受付時の情報から不具合の原因を推定できることが分かった。一方、既存技術では異なる商品の類似事例を抽出できない課題があるため、その改善案を提案する。

飯塚 新司	Iizuka Shinji
塚原 朋哉	Tsukahara Tomoya
中山 隆	Nakayama Takashi

1. はじめに

水回り製品などの住宅設備機器は、故障した際に現場を訪問して修理する必要がある。そこで住設機器メーカーでは、機器を購入した顧客に対して訪問修理サービスを提供している。修理サービスは顧客の維持や満足度向上のため不可欠となっているが、一方でコスト削減も課題となっている。特に、不具合が再現しないなどの理由で修理現場で処置を行わずに修理完了となるケースでは、不具合が再発して再訪問による修理が必要となる場合があり、顧客満足度の低下につながっている。また、処置せずに完了した場合、出張費はメーカー側の負担となるため、コスト増加の要因ともなっている。修理サービスでは、このようなケースを減らし、現場で適切な処置を行って訪問修理を完了することが求められている。

(株)日立ソリューションズ東日本 (HSE) ではこの課題を解決するため、AI により不具合の原因の特定を支援するシステムを研究している。このシステムでは、顧客の申し出などのテキストデータを入力とし、AI が不具合の原因を推定して修理エンジニアに提示する。これにより、エンジニアが原因を特定して適切な処置を行うことを支援する。本稿では、HSE が提案するシステムの概要と、それを実現するための AI 技術について述べる。

2. 現状の訪問修理サービスとその課題

訪問修理サービスでは、まずサービスセンターのオペレータが顧客から修理依頼を受け付け、発生した不具合の内容をヒアリングし、顧客の申し出としてシステムに登録する。その情報をもとに、修理エンジニアが修理に必要な部材を用意して出張訪問する。修理現場では、修理エンジニアが状況を確認し、不具合の原因を特定する。特定した原因をもとに、原因箇所の部品を交換するなどして処置を行う。現場で処置を行えないケースとして以下の二つがあり、これらの解消が課題となっている。

(A) 修理受付時に顧客が申し出た不具合が現場で再現せず、原因を特定できない。(不具合不再現)

(B) 出張訪問時に用意した部材では修理できない。

これらのケースが発生する共通の原因として、修理受付時に顧客が申し出た不具合の内容から、修理エンジニアが原因を正しく推定できていないことが考えられる。現状では、不具合の原因の推定は修理エンジニアが経験にもとづき行っている。そのため、過去に経験したことがない事例で上記のケースが起きていると考えられる。この場合、不具合の原因の推定だけでなく、原因を特定するための不具合の再現手順や、修理に必要な部材の選択についても、経験不足を補う支援が必要となる。

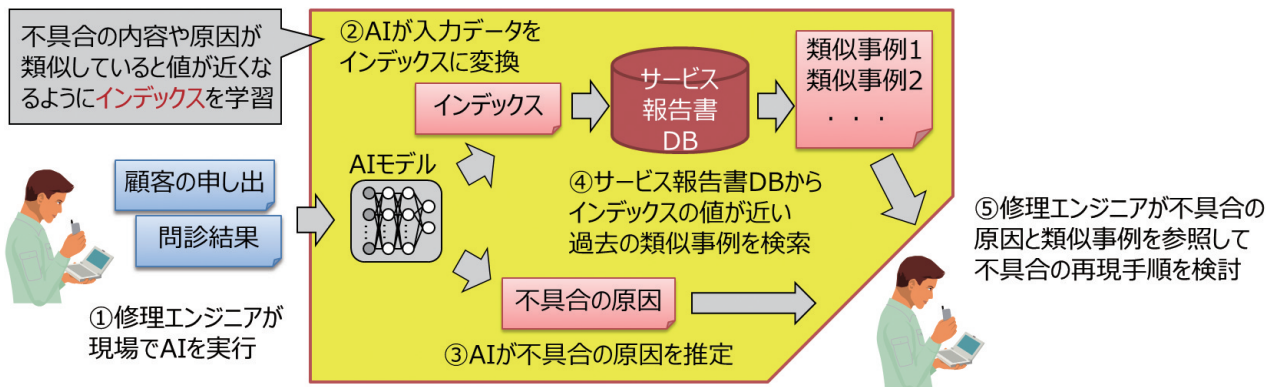


図 1 不具合原因特定支援システムの利用イメージ

3. 提案する不具合原因特定支援システム

上述の課題を解決するため、HSE では図 1 に示す不具合原因特定支援システムを提案する。図は、修理エンジニアが修理現場で不具合の再現手順を検討する場面での利用を想定したものである。この利用方法では、①修理受付時の顧客の申し出や修理現場での確認結果などのテキストデータを入力として、修理エンジニアが現場で原因分類 AI を実行する。② AI は入力データをインデックスと呼ばれるデータに変換する。ここでインデックスとは、不具合の内容や原因が類似していると値が近くなるように AI が学習した数値ベクトルである。③ AI は変換したインデックスをもとに不具合の原因を推定して出力する。また、④システムは修理サービスの報告書が格納されたサービス報告書 DB から、インデックスの値に近い過去の類似事例を検索して、修理エンジニアに提示する。⑤修理エンジニアは AI が推定した不具合の原因と提示された類似事例を参照して、不具合の再現手順を検討する。このようにすることで、修理エンジニアは経験の有無によらず、不具合の原因を正しく推定できるようになる。また、類似事例のサービス報告書の記載を参考にすることで、正しい不具合の再現手順を選択できるようになる。

以上はケース A (不具合不再現) の解消を想定した利用方法だが、ケース B についても不具合原因特定支援システムを活用することができる。この場合では、出張訪問前に修理に必要な部材を選択するとき、修理エンジニアがシステムを実行し、出力された不具合の原因と類似事例を参照する。これにより、不具合の原因を正しく推定できるとともに、類似事例でどのような部材で修理したかを確認することで、正しい部材を選択できるようになる。

このように不具合原因特定支援システムを利用することで、修理エンジニアは現場で適切な処置を行って訪問修理を完了することができ、処置を行えないケースを解消できると考える。

4. 不具合原因特定に適用する AI 技術

不具合原因特定支援システムで用いる AI 技術は、入力されたデータから不具合の原因を推定して出力するとともに、類似事例を検索するためのインデックスを出力する。このような AI 技術は、事例ベース推論へのディープラーニングの応用で研究されており、プロトタイプベースの手法として知られている¹⁾。この既存手法を適用した場合の原因分類 AI のネットワーク構成を図 2 に示す。

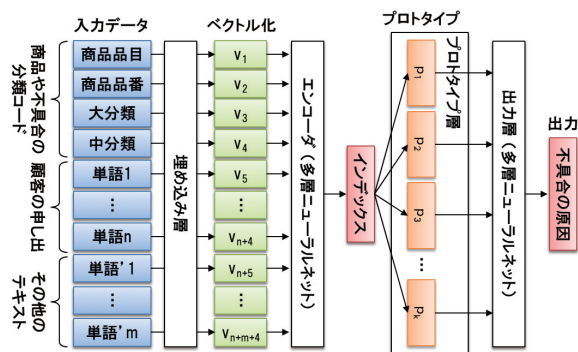


図 2 既存手法を適用した原因分類 AI の構成

原因分類 AI では、入力データとして、修理受付時に特定できる商品の分類コードや不具合の分類コードのほか、修理受付時の顧客の申し出や、現場で修理エンジニアが入力する確認結果などのテキストデータを用いる。これらを埋め込み層でベクトルに変換し、列データとしてエンコーダに入力する。出力は、不具合の原因を表すコードである。一般にプロトタイプベースの手法では、入力データはエンコーダによりインデックスに変換され、プロトタイプ層でインデックスと複数のプロトタイプとの距離が計算されて、その距離をもとに出力層で分類が行われる。ここでプロトタイプとは、訓練データでの典型的なインデックスの値であり、訓練時に AI が学習する。この構成により、入力データの内容が類似していて同じカテゴリに分類されるデータは、インデックスに近い値になるように学習される。

そのため原因分類 AI では、不具合の内容や原因が類似しているデータのインデックスは近い値となる。

5. 修理サービスデータを用いた評価

図 2 で示した原因分類 AI を以下の観点で評価するため、実データによる検証を行った。

- (1) どのくらいの精度で不具合の原因を推定できるか
- (2) インデックスで同じ原因の類似事例を検索できるか

上記 (2) は、類似事例の検索結果を修理エンジニアが参照する場合の利便性を考慮して検証の対象とした。不具合原因特定支援システムは、インデックスの類似度で上位複数件の類似事例を修理エンジニアに提示する。このとき、どの事例も異なる原因だとエンジニアはどの事例を参照すればよいか分からなくなる。同じ原因の事例が多数を占めれば、エンジニアは確度の高い情報としてそれらの事例を参照でき、利便性が高まると考える。

検証には、訪問修理サービスを提供している住設機器メーカーの修理サービスのデータ 1 ヶ月分を用いた。ケース A, B に該当するデータを評価対象から除くため、不具合不再現と、不具合の原因が欠損しているデータを除去した。また、頻度が低い原因は学習が困難なため、出現頻度で上位 100 件の原因に評価対象を絞った。抽出した評価対象データを訓練、検証、テスト用に 7 : 1 : 2 に分割して評価に用いた。データ件数を表 1 に記す。

表 1 評価対象データの件数

訓練	検証	テスト	合計
18,477	2,639	5,281	26,397

入力データに使用した項目は、ケース A, B 両方での利用を想定して、修理受付時にオペレータがシステムに登録した項目を用いた。コードデータとして、修理対象の商品品目、商品品番、不具合の大分類、中分類、テキストデータとして、顧客の申し出と、修理エンジニア向けの社内メッセージを用いた。テキストデータは MeCab²⁾ で形態素解析を行い単語に分かち書きした。それらを文末を表す記号で区切って連結し、64 単語で打ち切って入力に使用した。主なハイパーパラメータを表 2 に記す。また、訓練データと検証データでの不具合の原因の正解率の推移を図 3 に示す。横軸は訓練データに対する学習の繰り返しの回数を表すエポック数である。360 エポックで検証データに対する正解率が 76.7% と最大になったため、ここで学習を終了した。この時点の訓練データの正解率は 96.0% であった。

表 2 ハイパーパラメータ

バッチサイズ	128
エポック数	360
埋め込み層の出力の次元	100
インデックスの次元	100
プロトタイプの数	100

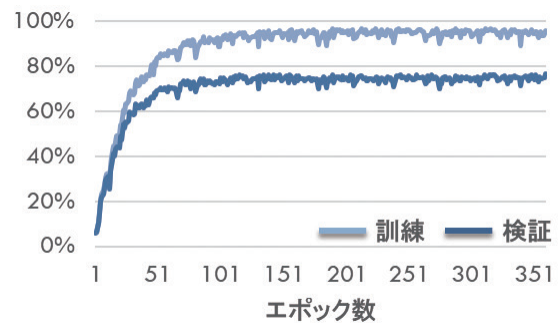


図 3 不具合の原因の正解率の推移

(1) の評価を行うため、学習済みの原因分類 AI モデルをテストデータに適用し、不具合の原因の正解率を評価した。その結果 76.8% の正解率となり、一定の精度が得られることが確認できた。グリッドサーチなどによるハイパーパラメータのチューニングを行うことで、より高い正解率が得られると考える。次に (2) の評価を行うため、訓練データをサービス報告書 DB のデータと見なし、各テストデータに対してインデックスのユークリッド距離が近い訓練データ上位 5 件を検索し、不具合の原因の正解データを比較した。テストデータと訓練データとで原因が一致する割合 (Precision@5) を評価した結果、75.9% となった。不具合の原因を正しく推定できているデータでは 100% 近い割合となっているため、原因の推定精度を改善することで、インデックスによる類似事例の検索精度も向上できると考える。テストデータによる評価結果を表 3 にまとめる。

表 3 テストデータによる評価結果

項目	評価指標	評価結果
不具合の原因の推定精度	正解率	76.8%
インデックスで同じ原因の類似事例を検索できる割合	Precision@5	75.9%

6. 既存手法の課題と改善案

インデックスによる類似事例の検索は、修理サービスでの利用にとどまらず、蓄積された修理サービスデータの品質分析を行う場面でも利点が期待される。修理サービスを提供する住設機器メーカーでは、ある商品で発生した不具合について、他の商品でも類似事例がないか横断的に分析したいというニーズがある。しかし、既存手法を適用した原因分類 AI (図 2)

では、異なる商品品目の類似事例を検索することは困難である。商品品目のコードも含めて入力データをインデックスに変換するため、インデックスが商品品目の情報を含んでしまい、不具合の内容や原因が類似していても異なる商品品目では近い値のインデックスにならないためである。

この課題を解決するため、異なる商品の類似事例も検索できるインデックスを算出する原因分類 AI を提案する。提案モデルの構成を図 4 に示す。特徴の一つ目は、インデックスを算出するエンコーダの入力から商品品目などのコードデータを除いたことである。コードデータは、プロトタイプ層の出力である類似度ベクトルと連結して出力層に入力する。特徴の二つ目は、インデックスから商品品目を予測する商品品目予測部を追加したことである。その学習には、敵対的生成ネットワーク (GAN) の学習で用いられる Gradient Reversal Layer³⁾ を利用する。これにより、商品品目の予測誤差が最大になるようにインデックスが学習され、インデックスが商品品目の情報を含むことを防ぐことができる。

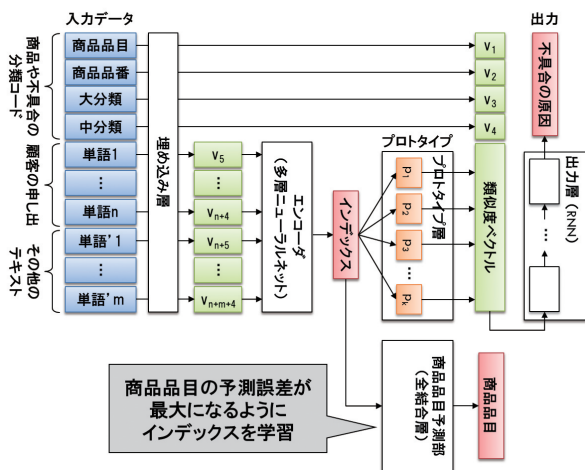


図 4 提案モデルの構成

7. おわりに

訪問修理サービスで課題となっている、現場で処置を行えないケースの解消を目的として、修理エンジニアによる不具合原因特定を支援するシステムを考案した。システムに適用する AI 技術として、プロトタイプベースの既存手法を対象とし、住設機器メーカーの修理データを用いて精度評価を行った。その結果、不具合の原因を 76.8% の正解率で推定できること、また、インデックスにより 75.9% の割合 (Precision@5) で同じ原因の事例を検索できることが分かった。一方、既存手法では異なる商品の類似事例を検索することが困難であるため、それを解決する原因分類 AI の構成を提案した。今後は、この提案モデルの効果の検証を行う予定である。

参考文献

- 1)Oscar Li, et al.: Deep Learning for Case-Based Reasoning Through Prototypes: A Neural Network That Explains Its Predictions, Proceedings of the AAAI Conference on Artificial Intelligence. Vol. 32. No. 1 (2018)
- 2)MeCab: Yet Another Part-of-Speech and Morphological Analyzer (2021/12/2 閲覧), <http://taku910.github.io/mecab/>
- 3)Heishiro Kanagawa, et al.: Cross-Domain Recommendation via Deep Domain Adaptation, European Conference on Information Retrieval, pp. 20-29, Springer, Cham (2019)



飯塚 新司 2008 年入社
研究開発部
データ分析・AI 関連技術の研究



塚原 朋哉 1997 年入社
研究開発部
データ分析・AI 関連技術の研究



中山 隆 1991 年入社
RPA・AI 推進センタ
新事業企画・推進