

## SVMに基づく水力発電所の異常予兆発見支援

Abnormal condition sign discovery support method based on SVM

小野田 崇\*1

Takashi Onoda

伊藤 憲彦\*1

Norihiko Ito

山崎 博信\*2

Hironobu Yamasaki

\*1(財)電力中央研究所

Central Research Institute of Electric Power Industry

\*2九州電力株式会社

Kyushu Electric Power Co.,Inc.

Kyushu Electric Power Co.,Inc. collects different sensor data and weather information to maintain the safety of hydropower plants while the plants are running. This paper proposes an approach of abnormal condition signs discovery by using a One Class SVM and a normal SVM. Then this paper shows the results of abnormal condition signs discovery for bearing vibration from the collected different sensor data and weather information. The result shows that our approach may be useful for the abnormal condition signs discovery in maintaining hydropower plants.

## 1. はじめに

九州電力(株)における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の記録を確認する日常点検により、性能を維持している。九州電力(株)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、異常の予兆を発見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発見が重要となる。しかし、この水車・発電機軸受異常予兆発見については、以下の理由でセンサ情報に基づく異常予兆の発見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、故障時の詳細なセンサ情報データがない。
- 実験による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値のデータを正常状態データと見なし、この正常状態データから外れた例外状態データに類似したデータの増加が異常予兆を表すと考えることで、水力発電所の水車・発電機軸受異常振動の予兆発見技術の開発に取り組み始めた。つまり、以下のような仮定の下で、水力発電所の異常予兆発見技術の開発に取り組み始めた。

異常予兆 ≈ 例外状態データに類似したデータの増加

上述の考えに基づき、2004年度には九州電力(株)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正常運転時の水車・発電機軸振動に関連する並列時)センサ情報値のデータから、One Class Support Vector Machine(One-Class SVM)によって、例外状態データを抽出した結果、および、その抽出データの水力発電所現場技術員による評価結果について報告した[小野田 04]。また、2005年度には正常運転時の水車・発電機軸振動に関連するセンサ情報値データを現場技術員の運転経験則で「起動時」「並列時」「解列時」「停止時」の4つ

連絡先: 小野田 崇, (財)電力中央研究所 システム技術研究所, 東京都狛江市岩戸北 2-11-1, 03-3480-2111, 03-5497-0318, onoda@criepi.denken.or.jp

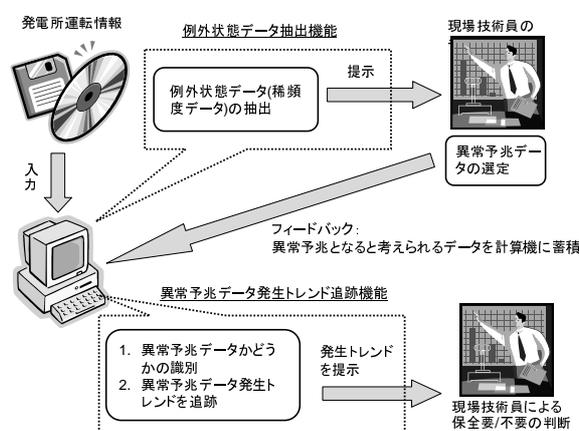


図 1: 異常予兆発見支援のイメージ

の運転状態に分類し、「起動時」「並列時」「解列時」の各運転状態で、例外状態データ抽出を試みた結果について報告した[小野田 05]。

本論文では、水力発電所の異常予兆発見支援のイメージと異常予兆発見支援ツールについて紹介する。また、開発した異常予兆発見支援ツールを試用した結果について報告する。

## 2. 水力発電所の異常予兆発見支援ツール

## 2.1 異常予兆発見支援のイメージ

図 1 に水力発電所の異常予兆発見支援のイメージを示す[小野田 05]。図 1 中の発電所運転情報は、水車・発電機軸振動に関連するセンサ情報値データを意味する。図に示したように異常予兆発見支援のイメージは、主に発電所運転情報から例外状態データを抽出する機能と異常予兆データ発生トレンド追跡機能から構成される。ここで、異常予兆データとは、計算機が抽出した例外状態データの中から運転員がセンサ情報以外の情報や経験則に基づき異常予兆を表すデータとして選定したデータを意味する。発電所運転情報の中には、センサ不良のデータや試験運転のようなことを行った際などの特異な状態のデータも含まれている。計算機にはこの特異な状態についての

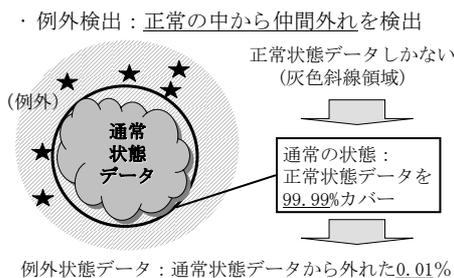


図 2: 例外状態データ抽出のイメージ

情報は与えられず、例外状態データを抽出するので、この特異な状態のデータが例外状態データとして抽出されてしまう。そこで、センサ不良や試験運転などの情報を有する現場運転員に抽出された例外状態データを提示し、そのデータから特異な状態のデータを指摘してもらい、全データから指摘された特異な状態のデータを削除したデータを作成するということを繰り返す。最終的には、特異な状態のデータが全て削除されたデータから例外状態データを抽出し、その抽出された例外状態データから運転員が異常予兆を表すデータである異常予兆データを選定する。ここまでが、例外状態データ抽出機能である。その後、オンラインで収集されるセンサデータが選定された異常予兆データに類似したデータかどうかの分類を行い、異常予兆データに類似したデータの発生率が増加した場合に警告などを発生させる。上記が異常予兆データ発生トレンド追跡機能である。本研究では、これら 2 つの機能から構成される異常予兆発見支援ツールを開発した。以下で簡単に各機能の実現方法について述べる。

## 2.2 例外状態データ抽出機能

正常状態データから例外状態データを抽出するイメージを図 2 に示す。図 2 中、灰色斜線が覆う領域にあるデータは、全て正常状態データである。例外状態データ抽出機能にとっては、この正常状態データから例外状態データを抽出する方法の実現が重要となる。図 2 にあるように、正常状態データの 99.99% を覆う円を発見し、その領域を通常状態データとすれば、この通常状態データ領域から外れた 0.01% のデータを例外状態データと考えることができる。図 2 では、太い黒い線で表される円の内部が正常状態データ中の通常状態データ領域を表し、黒い星が例外状態データを表す。つまり、 $(100 - \alpha)\%$  を例外状態データと判別するとした場合、正常状態データの  $\alpha\%$  に属さない(通常状態データ領域に属さない)例外状態データ  $((100 - \alpha)\%)$  を抽出することができるのである。水力発電所のセンサデータは、その値が高くなるほど異常を表すという特徴を考慮して、本研究では、正常状態データ中の通常状態データ領域を発見し、例外状態データ抽出機能を実現するために、One-Class SVM[Schölkopf 99, 小野田 07] を適用した。

## 2.3 異常予兆データ発生トレンド追跡機能

図 1 の上部に示されている例外状態データ抽出機能の利用により、正常状態データの中から、稀にしか起こらない例外状態データが現場運転員に提示される。現場運転員のチェックの後、現場運転員による説明も困難であるような非常に稀な例外状態データを選定し、システムに蓄積する。ここで選定された例外状態データが「異常予兆データ」である。異常予兆データ発生トレンド追跡機能は、次々と計測されるセンサデータが、

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	
軸受型式	上部軸受	油目蔵式セグメント式軸受(自然冷却方式)
	下部軸受	油目蔵式セグメント式軸受(自然冷却方式)
	水車軸受	油目蔵式円筒形軸受(自然冷却方式)
	スラスト軸受	油目蔵式ヒボットスプリング式(自然冷却方式)

システムに与えられた異常予兆データに類似したデータかどうかを識別し、類似データの発生率などを計算して、現場運転員にこの情報を提示する。現場運転員は、提示される異常予兆データの発生率が非常に増加している場合、水力発電所が何らかの異常予兆を示していると判断することが可能である。本研究では、異常予兆データに類似したデータかどうかを識別する分類器として線形 SVM[Vapnik 95, Vapnik 98, 小野田 07] を採用した。

## 3. データおよび試用条件

開発した異常予兆発見支援ツールの有効性を検証するために行った試用実験の実験条件と、試用実験に用いたデータについて簡単に述べる。

### 3.1 実験データ

今回試用実験の対象データを取得した石河内第二発電所の概要を表 1 に示す。試用実験の対象とした石河内第二発電所軸振動関連データは、2005 年 5 月 24 日から 2006 年 11 月 30 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\*1。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 2005 年 5 月 24 日から 2006 年 11 月 30 日までに収集されたデータは、水力発電所自体で事故や故障などの事象が起こっていない正常状態のデータである\*2。相対的に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を例外状態データとして抽出しないよう、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 つの運転状態に分類した。回転数が 200rpm 未満の「停止時」では、軸受が定格回転状態にないため、当該運転状態を例外状態データ抽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 つの運転状態ごとの測定データに対し、開発ツールの試用を行った。測定データは 38 項目から構成されているが、例外状態データを検出する際には、軸受振動に関連する測定項目に絞った。具体的には、「起動時」、「解列時」には 14 測定項目を使い、「並列時」には、15 測定項目に絞った。

また、測定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以下の式による正規化を行った。

$$\text{正規化値} = -\frac{\text{値} - \text{最小値}}{\text{最大値} - \text{最小値}} + 1$$

水力発電所に取り付けられたセンサからのデータは、その値が大きいほど基本的には発電所の安全性が低下していることを

\*1 ただし、2005 年 7 月 13 日から 2005 年 10 月 27 日、2005 年 10 月 30 日、31 日、2005 年 12 月 1 日から 2005 年 12 月 10 日、2006 年 2 月 1 日から 2006 年 3 月 10 日、2006 年 10 月 21 日から 10 月 25 日の期間のデータは蓄積されておらず、分析対象外とした。

\*2 落雷等の送電事故による発電機停止は、少ないが発生している。

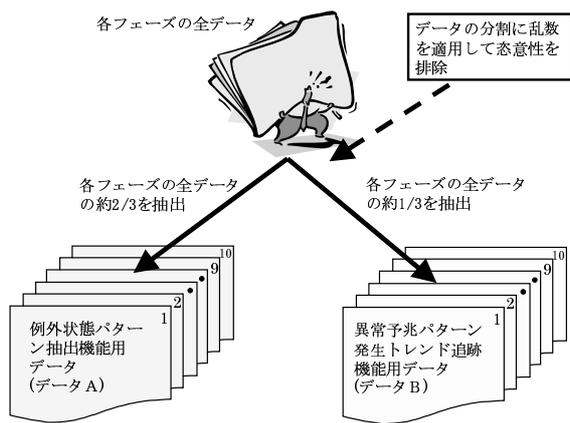


図 3: 試用データの生成手順

表 2: 起動時の例外状態データ抽出用データと異常予兆データ発生トレンド追跡用データの構成

実験セット	データ抽出用データ数 (率%)	トレンド追跡用データ数 (率%)
1	4,436(66.92)	2,263(33.08)
2	4,386(66.16)	2,243(33.84)
3	4,426(66.77)	2,203(33.23)
4	4,414(66.59)	2,215(33.41)
5	4,452(67.16)	2,177(32.84)
6	4,430(66.83)	2,199(33.17)
7	4,403(66.44)	2,226(33.56)
8	4,361(65.79)	2,268(34.21)
9	4,411(66.54)	2,218(33.46)
10	4,440(66.98)	2,189(33.02)

示している．そこで，上記のような正規化を行い，One Class SVM を用いることでセンサの値が大きく，かつ，起こる確率の低いものを例外状態データとして抽出することができる．

### 3.2 試用条件

開発した異常予兆発見支援ツールを試用し，有効性を検証するには，例外状態データを抽出する際に用いるデータ（データ A）と，異常予兆データの発生トレンドを追跡する際に用いるデータ（データ B）の 2 組のデータが必要となる．本研究では，各運転状態のデータ 2/3 と 1/3 に分け，それぞれデータ A，B として用いた．データの分割は，乱数を用いて行い，恣意性を排除した．その様子を図 3 に示す．各運転状態の全データに対し，図 3 の手順を 10 回繰り返して，例外状態データ抽出用のデータ A と異常予兆データ発生トレンド追跡用のデータ B の組（試用セット）を 10 セット用意した．例外状態データ抽出機能における One-Class SVM にも，異常予兆データ発生トレンド追跡機能における通常の SVM にも線形カーネルを試用した．各運転状態のデータから 15 件程度の例外状態データを抽出するという設定で試用実験を行った．

## 4. 試用結果

### 4.1 起動時データへの試用結果

起動時の 10 試用セットのデータ数の構成を表 2 に示す．ただし，起動時の全データ数は，6, 629 である．

起動時データに対し，One-Class SVM を上記の条件で適用し，例外状態データの抽出を行った．各試用セットに対し，例

表 3: 起動時データにおける例外状態データ抽出数と抽出率および異常予兆データ発生数と発生率

実験セット	例外状態データ抽出数	例外状態データ抽出率 (%)	異常予兆データ発生数	異常予兆データ発生率 (%)
1	12	0.32	12	0.55
2	16	0.36	5	0.22
3	14	0.32	10	0.45
4	13	0.29	5	0.23
5	17	0.38	8	0.37
6	16	0.36	10	0.45
7	16	0.36	11	0.49
8	17	0.39	8	0.35
9	16	0.36	7	0.32
10	17	0.38	4	0.18
平均	15.6	0.35	8.0	0.36

表 4: 並列時の例外状態データ抽出用データと異常予兆データ発生トレンド追跡用データの構成

データセット	データ抽出用データ数 (率%)	トレンド追跡用データ数 (率%)
1	2,897,250(66.66)	1,449,009(33.34)
2	2,898,155(66.68)	1,448,104(33.32)
3	2,896,254(66.64)	1,450,005(33.36)
4	2,895,773(66.63)	1,450,486(33.37)
5	2,894,936(66.61)	1,451,323(33.39)
6	2,895,956(66.63)	1,450,303(33.37)
7	2,897,564(66.69)	1,448,695(33.31)
8	2,898,716(66.69)	1,447,543(33.31)
9	2,896,997(66.65)	1,449,262(33.35)
10	2,898,720(66.69)	1,447,539(33.31)

外状態データ抽出機能を試用した結果を表 3 に示す．表には，例外状態データ抽出機能により抽出された例外状態データ数と，データ A に対する例外状態データ抽出率を示した．

本試用は「異常予兆データの絞り込を行う現場技術員の介在なし」という条件の下で行った．そのため，本試用では，抽出された例外状態データ全てを異常予兆データとして考えた．抽出された全ての例外状態データと通常状態領域のデータ（データ A から抽出された例外状態データを引いたデータ）に基づき，識別関数を決定し，この識別関数によって，異常予兆データ発生トレンド追跡機能用データ（データ B）中のデータで，異常予兆データと判定されたデータ数とその発生率を表 3 に示す．表 3 より，起動時において，例外状態データ抽出率と異常予兆データ発生率の平均を比較してみると，ほぼ同じくらいの率となっていることがわかる．

#### 4.1.1 並列時データへの試用結果

並列時の 10 試用セットのデータ数の構成を表 4 に示す．ただし，並列時の全データ数は，4, 346, 259 である．

並列時データに対し，One-Class SVM を上記の条件で適用し，例外状態データの抽出を行った．各試用セットに対し，例外状態データ抽出機能を試用した結果を表 5 に示す．表には，例外状態データ抽出機能により抽出された例外状態データ数と，データ A に対する例外状態データ抽出率を示した．

起動時と同様に，本試用では，抽出された例外状態データ全てを異常予兆データとして考えた．異常予兆データ発生トレンド追跡機能用データ（データ B）中のデータで，異常予兆データと判定されたデータ数とその発生率を表 5 に示す．表 5 より

表 5: 並列時データにおける例外状態データ抽出数と抽出率および異常予兆データ発生数と発生率

実験セット	例外状態データ抽出数	例外状態データ抽出率 (%)	異常予兆データ発生数	異常予兆データ発生率 (%)
1	15	$5.18 \times 10^{-4}$	7	$4.83 \times 10^{-4}$
2	15	$5.18 \times 10^{-4}$	8	$5.52 \times 10^{-4}$
3	13	$4.49 \times 10^{-4}$	12	$8.28 \times 10^{-4}$
4	18	$6.22 \times 10^{-4}$	6	$4.14 \times 10^{-4}$
5	14	$4.84 \times 10^{-4}$	7	$4.82 \times 10^{-4}$
6	13	$4.49 \times 10^{-4}$	12	$8.27 \times 10^{-4}$
7	12	$4.14 \times 10^{-4}$	8	$5.52 \times 10^{-4}$
8	15	$5.17 \times 10^{-4}$	11	$7.60 \times 10^{-4}$
9	14	$4.83 \times 10^{-4}$	4	$2.76 \times 10^{-4}$
10	14	$4.83 \times 10^{-4}$	7	$4.84 \times 10^{-4}$
平均	14.3	$4.94 \times 10^{-4}$	8.2	$5.66 \times 10^{-4}$

表 7: 解列時データにおける例外状態データ抽出数と抽出率および異常予兆データ発生数と発生率

実験セット	例外状態データ抽出数	例外状態データ抽出率 (%)	異常予兆データ発生数	異常予兆データ発生率 (%)
1	15	3.15	8	4.08
2	13	2.95	10	4.33
3	14	3.20	7	2.99
4	12	2.72	14	6.06
5	14	3.04	11	5.21
6	13	2.82	6	2.84
7	12	2.84	3	1.20
8	14	3.15	5	2.19
9	14	3.23	8	3.36
10	13	2.80	10	4.81
平均	13.4	2.99	8.2	3.71

表 6: 解列時での例外状態データ抽出用データと異常予兆データ発生トレンド追跡用データの構成

実験セット	データ抽出用データ数 (率%)	トレンド追跡用データ数 (率%)
1	476(70.83)	203(29.17)
2	441(65.63)	231(34.37)
3	438(65.18)	234(34.82)
4	441(65.63)	231(34.37)
5	461(68.60)	211(31.40)
6	461(68.60)	211(31.40)
7	422(62.80)	250(37.20)
8	444(66.07)	228(33.93)
9	434(64.58)	238(35.42)
10	464(69.05)	208(30.95)

り、並列時において、例外状態データ抽出率と異常予兆データ発生率の平均を比較してみると、ほぼ同じくらいであることがわかる。

#### 4.2 解列時データへの試用結果

解列時の 10 試用セットのデータ数の構成を表 6 に示す。ただし、解列時の全データ数は、672 である。

解列時データに対し、One-Class SVM を上記の条件で適用し、例外状態データの抽出を行った。各試用セットに対し、例外状態データ抽出機能を試用した結果を表 7 に示す。表には、例外状態データ抽出機能により抽出された例外状態データ数と、データ A に対する例外状態データ抽出率を示した。

本試用でも、起動時と同様に、抽出された例外状態データを全てを異常予兆データとして考えた。異常予兆データ発生トレンド追跡用データ (データ群 B) 中のデータで、異常予兆データと判定されたデータ数とその発生率を表 7 に示す。表 7 より、解列時において、例外状態データ抽出率と異常予兆データ発生率の平均を比較してみると、ほぼ同じくらいであることがわかる。

### 5. まとめ

本論文では、水力発電所の異常予兆発見支援イメージと、それを実現する異常予兆発見支援ツールの機能について提案した。また、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、気象情報データを「起動時」、「並列時」、「解列時」、「停止時」の 4 運転状態に分類し、「停止時」以外の各運転状態データに開発

ツールを試用した結果について報告した。

試用結果からは、異常予兆データ発生トレンド追跡機能において、例外状態データ抽出機能で抽出される例外状態データ抽出率より、異常予兆データ発生率の方がやや多めになる。本報告の実験では、例外状態データ抽出率より、最大で約 1.2 倍の異常予兆データ発生率が観測された。これは、通常の SVM ができるだけ大きなマージンを生成し、異常予兆データの境界面と判別超平面との間に入るデータを「異常予兆データ」と分類するためであると考えられる。

今後、石河内第二水力発電所における 2007 年度の測定データに開発ツールを適用し、異常予兆データの発生数等を 2006 年度の結果と比較して、経年による常予兆発生の特徴を調査する。また、ツールを他の水力発電所のデータにも適用し、実環境下でのツールの有効性を評価する。

### 参考文献

- [小野田 04] 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異常振動の予兆発見 (1), 人工知能学会 2004 年全国大会, 2F2-01,(2004).
- [小野田 05] 小野田 崇, 伊藤 憲彦, 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異常振動の予兆発見 (1), 人工知能学会 2005 年全国大会, 1F4-03,(2005).
- [Schölkopf 99] B. Schölkopf, J.C. Platt, J. Shawe-Taylor, A.J. Smola, R.C. Williamson: Estimation support of high-dimensional distribution, Microsoft Research, MSR-TR-99-87, (1999).
- [Vapnik 95] V.N. Vapnik: The Nature of Statistical Learning Theory, Springer, (1995).
- [Vapnik 98] V.N. Vapnik: Statistical Learning Theory, Wiley, New York, (1995).
- [小野田 07] 小野田 崇: サポートベクターマシン (知の科学シリーズ), オーム社, (2007).