

# One-Class SVMに基づく水力発電所におけるリスクマネジメント

小野田 崇

故障等の異常がほとんどない水力発電所の水車・発電機軸受に関する各種センサ情報に One Class Support Vector Machine を適用して、例外状態データを発見し、その発生頻度に基づく水力発電所異常予兆発見リスクマネジメントの取組について解説する。特に、本稿では、実際の水力発電の正常状態データから外れた状態データの抽出に One Class Support Vector Machine を適用した結果について報告する。

キーワード：One Class Support Vector Machine, リスクマネジメント, 水力発電所, 予兆発見

## 1. はじめに

水力発電所の保守は、1ヶ月に1回実施する五感を用いた設備巡視、並びに2ヶ月に1回実施する計器類の数値を記録・確認する日常点検により、性能を維持している。九州電力㈱では、この保守業務の省力化を目指し、水力発電所のセンサ情報から、異常の予兆を検出する技術の開発に取り組んでいる。特に、水力発電所の性能維持には水車・発電機軸受の異常予兆検出が重要となる。しかし、この水車・発電機軸受異常予兆検出については、以下の理由でセンサ情報に基づく異常予兆の検出が困難な状況にある。

- 多くのセンサ情報と軸受振動との因果関係は非常に複雑。
- 異常予兆発見に必要な異常、故障時のデータ発生は稀で、異常、故障時の詳細なデータがない。
- 実機を模擬した異常状態の生成が困難。

このような状況の中、著者らは、2003年から水車・発電機軸受が正常振動している際の各センサ情報の組み合わせを正常状態のデータと見なし、この正常状態データから外れた状態データの蓄積が異常予兆となると考えることで、水力発電所の水車・発電機軸受異常振動の予兆検出技術の開発に取り組み始めた。言い換えれば、例外状態データに基づく、水力発電所異常予兆発見リスクマネジメントの確立に取り組み始めた[1]。

おのだ たかし  
電力中央研究所 システム技術研究所  
〒201-8511 狛江市岩戸北 2-11-1

本稿では、正常状態データから外れた状態データの抽出に One Class Support Vector Machine[2]（以下、1クラス SVM）を採用し、九州電力㈱宮崎電力所の石河内第二水力発電所において収集された通常運転時の水車・発電機軸振動に関連するセンサ情報値の組み合わせデータを「起動時」、「並列時」、「解列時」、「停止時」の4つのフェーズのデータに分類し、「起動時」、「並列時」、「解列時」の3つのフェーズで、例外状態データ抽出を試みた結果について報告する。また、抽出された例外状態にデータに基づく、水力発電所異常予兆発見リスクマネジメントのイメージについて紹介する。

## 2. 石河内第二発電所の概要と監視データ

今回対象とした石河内第二発電所の概要を表1に示す。分析対象とした石河内第二発電所軸振動関連データは、2004年3月16日から同年11月23日まで、石河内第二発電所に設置したセンサ情報を九州電力宮崎電力所においてオンライン収集したものである。測定間隔は5秒であり、一つのデータは38項目のセンサ、気象情報で構成されている。この2004年3月16日か

表1 石河内第二発電所の概要

発電出力	18,000kW
使用水量	45m <sup>3</sup> /s
有効落差	46.3m
水車型式	縦軸フランシス水車
定格回転速度	240rpm
軸受	上部軸受 油自藏式セグメント式軸受(自然冷却方式) 下部軸受 油自藏式セグメント式軸受(自然冷却方式)
型式	水車軸受 油自藏式円筒形軸受(自然冷却方式) スラスト軸受 油自藏式ビボットスプリング式(自然冷却方式)
運転パターン	プロコン運転 (1日単位で運転パターンを決めて運転)

ら同年 11 月 23 日までに収集されたデータは、通常運転中の全て正常状態のデータであり、事故や故障などの事象が起こっていないデータである。

### 3. 例外パターン検出方法

本節では、例外状態パターン検出方法の概要について述べる。

通常、異常予兆の発見とは、既存の異常事例と正常事例とを比較分析し、その異常事例が起こる前にのみ現れる特異な事例を検出することである。しかし、電力会社の有するプラント等の設備は安全係数を高くして設計され、適切に保守されており、異常事例のデータが殆ど無いのが実状である。本研究で扱う水力発電所の軸受振動データについても、これまでのところ異常・故障事例がなく、そのため異常事例と正常事例との比較分析に基づく、異常事例が起こる前に現れる特異な事例を直接検出することは不可能である。そこで、異常事例の起こる前の特異事例（以下、異常予兆事例と呼ぶ）と正常状態から外れている事例との関係を次式のように考えることにする。

#### 3.1 異常予兆事例～正常状態から外れた事例

上式のように考えることで、異常予兆事例発見を正常状態データ中から仲間外れパターンを検出することに代替させることができる。つまり、正常状態データ中で発生確率が低い事例ほど、異常予兆を表している可能性が高いと考えるのである。正常状態事例から仲間外れパターンを検出するイメージを図 1 に示す。図 1 中、灰色斜線が覆う領域にあるデータは、全て正常状態事例である。本研究では、この正常状態事例から仲間外れパターンを検出する、つまり、例外状態パターンを検出することが本研究の目的となる。図 1 にあるように、正常状態データの 99% を覆う円を発見し、その領域を通常状態とすれば、この通常状態領域から外れた 1% のデータを例外状態パターンと考えることができ。図 1 では、太い黒い線で表される円の内部

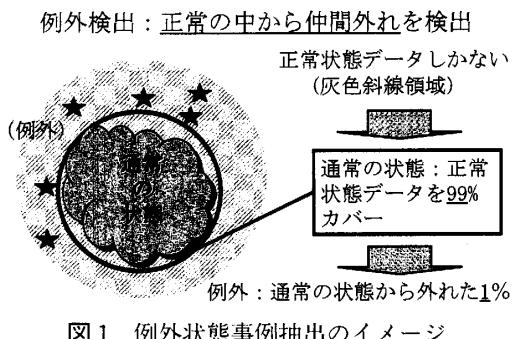


図 1 例外状態事例抽出のイメージ

が正常状態データ中の通常領域を表し、黒い星が例外状態パターンを表す。つまり、正常状態データを  $\alpha\%$  覆う境界を正確に発見することができれば、正常状態データの  $\alpha\%$  に属さない例外状態パターンを検出することができるるのである。

上述したように、正常運転中のデータより、正常状態パターンとは異なる例外状態パターンを検出するには、正常状態データを  $\alpha\%$  覆う境界を正確に発見する必要がある。この境界を正確に見つける方法の一つとして、本研究では、1 クラス SVM[2]を採用した。本研究で適用する 1 クラス SVM は、正常状態データ中の通常状態データの割合  $\alpha\%$  を与える代わりに、正常状態データ中の例外状態パターンの割合  $\gamma (=1-\alpha/100)$  を与えることで、正常状態データを  $\alpha\%$  覆う境界を正確に発見する方法である。

以下で、本研究で採用した 1 クラス SVM について、簡単に説明する。その詳細については、文献[2]を参照。

まず、学習データが以下の式で表現されるとする。

$$\mathbf{x}_1, \dots, \mathbf{x}_l \in X \quad (1)$$

ここで、 $l \in N$  であり、 $X \in R^N$  である。

今、 $\Phi$  を特徴写像  $X \rightarrow F$  であるとする。この特徴写像は、学習データをある特徴空間へと写像する。また、この写像  $\Phi$  による特徴空間での内積は、元の学習データ空間上の簡単なカーネル関数で表現される。つまり、次式が成り立つ。

$$k(\mathbf{x}, \mathbf{y}) = (\Phi(\mathbf{x}) \cdot \Phi(\mathbf{y})). \quad (2)$$

式(2)を満たすようなカーネル関数としては、ガウスカーネル関数  $k(\mathbf{x}_i, \mathbf{y}_j) = \exp(-\|\mathbf{x}_i - \mathbf{y}_j\|^2/c)$  が有名である。インデックス  $i$  と  $j$  は、 $1, \dots, l$  を表す。簡単のため以下では、 $i, j \in [l]$  の表現を探る。

1 クラス SVM では、ほとんどの学習データが入る小さな領域内で +1 (正常状態データ) の値を取り、それ以外の領域で -1 を採るような関数  $f$  を、以下の考え方によって生成する。

1. カーネル関数によって特徴空間へデータを写像。
2. 写像されたデータを原点からの最大マージンによって得られる分類面によって分類。言い換れば、原点に最も近いデータと原点との距離を最大化するように分類超平面を生成。

特徴空間上の学習データを原点から最大マージンによって分類するため、以下の 2 次計画問題を解く。

$$\min_{w \in F, \xi \in R^l, \rho \in R} \frac{1}{2} \|w\|^2 + \frac{1}{\nu l} \sum_i \xi_i - \rho$$

$$\begin{aligned} \text{subject to } & (w \cdot \Phi(\mathbf{x}_i)) \geq \rho - \xi_i, \\ & \xi_i \geq 0. \end{aligned} \quad (3)$$

この2次計画法を解くことで、原点に最も近いデータと原点との距離を最大化するような分類超平面を見つけることができる。つまり、正常状態データと正常状態でないデータを分ける超平面を見つけることができる。ここで、 $\nu$ は、 $\nu \in (0, 1)$ となるパラメータである。

#### 4. 例外状態パターン検出条件・結果および検出結果の評価

本節では、2節で紹介した九州電力株宮崎電力所で収集された2004年度の軸受振動に関連するセンサ、気象情報からの例外状態パターン検出条件とその抽出結果、および、抽出結果に対する評価について報告する。

##### 4.1 例外状態パターン検出条件

3節で説明した5秒間隔の測定データを分析対象とした。測定データは38項目から構成されているが、例外状態パターンを検出する際には、軸受振動に関連する測定項目に絞って分析した。具体的には、分析対象とする測定項目が、現場技術員の軸受振動に関する知見に基づき、表2に示す16項目を選定された。

また、収集された測定データをそのまま分析すると、並列時のデータに比べて事例の少ない発電機起動開始、および、発電機停止開始部分の測定データのみを例外状態パターンとして抽出してしまう。そこで、発電機起動開始、および、発電機停止開始部分の測定データのみを例外状態パターンとして抽出しないように、現場技術員の以下の経験則に基づき、測定データを「停止時」、「起動時」、「並列時」、「解列時」の4つのフェーズに分類した。

**経験則1** 発電機電圧 (V-W) 10 kV未満、ガイドベーン開度10%以上、回転数200 rpm以上なら起動時。

**経験則2** 発電機電圧 (V-W) 10 kV以上、回転数

表2 分析に用いた測定項目

分析対象項目	
A. 発生電力 (MW)	B. 回転数 (rpm)
C. 室温 (°C)	D. 水温 (°C)
E. オイルクーラー入口空気温度 (°C)	F. オイルクーラー出口空気温度 (°C)
G. 上部軸受温度 (°C)	H. 下部軸受温度 (°C)
I. 上部軸受油温 (°C)	J. 水車軸受温度 (°C)
K. 水車軸受油温 (°C)	L. スラスト軸受温度 (°C)
M. 下部油槽油温度 (°C)	N. 下部軸受入気温度 (°C)
O. 発電機軸振 (X 軸)(μm)	P. 水車軸振 (X 軸)(μm)

200 rpm以上なら並列時。

**経験則3** 発電機電圧 (V-W) 10 kV未満、ガイドベーン開度10%未満、回転数200 rpm以上なら解列時。

**経験則4** 上記以外の場合、停止時。

経験則による測定データの分類によって得られた各フェーズの測定データ数を表3に示す。

「停止時」フェーズでは軸受が回転していないため、当該フェーズを例外状態パターン検出分析の対象からは外した。つまり、「起動時」、「並列時」、「解列時」の3つのフェーズごとの測定データから例外状態パターン検出を行った。また、項目ごとの測定単位の違いによる影響を無くすため、測定データを測定項目ごとに平均0分散1に正規化した。

##### 4.2 分析結果および評価

上述のデータに対し、3節で述べた1クラスSVMを「起動時」、「並列時」、「解列時」の各フェーズデータに適用し、例外状態パターンの抽出を行った。実験では、抽出する例外状態パターン数を変化させた試行を実施した。ここでは、現場技術員が妥当であると判断した例外状態パターン数での各フェーズデータに対する分析結果について報告する。

###### 4.2.1 例外状態パターンの抽出（起動時）

起動時データに対し、1クラスSVMを $\nu=0.05$ (6件程度の例外状態パターン数)として適用し、例外状態パターンの抽出を行った。 $\nu=0.05$ とは、全ての起動時データ中の約5%が例外状態パターンであることを表している。抽出された例外状態パターンを表4に示す。表4に示した例外状態パターンは、識別値が0以下の場合に相当する。ここで抽出された例外状態パターンは、水力発電所の知識、運転状態の日報等の情報を利用せずに選択されたセンサ、気象情報値の組み合わせパターンである。

表4より、9件の例外状態パターンの内、斜体字で示した事例4および事例5の2件は、本来並列運転時に入るべきデータであることが分かった。これは、技術員の経験則が「起動時」を連続なパターンとして捉えることで形成されているために、5秒間隔で各センサの数値を測定する離散データを完全には「起動時」に分類できなかったことを表す。本来「並列時」に入

表3 各フェーズの測定データ数

フェーズ	停止時	起動時	並列時	解列時
データ数	433,935	120	2,368,756	132

表4 起動時データより抽出された例外状態パターン

測定項目	事例1	事例2	事例3	事例4	事例5	事例6	事例7	事例8	事例9
A. 発生電力 (MW)	-0.192	-0.192	-0.192	<i>-0.192</i>	-0.192	-0.192	<i>-0.162</i>	-0.192	-0.18
B. 回転数 (rpm)	239	224	238	<i>243</i>	<i>243</i>	238	<i>330</i>	233	224
C. 室温 (°C)	15.0	16.1	15.2	<i>23.1</i>	<i>23.1</i>	29.8	<i>28.8</i>	27.4	26.8
D. 水温 (°C)	10.1	10.9	10.4	<i>21.1</i>	<i>21.1</i>	27.9	<i>27.4</i>	25.8	24.5
E. オイルクーラー 入口空気温度 (°C)	20.3	22.9	18.0	<i>25.9</i>	<i>25.9</i>	36.6	<i>30.9</i>	28.6	27.9
F. オイルクーラー 出口空気温度 (°C)	25.4	27.6	21.8	<i>35.0</i>	<i>34.8</i>	40.9	<i>40.5</i>	29.9	28.5
G. 上部軸受温度 (°C)	40.0	41.0	36.2	<i>46.4</i>	<i>46.5</i>	50.3	<i>50.8</i>	32.2	30.6
H. 下部軸受温度 (°C)	36.3	35.1	32.9	<i>44.3</i>	<i>44.3</i>	44.5	<i>50.9</i>	31.2	29.6
I. 上部軸受油温 (°C)	35.9	36.8	32.1	<i>42.9</i>	<i>42.8</i>	47.7	<i>47.5</i>	31.6	29.5
J. 水車軸受温度 (°C)	34.1	31.7	30.8	<i>41.1</i>	<i>41.1</i>	40.8	<i>43.8</i>	24.6	22.5
K. 水車軸受油温 (°C)	32.3	30.0	29.2	<i>33.1</i>	<i>33.1</i>	38.2	<i>37.0</i>	24.8	22.5
L. スラスト軸受温度 (°C)	40.4	41.3	36.5	<i>54.6</i>	<i>54.8</i>	51.3	<i>59.7</i>	32.1	30.4
M. 下部油槽油温度 (°C)	33.3	32.5	29.7	<i>40.5</i>	<i>40.4</i>	43.3	<i>47.8</i>	30.1	28.6
N. 下部軸受入気温度 (°C)	18.8	21.0	18.1	<i>24.3</i>	<i>24.5</i>	33.5	<i>29.2</i>	29.1	27.8
O. 発電機軸振 (X 軸)(μm)	11	22	16	<i>12</i>	<i>8</i>	15	<i>23</i>	11	14
P. 水車軸振 (X 軸)(μm)	21	33	31	<i>34</i>	<i>27</i>	35	<i>33</i>	20	22

表5 並列時データより抽出された例外状態パターン(1)

測定項目	事例1	事例2	事例3	事例4	事例5	事例6	事例7
A. 発生電力 (MW)	1.602	2.112	1.542	2.622	1.122	16.68	16.26
B. 回転数 (rpm)	242	242	242	242	242	243	242
C. 室温 (°C)	15.0	14.8	15.0	15.0	12.1	23.3	28.6
D. 水温 (°C)	10.2	10.3	10.7	10.3	12.2	20.8	27.4
E. オイルクーラー 入口空気温度 (°C)	18.4	18.3	16.9	16.7	11.1	25.9	31.2
F. オイルクーラー 出口空気温度 (°C)	24.2	24.4	22.9	23.2	22.0	34.3	40.6
G. 上部軸受温度 (°C)	37.9	38.1	37.0	37.3	39.6	45.8	50.7
H. 下部軸受温度 (°C)	35.0	35.2	34.6	35.6	44.3	42.6	51.0
I. 上部軸受油温 (°C)	34.1	34.2	33.0	33.2	35.1	42.2	47.6
J. 水車軸受温度 (°C)	32.5	32.9	32.9	33.5	43.3	39.7	44.1
K. 水車軸受油温 (°C)	29.4	29.3	29.1	29.0	35.5	31.9	37.4
L. スラスト軸受温度 (°C)	39.6	40.3	39.1	40.6	46.9	53.9	59.8
M. 下部油槽油温度 (°C)	32.1	32.4	31.6	32.0	39.2	38.7	47.8
N. 下部軸受入気温度 (°C)	16.3	16.3	15.9	15.7	12.1	24.5	29.0
O. 発電機軸振 (X 軸)(μm)	18	21	21	19	24	17	22
P. 水車軸振 (X 軸)(μm)	40	35	42	44	87	26	51

るべきデータを、経験則では「起動時」に分類してしまったわけであるが、提案している例外状態パターン抽出方法により、「起動時」に入ってしまった「並列時」データを抽出できたことは、提案手法が「起動時」のデータから抽出されるべき例外状態パターンを発見できる方法となっていることを示すものである。

また、9件の例外状態パターンの内、斜体字で示した事例7は、通常運転とは異なる「事故遮断時」中のデータであることが、現場技術員の有する日報等から確認できた。提案している例外状態パターン抽出方法により、「起動時」データから非常に希である「事故遮断時」データを例外状態パターンとして抽出できたことは、提案手法が「起動時」のデータから抽出されるべき例外状態パターンを発見できる方法となっていることを示すものである。

#### 4.2.2 例外状態パターンの抽出（並列時）

並列時データに対し、1クラス SVM を  $\nu=5 \times 10^{-6}$  (12件程度の例外状態パターン数) として適用し、例外状態パターンの抽出を行った。 $\nu=5 \times 10^{-6}$  とは、全ての並列時データ中の約  $5 \times 10^{-4}\%$  が例外状態パターンであることを表している。抽出された例外状態パターンを表5、6に示す。

ここで抽出された例外状態パターンは、「起動時」データの分析と同様、水力発電所の知識、運転状態の日報等の情報を利用せずに選択されたセンサ、気象情報値の組み合わせパターンである。

表5、6より、14件の例外状態パターンの内、斜体字になった事例10、11、12の3件は、通常運転とは異なる「作業運転」中のデータであることが、現場技術員の有する日報等から確認できた。この「作業運転」は非常に希な事象で、現場技術員も提案手法によ

表6 並列時データより抽出された例外状態パターン(2)

測定項目	事例 8	事例 9	事例 10	事例 11	事例 12	事例 13	事例 14
A. 発生電力 (MW)	15.792	14.64	-0.192	-0.192	-0.192	-0.18	1.632
B. 回転数 (rpm)	242	243	232	231	229	233	242
C. 室温 (°C)	28.6	28.7	26.8	26.8	26.7	27.6	12.4
D. 水温 (°C)	27.4	27.6	25.6	25.6	25.6	25.7	13.1
E. オイルクーラー 入口空気温度 (°C)	30.8	30.6	28.1	28.0	28.0	28.6	12.8
F. オイルクーラー 出口空気温度 (°C)	40.3	40.0	35.3	35.3	35.3	30.6	22.5
G. 上部軸受温度 (°C)	50.5	50.7	45.6	45.6	45.8	36.8	39.2
H. 下部軸受温度 (°C)	50.7	50.9	43.5	43.7	43.8	32.8	44.2
I. 上部軸受油温 (°C)	47.3	47.4	42.4	42.6	42.4	34.7	35.1
J. 水車軸受温度 (°C)	43.8	43.7	39.9	40.0	39.9	27.4	43.8
K. 水車軸受油温 (°C)	36.5	36.0	31.1	31.1	31.1	25.2	36.3
L. スラスト軸受温度 (°C)	59.7	59.4	52.9	52.9	53.1	38.1	46.8
M. 下部油槽油温度 (°C)	47.8	48.1	40.3	40.2	40.2	30.8	39.0
N. 下部軸受入気温度 (°C)	29.2	29.1	26.8	26.7	26.8	28.5	11.7
O. 発電機軸振 (X 軸)(μm)	20	22	23	18	12	10	23
P. 水車軸振 (X 軸)(μm)	54	63	70	54	47	24	87

表7 解列時データより抽出された例外状態パターン

測定項目	事例 1	事例 2	事例 3	事例 4	事例 5	事例 6	事例 7	事例 8	事例 9	事例 10	事例 11
A. 発生電力 (MW)	-0.21	-0.192	-0.192	-0.192	-0.192	-0.192	-0.18	-0.192	-0.192	-0.192	-0.192
B. 回転数 (rpm)	227	208	239	233	240	208	242	261	208	225	236
C. 室温 (°C)	15.6	16.4	13.8	16.9	22.8	22.7	29.9	28.8	28.8	26.7	27.6
D. 水温 (°C)	9.4	9.6	13.2	14.7	20.6	20.4	28.7	27.6	27.6	25.7	25.6
E. オイルクーラー <sup>1</sup> 入口空気温度 (°C)	17.6	18.6	13.9	20.1	26.3	26.3	32.3	31.1	31.1	28.0	28.6
F. オイルクーラー <sup>1</sup> 出口空気温度 (°C)	27.4	28.0	24.1	29.1	32.0	31.9	41.1	40.6	40.5	35.3	30.8
G. 上部軸受温度 (°C)	42.4	42.3	40.3	43.0	42.6	42.8	50.8	50.6	50.7	45.6	36.6
H. 下部軸受温度 (°C)	45.6	45.6	44.7	44.7	38.1	38.1	51.6	50.7	50.9	43.7	32.5
I. 上部軸受油温 (°C)	38.3	38.3	36.2	39.0	39.0	39.3	48.1	47.6	47.7	42.6	34.6
J. 水車軸受温度 (°C)	42.4	42.6	42.6	41.5	35.5	35.6	48.1	44.0	43.9	40.0	26.8
K. 水車軸受油温 (°C)	35.5	35.0	34.8	34.0	31.9	31.9	43.0	37.0	37.0	31.1	25.3
L. スラスト軸受温度 (°C)	50.2	49.9	47.9	50.9	45.6	45.8	59.4	59.7	59.7	53.1	37.2
M. 下部油槽油温度 (°C)	41.0	41.1	39.7	40.2	35.4	35.4	48.8	47.7	47.9	40.3	30.9
N. 下部軸受入気温度 (°C)	16.4	17.1	14.1	17.9	24.6	24.6	31.0	29.2	29.4	26.6	28.2
O. 発電機軸振 (X 軸)(μm)	11	11	12	12	13	13	12	17	10	12	9
P. 水車軸振 (X 軸)(μm)	35	33	34	33	28	23	46	37	37	34	23

る例外状態パターン抽出結果としてそのデータが提示されるまで、「作業運転」が行われていたことに気付かなかつた。提案している例外状態パターン抽出方法により、「並列時」データから非常に希である「作業運転」データを例外状態パターンとして抽出できたことは、提案手法が「並列時」のデータから確実に例外状態パターンを発見できる方法となっていることを示すものである。

#### 4.2.3 例外状態パターンの抽出（解列時）

解列時データに対し、1 クラス SVM を  $\nu=0.05$  (7 件程度の例外状態パターン数) として適用し、例外状態パターンの抽出を行つた。 $\nu=0.05$  とは、全ての解列時データ中の約 5% が例外状態パターンであることを表している。抽出された例外状態パターンを表7 に示す。

表7 より、11 件の例外状態パターンの内、斜体字

になった事例 10, 11 の 2 件は、通常運転とは異なる「作業運転」中のデータであることが、現場技術員の有する日報等から確認できた。この「作業運転」は非常に、前述したように希な事象で、現場運転員も提案手法による例外状態パターン抽出結果として、「作業運転」が行われていたことに気付かなかつた。提案している例外状態パターン抽出方法により、「並列時」データから非常に希である「作業運転」データを例外状態パターンとして抽出できたことは、提案手法が「並列時」のデータから確実に例外状態パターンを発見できる方法となっていることを示すものである。

また、11 件の例外状態パターンの内、斜体字で示した事例 8, 9 は、通常運転とは異なる「事故遮断時」中のデータであることが、現場技術員の有する日報等から確認できた。提案している例外状態パターン抽出方法により、「解列時」データから非常に希である

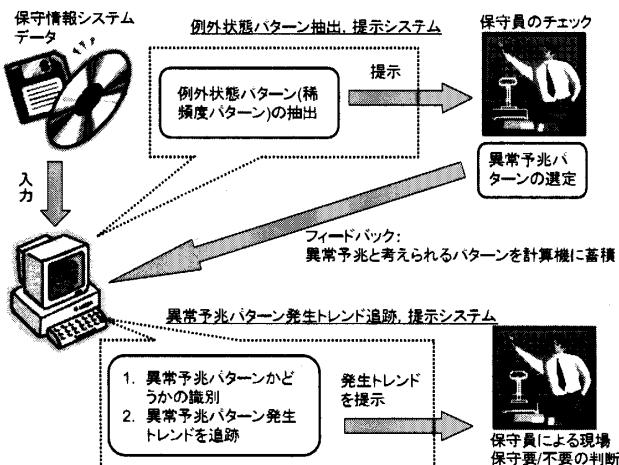


図2 異常予兆発見システムのイメージ

「作業運転時」、および、「事故遮断時」データを例外状態パターンとして抽出できたことは、提案手法が「解列時」のデータから抽出されるべき例外状態パターンを発見できる方法となっていることを示すものである。

## 5. 軸受振動における異常予兆発見

本節では、4節の分析結果に基づく、軸受振動における例外状態パターン抽出による異常予兆発見に基づく、水力発電設備のリスクマネジメントのイメージについて述べる。

本報告で示した各フェーズでの例外状態パターン抽出能力および現場技術員等の評価に基づき、通常運転時データのみ（異常事例が無い）からの異常予兆発見システムおよびリスクマネジメントのイメージを検討した。異常予兆発見システムのイメージを図2に示す。

図2に示した異常予兆発見システムのイメージは、例外状態パターン抽出能力に基づき、稀なパターン（年に5または10回起こる程度）を現場の保守員に提示するとともに、初期に抽出した例外状態パターン事例の発生トレンドを管理する機能から構成されている。この2つの機能を持たせる理由は、非常に稀な例外状態パターンを保守員に提示することにより、保守員による事例の説明と異常予兆事例の発見・確認するフェーズと、非常に稀な例外状態パターンの発生トレンドを管理することにより、軸受振動の経年劣化的な異常予兆を確認するフェーズが重要であると判断したため

である。また、発生トレンド管理機能は、図2のフィードバックによって得られる異常予兆パターンの特性が変わった場合、過去のデータに溯って、その特性に合わせた発生トレンド管理ができる仕組みを備えている。

この希少パターン発生トレンド管理機能により、異常予兆に結び付きそうな希少パターンデータの年間の発生頻度、あるいは、発生確率の変動情報に基づく水力発電所のリスクマネジメントが可能となる。

## 6. まとめと今後の展開

本報告では、九州電力(株)宮崎電力所石河内第二発電所の通常運転時における水車、発電機軸受振動に関するセンサ、気象情報2,802,943データを現場技術員の経験則で「起動時」、「並列時」、「解列時」の3フェーズに分類し、各フェーズデータから抽出した例外状態パターンの分析結果を報告した。分析結果より、1クラスSVMにより、非常に稀なパターンを測定データより抽出できることを確認した。

非常に稀な例外状態パターンの分析結果と現場技術員の評価に基づき、水車・発電機軸受振動の異常予兆発見システムのイメージおよびそのシステムの機能を利用した水力発電所のリスクマネジメントについて紹介した。

今後、水車・発電機軸受振動の異常予兆発見システムを、恒常に測定データに適用し、希少パターンデータのトレンド管理を行い、異常予兆発見の実現可能性を評価する。また、希少パターンデータのトレンド管理機能に基づく、水力発電所のリスクマネジメントの詳細な検討と、その実現可能性の検討を行う。

## 参考文献

- [1] 小野田崇、村田博士、山名美智子、清水健二、野邊信勝、村川秀樹. One class svmに基づく水力発電所軸受振動の予兆発見(1). 第18回人工知能学会全国大会, 2004.2 F 2-01.
- [2] B. Schölkopf, J. C. Platt, J. Shawe-Taylor, A. J. Smola and R. C. Williamson. Estimation support of high-dimensional distribution. Technical Report MSR-TR-99-87, Microsoft Research, 1999.