

# 機械学習手法を活用した CRDM 作動分析技術の高度化について

## Improvement of CRDM Motion Analysis using Machine Learning

三菱重工業株式会社  
三菱重工業株式会社  
三菱重工業株式会社  
三菱重工業株式会社  
三菱重工業株式会社

西村 卓也  
山寄 将平  
斎藤 真由美  
中山 博之  
矢口 誓児

Takuya NISHIMURA  
Shohei YAMASAKI  
Mayumi SAITOH  
Hiroyuki NAKAYAMA  
Seiji YAGUCHI

Control Rod Drive Mechanism (CRDM) for pressurized water reactor (PWR) plant operates control rods in response to electrical signals from a reactor control system. CRDM operability is evaluated by characteristic of CRDM operational data. MHI has already developed an automatic CRDM motion analysis and applied it to actual plants so far. However, CRDM operational data has wide variation and noise depending on their characteristics such as plant condition, address, plant, and so on. In the existing motion analysis, detecting characteristics was conducted using manually adjusted criteria. In some operational data with wide variation and noise, detecting accuracy was not so high due to this limitation. In this study, MHI investigated motion analysis using machine learning (Random Forests) which is flexibly accommodated to CRDM operational data with wide variation and noise, and improved analysis accuracy.

**Keywords:** CRDM, motion analysis, Machine Learning, maintenance

### 1. 緒言

加圧水型原子力発電所 (PWR) の磁気ジャック式制御棒駆動装置 (CRDM) は、制御盤からの電気信号に対応して、制御棒 (RCC) を炉心から引抜挿入保持する装置である。CRDM は、Fig.1 に示すように、圧力ハウジング、ラッチアセンブリ、駆動軸アセンブリ及びコイルアセンブリの 4 つのサブアセンブリで構成している。また、ラッチアセンブリは、SG ラッチ部、MG ラッチ部、リフト部の 3 つの駆動部に分類され、SG ラッチ部及び MG ラッチ部は、それぞれ SG ラッチ及び MG ラッチの把持・開放動作を司る。一方、リフト部は、MG ラッチ部の 1 ステップ分の上昇・下降動作を司る。圧力ハウジング外側には、3 つの駆動部に対応する 3 つのコイルが設けられており、これら 3 つのコイルをシーケンシャルに励磁・非励磁することで、SG ラッチ及び MG ラッチの把持・開放動作と MG ラッチ部の上昇・下降動作を組合せ、RCC 引抜・挿入のステップ動作を実現する。

ラッチアセンブリは、圧力ハウジングに内包されているため、その動作状況を直接確認することができない。そこで、3 つの駆動用コイルの電流信号と駆動時に発生する振動 (加速度) 信号をデジタルデータとして取り込み、信号上の特徴を抽出して間接的に動作状況を確認してい

る。具体的には、Fig.2 に示すように、電流信号 on/off のタイミングと磁極の開閉動作完了のタイミングを抽出して、「電流信号 on/off から磁極の開閉動作完了までの時間」を算出して、CRDM の動作状況を確認している。

1 プラントの全 CRDM の動作状況を確認するためには、約 145,000 個 (6 動作×228 ステップ×2 引抜挿入×53 体) の信号を処理する必要がある。このため、データ採取後のタイムリーな CRDM 動作性の診断のためには、信号分析作業の自動化が必要である。




Fig.1 Schematic view of CRDM




Fig.2 Definition of armature's response time  
(example of withdrawal sequence)

## 2. 既存の CRDM 作動分析技術

これまでに、MHI では信号分析作業を自動で行うために、CRDM 作動分析技術を開発し、実機プラントの CRDM 動作性の診断に適用してきている（以後、既存の分析技術と称す）。

既存の分析技術では、コイル電流 on/off のタイミングは、コイル電流信号の変化点から検出している。また、磁極動作完了のタイミングは、Fig.3 に示すように、磁極動作毎に固定の検出範囲を設定し、その範囲の中から動作完了のタイミングを検出している。この検出範囲は、先行実績データを基に固定のクライテリアとして設定している。

コイル電流信号は、CRDM 動作条件（プラント状態、アドレス、プラント等）の違いによる変動は小さく安定しているため、高い精度で検出することが出来る。一方、加速度信号は、CRDM 動作条件の違いによって大きく変動しノイズレベルにも差が生じる。このため、変動やノイズレベルの差に対して、統一的な検出範囲で対応するには限界があり、検出精度の低い条件もある (Fig.4 参照)。

上記への対応として、個別に検出範囲を設定する方法が考えられるが、管理/運用面で煩雑になりヒューマンエ

ラー発生の基本となる懸念がある。

そこで、加速度信号の変動やノイズレベルの差に柔軟に対応出来る分析技術高度化が望まれていた。

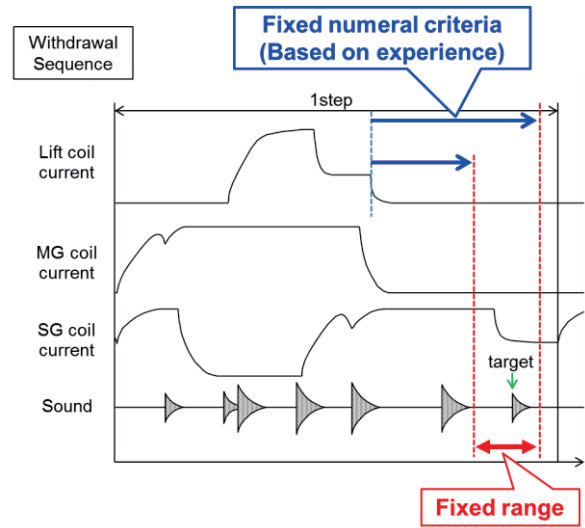


Fig.3 Detecting method of existing CRDM motion analysis  
(example of withdrawal sequence)




Fig.4 Example of CRDM operational data  
with wide variation and noise

## 3. CRDM 作動分析技術の高度化

CRDM 作動分析では、加速度信号から 6 つの磁極の動作完了のタイミングを検出しており、本処理はビックデータ処理で活用されている機械学習手法におけるクラス分け問題と類似している。よって、本研究では、機械学習手法を適用して、信号の変動やノイズレベルの差に柔軟に対応出来る CRDM 作動分析技術確立を試みた。なお、コイル電流信号の on/off のタイミング検出は、既存の分析技術で高い精度を確保できているため、既存技術を維持し機械学習手法は適用しない。

### 3.1 基本概念

機械学習手法を適用した CRDM 作動分析技術（以降、高度化した分析技術）の基本概念を Fig.5 に示す。既存の分析技術では、磁極動作完了のタイミングを検出するための検出範囲を固定のクライテリアを基に設定していたのに対して、高度化した分析技術では、機械学習による識別結果（クラス分け結果）を用いて、条件毎に検出範囲を自動で設定する方法に変更する。本研究では、機械学習手法として、多クラス分け問題で多く活用されている『Random Forests』を用いた。

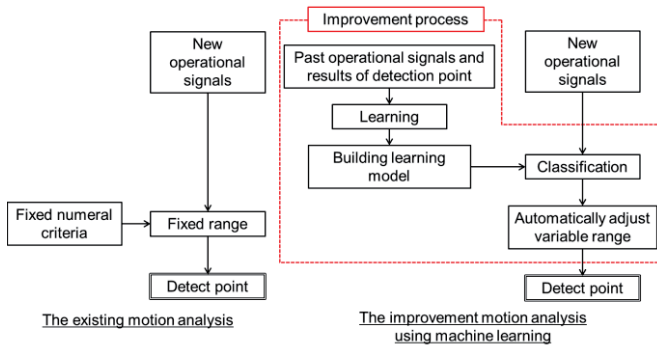


Fig.5 Concept of CRDM motion analysis using machine learning

### 3.2 機械学習の考え方

機械学習は、学習データに内在する非明示的なルールを自動で見つけ出し、そのルールを基に作成した学習モデルを用いて新しいデータの識別や予測を行う技術である。

Random Forests は、学習データから複数の学習モデルを生成して、各学習モデルでの識別結果を統合して最終的な結果を導き出す学習手法である。これは、多くの情報からルールを見つけ出す場合、少ない学習モデルでは偏った答えとなる可能性があるため、着目する情報や優先順位のパターンを変えた複数の学習モデルを用いて、識別精度と汎化性の向上を図ったものである。

CRDM 波形分析においては、学習データとして「採取データ（コイルの電流信号及び加速度信号）と磁極動作完了のタイミングの情報」を与えることで、Fig.6 に示すように、採取データ（コイルの電流信号及び加速度信号）と磁極動作完了のタイミングとの関係性を自律的に見つけ出させる。そして、機械学習にて見つけ出した関係性（以降、学習モデルと呼び）を用いて、新しいデータの識別を行う。


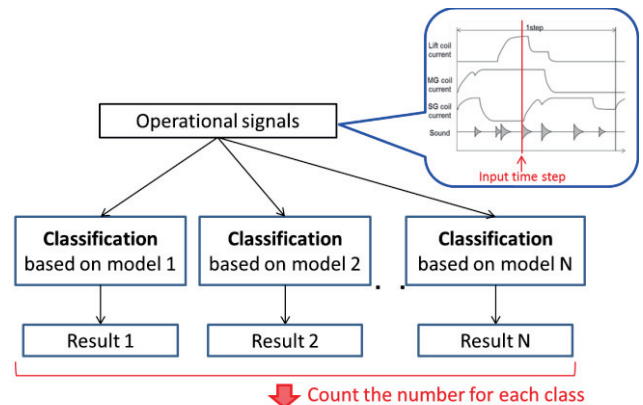


Fig.6 Example of learning information at CRDM motion analysis

### 3.3 Random Forests によるクラス分け

CRDM 波形分析では、各時間を「6 つの磁極動作の完了のタイミング」と「その他」の合計 7 つのクラスに分ける必要がある。1 ステップあたりの時間は 900msec であり、1msec 単位でクラス分けを行う。Random Forests によるクラス分けでは、Fig.7 に示すように、学習モデル毎に識別処理を行い、結果を集計して、識別対象の時間がどのクラスとなる確率が高いかを算出している。識別結果としては、Fig.8 に示すように、クラス毎に時間に対する確率値の関係を得る。



class	0msec*	1msec*	...	900msec*
Lin	$a_0/N$	$a_1/N$	...	$a_{900}/N$
Lout	$b_0/N$	$b_1/N$	...	$b_{900}/N$
Min	$c_0/N$	$c_1/N$	...	$c_{900}/N$
Mout	$d_0/N$	$d_1/N$	...	$d_{900}/N$
Sin	$e_0/N$	$e_1/N$	...	$e_{900}/N$
Sout	$f_0/N$	$f_1/N$	...	$f_{900}/N$
Other	$g_0/N$	$g_1/N$	...	$g_{900}/N$

\* $a+b+c+d+e+f+g=N$

Fig.7 Classification by Random Forests

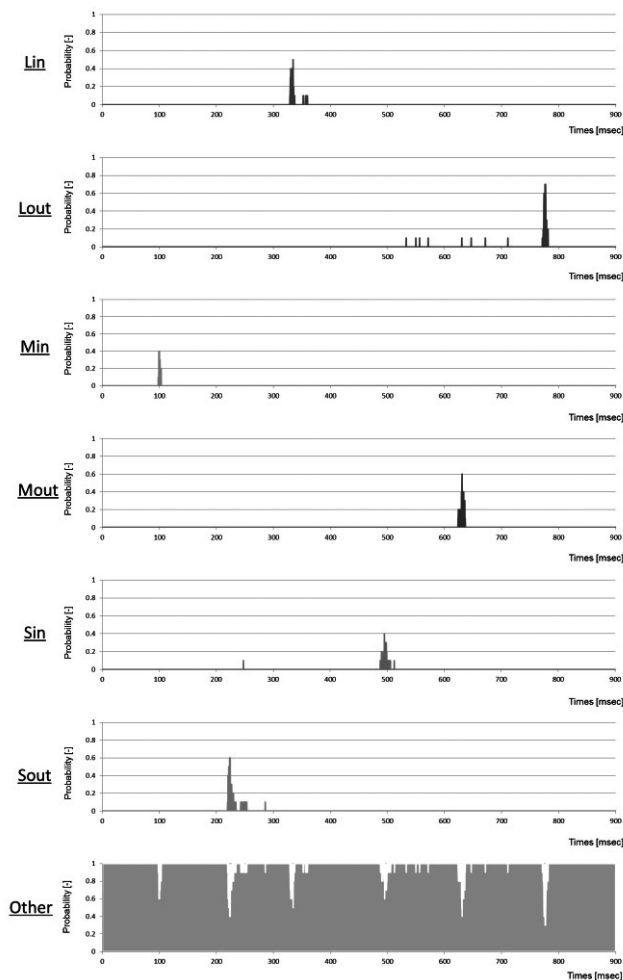


Fig.8 Classification results

### 3.4 検出範囲の設定

磁極動作完了のタイミングを検出する範囲の設定方法としては、Fig.9に示すように、機械学習による識別結果（クラス分け結果）から、磁極動作毎に確率が高い時間（ピーク位置）を抽出して、その時間を中心とした狭い範囲を検出範囲とした。この検出範囲の設定は、動作毎、ステップ毎に自動で実施するため、可変である。

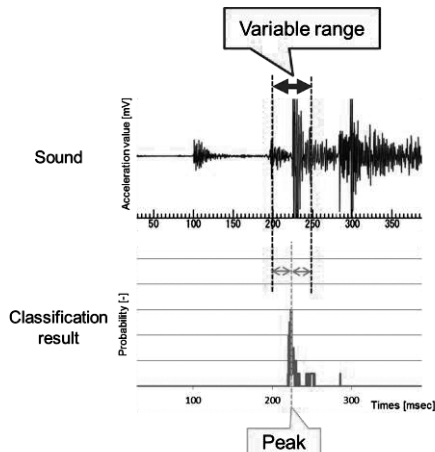


Fig.9 Set up variable range

### 3.4 分析精度

高度化した分析技術を用いて作動分析を実施し、分析精度の確認を行った。分析精度の確認は、約 50 条件（約 100 万ステップのデータ）に対して実施した。代表として既存の分析技術において分析精度が低かった条件の確認結果を Table1 に示す。Table1 より、高度化した分析技術では、99%を超える高い分析精度を達成できることを確認した。なお、他の条件についても大部分で 99%を超える高い分析精度を達成できることを確認した。

Table1 Detection accuracy rate

Analysis method	Detection accuracy
Existing motion analysis	80%
Improved motion analysis	99%

## 4. 結論

CRDM 波形分析に機械学習手法を適用することで、加速度信号の変動やノイズレベルの差にも柔軟に対応できる分析技術を開発することが出来た。これにより、CRDM 波形分析の分析精度向上が図れ、分析作業が効率化できることを確認した。

今後は、様々な条件に対して高い分析精度の確保、分析作業の迅速化のために、より多くの実機データを取得し機械学習に使用する学習データの拡充を図る。

## 参考文献

- [1] Jinichi Miyaguguchi, Development of a PWR CRDM data-analyzing system, Transactions of the American Nuclear Society, Vol.60, 1989, pp.466-468
- [2] Jamie Shotton, Matthew Johnson and Roberto Cipolla, Semantic Texton Forests for Image Categorization and Segmentation, Computer Vision and Pattern Recognition, 2008, pp.1-8
- [3] Leo Breiman, Random Forests, Machine Learning, Vol.45, No.1, (2001) pp.5-32
- [4] David S. Siroky, Navigating Random Forests and related advances in algorithmic modeling, Statistics Surveys, Vol.3, (2009) pp.147-163
- [5] Florian Schroff, Antonio Criminisi and Andrew Zisserman, Object Class Segmentation using Random Forests, Proceedings of the British Machine Conference, (2008) pp.54.1-54.10
- [6] 波部 齊, ランダムフォレスト, 情報処理学会研究報告, Vol.2012-CVIM-182, No.31, 2012, pp.1-8