

## ランダムフォレストを用いた

## 装置停止発生判別のためのアラームルール抽出の検討

## Proposal on alarm rule extraction method to discriminate machine stop troubles

寺本 やえみ<sup>†</sup> 石井 智之<sup>†</sup> 村上 貴広<sup>‡</sup> 橋崎 元裕<sup>‡</sup> 大塚 英明<sup>‡</sup>

Yaemi Teramoto Tomoyuki Ishii Takahiro Murakami Motohiro Hashizaki Hideaki Otsuka

## 1. はじめに

装置保守サービスの事業分野においては、装置停止を未然に防ぐ保守を実現するために、過去の装置稼働や保守履歴のデータから装置停止要因に関わる知見を抽出し活用しようという動きがある。本研究では、装置保守サービス事業者である日立ハイテクフィールドディングと共同研究を行い、実稼働中の成分分析装置を対象として、装置稼働・保守のデータを活用した保守サービスの高度化・効率化のための検討を行った。

装置保守サービスの理想像は、装置停止等のトラブルの発生を予見し未然に対応をすることで、トラブルを一切発生させないことである。しかし実際には、高度なセンサで装置状態をモニタリングしたり、実用精度の予兆検知モデルを開発したりすることが困難な場合も多い。そこで本研究では、多くの装置で取得可能なアラームデータを用いて、装置保守エンジニアが早期に装置トラブルの可能性に気づくきっかけとなる情報を抽出することを目的とし、装置停止が発生する前の、各種アラームの発生量や発生順のルールを抽出する手法を開発した。このようなルールを抽出することにより、装置保守エンジニアは、担当装置のアラーム発生がルールに該当した場合に、装置停止トラブル発生の可能性を未然に検討することが可能となる。

## 2. 関連研究

装置故障の要因分析に用いられる代表的な手法として、ベイジアンネットワークが挙げられる[1][2]。ベイジアンネットワークでは、入力変数間の因果関係の確率的な表現を出力可能であるが、ベースとする因果関係のネットワーク構造を事前知識によって適切に設計する必要がある。

サポートベクトルマシンやランダムフォレスト等の機械学習の手法では、学習した識別や回帰のモデルが、どの入力変数を重視したかを定量評価することが可能である[3][4]。また、決定木による判別モデルでは、判別に用いたルールが可読である。

## 3. ルール抽出方式の提案

アラームデータからの装置停止発生判別ルール抽出の基本方針は、機械学習の手法を用いて装置停止判別モデルを作成し、モデルが判別に用いたルールを抽出するという流れである。適用する機械学習手法は、学習モデルの判別の根拠や過程を人間が理解しやすい手法が適しているため、ランダムフォレストを採用した。ランダムフォレストでは、ランダムに抽出したデータとカラムを用いて学習した多数の決定木を弱学習器として集団学習を行い、各弱学習器が

<sup>†</sup>(株)日立製作所 Hitachi, Ltd.

<sup>‡</sup>(株)日立ハイテクフィールドディング Hitachi High-Tech Fielding Corporation

出力した判定結果の多数決をもって、最終的な判定結果を出力する。個々の弱学習器である決定木によって判定のルールが明確に示され、このルールを集約するアルゴリズムを用いることで、主要な判定ロジックを抽出することが可能である。なお、ランダムフォレストの学習モデルから判別ルールを集約し抽出するアルゴリズムは、統計解析のフリーソフトウェア R のライブラリ (inTrees) として公開されている[5]。

## 4. 提案方式の評価

## 4.1 事前精度検証

まず、アラームデータに装置停止を予見可能とする情報が含まれていることを確認するため、アラームデータを用いた装置停止判別精度の検証を行った。対象としたデータは、実稼働中の成分分析装置約 200 台の、アラームデータ約 600 万件である。アラームの種類は約 100 種であり、判別対象である装置停止の際に発報するアラームを含む。データ期間は約 3.5 年間である。これらのデータを用いて、装置停止の発生有無を判別するランダムフォレストモデルを構築することとした。具体的には、4 週間分の全アラーム発生の情報を入力として、翌 1 週間の装置停止発生有無を判別するモデルを学習した。入力とした 4 週間分のアラームは、発生量の日毎集計と週毎集計の 2 パターンで検証した。また、データの期間で学習データとテストデータに分けた。学習データは約 3 年分、テストデータは学習データの直後の期間の約 5 か月分とした。学習データとテストデータをあわせた全データ件数は、約 2 万件であった。

精度検証結果を図 1 に示す。なお、ランダムフォレストでは、ランダムにデータを抽出して弱学習器を学習するため、抽出されなかったデータを用いて学習モデルの性能 (Out-Of-Bag (OOB) エラー) を評価することが可能である。図 1 には OOB エラーも示した。

図 1 の精度評価結果を見ると、装置停止が発生する場合の判別エラー率が 50% を超えており、予想した通り、判別

正解	テストデータでの 評価のエラー率	OOB エラー率
装置停止有	58.9%	56.3%
装置停止無	24.0%	24.7%

(1) 入力データ: 日毎の集計

正解	テストデータでの 評価のエラー率	OOB エラー率
装置停止有	53.3%	52.8%
装置停止無	24.5%	25.2%

(2) 入力データ: 週毎の集計

図 1 全データの判別精度確認結果

精度が実用レベルとは言えない。しかし、検証用データにおける装置停止有/無のデータ数の比を考慮すると、ランダムな判定と比較してエラー率が 2/3 程度に抑えられている。よって、装置停止を判別可能な情報が入力データに一部含まれていると考えられる。入力データの日単位と週単位との比較では、判別精度が大きく変わらないため、以降の議論では、データの解釈のしやすさと次元数の削減というメリットも考え、週単位のアラーム発生量の集計値を入力データとして用いることとした。

#### 4.2 ルール抽出結果

ルール抽出の分析対象は、保守点検実施日にデータのスタート時点をそろえ、点検から 4 週間のデータに限定した。こうすることで、分析対象データの装置の状態がある程度そろい、抽出したルールを理解しやすくなる。分析対象のデータ件数は約 600 件であった。

まず、データ入力期間と装置停止発生有無の判別期間を分け、入力データから判別期間の装置停止有無を判別するランダムフォレストのモデルを学習した。入力期間と判別期間の分け方は、3 週間-翌 1 週間、2 週間-翌 2 週間の 2 パターンを試した。ランダムフォレストの OOB エラー確認結果を図 2 に示す。エラー率は、図 1 に示した全データを用いて評価した結果と大きくは変わっておらず、ルール抽出の対象とする価値のあるモデルが学習できたと考える。

図 3 に、抽出したルールの例 (ダミー例) を示す。示した表全体で、対象装置に装置停止が発生する条件となる 1 件のルールを表す。なお、装置は複数のモジュールからなる。示したルールの読み方は、“「1 週目の「装置モジュール A」での「アラーム 1」の日毎発生回数の最大値が 7 より大きい」かつ、「2 週目の「装置モジュール B」での「アラーム 2」の日毎発生回数の平均値が 0.5 以下」かつ、「データ入力期間の日毎処理検体数の平均値が 500 以下」であるならば、翌週に装置停止が発生する”となる。

図 4 にルール抽出結果を示す。なお、提案手法を用いると、装置停止発生「有」を判別するルールと装置停止発生「無」を判別するルールの両方が抽出されるが、本検討では、装置停止発生有を判別するルールのみに着目した。ルールは 2 件、10 件抽出され、各ルールの判別エラー率の平均値は 54.2%、22.7% となった。ただし、各データセットではデータ期間が異なり、装置停止有/無のデータ数の偏りに違いがあることに注意が必要である。入力期間が 3 週間のデータセットでは、装置停止有のデータが少なく、このデータセットで学習するとエラー率が高くなることが自然

入力データ期間	判定対象期間	装置停止有 OOBエラー率	装置停止無 OOBエラー率
3週間	翌1週間	51.7%	18.7%
2週間	翌2週間	53.1%	18.6%

図 2 ルール抽出対象データの判別精度確認結果

週番号	項目	装置 モジュール	max/avg	閾値	<>
1	アラーム1	A	Max	7	>
2	アラーム2	B	avg	0.5	<=
-	検体数	-	avg	500	<=

図 3 抽出したルールの例 (ダミー例)

入力データ 期間	判定対象期間	有効 ルール数	ルールの 平均判定 エラー率	ルールにより 正しく判別できた 装置停止の割合
3週間	翌1週間	2	54.2%	35%
2週間	翌2週間	10	22.7%	57.8%

図 4 ルール抽出結果

である。また、抽出したルール群が、装置停止発生全件のうちのどれだけの割合を捉えることができたかを図 4 に示した。全装置停止のうち 35%、60%程度をルールにより捉えられたことが分かる。以上の結果より、提案手法を用いて、一定の精度とカバー率を持った装置停止判別ルールを抽出することが可能であることを確認できたと考える。

#### 4.3 考察

抽出したルールについて、装置保守エンジニアにヒアリングを行った結果、ルールから装置停止要因を想像することは可能であるが、ルール自体を気づきとして装置停止要因を理解するのは少し難しいとの意見であった。その理由としては、まず、複数週のアラーム発生によるルールについて、アラーム間の前後関係を理解できるルールがほとんどないことが挙げられた。これに対しては、アラーム発生の時間変化を表現可能な特徴量を設計するという改善が考えられる。もう一つの理由として、アラームが閾値より多いと装置停止が発生しやすいというルールは理解しやすいが、少ないと発生しやすいというルールは、基本的には直感に合わず理解しにくいという意見が挙げられた。これに対しては、ルールに説明力を持たせるアプローチも考えられるが、ルールの判定精度を向上し、直感に合わなくても保守に活用する価値があることを示すアプローチもあると考える。

#### 5. おわりに

本研究では、装置保守サービスにおける効率的な不具合低減をめざして、装置停止発生の有無を判別するアラーム発生のルールを抽出する方式を提案した。また、実稼働中の装置のデータを用いた提案方式の検証を行った。その結果、ランダムフォレストを用いた方式で、平均エラー率が 20%程度で、カバー率が 60%程度のルール群を抽出することが可能であることを確認した。今後の課題は、ルールの汎化性能の検証と精度向上である。また、現場での有効性の検証と、ルールが有効に活用される業務プロセスの設計も必要である。

#### 参考文献

- [1] 山田紀一、足立康二、本村陽一. “複写機の障害診断における確率推論アルゴリズムの性能評価”. 人工知能学会基本問題研究会 64. 15-19. (2006).
- [2] O. J. Mengshoel, M. Chavira, K. Cascio, S. Poll, A. Darwiche, and S. Uckun. Probabilistic model-based diagnosis: An electrical power system case study. *IEEE Trans. on Systems, Man, and Cybernetics*, (2009).
- [3] Bishop, Christopher M. "Pattern recognition." *Machine Learning* 128 (2006): 1-58.
- [4] L. Breiman, "Random forests." *Machine learning* 45.1 (2001): 5-32.
- [5] Deng H. "Interpreting tree ensembles with inTrees". Intuit. ArXiv: 1408.5456. (2014)