

帰納学習に基づくプラント異常症候識別知識の獲得に関する研究

石毛 太郎*, 高橋 勝利**, 高橋 信*, 北村 正晴*

Taro Ishige*, Katsutoshi Takahashi**, Makoto Takahashi*, Masaharu Kitamura*

*東北大学大学院工学研究科量子エネルギー工学専攻,

**東北大学大学院情報科学研究科人間社会情報科学専攻

*Department of Quantum Science & Energy Engineering, Tohoku University,

**Department of Human-Social Information Sciences, Tohoku University

キーワード: 運転員支援システム(Operator Support System), 異常診断(Fault Diagnosis),
知識獲得(Knowledge Acquisition), C4.5, DP マッチング法(DP Matching)

連絡先: 〒980-77 宮城県仙台市青葉区荒巻字青葉 東北大学工学部量子エネルギー工学科 北村研
石毛太郎, Tel.: (022)217-7907, Fax.: (022)217-7907, E-mail: taro@mine4.nucle.tohokou.ac.jp

1. はじめに

原子力プラントは、非常に高い安全性の確保が要求されるシステムであり、運転、保守において要求される信頼性のレベルは非常に高い。原子力プラントの運転員は高度な教育を受けはいるが、人間である限りエラーを犯す可能性をゼロにすることは不可能であり、ヒューマン・エラーの抑制が重要な課題となっている。近年、ヒューマン・インターフェースの研究、運転の自動化の研究、運転員支援システムの研究等、ヒューマン・エラーの抑制を目的とした様々な研究が行われている。本研究では特に運転員支援システムに焦点を当て、運転員支援において重要な役割を果たす異常診断のための知識獲得に関する研究を行っている。

運転員支援システムとは、プラントの状況把握、異常識別等を行い、運転員に支援情報を提供するシステムであり、運転員の判断の誤り、状況認識の偏向などを抑制するために有用であると考えられる。運転員に対して適切な情報を提供するためには、システム自体がプラントの状況を正しく同定する必要があり、異常診断技術はその基礎となるものである。この異常診断に用いられる代表的な手法として、ニューラルネットワークによる推論とルールベース推論が挙げられる。前者のニューラルネットワークによる推論はパターン認識など広い分野で応用されている手法であり、その有用性は証明されているが、この手法を異常診断に用いる場合、その推論過程がブラックボックスとなってしまう、診断過程の説明が困難であるという難点を持つ。一方、後者の異常識別知識を利用したルールベース推論においては、異常識別

知識の獲得がボトルネックとなる。現在、この異常識別知識は多くの場合、熟練した運転員へのアンケートにより獲得しているが、その知識獲得、整理に要する労力は膨大なものであり、熟練者の持つすべての知識をもれなく獲得することは困難であると考えられる。

本研究は、異常診断のための識別知識を、シミュレーションデータに基づき帰納的学習により半自動的に獲得する試みである。このように与えられるデータから自動的に異常識別知識を獲得することで、熟練者からの知識獲得の方法における労力的な問題を軽減することが期待されると同時に、知識の取り込み漏れや偏りの問題を回避することができると期待される。

2. 概要

帰納学習は、複数の属性値の集合とそれに対する事象(本研究において属性値とはプラントのプロセス量の属性、増加・減少・分散増加等を意味し、事象とは対応するプラントの状態、すなわち正常か異常か、異常の場合はどのような異常が生起しているか、を意味する。)の集合から、属性の情報量に基づき事象を分類するを診断ルールを構

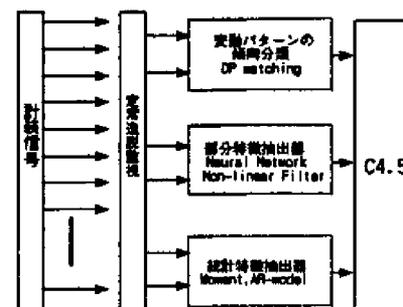


図1 プロセス量からの属性抽出

成する。本研究では、決定木という段階的な診断ルールを形成するC4.5[1]と呼ばれる標準的な方法を採用した。計測信号のような時系列データに対してこのような帰納学習を適用する場合、そのデータの特徴と捉え方、つまりデータに対する属性の選択方法が一つのキーポイントとなり、得られる結果を大きく左右する。本研究では属性として、より多様な側面からのプロセス量の特徴的傾向を捉えるために、図1に示すような複数の特徴抽出器を並列して適用することとした。特徴抽出器としては、信号の変動パターンの全体的な傾向を分類をするDPマッチング、信号の変動パターンの部分的な特徴を抽出するためにニューラルネットワーク、信号の統計的特徴を抽出するためにモーメント、ARモデルなどを考えている。ニューラルネットワーク、モーメント、ARモデルに関しては、それらの高い特徴抽出能力がすでに証明されている[2]。従って本稿では、今回新たに導入した手法であるDPマッチングを中心に特徴抽出を試みる。一方、このようにプロセス信号の傾向を多面的に捉えることで扱う必要のあるデータ量が増大し、人間による効率的な診断知識の構成は困難になることが予想されるが、帰納的学習法であるC4.5を利用することでプラント状況の識別に本質的に重要な属性だけを選択的に利用することが可能になると期待できる。

3. 帰納的推論アルゴリズムC4.5

C4.5は、情報量に基づく帰納的推論アルゴリズムであり、対象の状態とその時のプロセス量の属性値の集合を与えることにより決定木を構築する。決定木の構築は、決定木の各分岐点において各属性の情報量を計算し、得られる情報量のもっとも多い属性をその分岐の属性として選択していくことで進められる。この操作は分類された事例が単一の事象をのみを含む、もしくは、どの属性に関して分岐を行っても改善がみられなくなるまで繰り返され、最終的に求める決定木が得られる。ここでは、野外イベントの開催、中止の決定を例として取り上げ説明する。図1はC4.5により生成された開催・中止を決定する決定木であり、表1は学習用入力データである。例において事象とは開催、中止の2つであり、属性は天候、強風、温度、湿度である。開催について9事例、中止について5事例の全14事例が学習用入力データとして用いられ、決定木は構築されている。C4.5は上でも述べたように学習に用いられた属性の内、情報量の多いものを自動的に選択し、決定木を作成する。例

の場合、決定木構築の際選択された属性は、天候、湿度、強風であり、得られた決定木は学習に用いられた全ての事例を正確に分類する。例において曇りの時は必ずイベントが開催されることになっているが、これは学習用データ中の事例・中止の中に属性値・曇りを持つものが存在しなかったためである。

表1 野外コンサートに関する学習用データ

事例	天候	温度(°F)	湿度(%)	強風	事象
事例1	晴れ	75	70	真	開催
事例2	晴れ	80	80	真	中止
事例3	晴れ	85	85	偽	中止
事例4	晴れ	72	85	偽	中止
事例5	晴れ	69	70	偽	開催
事例6	曇り	72	90	真	開催
事例7	曇り	83	78	偽	開催
事例8	曇り	64	85	真	開催
事例9	曇り	81	75	偽	開催
事例10	雨	71	80	真	中止
事例11	雨	65	70	真	中止
事例12	雨	75	80	偽	開催
事例13	雨	68	80	偽	開催
事例14	雨	70	86	偽	開催

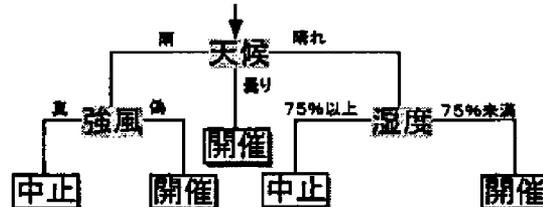


図2 野外コンサートの開催、中止に関する決定木

4. 対象データ

BWRプラントシミュレータPCTTRAN/Bを利用して、12種類の異常を模擬し、その時のプラントの挙動を示すプロセスデータを代表的な信号26点について異常発生直後より120秒、サンプリングタイム1秒でサンプリングし、サンプルデータとした。表2に診断の対象とした異常事象、表3に異常診断に関する決定木の構築に用いた信号を示す。10種類の異常事象は、4つの大きな系統(タービン系、炉心系、給水系、再循環系)に分類してある。また、各異常に関しては、異常の規模の異なる複数の事例を用意したが、異常の規模の大きさに自由度のない事象については、同一規模の事例を複数用いている。これは、事例が極端に少ない場合、その異常事象が情報量的に無視されてしまい、分類されないためである。また、サンプルデータは、シミュレー

表2 学習に用いた異常事象と事例数

異常系統	異常事象名	事例数
タービン系異常	タービン・トリップ	7
	主蒸がし弁誤開	20
	主蒸気逃がし弁誤開	6
	自動減圧系誤開	5
炉心系異常	制御棒誤挿入	17
	制御棒誤引き抜き	12
	炉水位制御系異常(水位上昇)	5
	炉水位制御系異常(水位下降)	5
	炉圧制御系異常(炉圧上昇)	5
	炉圧制御系異常(炉圧下降)	5
給水系異常	給水加熱喪失	21
再循環系異常	再循環ポンプ速度変動	19
計12事象		計127事例

タよりサンプリングした信号26種の他に、物理的な意味があると思われる2信号の差分(表2中の加工)も定義し使用した。

表3 学習に用いた信号(属性)

番号	計測信号(プロセス量)	番号	計測信号(プロセス量)
1	中性子束	18	再循環流量
2	融出力	19	低圧スレイ系統流量
3	制御棒位置	20	停止時冷却系流量
4	炉心流量	21	補助給水系流量
5	再循環回転数	22	ボロン注入タンク水位
6	給水温度	23	換気箱モニタ
7	炉内圧力	24	線ガスモニタ
8	タービン圧力	25	主蒸気管モニタ
9	DW圧力	26	ドライウェル監視モニタ
10	炉水位	加工1	給水、再循環温度差
11	WW水位	加工2	給水、炉心流量差
12	再循環ループ温度	加工3	給水、蒸気流量差
13	DW温度	加工4	炉心、再循環流量差
14	WW温度	加工5	炉心、蒸気流量差
15	換気室換気水温度	加工6	再循環、蒸気流量差
16	蒸気流量	加工7	炉心、タービンヘッド圧力差
17	給水流量		

5. 異常診断に関する決定木の構築

本稿では、C4.5の入力データとなる属性を定義するために、DPマッチング法を用いた。表2に示される33種の信号から成るサンプルデータを予め用意しておいた代表的なパターン14種類とマッチングし、選択されたパターンをその信号(属性)の属性値とした。DPマッチング法は信号のパターンが、予め与えるパターンのどれに最も当てはまるかを判定する手法であり、検討の結果DPマッチングは良好な時系列パターン認識能力をもつことが判った。また、属性によって特徴付けられたサンプルデータを、決定木を構築するための学習用入力データと構築された決定木をテストするためのテスト用入力データに分割し、C4.5の入力データとして用いた。なお、本稿ではサンプルデータを2通りの方法で分割し、決定木の構築を試みている。

決定木による異常事象の分類は2段階に分けて行い、始めに異常事象を各系統に分類する決定木を構築した後、各系統について詳細な異常事象診断を行う決定木を構築した。上記のようにサンプルデータを2通りの方法で分割し、決定木の構築を試みたが構築された異常系統に関する決定木は図3に示すような全く同じ決定木になった。学習用入力データが

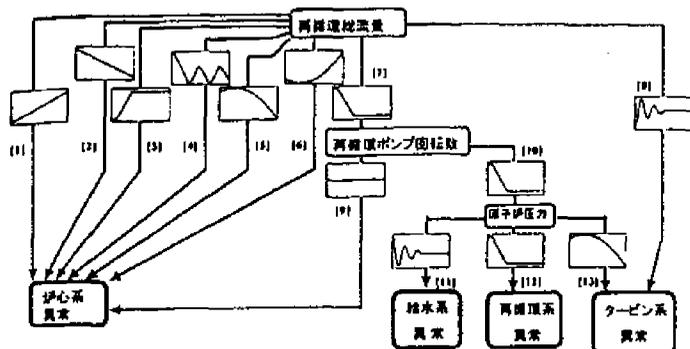


図3 異常系統の診断に関する決定木

異なるにも関わらず同一の決定木が構築されることから、学習入力データに対してある程度のロバスト性を持つことが判る。この異常診断に関する決定木は、属性27種類の内1~3種類と非常に少数の信号波形の傾向をみることで異常系統の同定を行っていることが分かる。これは、DPマッチングを行う際に用いた類型的なパターンが14種類も用意してあったため、少数の信号に対して詳細な波形分別を行ってしまったためであると考えられる。より多くの信号の傾向を見ることにより、より信頼性の高い診断が可能になると考えられるので、マッチングするパターンの類型化を大まかにを行い単純で少数のパターンについてDPマッチングを行うことにより、より多くの信号の傾向を見て異常識別を行うような決定木を構築することが可能になると考えられる。

表4, 5に分割の違いによる異常識別率の差異を示す。表よりどちらの分割による決定木についても給水系異常に関する識別において誤分類があることが分かるが、その他の異常系統については適切に識別されている。

表4 異常系統診断に関する決定木の異常識別率1

異常系統	判別結果			
	(a)	(b)	(c)	(d)
(a)タービン系異常	100%			
(b)炉心系異常		100%		
(c)給水系異常			67%	33%
(d)再循環系異常				100%

表5 異常系統診断に関する決定木の異常識別率2

異常系統	判別結果			
	(a)	(b)	(c)	(d)
(a)タービン系異常	100%			
(b)炉心系異常		100%		
(c)給水系異常			84%	16%
(d)再循環系異常				100%

次に異常系統毎の詳細な診断の例として、炉心系統の異常事象に関する識別を行う決定木を図4に示す。この決定木も図3の決定木と同様に分岐の少ない非常にシンプルな構造の決定木が構築されている。これは、上でも述べたようにDPマッチングによる弁別を細かく行ったためであり、より少数の類型的

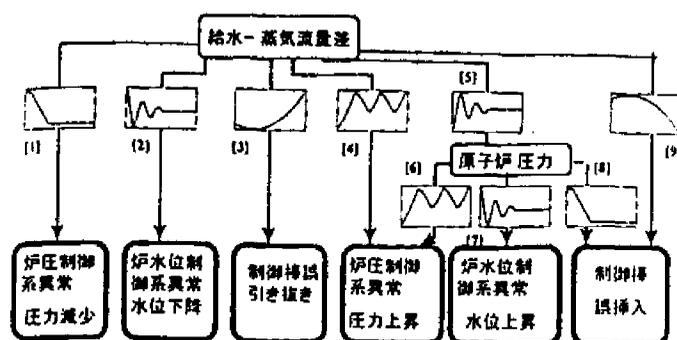


図4 炉心系統の異常診断に関する決定木

パターンに対してマッチングを行えば、分岐の多い決定木が構築されることが考えられる。図4中で選択されている属性である給水流量と蒸気流量の差は、原子炉格納容器内に流入する水と流出する水のマスバランスであり、現実のプラント運転員が常に監視している重要なパラメータである。また、原子炉圧力も原子炉の出力への影響の大きい重要なパラメータである。これらのことから、数は少ないが重要なパラメータを選択していることから、良質な知識が得られたといえる。

次に、図4の決定木に関する異常識別テストの結果を表6に示す。この炉心系統に分類されるサンプルデータは非常に少ないために、学習用入力データとテスト用入力データを分割して用いることが出来なかった。従って、この結果において決定木を構築する学習用入力データとテスト用入力データは全く同一のものを使用している。表より、炉圧制御系異常の事例の内20%が誤分類されているが、ほとんどの事象を100%の確率で適切に分類していることが分かる。このことから決定木は良好な識別能力を示しているといえるであろう。

表6 炉心系異常診断に関する決定木の異常識別率

異常事象名	識別結果					
	(a)	(b)	(c)	(d)	(e)	(f)
(a) 制御棒誤挿入	100%					
(b) 制御棒誤引き抜き		100%				
(c) 炉水位制御系異常(上昇)			100%			
(d) 炉水位制御系異常(下降)				100%		
(e) 炉圧制御系異常(上昇)		20%			80%	
(f) 炉圧制御系異常(下降)						100%

6. まとめ

本稿では、BWRシミュレータPCTTRAN/BからサンプリングしたサンプルデータをDPマッチングにより典型的なパターンに分類した後、情報量に基づく帰納的推論アルゴリズムC4.5を用いて原子力プラントの異常診断に関する知識を獲得した。また、今回新たに導入した手法であるDPマッチング法の時系列データに対するパターン識別能力の検討も行った。その結果、DPマッチング法に関しては、良好な時系列パターン識別能力を持つことが判った。知識の獲得に関しては、獲得した知識の基づいた決定木による異常診断は、良好な異常識別能力を持ち、少数ではあるが原子力プラントの保守、運転において重要なパラメータが選択されていることから、良質な知識が得られたと言える。

今後の課題として次のようなものが挙げられる。

- より少数の典型的パターンによる知識の獲得
- より小規模な異常の識別の可能性の検討
- 全体の知識獲得過程のシステム化

参考文献：

- [1] J.R.Quinlan, "C4.5: Programs for Machine Learning", Morgan Kaufmann Publishers, Inc.(1993).
- [2] H.Furukawa, T.Ueda, M.Kitamura, A systematic method for rational definition of plant diagnostic symptoms by self-organizing neural networks. Neurocomputing 13(1996), 171/183.
- [3] Ming-Syan Chen, Jiawei Han, Philip S. Yu, Data Mining: An Overview from a Database Perspective, IEEE Transaction on knowledge and data engineering, vol.8, No.6, December 1996.
- [4] 元田 浩, 鷲尾 隆, 機械学習とデータマイニング, 人工知能学会誌, Vol.12, No.4, July 1997.