

# ソフトセンサ（仮想計測）を用いたプラント水質監視の取り組み

三菱重工業(株)	澤津橋 徹哉	Testuya SAWATSUBASHI	Non-Member
三菱重工業(株)	梶 伸之介	Shinnosuke KAJI	Non-Member
三菱重工業(株)	嬉野 絢子	Ayako URESHINO	Non-Member
三菱重工業(株)	松原 龍一	Ryuichi MATSUBARA	Non-Member
三菱重工業(株)	松澤 寛	Hiroshi MATSUZAWA	Member
東京大学	船津 公人	Kimito FUNATSU	Non-Member

## Abstract

On a power plant, the water quality of system water needs to be properly monitored and controlled. On this study proposes a monitoring method for the concentration of Chloride, one of the main impurities dissolved in feed water of a power plant. The proposed method is based on soft sensor, and variable selection through GAVDS contributes the predictive models to higher prediction accuracy.

**Keywords:** soft sensor, monitoring, water quality,

## 1. はじめに

発電所では、独立系発電業者（IPP）案件の増加や熟練運転員不足を背景に、健全運転のための水質管理支援ニーズが増している<sup>[1]</sup>。

昨今、AI、IoTの技術進展が目覚ましく、ソフトセンサと呼ばれる仮想計測の技術開発が盛んに進められ、化学・石油産業、半導体産業、鉄鋼産業、製薬産業への実用が進んでいる<sup>[2]</sup>。

そこで、このソフトセンサを活用することで、プラント水質を連続的に仮想モニタリングし、運転最適化（性能・健全性・ランニングコスト）の実現を目指して研究を開始した状況である。

本発表、プラント水質に混入する塩化物イオン（Cl）を題材に、その濃度予測の検討事例を紹介する。

## 2. ソフトセンサとは

### 2.1 ソフトセンサ

ソフトセンサ<sup>[3,4]</sup>とは、Fig.1に示すとおりオンラインのハードセンサで直接測定が容易な温度、圧力などの説明変数と、手分析などで不定期に得られる目的変数との間で数値モデルを構築し、以降、監視したい目的変数の値を推定する方法である。この手法は、既存のセンサ値を用いて、現在、過去、未来の状態を推測することで、あたかもハードセンサかのように対象となる状態量を仮想計測することが可能である。

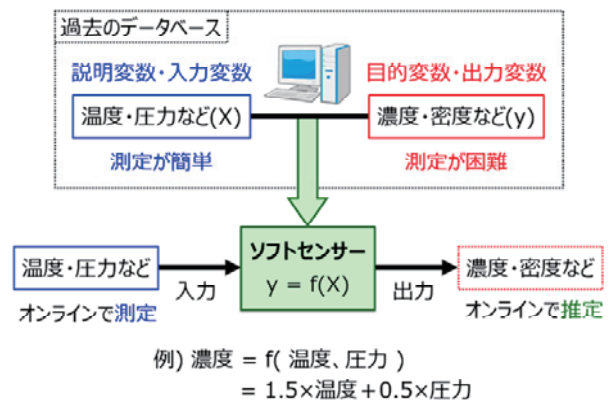


Fig.1 ソフトセンサの概念図

### 2.2 時刻遅れを考慮した説明変数の選択手段

ソフトセンサで数値モデルを構築する際、目的変数と相関の大きい説明変数を選択することが重要である。物理モデルや経験から、目的変数と説明変数の関係が既知の場合は、良好なモデルを構築できるが、データセットによっては、時間遅れを伴う場合や単純な一次式のモデルでは説明できないケースがあり、相関の高い変数の選択が課題となる。

そこで、今回は、遺伝的アルゴリズムを用いた動特性の考慮と変数選択を同時に行う手法 (genetic algorithm-based process variables and dynamics selection, GAVDS<sup>[5]</sup>)を採用した。Fig.2にGAVDSの考え方を示す。プラントの下流にある変数 (Fig.2 y) を、上流にある変数 (Fig.2  $x_1, x_2$ ) から予測する際、時刻  $t$  における  $y(t)$  は、同一時刻に得られる  $x_1(t)$  や  $x_2(t)$  から予測す

るよりも、 $x_1(t-t_1)$ や $x_2(t-t_2)$ から予測を行ったほうが予測精度の高いモデルが構築できる。GAVDS を用いることで時刻遅れを考慮した変数選択が可能となる。




Fig. 2 GAVDS による変数選択例

### 2.3 予測モデル

選択されたモデル構築用サンプルを用いて予測モデルの構築を行う。今回の解析では線形回帰手法である部分的最小二乗法 (Partial Least Squares Regression, PLS<sup>[6]</sup>), 非線形回帰手法であるサポートベクター回帰 (Support Vector Regression, SVR<sup>[7]</sup>), ランダムフォレスト (Random Forest, RF<sup>[8]</sup>) の3手法を比較した。

### 2.4 適応型ソフトセンサ

プラントでは、劣化や配管へのスケール付着等によって予測対象の目的変数と予測に用いる説明変数の関係が時間の経過とともに変化していく。このため、初期のモデル構築用サンプルから作成した予測モデルの精度は時間の経過とともに低下していく。この問題に対処する為、適応型ソフトセンサが用いられる。適応型ソフトセンサでは、予測モデルを更新しながら予測を行う。更新を行う際に利用するサンプルの選択方法の違いでMW (Moving Window) 方式<sup>[9]</sup>とJIT (Just in Time) 方式<sup>[10]</sup>などが研究されている。MW方式では新しいサンプルをいくつか選択し予測モデルの構築を行う。一方、JIT方式では過去のサンプルから現在のプラント状態に近いサンプルをいくつか選択し予測モデルの構築を行う。MW方式とJIT方式の概念をFig.3に示す。今回の解析では、予測モデルの構築に利用するサンプルの選択方法として、MW方式を採用した。

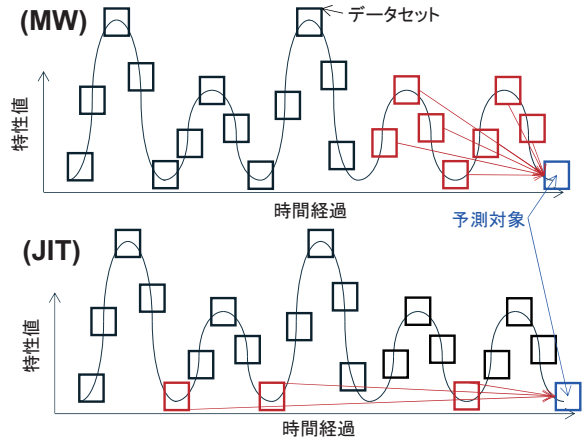


Fig.3 適用型モデルの比較

## 3. 不純物濃度予測の検討状況

### 3.1 検討対象の系統図と予測データ位置

検討対象となるプラント系統図をFig.4に示す。何らかの原因で系統内に海水が混入し、海水に含まれるClイオンが循環水系統に混入すると、復水系統、給水系統、ボイラ系統、蒸気系統などを経由して蒸気に混入し、最終的にタービン上に析出する。そのため、復水器漏洩を検知するサンプリングスポットとして、高圧ドラム水のClイオン濃度を選定した。高圧ドラム水のClイオン濃度を推定することで、不純物混入状況によるプラント運転継続可否の早期判断を行い、海水漏えいによるタービン腐食リスクを最小限にすることを目的とする。

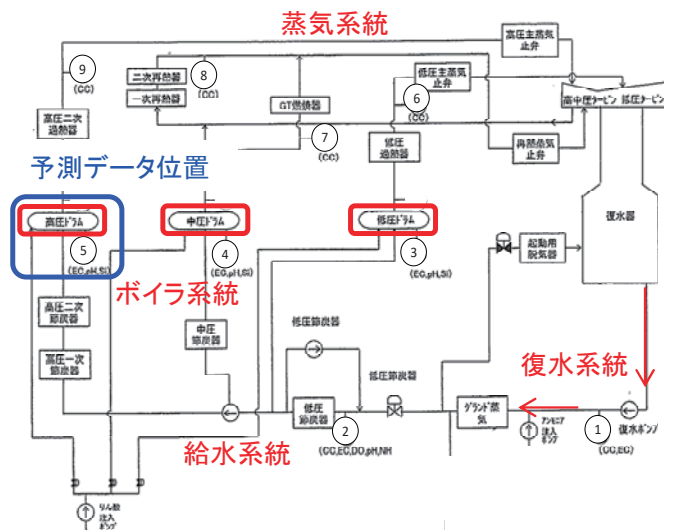


Fig.4 対象プラントの系統図

### 3.2 検討対象データ

説明変数及び目的変数として用いたデータの一覧を Table 1 に示す。説明変数としては、電気伝導率、pH 等、プラントに取り付けられている、オンライン測定が可能な変数を設定した。また、目的変数として、Cl イオン混入を把握するために最適な変数である、高圧ドラム水の Cl イオン濃度とした。解析には対象期間の 2344 サンプル (目的変数は 134 サンプル) を用いた。前半の 933 サンプル (目的変数は 63 サンプル) を初期データとして使い、MW 方式でモデルを更新しながら後半の 1411 サンプル (目的変数は 71 サンプル) の予測を行った。また、MW 方式における使用するサンプル数は、10 個から初期データの目的変数サンプル数までのうち、最適な値を選定した。なお、目的変数である塩素濃度の分析に要する時間は 10 分を想定した。

Table 1 検討対象の変数

説明変数	目的変数
連続データ (各 2345 点)	手分析データ (134 点)
①復水ポンプ出口 CC, EC	⑤高圧ドラム水 Cl
②低圧節炭器入口 CC, EC, DO, pH, N <sub>2</sub> H <sub>4</sub>	
③低圧ドラム水 EC, pH, Si	
④中圧ドラム水 EC, pH, Si	
⑤高圧ドラム水 EC, pH, Si	
⑥低圧過熱器出口蒸気 CC	
⑦ガスタービン燃焼器入口蒸気 CC,	
⑧再熱器出口蒸気 CC	
⑨高圧過熱器出口蒸気 CC	
発電容量, 真空度, 補給水量	

CC : 酸電気伝導率, EC : 電気伝導率, DO : 溶存酸素, pH : 水素イオン濃度, N<sub>2</sub>H<sub>4</sub> : ヒドラジン

### 3.3 検討結果及び考察

#### 1) GAVDS

解析結果例を以下に示す。ヒートマップで黄色く表示されている箇所が選択された変数と時刻である。Fig. 5 は上位 10 個体

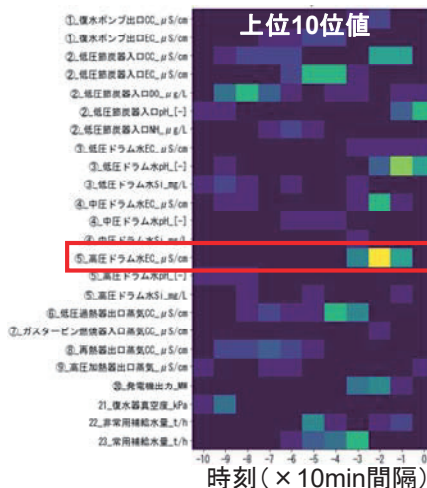


Fig.5 GAVDS 解析結果例

の選択領域を予測精度の高さに応じてバイアスをかけ重ね合わせた図である。以上の結果から、高圧ドラム水の Cl の予測において、20 分前後の高圧ドラム水 EC が重要であることを示唆している。

### 2) Cl 濃度予測

データセットの前半区間を学習データ、後半区間を検証データとし、後半区間の Cl 濃度予測を実施した。適用型モデルとしてプラント状態のドリフトに対応可能な手法である MW を、回帰モデルは PLS, SVR 及び RF を用いた。解析結果を Table 2 に示す。検証の結果、RF の予測精度が最も高い (決定係数 R<sup>2</sup>=0.68) ことが確認された (Fig. 6)。今後データを蓄積するとともに、JIT 方式を用いるなど検討を継続し、信頼性の高いモデルを構築することで、Cl 予測精度の更なる向上を図っていく。

Table 2 Cl 濃度の予測結果

サンプル	回帰モデル	R <sup>2</sup>	RMSE
MW	SVR	0.62	0.03
MW	RF	0.68	0.03
MW	PLS	0.63	0.03

R<sup>2</sup> : Coefficient of determination (決定係数)  
RMSE : Root mean square error (平均平方二乗誤差)

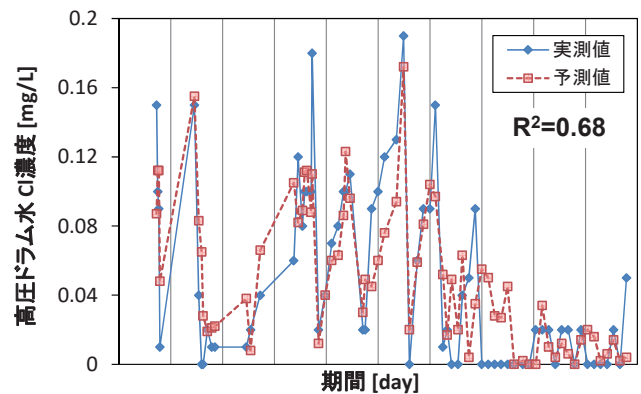


Fig.6 Cl 濃度の実測値と予測値のトレンド比較 (解析手法 : MW-RF)

### 4. まとめ

発電所のプラント水質を題材に、ソフトセンサによる塩化物イオン濃度の仮想計測の可能性を検討した。遺伝的アルゴリズムを用いた変数選択、非線形回帰

モデルと適用型モデルを組み合わせたプラント運転追従型のソフトセンサモデルを構築し、これまで連続測定が困難であった塩化物イオン等の成分濃度を、仮想計測できる可能性が示された。

今後、データの蓄積と他のプラント水質での検証を進め、モデルの改良や異常検知との組合せによる精度向上など、火力・原子力関連プラントの安全運転、保全活動に資する技術開発を進めていく。

## 参考文献

- [1] 椿崎仙市ら：三菱重工技報, 2018, **55**(1), 30-35
- [2] 大寶ら：化学工学, 2019, **83**(4)
- [3] 船津公人ら：ソフトセンサー入門, 基礎から実用的研究例まで, コロナ社 (2015)
- [4] P. Kadlec, et al. *Comput. Chem. Eng.* 2009, **33**, 795-814
- [5] H. Kaneko, K. Funatsu. *AIChE*, 2012, **58**(6), 1829-1840
- [6] S. Wold, et al., *Chemom. Intell. Lab. Syst.*, 2001, **58**, 109-130
- [7] D. Basak, et al., *Neural Inform. Proc.*, 2007, **11**(10), 109-130
- [8] L. Breiman, *Machine Learning*, 2001, **45**, 5-32
- [9] J. C. Jeng, *J. of Taiwan Inst. Of Chem. Eng.*, 2010, **41**, 472-481
- [10] K. Fujiwara, et al., *AIChE*, 2009, **55**, 1754-1765