解析と知識の抽出のための ニューラルネットワークの構造化学習

正 員 飯 坂 達 也 (富士電機総合研究所)

正 員 松 井 哲 郎 (富士電機総合研究所)

Structural learning of neural networks for analysis and knowledge extraction

Tatsuya Iizaka, Member   Tetsuro Matsui, Member
(Fuji Electric Corporate R&D)

This paper presents structure of a neural network for analysis and knowledge extraction from continuous valued problems and a training method for the structure. The proposed neural network consists of two types of hidden units. One type of hidden units has weights connected to only a group of input units. Another one has weights connected to all input units. The former type of hidden units allows to analyze each relation between a certain input data and corresponding output data. The latter type of hidden units ensures performance of the neural network as same as conventional neural networks. While the neural network is been training, needless hidden units are pruned automatically by the superposed energy function, the structure learning with forgetting, and the compact structuring algorithm. Therefore, it is easy to analyze the neural network and extract knowledge.

The effectiveness of the proposed method is shown by function approximation, peak load forecasting of electric power and water flow forecasting into the dam.

キーワード：ニューラルネットワーク，構造化学習，内部解析，知識抽出

1. まえがき

ニューラルネットワーク⁽¹⁾は優れた非線形モデル化能力と学習能力を有しており，パターン認識，診断，予測などの多くの分野で応用が進められている。しかし，バックプロパゲーション法（ＢＰ法）によって学習されるニューラルネットワークは，最適な大きさのネットワークの規模が事前に得難いため試行錯誤的に学習しなければならず，また中間層素子の解釈が困難である等の問題がある。そのため，安全性や信頼性に関わる分野において，内部構造の解析や出力値の理由説明の実現が切望されている。

これら問題点を解決するため，ネットワークの構造の最適化や知識抽出を重視する学習の研究が行われており，総称して構造学習⁽²⁾と呼ばれている。

特に，前者に重点をおいた例としては，Plaut⁽³⁾，高橋⁽⁴⁾，増田⁽⁵⁾，松永⁽⁶⁾らの研究があり，いずれも冗長な結合の少ない小さなネットワークを構築する方法である。また，

赤池の情報量基準⁽⁷⁾を使用する方法もよく用いられる。これらの方法は，汎化能力向上に極めて有効と言われる。

後者に重点を置いた例として，石川⁽⁸⁾，福見⁽⁹⁾らの忘却付き構造学習は学習済みのニューラルネットワークから知識を抽出することに成功している。これらの方法は，比較的大きな問題にも適用できるが，適用範囲が離散値出力の問題に限られる。

また，知識抽出に関連した研究としてニューラルネットワークの学習能力とファジィ推論の推論説明機能を合わせ持つファジィニューラルネットワーク⁽¹⁰⁾がある。この方法は，連続値問題も扱えるが，入力因子が増加すると指数関数的に計算量が増加するため，大規模問題への適用は困難と思われる。

ニューラルネットワークの主要な応用分野の１つである予測問題は，多入力連続値問題であることが多い⁽¹¹⁻¹⁶⁾。そのため，従来解析が不可能であった連続値問題を扱うニューラルネットワークについて，入出力特性の内部解析及び知識抽出のための手法が切望されている。

本論文では、予測等の連続値問題を扱う階層型ニューラルネットワークにおいて、入出力特性の内部解析及び知識の抽出方法⁽¹⁷⁾⁽¹⁸⁾を提案する。

提案するニューラルネットワークは、任意の入力因子グループにのみ結合する中間層素子（疎結合部分）と全ての入力因子と結合する中間層素子（全結合部分）より構成される。疎結合の構造を持つことにより、任意入力因子グループごとの入出力特性を解析することが可能であり、全結合の構造により、従来のニューラルネットワークと同等の性能を維持することが可能である。また、学習中に不要な結合を削除するため、解析や知識の抽出が容易であり、汎化能力も高い。計算量も従来のニューラルネットワークと大差なく、大規模問題への適用も容易である。

提案手法の有効性を検証するために、2次関数の近似、電力系統の翌日最大電力予測と1時間先ダム流入量予測に対する計算機シミュレーションを行い、入出力特性の解析、知識の抽出が可能であることを示す。

2. ニューラルネットワークの構造と解析方法

従来のニューラルネットワークから知識を抽出する方法は、ニューラルネットワークの学習後の骨格構造から知識を抽出する。そのため、論理関数の学習⁽⁸⁾、クラスタリング⁽¹¹⁾、分類^(8,9,11,12)等の離散値問題に適用が限られた。

提案手法は連続値問題を扱うものであり、ニューラルネットワークの骨格構造より大まかな知識を抽出し、ニューラルネットワークの入力値と各中間層素子から伝達される出力層の入力値（中間層素子出力と出力層との重みの積）の入出力相関関係より詳細な解析を行う方法である。

提案するニューラルネットワークの構造の概念を図1に示す。複数のサブネットワーク構造を持ち、任意の入力因子グループだけと結合する中間層素子（疎結合部分）と全ての入力因子と結合する中間層素子（全結合部分）より構成される。疎結合のサブネットワークは、任意グループと出力との独立した関係を表しており、任意グループごとの解析が可能である。全結合のサブネットワークは、入力グループ間の相互作用を表し、従来のニュー

図1 提案するネットワーク構造

Fig. 1 Structure of proposed neural network

ラルネットワークと同等の性能を保証する。

解析方法を以下の2次関数を例題にして具体的に説明する。

$$y = x_1 + x_2 + x_1 x_2$$

$$x_1, x_2 = \{0.0 \sim 1.0\}$$

ニューラルネットワーク構造の一例として図2を示す。図2の結合状態は、1, 2番目の中間層素子は x_1 , x_2 の独立した成分の存在を示唆し、3番目の中間層素子は x_1 , x_2 の相互作用の存在を示唆している。このように、ニューラルネットワークの骨格構造から入出力間の大まかな関係を把握することができる。

図3に学習により得られたニューラルネットワークの入出力特性を示す。1, 2番目の中間層素子は線形かつほぼ同値、3番目の中間層素子は2次の関係である。これは関数の各項の特性そのものである。このように、入出力特性を解析することで、容易にニューラルネットワークの特性を把握し、知識を抽出することができる。

例題のような2変数程度の関数では、全結合の中間層素子の特性も（ x_1 , x_2 , 出力層の入力値）の張る3次元空間にプロットすることで入出力特性を解析することができるが、入力変数が多くなると解析は困難になる。よって、本論文では疎結合部分に抽出される独立成分のみを解析対象にしている。

以下3章に、このような構造にするための学習方法について述べる。

図2 2次関数学習後の構造

Fig. 2 Structure of trained neural network for quadric function

図3 2次関数を学習したニューラルネットの入出力特性

Fig. 3 IO relations of trained neural network for quadric function

3. ニューラルネットワークの学習法

＜3.1＞不要素子を削除するための定式化

不必要な中間層素子や結合があると解析や知識の抽出が容易でなく、汎化能力低下の原因にもなる。忘却付き構造学習は、不要素子の削除性能や学習後のニューラルネットワークの性能が、削除のためのパラメータに大きく依存し、適値が狭いと指摘されている⁽¹⁾。特に連続値問題に適用した場合には、適切な中間層素子数に収束させがたい。この原因はBP法をベースにした学習方法であるため、全ての中間層素子が同じように成長し、要・不要素子の区別が明確にならないためと思われる。

本論文では、連続値問題でも不要素子の削減が容易であり、かつ構造化のため拡張が容易な学習方法を提案する。提案手法は、中間層素子の要・不要判定と構造化のための拡張が容易であることから重畳エネルギー関数⁽⁴⁾をベースにした学習方法である。また、忘却付き構造学習^(2,8)とコンパクト構造化法⁽⁵⁾を併用して不要素子と不要結合を削除している。重畳エネルギー関数を用いること

で、重要素子の結合や出力分散が極めて大きくなり、重要素子が削除されづらくなる。忘却付き構造学習により、不要な結合の削除だけでなく、不要素子の出力分散も小さくすることができる。不要素子の出力分散が小さいため、コンパクト構造化法による削除が容易である。つまり、3つの学習アルゴリズムを併用することで、重要素子の削除防止と、不要素子の削除の容易化を実現している。

重畳エネルギー関数は、複数の部分パーセプトロンを定義し、番号の小さい部分パーセプトロンの結合は相対的に早く成長させ、番号の大きい部分パーセプトロンの結合は相対的に遅く成長させる方法である。これにより必要な素子は大きく成長し、不要な素子の成長は抑制されるため要・不要が明確になる。忘却付き構造学習は、評価関数に重みの絶対値和の項を付加することで、不要な結合を削除する方法である。2つのアルゴリズムを併用したエネルギー関数を次式に示す。

Fig. 4 Structure of neural network each learning steps(A sample of training for quadric function)

$$F = \sum_i^H \beta_i E_i + \varepsilon' \sum |\omega_{ij}| \quad \cdots(1)$$

$$E_i = \frac{1}{2} (y_i - y_i')^2 \quad \cdots(2)$$

$$\beta_i = \frac{\alpha^2}{H(H+1)(2H+1)} \quad \cdots(3)$$

ここで、F:エネルギー関数、H:部分パーセプトロンの総数、 β_i :正の定数、 ε' :忘却係数、 E_i :部分パーセプトロンのエネルギー関数、 y_i :教師データ、 y_i' :部分パーセプトロンの出力重みの修正量は次式である。ただし $\Delta w'_{ij}$ は重畳エネルギー関数による修正量であり、 ε は忘却量である。

$$\Delta w_{ij} = -\eta \frac{\partial F}{\partial w_{ij}} = \Delta w'_{ij} - \varepsilon \operatorname{sgn}(w_{ij}) \quad \cdots(4)$$

$$\operatorname{sgn}(x) = \begin{cases} -1 & (x < 0) \\ 0 & (x = 0) \\ 1 & (x > 0) \end{cases}$$

上記エネルギー関数使用時には、忘却量 ε の設定が重要になる。もし大きすぎると必要な結合までも削除され、小さすぎると不要な結合が残ってしまう。特に本論文で扱う問題は連続値であり、微妙な出力変化が重要である。離散値問題に適用するような大きな忘却量では結合を削除しすぎる傾向があった。また、最適な忘却量も学習中に変化すると思われ、動的な調整が必要と考えられる。従来の忘却量を調整する方法⁽¹¹⁾⁽¹²⁾は、離散値問題を対象にしたものであり、また試行錯誤的な調整が必要である。そこで本論文では、入力層に乱数を入力する素子を1つ付加し、乱数入力につながる結合を学習終了時まで0にするような値を忘却量にすることを提案する。算出式は次式である。ただし、忘却量の発散を防ぐため、残り学習回数が規定回数以下になったら、忘却量を固定する。提案手法は、3.3節に示すように経験的には誤差の増大等の問題はなく良好な結果を示している。

$$\varepsilon = \operatorname{avg}(\text{乱数入力の重み係数}) / \text{残り学習回数} \cdots(5)$$

〈3.2〉ニューラルネットワークの構造化

提案するニューラルネットワーク構造を構築するために、図4に示す3段階の学習方法を提案する。図4は、2次関数の学習時の構造変化の一例である。

最初に解析目的に応じて任意の結合の重みを0に置き換えて初期化する。図の例では x_1 、 x_2 の関係抽出を目的にしており、 x_1 、 x_2 だけにつながる疎結合部分と、 x_1 、 x_2 の両方につながる全結合部分を構築している。ここで、0に初期化せず全結合だけにすると、学習後も疎結合が構築されず全結合だけの解析困難な構造になる。

次に第1段階の学習において構造の概略を決定する。まず、疎結合は奇数番号の部分パーセプトロンに、全結合は偶数の部分パーセプトロンに配置する。番号の大きい部分パーセプトロンの中間層素子は番号の小さい部分

パーセプトロンで学習しきれない部分だけを学習する性質があるため、全結合部分は疎結合部分では学習しきれない相互作用分だけを学習する。また、学習に必要な不要な中間層素子は、忘却の作用で縮退するため、コンパクト構造化法で容易に削除することができる。

第2段階の学習は構造の明確化である。入力因子の独立成分を疎結合部分に、相互作用分を全結合部分に抽出することを目的にしている。2つの部分パーセプトロンを定義し、疎結合を部分パーセプトロン1に、全結合を部分パーセプトロン2に定義する。これにより、全結合部分は、疎結合で学習しきれない成分、つまり入力因子の相互作用分だけを学習するようになる。

第3段階の学習は、構造のさらなる最適化である。重要素子順に部分パーセプトロンを組み替えて、新たに生じた不要素子を削除している。重要・不要素子の判定には、Goodness Factor⁽⁶⁾を用いている。次式のように出力層に伝達する値の2乗を全学習パターンで加算して算出する。

$$G_i = \sum_p \sum_j (\omega_{ij} O_i)^2 \quad \cdots(6)$$

ここで、 G_i :中間層素子 i のGoodness Factor、 O_i :中間層素子 i の出力、 ω_{ij} :中間層素子 i と出力層素子 j 間の重み、 p :全学習パターンについての加算

上述のように、本提案手法は重畳エネルギー関数の特性を利用して、疎結合部分に各入力因子の独立成分を、全結合部分に疎結合だけでは学習仕切れない相互作用成分を誘導しながら学習している。

〈3.3〉提案学習法の検証

以下の2次関数を例題にして、BP法と比較して提案手法の有効性を検証する。

$$y = x_1 + x_2 + x_1 x_2$$

$$x_1, x_2 = \{0.0 \sim 1.0\}$$

提案するニューラルネットワークの初期構造は、図4に示すように、 x_1 、 x_2 の疎結合の中間層素子が各3つ、全結合の中間層素子が3つの計9つの中間層素子から成り立つ。BP法で学習するニューラルネットワークは中間層素子数が1～9の9種類である。表1に示す学習条件で、重みの初期値を変えて100例ずつ学習を行った。学習・評価用データは、 x_1 、 x_2 を0から1まで0.1刻みで変化させて作成した121パターンから60パターンずつランダムに抽出して作成した。

表1 学習条件

Table 1 Training conditions

項目	値・内容	備考
学習回数	各学習ステップで10万回	
忘却量算出	学習9万回目まで、以降固定	
中間層素子の融合条件	相関係数 0.95 以上 分散 0.0001 未満	コンパクト構造化の係数

図 5に学習時の中間層素子の出力分散の変化の様子を中間層素子数 9 の B P 法と対比して示す。提案手法では、部分パーセプトロン 1, 2 に配置した中間層素子 1, 4, 7 が大きく成長し、要・不要素子が明確になる傾向がある。それに対し、B P 法では全ての素子が同じように成長している。B P 法をベースにした従来の忘却付き構造

図5 学習時の中間層出力分散の変化の一例
Fig. 5 A sample of hidden units variance.

図6 学習時の忘却量の変化の一例
Fig. 6 A sample of amount of forgetting while training.

図7 評価データに対する絶対値平均誤差
Fig. 7 Mean absolute errors

学習やコンパクト構造化法の性能は、削除に関するパラメータの設定に大きく依存するが、これは各中間層素子の分散の差が不明確であることが原因と思われる。一方、提案手法では、中間層素子の差が大きく、不要素子の削除が容易である。図 6 に忘却量の変化を示す。離散値問題で適切と言われる値 ($10^{-5} \sim 10^{-3}$)⁽⁸⁾ よりも小さく推移しているが、不要素子の分散が B P 法の分散と比較して小さいこと、必要素子の分散が B P 法よりも大きくなっていることから、提案手法による忘却量は、必要素子の成長を阻害するほど小さくなく、また不要素子を削除するのに適切な大きさであるといえる。

図 7 に B P 法との比較を示す。提案手法は、評価用データに対する絶対値平均誤差が B P 法と比較しても小さく汎化能力が高い。学習終了時の中間層素子数は 3 もしくは 4 であった。B P 法で最小の誤差を示した中間層素子数は 3 であることから、不要素子が良好に削減できていると言える。

提案する学習方法は、図 3 に示すように、2 次関数についての知識を各中間層に適切に抽出することができた。

4. 数値シミュレーション

〈4.1〉翌日最大電力需要予測問題

翌日最大電力予測問題とは、1 つの電力会社の過去の需要実績と気象より翌日の最大電力を予測する問題である。電力需要は、気象と非線形の相関関係があり、気温が高いときと低いときには冷暖房機器の使用により電力需要が増加すると言われる。

表2 翌日最大電力需要予測問題の入力因子 (春季)

Table 2. Input data of next day peak load forecasting	
入力グループ	詳細
電力	実績電力 (前日), 実績電力 (7 日前)
最高気温	最高気温 (当日 ~ 2 日前), 最低気温 (当日 ~ 2 日前)
フラグ	休日 (当日 ~ 2 日前), 土曜 (当日 ~ 2 日前)

注) フラグは 1, 0 の離散値。休日、土曜のときに 1。

図8 翌日最大電力予測用ニューラルネットワーク構造
Fig. 8 Structure of neural network for next day peak load forecasting

表2に入出力因子を示す。入力因子は14あるが、その性質により3つの入力グループにまとめ、その入力グループごとに解析を行うことにした。予測の精度評価に用いるデータは、春季(4, 5月)のデータであり、学習用のデータはその過去3年分の春季データである。学習条件は表1と同一である。学習前のニューラルネットワークは、3つの疎結合と1つの全結合に中間層素子を3つずつ配置し、計12の中間層素子を持つ構造である。図8に学習後の結合状態を示す。学習により半数の中間層素子が削減されている。

図9に入出力特性を、図10に学習データを示す。図9の気象の入出力特性は、図10の学習データの分布とほぼ同じ形状であり、気温と最大電力に関する知識が適切に抽出されている。図9のフラグの入出力特性は、0(平日)

図9 翌日最大電力需要予測問題の入出力特性
Fig. 9 IO relations of trained neural network for next day peak load forecasting

図10 翌日最大電力需要予測の学習データ
Fig. 10 Training data for next day peak load forecasting

表3 翌日最大電力予測の予測結果比較
Table 3 Comparision of forecasting errors between proposed method and BP

	提案手法	B P 法
最大誤差	5.29	5.40
最小誤差	-8.68	-8.84
絶対値平均誤差	2.28	2.64

単位 : %

のときに大きく、1(土曜や休日)のときに小さくなることを示しており、この知識も学習データと一致している。

表3に予測誤差をBP法(中間層素子数12)と比較して示す。ここで、最大誤差とは正の誤差の中で最大の誤差であり、最小誤差とは負の誤差の中で最大のものである。提案手法はBP法と比較して良好な結果を示した。

<4.2>1時間先ダム流入量予測

ダム流入量予測⁽¹³⁾⁽¹⁴⁾とは、上流の測水所の流量と雨量データを用いて、ダムに流入する水量を予測する問題である。これを例題にして、本提案手法の有効性を検証する。

対象流域の概略図を図11に示す。各測水所と対象ダム間の流下時間は、河川流量により大きく変動するが平常時で1~2時間である。入力因子を表4に示す。通常、ダム運用者は、上流流量、雨量等の数個の因子で予測を行っている。よって、35の入力因子は、その性質ごとに5つのグループにまとめ、その入力グループごとの解析を行う。学習前のニューラルネットワークは、5つの疎

図11 予測対象の流域概略図
Fig. 11 Target river basin

表4 ダム流入量予測の入力因子

Table 4 Input data of water flow forecasting

入力グループ	詳細
上流流量	測水所1, 測水所2, 測水所3
上流流量差分	測水所1 (-1h, -2h, -3h) 測水所2 (-1h, -2h, -3h) 測水所3 (-1h, -2h, -3h)
ダム流入量	ダム流入量
ダム流入量差分	ダム流入量差分(-1h, -2h)
雨量	流域平均雨量(-1h, -2h, ..., -20h)

図12 各入力因子と出力の相関係数
(入力因子の順番は表4に準拠)

Fig. 12 Correlation coefficients of each input units

結合と1つの全結合のサブネットワークに2つの中間層素子を配置した計12個の中間層素子を持つ。全洪水事例23のうち、11～23事例を評価用に、1～評価事例直前の事例までを学習用に用いた。学習条件は表1と同様である。

学習後のニューラルネットワーク構造の一例を図13に示す。ニューラルネットワークの構造は、評価した13事例の全てにおいて、「上流流量差分の疎結合」、「雨量の疎結合」と「全結合」の中間層素子が構築され、他の疎結合は削除された。図12に学習データにおける入力因子と出力の相関係数の一例を示す。相関係数の低い入力グループが削除されている。「ダム流入量差分」は相関係数は高いが、「上流流量差分」と本質的に同じデータであるため削除されたと思われる。図13の「雨量の疎結合」に結合する大きな重み（絶対値が1.0以上）を持つ因子は1時間前雨量と3時間前雨量の2つだけであり、その符号は逆であった。これは、雨量そのものの値よりもその差分が重要であることを示している。実際、1時間前雨量の相関係数は0.203であるが、1時間前雨量と3時間前雨量の差分の相関係数は0.382である。

学習データの相関図を図14に、入出力特性を図15に示す。ここで、入力値は0～1に正規化してある。抽出した入出力特性は学習データとほぼ一致しており、良好に知識を抽出している。

図16、表5に提案手法とBP法（中間層素子数12）で学習したニューラルネットワークとの予測結果の比較を示す。どちらも良好に予測しているが、提案手法の方が誤差が小さい。

表5 予測誤差の比較

Table 5 Comparision of forecasting errors between proposed method and BP

	提案手法	B P 法
絶対値平均誤差	5.06 %	6.23 %
標準偏差	7.79 %	7.95 %
相関係数	0.989	0.988

図13 ダム流入量予測のニューラルネットワーク構造（入力因子の順番は表4に準拠）

Fig. 13 Structure of trained neural network for water flow forecasting

(a) 流入量差分（3つの測水所の1時間前観測値の合計）

(b) 雨量差分（1時間前雨量と3時間前雨量の差分）

図14 出力と入力因子の相関図

Fig. 14 Correlation between output and input units

図15 ダム流入量予測の入出力特性

Fig. 15 IO relations of trained neural network for water flow forecasting

— 実績値 — 提案手法による予測結果 — BPによる予測結果

図16 ダム流入量予測の比較の一例

Fig. 16 A sample of forecasting comparison between proposed method and BP

5. あとがき

連続値データを扱うニューラルネットワークの内部解析、及び知識抽出のための構造と学習方法を提案した。提案するニューラルネットワークは、任意の入力グループごとにモジュール化した構造を持ち、学習により入出力関係を表現する構造が自動的に構築される。この結果、従来不可能であった連続値の入出力特性の解析、知識の抽出が可能である。

2次関数、翌日最大電力需要予測、ダム流入量予測に適用し、入出力特性を解析した結果、知識を適切に抽出することができることを確認した。関数近似能力や予測精度が高いことから、BP法と比較して汎化能力が高いことも確認した。

(平成12年6月22日受付、平成12年10月24日再受付)

文献

- (1) D. E. Rumelhart, J. L. McClelland and the PDP Research Group: "Parallel distributed processing, 1-2", The MIT Press (1986)
- (2) 石川: 「ニューラルネットワークの忘却付き構造学習」, 日本ファジィ学会誌, Vol. 9, No. 1, pp. 2-9, (1997)
- (3) D. C. Plaut, S. J. Nowlan and G. E. Hinton: "Experiments on learning by back propagation", Technical Report, CMU-CS-86-126, Carnegie Mellon Univ., (1986)
- (4) 高橋, 徳永: 「重畳エネルギー関数による多層パーセプトロンの冗長性削除」, 電子情報通信学会論文誌 D-II, Vol. J80-D-II, No. 9, pp. 2532-2540, (1997)
- (5) 増田, 藤井, 池谷, 相部: 「隠れユニットの合成による階層型ニューラルネットワークのコンパクト構造化」, 計測自動制御学会論文集, Vol. 28, No. 4, pp. 519-527, (1992)
- (6) 松永, 中井, 村瀬: 「階層型ニューラルネットワークの中間層素子数を自動削減する誤差逆伝播学習アルゴリズム」, 信学技報, NC91-2, (1991)
- (7) 赤池: 「情報量基準 AIC とは何か その意味と将来への展望」, 数理科学, No. 153, pp. 5-11, (1976)

- (8) 石川: 「忘却を用いたコネクショニストモデルの構造学習アルゴリズム」, 人工知能学会誌, Vol. 5, No. 5, pp. 595-603, (1990)
- (9) 福見, 赤松: 「進化的アルゴリズムにより構造化されたニューラルネットワークからのルール抽出の方法」, 電学論 C, Vol. 120-C, No. 4, pp. 529-535, (2000)
- (10) 堀川, 古橋, 大熊, 内川: 「ファジィニューラルネットワークの構成法とその性能評価」, 6th Fuzzy System Symposium, pp. 57-62, (1990)
- (11) 上田, 高橋, 森: 「ファジー推論を用いた階層型ニューラルネットワークの構造決定法—不要な結合重みと中間層素子の削除—」, 電子情報通信学会論文誌, Vol. J78-D-II, No. 10, pp. 1479-1490, (1995)
- (12) 渡辺: 「学習と忘却のバランスを考慮した選択的忘却付き学習法」, 信学技法, NC95-171, (1996)
- (13) 飯坂, 松井, 植木: 「ニューロ・ファジーによるダム流入量予測システムの開発」, 電気学会論文誌 B, Vol. 119-B, No. 10, pp. 1020-1025, (1999)
- (14) 松井, 飯坂, 植木: 「ニューラルネットワーク応用のダム流入量予測システム」, 富士時報, Vol. 71, No. 3, pp. 157-160, (1998)
- (15) 植木, 松井, 遠藤, 加藤, 荒家: 「ニューロ・ファジー応用最大電力システムの開発」, 電気学会論文誌 B, Vol. 115-B, No. 9, pp. 1038-1045, (1995)
- (16) 石岡, 佐藤, 石原, 植木, 松井, 飯坂: 「NN 応用電力需要予測システムの開発」, 電気学会 電力・エネルギー部門大会, 38, (2000)
- (17) 飯坂, 松井: 「階層型ニューラルネットワークの構造化と内部解析手法」, 電気学会 電力・エネルギー部門大会, 291, (2000)
- (18) 飯坂, 松井: 「連続値データを扱うニューラルネットワークの解析と知識の抽出」, 電気学会 電子・情報・システム部門大会, GS8-1, (2000)

飯坂 達也

(会員) 1969年5月20日生まれ。1994年3月埼玉大学理工学研究科電気工学専攻博士前期課程修了。同年4月富士電機㈱に入社。現在に至る。主として電力システムのインテリジェントシステムに関する研究に従事。

松井 哲郎

(会員) 1965年3月31日生まれ。1988年3月横浜国立大学工学部情報工学科卒業。同年4月富士電機㈱に入社。現在に至る。主として電力システムのエキスパートシステム、インテリジェントシステムに関する研究に従事。