ニューラルネットを用いたプラント運転ルールの抽出に関する研究

—— 浄水プラント薬品注入操作への適用 ——

正 員 圓 佛 伊智朗 (日 立)

正 員 馬 場 研 二 (日 立)

非会員 松 崎 晴 美 (日 立)

正 員 依 田 幹 雄 (日 立)

Rule Extraction from Neural Network

——Application for the operation support of coagulant injection in water purification plant——
Ichiro Enbutsu, Member, Kenji Baba, Member, Harumi Matsuzaki, Non-member, Mikio Yoda, Member (Hitachi, Ltd.)

In this paper, an enhanced method for rule extraction from a multilayered neural network is proposed. Conventionally a learned network is treated as a black-box model, so internal distributed knowledge in it can not be indicated in explicit form. The authors analyzed the mathematical properties of a neural network, and based on the properties, defined an index to evaluate a weights matrix. By using this index, the causal relationships between each input and output are interpreted as production rules. Furthermore, a modified error backpropagating algorithm which can control excessive redundancy in a network is proposed to enhance learning ability. This algorithm was applied to the operation support of coagulant injection in a water purification plant. The computer simulation showed advanced reliability regarding extracted rules and association.

キーワード：ニューラルネット，ルール抽出，浄水プラント，誤差逆伝搬法

1. ま え が き

ニューラルネットは、人間の脳の神経回路網を工学的に模擬したモデルであり、無数のニューロン間の結合強度内に分散表現された知識によって、主に人間の右脳の判断を再現する。ニューラルネットのうち、階層形モデルは、文字や波形などのパターン認識への適用⁽¹⁾⁽²⁾が行われてきた。これらの例では、学習による高い認識能力が報告されている。

著者らは、ニューラルネットの学習能力を、過去の実績による運転が有効な浄水プラント薬品注入操作の支援に適用することを考えた。ニューラルネットの想起によって、実際にオペレータに操作量をガイダンスしようとする、モデルが含む意味内容(ガイダンス

の判断根拠)を理解しやすい形式で陽に提示できることが必要条件となる。また、ニューラルネット単独ではなく、オペレータの経験則も併せて利用する場合には、宣言的知識を介して知識工学との融合を図ることが必要である。

これに対して与える方法の一つとして、学習済みニューラルネットからのルール抽出が試みられている。Bochereauら⁽³⁾は、複数のニューロンの重み係数を一つのニューロンで近似的に置き換える方法により、隣り合う層のニューロン間の関係を数式のルールで抽出する方法を提案している。また、林ら⁽⁴⁾は真理値を入出力とするニューラルネットからファジールールを抽出する方法を提案している。前者は、特殊なニューロンの導入と近似により、精度が不十分であり、

適用範囲に限られる。また、後者は入出力が0, 1の2値に限られるため、一般のプラントデータのようなアナログ値を入出力とする場合には適用できない。

そこで本論文では、アナログ値を入出力とする一般的なニューロン(2・1節で後述)からなる階層形モデルに適用可能なルール抽出方法を提案する。また、より信頼性の高いルールを抽出するために、新しい学習法も併せて提案する。この新しい学習法を用いた学習結果により、抽出ルールの信頼性とニューラルネットの想起精度の関係について考察する。

更に、これらを用いたニューラルネット応用浄水場薬品注入支援システムの運用方法についても報告する。

2. ニューラルネットからのルール抽出

2・1 ニューラルネットの基本動作 一般に用いられているニューロンは、McCulloch and Pitts⁽⁵⁾が提案した、重み係数付きの多入力1出力のニューロン(しきい値ニューロン)の変換部分をシグモイド関数に変更したものである。図1(a), (b)に示す中間層のニューロン $2j$ は、(1)式のように各々の入力 x_{1i} と重み係数 $w_{2j,1i}$ との積和 u_{2j} を求め、これを(2)式のシグモイド関数 f で変換した値を出力 y_{2j} として出力層のニューロン $3k$ へ送る。ニューロン $3k$ は同様の動作で出力 y_{3k} を出力する。

図1 ニューロのモデル

Fig. 1. Neural network model.

$$u_{2j} = \sum_i w_{2j,1i} x_{1i} \quad (1)$$

$$y_{2j} = \frac{1}{1 + e^{-u_{2j}}} \quad (2)$$

ただし、入力層のニューロン $1i$ の動作は、中間層、出力層と異なり、入力 x_{1i} を変換せず、そのままで中間層ニューロン $2j$ に出力する。

2・2 ネットワークの因果関係評価 学習後のニューラルネットが、正しく想起できる場合には、ネットワーク内部に入出力間の因果関係(本論文の場合、薬品注入操作のロジック)と等価な知識が内包されているといえる。この知識は重み係数行列として分散表現されているので、そのままでは入出力間の因果関係を知ることができない。

そこで著者らは、まず最初に、着目した入力 x_{1i} が中間層を通して、着目した出力 y_{3k} に及ぼす影響の度合いを解析的に調べた。このうち、中間層ニューロン $2j$ を通過する経路 j の影響は、(3)式で表される。

$$(\text{経路 } j \text{ の影響}) \propto \left(\frac{\partial y_{3k}}{\partial x_{1i}} \right)_{2j} \quad (3)$$

(3)式の右辺をニューラルネットの基本動作である(1), (2)式に基づいて変形すると、(4)式で表現されることがわかる。

$$\begin{aligned} \left(\frac{\partial y_{3k}}{\partial x_{1i}} \right)_{2j} &= \frac{\partial y_{3k}}{\partial u_{3k}} \frac{\partial u_{3k}}{\partial y_{2j}} \frac{\partial y_{2j}}{\partial u_{2j}} \frac{\partial u_{2j}}{\partial x_{1i}} \\ &= f'(u_{3k}) w_{3k,2j} f'(u_{2j}) w_{2j,1i} \\ &= f'(u_{3k}) f'(u_{2j}) w_{3k,2j} w_{2j,1i} \end{aligned} \quad (4)$$

着目した入力 x_{1i} から着目した出力 y_{3k} に至る全経路について総和をとることにより、(5)式を用いて両者の因果関係を定量的に評価することにした。ここで定義した $C_{3k,1i}$ を入力 x_{1i} と出力 y_{3k} の因果関係を評価する尺度として、本論文では「因果性尺度」と呼ぶ。

$$C_{3k,1i} \equiv \sum_j f'(u_{3k}) f'(u_{2j}) w_{3k,2j} w_{2j,1i} \quad (5)$$

(5)式のうち、シグモイド関数の微分値 $f'(u_{3k})$ と $f'(u_{2j})$ は、入力層からの入力パターン($x_{11}, x_{12}, \dots, x_{1n}$)に依存するので、入出力間の因果関係も入力パターンごとに違ったものとなる。しかし、入出力間の非

図2 ルール抽出手順

Fig. 2. Procedure of rule extraction.

線形性が強くない場合には、 u_{3k} と u_{2j} は、0の近傍でしか変動しないので、 $f'(u_{3k})$ と $f'(u_{2j})$ を定数とみなすことができる。このとき、(5)式は(6)式のように $w_{3k,2j}$ と $w_{2j,1i}$ との積和で表現され、 $C_{3k,1i}$ を学習後の重み係数行列のみから求めることができる。

$$C_{3k,1i} \equiv \sum_j w_{3k,2j} w_{2j,1i} \quad \dots\dots\dots (6)$$

この方法は、入出力間の関係を、入力パターンに依存しない重み係数のみで評価するものである。

上述のように入力と出力の偏微分で両者の因果関係を評価する方法は、重回帰分析で偏回帰係数を求めるのと同じ発想であり、 $C_{3k,1i}$ は偏回帰係数と同様に、その値の符号と絶対値の大小によって、入出力間の関係を相対的に評価する尺度として用いる。

この因果性尺度を用いることにより、図2に示す手順でネットワークからプロダクションルールを抽出し、明示することが可能となる。

3. ルール抽出のための学習法

ルール抽出は、ネットワーク内の重み係数行列を用いて行うため、抽出されたルールの信頼性は、学習が適切に行われたかどうか依存する。ここでいう適切な学習とは、有限個の教師データの学習により、誤差を小さくすると同時に、教師データの母集団がもつ因果関係を選択的に重み係数行列に獲得できるような学習である。本章では、この条件を満足するルール抽出に適した学習法について提案する。

〈3・1〉 従来の学習法と課題 ニューラルネットの学習法としては、Rumelhartら⁽⁶⁾による誤差逆伝搬法(Error Backpropagation Method, 以下BP法と略称する)が一般的である。BP法は、(7)式に示すネットワークの出力 y_{3k} と教師データの教師値 y_{3k*} との誤差自乗和 E_E を減少させる重み係数を修正する最急降下法である。

$$E_E = \frac{1}{2} \sum_k (y_{3k*} - y_{3k})^2 \quad \dots\dots\dots (7)$$

そこで、出力層と中間層間の重み係数 $w_{3k,2j}$ の修正量 $\Delta w_{3k,2j}$ は、(8)式で示され、同様に中間層と入力層間の重み係数 $w_{2j,1i}$ の修正量 $\Delta w_{2j,1i}$ は(9)式となる。

$$\Delta w_{3k,2j} \propto -\frac{\partial E_E}{\partial w_{3k,2j}} \quad \dots\dots\dots (8)$$

$$\Delta w_{2j,1i} \propto -\frac{\partial E_E}{\partial w_{2j,1i}} \quad \dots\dots\dots (9)$$

BP法では、図3(a)に示すように重み係数の初期値の与え方によって、 E_E の最小値(1)や極小値(2)に相当する異なった値に収束することが一般的に知られている⁽⁷⁾。このような誤差のみに基づく学習では、図3(b)の曲線(1)に示すような、与えられた教師値 y_{3k*} の母集団が本来もっている入出力間の関係を正しく学習しない場合も生じ、曲線(2)のような学習となる場合がある。

本論文の目的であるルール抽出を行う場合、上述の課題をもつBP法で学習した重み係数行列から得られるルールは信頼性が低くなる場合が生じやすいものと考えられる。また、未学習のデータに対する想起誤差も大きくなる可能性がある。

学習法はBP法以外にも、高速化を目的とする学習法⁽⁸⁾⁽⁹⁾や構造化を目的とする学習法⁽¹⁰⁾⁽¹¹⁾などが提案されているが、ルール抽出という観点からはBP法と同じ課題を含んでいる。このため、ルール抽出に適した学習法が必要と考えた。

〈3・2〉 因果選択形学習法 著者らは、先に述べた不正確な学習の原因として、教師値への過剰な適合、重回帰分析でも見られるような独立でない入力間の影響の相殺などがあると考えた。このような学習を避け、抽出ルールの信頼性を向上させるためには、ネットワーク内の無数の結合のうち、その結合がなければ正確な想起ができないような必要最小限の結合のみを残し、出力への影響が小さい結合を省くことが有効

図3 評価関数の極小値への収束
Fig. 3. Convergence to local minimum of evaluation function.

と考えた。

そこで著者らは、想起誤差が増加しない範囲で、 $C_{3k,1i}$ の自乗和を小さくするという制約条件付きの学習を考えた。 $C_{3k,1i}$ は絶対値が大きいほど、因果関係の強度が強いという性質のものであるから、その自乗和は冗長な因果関係も含めてネットワーク全体がもつ因果関係の強度に相当する。従って、ネットワーク全体の因果関係の強度を必要最小限にし、冗長な因果関係を抑制する学習を提案する。

以下に、本学習法の重み係数修正方法を示す。

(1) 中間層と出力層間の重み係数 $w_{3k,2j}$ の修正

評価関数 E_{EC} は、(10)式のように想起誤差と因果性尺度に関する項からなると定義する。

$$E_{EC} = E_E + E_C \quad \text{.....(10)}$$

E_E は(7)式で示した誤差自乗和の項であり、 E_C は本論文で導入した因果性尺度の自乗和の項であり、(11)式のように定義する。

$$E_C = \frac{\varepsilon}{2} \sum_k \sum_i C_{3k,1i}^2 \quad \text{.....(11)}$$

(11)式はネットワーク全体のもつ因果関係の強度に相当する量である。 ε は因果抑制係数であり、学習時に誤差を小さくすることを重視するか、冗長性を除くことを重視するかを調整する係数である。重み係数 $w_{3k,2j}$ の修正量 $\Delta w_{3k,2j}$ は、(12)式のように評価関数 E_{EC} が減少するように決定する。

$$\Delta w_{3k,2j} \propto -\frac{\partial E_{EC}}{\partial w_{3k,2j}} \quad \text{.....(12)}$$

ここで、(7)、(11)式を $w_{3k,2j}$ で偏微分すると、(13)、(14)式となる。

$$\frac{\partial E_E}{\partial w_{3k,2j}} = -(y_{3k*} - y_{3k}) f'(u_{3k}) y_{2j} \quad \text{.....(13)}$$

$$\begin{aligned} \frac{\partial E_C}{\partial w_{3k,2j}} &= \frac{\varepsilon}{2} \sum_i \left\{ 2C_{3k,1i} \frac{\partial C_{3k,1i}}{\partial w_{3k,2j}} \right\} \\ &= \varepsilon \sum_i \{ C_{3k,1i} w_{2j,1i} \} \quad \text{.....(14)} \end{aligned}$$

ゆえに、(10)、(12)式より $\Delta w_{3k,2j}$ は(15)式となる。

$$\begin{aligned} \Delta w_{3k,2j} &= \eta \{ (y_{3k*} - y_{3k}) f'(u_{3k}) y_{2j} \\ &\quad - \varepsilon \sum_i \{ C_{3k,1i} w_{2j,1i} \} \} \quad \text{.....(15)} \end{aligned}$$

η は加速係数であり、1回の重み係数の修正量を調整するための係数である。実際の修正は、以下の重み係数修正式の(16)式に(15)式を代入して行う。

$$\begin{aligned} w_{3k,2j}(t) &= w_{3k,2j}(t-1) + \Delta w_{3k,2j}(t) \\ &\quad + \alpha \Delta w_{3k,2j}(t-1) \quad \text{.....(16)} \end{aligned}$$

α はスムージング係数であり、前回修正量をどの程度反映させるかを調整する。また、 t は修正のステップ数である。

(2) 入力層と中間層の重み係数 $w_{2j,1i}$ の修正

$$\Delta w_{2j,1i} \propto -\frac{\partial E_{EC}}{\partial w_{2j,1i}} \quad \text{.....(17)}$$

(17)式を先と同様に変形すると、(18)式が導かれる。

$$\begin{aligned} \Delta w_{2j,1i} &= \eta \{ (y_{3k*} - y_{3k}) f'(u_{3k}) w_{3k,2j} f'(u_{2j}) \\ &\quad \times x_{1i} - \varepsilon C_{3k,1i} w_{3k,2j} \} \quad \text{.....(18)} \end{aligned}$$

これを(19)式によって修正する。

$$\begin{aligned} w_{2j,1i}(t) &= w_{2j,1i}(t-1) + \Delta w_{2j,1i}(t) \\ &\quad + \alpha \Delta w_{2j,1i}(t-1) \quad \text{.....(19)} \end{aligned}$$

修正のステップは、教師データに対する平均の想起誤差が終了条件以下となるまで繰返す。

この学習法を「因果選択形学習法」と呼ぶことにする。因果選択形学習法で ε を調整することは、重回帰分析の目的変数の選択を帰無仮説の検定で行うときの有意水準の調整と考えれば理解しやすい。

4. 計算機シミュレーション

〈4・1〉 対象プラント シミュレーションの対象とした浄水プラントの概要を図4に示す。浄水プラントでは、河川などから取水した原水中の懸濁微粒子(粒径1~10 μm)を除去し、更に塩素殺菌した後、水道水として供給する。

混和池では、凝集剤(ポリ塩化アルミニウム)を注入かくはんし、更にフロック形成池で緩速かくはんして、懸濁微粒子を凝集させる。この凝集塊(フロック、粒径1~2 mm)を沈殿池で沈殿させ固液分離する。このため、凝集剤注入操作は浄水処理において最も重要である。

従来、凝集剤注入操作は、オペレータが原水の水質

図4 浄水プラント概要

Fig. 4. Schematic diagram of water purification plant.

データを分析し、またフロックの形成の良否を目視観察すると共に、水質データと目視観察結果との過去の経験に基づいて判断し、注入率を決定している。従って、この操作を計算機システムによって支援する場合には、過去の水質データと目視観察結果を用いてオペレータの判断を模擬することが有効であり、ニューラルネットの応用が好適と考えた。

〈4・2〉 シミュレーション方法 使用したデータは、A 浄水場の凝集剤(ポリ塩化アルミニウム; PAC)注入率に関する昭和 61 年 1~12 月の運転履歴データで、下記の 10 変数である。これらのデータは、値のレベル差による影響をなくすために、規準化した値でを使用した。

図 5 に示す凝集剤注入率のデータでは処理水質が目標水質を満足しているので、教師データとして使用可能である。なお、目視観察結果に代替するものとしてここでは画像処理によるフロック特徴量⁽¹²⁾を用いた。

水質データ：①原水アルカリ度 ②原水 pH

③原水水温 ④原水流量

⑤原水濁度

画像データ：⑥密度指標 ⑦フロック個数

⑧フロック形成量 ⑨幾何平均径

⑩平均輝度

浄水プラントの凝集剤注入操作は、原水濁度が低く安定した定常時(主に晴天時)と原水濁度が高い非定常時(主に降雨時)とで異なった運転となることに着目した。これは、各運転条件の違いを反映できるようにネットワークを複数構築し、運転条件ごとのルールを抽出しようと考えたためである。本論文では、頻度分布の予備検討に基づき、原水濁度が 10 mg/l 未満を定常時、10 mg/l 以上のときを非定常時と定義し、上記データを分けて学習した。なお、1 年分のデータから欠損部を除いた有効データ数は、定常時 177 日、非定

図 5 昭和 61 年凝集剤注入率実績値
Fig.5. Trend of actual coagulant injection rate.

常時 36 日(図 5 のグラフ中の●印)である。

また、学習時のネットワーク構造および下記の学習条件によって学習結果に差がでることが経験的に知られているので、予備実験でそれらの影響を検討し、以下の条件とした。

・ネットワークの数 : 定常時と非定常時に分けて二つのネットワークを用いた。

・各層のニューロン数: 入力層と出力層は、データ数に対応して、それぞれ 10 個と 1 個(凝集剤注入率)とした。また、中間層では 4 個とした。

・加速係数 η : 1.0

・スムージング係数 α : 1.0

・学習パターン数 : 定常時、非定常時から代表的な 10 日分ずつを選択した。

また、重み係数の初期値によって、学習結果に多少の違いが出るため、ランダムに発生させた初期値による学習を 10 回実行し、その平均値を用いることとした。

表 1 凝集剤注入に関するオペレータの知識例
Table 1. Example of operators' knowledge of coagulant injection.

入力データ 項 目	PAC 注入率との因果関係	相 関	
		定 常 時	非定常時
原 水 pH	pH が高いと PAC が多く必要ことが知られている (PAC の解離による水和物生成は、pH が高いと悪くなり、注入量を増加させる)。	正	正
幾 何 平 均 径	凝集剤が多ければ、幾何平均径は大きい。	正	正
原水水温	水温が低いと多く注入する (粘度が高いので、拡散が悪い)。また、水温が低い冬期は濁度が低い場合が多いことも、これを助長する。	負	負
フロック 個 数	[定常時] 凝集剤を多くすると、大きなフロックができ、数は少なくなる。 [非定常時] 凝集剤を多くすると、大きなフロックができ、数も多い。	負	正
密度指標	凝集剤が多いときは、密度が高いときである。	正	正
平均輝度	凝集剤が多いときは、平均輝度は高い。	正	正
原水流量	流量が多いと、注入量も多くなるが注入率は変わらない。流量は夏期に多く、逆に冬期は少ないが、これと水温が正の相関をもつ。	負	負

〈4・3〉 ルール抽出結果 学習後のネットワークの重み係数行列から因果性尺度を算出し、知識へ変換した。ここで用いたネットワークの構造は、入力層ユニット数=10、出力層ユニット数=1であるので、入力データと凝集剤に関する10個の因果性尺度(つまり10個のルール)が得られる。因果性尺度の絶対値が小さい入力データは、出力に対する影響が小さく、また、予備検討により再現性が低いことを確認したので、絶対値が大きいほうの上位(ここでは3分の2の7個)のものを知識候補とした。

表1は、A浄水場のオペレータが凝集剤注入率を決定する際に、水質データや画像データをどのようなロジック(定性的判断根拠)で判断しているかの一例を

図6 知識納得率に及ぼす ε の影響
Fig. 6. Relationship between knowledge agreement rate and ε .

表2 ルール抽出結果(定常時)
Table 2. Example of extracted rules.

因果性尺度	入力データ項目	抽出された知識(上位7個が知識候補)	評価
5.4	原水pH	原水pHが高ければ、PAC注入率が高い。	○
3.8	幾何平均径	幾何平均径が大きければ、PAC注入率が高い。	○
-2.8	原水水温	原水水温が低ければ、PAC注入率が高い。	○
-1.9	フロック個数	フロック個数が少なければ、PAC注入率が高い。	○
1.8	密度指数	密度指標が大きければ、PAC注入率が高い。	○
-1.8	平均輝度	平均輝度が低ければ、PAC注入率が高い。	×
-1.6	原水流量	原水流量が少なければ、PAC注入率が高い。	○

示すものである。ここではネットワークから抽出した知識候補の信頼性を評価するために、表1の知識と定性的に一致する割合を(20)式のように「知識納得率」と定義する。

$$\text{知識納得率(\%)} = \frac{\text{専門家が納得した知識数}}{\text{抽出知識数}} \times 100 \quad (20)$$

図6は知識候補の納得率に及ぼす ε の影響を示す。 $\varepsilon=0$ では因果抑制なしの学習となるので、従来形BP法の結果に相当する。また、 ε が大きいくほど強い因果抑制を受ける学習となっている。

図6より知識納得率は、定常時で $\varepsilon=2 \times 10^{-5}$ 、非常時で $\varepsilon=1 \times 10^{-5}$ で最大となっている。これより、各データごとに最適な ε を選択して学習すれば、従来形BP法よりも信頼性の高いルールを抽出可能なことがわかる。このときの知識納得率は、定常時で81%、非常時で97%であり、従来形BP法の結果よりもそれぞれ7%、10%の向上を確認できた。

表2に定常時の最適 ε における抽出ルールを示すが、この例では平均輝度の知識がオペレータの経験則と一致していない。この原因としては、(i)オペレータの認識と履歴データが示すプラント特性の実態とが異なっていること(主にオペレータの誤り)、(ii)ルール抽出が不正確であること(ニューロの誤り)、の二つの場合がある。ルールを知識ベースとして使用する場合には、どちらの原因かによって一方のルールを棄却する措置をとる。

〈4・4〉 想起結果 図7は学習後のネットワークで1年分の凝集剤注入率を想起したときの、想起値と実績値との平均想起誤差に及ぼす ε の影響を示す。図7より平均想起誤差は、定常時で $\varepsilon=2 \times 10^{-5}$ 、非常時で $\varepsilon=1 \times 10^{-5}$ で最小となり、従来形BP法よ

図7 平均想起誤差に及ぼす ε の影響
Fig. 7. Relationship between mean association error and ε .

図8 因果選択形BP法による想起結果
Fig.8. Result of association learned by causal selecting BP method.

りも想起精度が向上できた。この結果は、評価関数を(10)式の E_{EC} としたことにより、想起誤差の評価だけでは修正されなかった冗長な入出力関係が第2項 E_c によって弱められることの効果であると考えられる。一方、 ϵ を過剰に大きくしたときに、平均想起誤差が増加するのは、第1項 E_ϵ による誤差減少のための重み係数修正に対して第2項の修正が過度になり、学習パターンのみに対応した入出力関係しか残らない、汎化能力の低い重み係数になるためと考えられる。

想起における最適 ϵ は知識納得率の最適値と一致している。このことから、ネットワーク全体がもつ因果関係の強度を適度に抑制し、正しい想起に寄与しないような因果関係(重み係数)を小さくする学習により、抽出ルールの信頼性と想起精度の両方を同時に向上できることがわかった。

最適 ϵ における1年間の想起結果を図8に示す。実機での凝集剤注入操作の許容誤差は、定常時で1~2 mg/l 程度(6.7~13.3%)、非定常時で2~3 mg/l 程度(13.3~20.0%)である。図8の想起値のうち、十数日が許容範囲を超えるが、平均想起誤差では許容範囲を満足している。

また、定常時と非定常時の結果を比較すると、定常時では、非定常時よりも知識納得率が低い(81%)にもかかわらず想起誤差が小さくなっている。この結果はより正しいルールを内包するニューラルネットであるほど、想起誤差が小さくなるという傾向に反するもの

図9 ニューラルネット応用運転システム
構成図
Fig.9. Configuration of support system.

図10 運用システムフロー(自動追加学習)
Fig.10. Neuro system flow for practical use.

である。定常時のほうが非定常時よりも予測しやすい傾向であることを差し引いても、19%(100-81)のルールが誤りであったうえで、図7の想起精度を達成することは難しいと考えられる。すなわち、経験則と一致しなかった19%のルールの中に、プラント特性の実態に合うルールが存在することが予想される。これより、このようなルールはオペレータの誤りを正せる可能性があり、知識獲得の支援に役立つものと考えられる。

〈4・5〉 実機での運用法(自動追加学習) 浄水プラントでは、流入水質や計測器の特性が経時的に変化するために、これに応じて凝集剤注入方法も変化する。この状況変化に対応して、ニューロが臨機応変に

図 11 平均想起誤差に及ぼす N の影響
Fig. 11. Relation between mean association error and N .

学習していけば、自己成長性を有する運転支援が実現できる。そこで、著者らは実機での運用を目的として、図 9 に示す運転支援システムを構築し、図 10 のような自動追加学習のフローを考案した。このフローの考え方は、

- (i) 処理良好で、かつ過去の運転実績と大きく矛盾しないデータのみをネットワークに反映させる。
- (ii) 過去の運転実績を尊重しつつ、新たなデータを最も強く反映させる
- (iii) メンテナンスフリーで自動学習する

ことにより、プラントデータの構造変化に適応して常に適切なガイダンスを行うことである。学習には因果選択形学習法を用いる。

図 10 の自動追加学習フローを用い、昭和 61 年のデータを既存データとして、昭和 62 年のデータを 1 日周期で追加学習しながら、昭和 62 年の 1 年分を想起した。なお、フロー中の学習判定日数(以下、 N と略記)とは、ネットワーク更新の条件として履歴データ N 日分の平均想起誤差を求めるための日数である。ネットワークの更新は、現在から直前の過去 N 日分の平均想起誤差が増加しない場合にのみ行う。これにより、過去の運転実績と大きく矛盾するデータの学習を避けることができる。

図 11 は昭和 62 年の平均想起誤差に及ぼす N の影響を示す。最適な N は定常時で 1 日、非定常時で 7 日以上(非定常時は平均して月に 2, 3 日なので、期間にして 3 箇月分程度)であることがわかる。このことはオペレータが凝集剤注入率を決定する際に、定常時には前日の運転を最も参考とし、非定常時には以

前に起こった非定常時の 3 箇月分を思い返ししながら運転することに対応する。

昭和 61 年のデータのみの学習で昭和 62 年を想起したときの平均想起誤差は、定常時で 11.2%, 非定常時で 15.6% であったのに対し、自動追加学習による最適な N では、それぞれ 9.5, 15.0% であった。このことから、プラント状態の変化に応じて学習パターンを更新することにより、ガイダンス時の想起誤差を低減できることを確認できた。

ここでの想起結果は、外挿による予測であるため、先の(4・4)節の想起結果(内挿による予測)よりも精度が落ちるが、最適な N における自動追加学習では凝集剤注入操作のガイダンスに十分な精度を達成している。ガイダンス値がオペレータの判断と大きく異なる場合には、オペレータの判断が優先されるが、それ以外の場合には、ガイダンス値に従って運転される。

また、ここでは詳細を述べないが、外乱のダイナミックな変動を反映させ、かつ想起精度を向上させるために、データの時間偏差を入力する方法を考案し、効果を確認済みである⁽¹³⁾。

5. む す び

本論文ではニューラルネットからプラント運転ルールを抽出し、更に抽出したルールとガイダンス時の想起精度を向上させる方法を提案した。これらを浄水プラントの薬品注入操作支援へ適用し、以下の結果を得た。

(1) ニューラルネットの入出力間の関係を評価する尺度(因果性尺度)を考案し、ネットワークに内包される知識をプロダクショナルルールとして明示できるようにした。これによりオペレータに対して、想起による操作量ガイダンスの判断根拠を示すことが可能となった。また、これらのルールによりオペレータの経験をとらえる可能性があることを見いだした。

(2) ニューラルネット内の不要な因果関係を抑制する新しい学習法(因果選択形学習法)を考案し、従来形学習法と比較して、(i) 抽出ルールの信頼性向上、(ii) 想起能力向上を確認した。

(3) 自動追加学習法により、プラント状態の経時変化に追従したガイダンスが可能であることを確認した。

最後に、本研究の遂行にあたり、常に貴重な御助言と御協力を賜った(株)日立製作所日立研究所宮寺博博士、梶隆一博士、渡辺昭二氏、矢萩捷夫氏、および同大みか工場 原 直樹氏に深く感謝します。

(平成 2 年 6 月 18 日受付)

文 献

- (1) 立石・山崎：「手書き数字認識における階層型ニューラルネットワークの中間層に関する考察」，情報処理学論，30，10（平元）
- (2) 渡辺・玉山・橋高：「ニューラルネットワークを用いた時系列信号パターンの認識方法の開発」，第3回人工知能学会大会（平元）
- (3) L. Bocheureau & P. Bourguine："Extraction of Semantic Features and Logical Rules from Multilayer Neural Network"，IJCNN '90 Washington Conference Proceedings (1990)
- (4) 林・中井：「ニューラルネットワークを用いたファジィブロダクションルールの自動抽出」，5th Fuzzy System Symposium Proceedings (1989)
- (5) W. S. McCulloch, W. Pitts："A Logical Calculus of the Ideas Immanent in Nervous Activity"，*Bullet. Math. Biophysics*, 5 (1943)
- (6) D. E. Rumelhart, G. E. Hinton & R. J. Williams："Learning Internal Representations by Error Propagation"，Parallel Distributed Processing 1, The PDP Research Group (1986)
- (7) 麻生：「ニューロ・コンピューティング—原理と概要—」，情報処理，29，9（昭63）
- (8) 木本・長田・関口・吉沢・渡部・浅川：「ニューラルネットワークによる移動ロボットの制御」，計算機アーキテクチャ，71，14（昭63）
- (9) 島田・西村：「ニューラルネットの教師あり学習の高速化」，信学技報，88，465（平元）
- (10) 石川：「コネクショニストモデルの忘却を用いた構造化学習」，同上，88，465（平元）
- (11) 石川：「コネクショニストモデルの忘却を用いた一般構造化学習」，同上，89，464（平2）
- (12) 一木・馬場：「画像認識によるブロック監視に関する研究（1）」，水道協会誌，56，7（昭62）
- (13) 馬場・圓佛・松崎・野北：「履歴学習型・上下水プラント運転支援システム」，第3回水システム自動計測制御国内ワークショップ論文集（1989）

圓 佛 伊智朗（正員）

昭和38年6月14日生。63年3月京都大学大学院工学研究科衛生工学専攻修士課程修了。同年4月(株)日立製作所入社。日立研究所におい

て、上下水プロセスの知能的運転支援に関する研究開発に従事。電子情報通信学会会員。

馬 場 研 二（正員）

昭和28年1月7日生。53年3月北海道大学大学院工学研究科衛生工学専攻修士課程修了。同年4月(株)日立製作所入社。日立研究所におい

て上下水プロセス・計測制御システムの研究開発に従事。工学博士。(社)日本水質汚濁研究協会昭和63年度論文賞受賞。同協会平成元年度技術賞受賞。計測自動制御学会，土木学会会員。

松 崎 晴 美（非会員）

昭和23年1月2日生。47年3月北海道大学大学院工学研究科機械工学専攻修士課程修了。同年4月(株)日立製作所入社。日立研究所におい

てバイオプロセスの診断・制御に関する研究開発に従事。工学博士。日本機械学会，化学工学会会員。

依 田 幹 雄（正員）

昭和21年1月12日生。39年3月上田千曲高校機械科卒業。同年4月(株)日立製作所入社。大みか工場において上下水プロセスの知能的監視制御システムの開発・設計に従事。(社)日本水質汚濁研究協会平成元年度技術賞受賞。