

重回帰分析と階層型ニューラルネットによる 翌日電力需要予測

田中 英一, 長谷川 淳, 伊藤 正義

1. はじめに

電力系統において、各発電機の運転計画や他地域との電力融通計画などの需給計画は、電力需要予測に基づいて立案される。予測精度の良し悪しは、経済性ならびに信頼性に大きな影響を与えることから、なるべく精度の良い、また予測担当者の経験年数などに依存しない客観的な予測手法の確立が望まれている[1]。

ここでは、電力供給地域全体の翌日24時間にわたる1時間ごとの平均的な電力需要を予測するための一手法について概説する[2]。この手法では、まず、前年の需要実績データならびに気象データを用いて重回帰分析[3]を行い、線形予測モデルを作成する。次に、この予測モデルによって算出される平均的な予測値と実績データとの差(予測誤差)を縮小するように、階層型ニューラルネットワーク(NN)[4]を学習させる。実際に予測を行う際には、まず、当日の気象予報データと前日までの需要実績データを用いて重回帰モデルで予測値を求め、さらに階層型NNによって補正を行う。

この手法の特徴としては、重回帰係数を求める際に曲面近似[5]を用いて予測モデルの平滑化をはかっていること、NNの適用において教師信号にある幅を持たせるというような様々な工夫を施していることなどがあげられる。

実際のデータを用いたシミュレーションでは、特殊日を含めた通年での平均予測誤差は2%以下となっており、ある程度満足できる精度が得られている。

たなか えいいち, はせがわ じゅん 北海道大学 工学部 〒060 札幌市北区北13条西8丁目
いとう まさよし
北海道電力(株) 函館支店 電力部
〒041 函館市富岡町1丁目2-1

2. 回帰分析に基づく予測モデル

2.1 曲面近似を用いた平日用予測モデル

まず、供給エリアの気候と電力需要との関係に基づいて、暖房用負荷が必ずかかる期間、暖房用負荷がかかる可能性のある期間というように、1年を6つの期間に分割する。そして、前年のデータから各期間ごとの平日の標準的な予測モデルを重回帰分析によって作成する。その際に、曲面近似[5]と呼ばれる手法を用いている。

いま、第 k 日第 i 時間帯の予測値 $P^*(k, i)$ が、 N 個の説明変数 $X_n(k, i)$ によって計算できるものとする。と、(1)式のように表すことができる。ここで、 $\alpha_n(i)$ は、(2)式に示すように時間帯 i の M 次式で表される。

$$P^*(k, i) = \sum_{n=1}^N \alpha_n(i) X_n(k, i) \quad (1)$$

$$\alpha_n(i) = \sum_{m=0}^M \beta_{nm} i^m \quad (2)$$

負荷の実績値を $P(k, i)$ とすると、(3)式のように観測期間日数 K 全体にわたる残差平方和 E を最小にするように β_{nm} を定め、これを M 次曲面近似における回帰係数とする。

$$E = \sum_{k=1}^K \sum_{i=1}^{24} \{P^*(k, i) - P(k, i)\}^2 \quad (3)$$

なお、説明変数としては、予測日前日の需要実績値、前日と前々日の需要実績値の差分、同様に前々日と3日前の需要実績値の差分、予測日の予想最高気温、前日と前々日の最高気温の差分、前々日と3日前の最高気温の差分の6個を採用している。また、次数 M の値としては、これまでの検討では、一般に2で十分と考えられる(2次曲面近似)。

2.2 特殊日処理のための平日値換算係数

土・日・月曜や祝日・年末年始・ゴールデンウィーク

ク・お盆などの電力需要は、火曜から金曜までの平日の需要と比べて一般に小さめで、異なった傾向を示すが、ここでは、これらを一括して特殊日として処理する。前述の予測モデルは、平日の需要曲線を予測するためのものであるから、このモデルを特殊日にも適用するためには平日値への換算が必要である。すなわち、特殊日 s の第 i 時間帯における平日値換算係数 $R(s, i)$ は、観測期間内の平日の第 i 時間帯における需要の平均値 $\bar{P}_o(i)$ に対する比率として(4)式で与えられる。

$$R(s, i) = \bar{P}_s(i) / \bar{P}_o(i) \quad (4)$$

ここで、 $\bar{P}_s(i)$: 特殊日 s 第 i 時間帯の需要平均値。

この係数を用いて、(5)式のように、特殊日の需要 $P_s(k, i)$ を等価的に平日需要 $P_o(k, i)$ に換算したうえで、(1)式に組み込む。

$$P_o(k, i) = P_s(k, i) / R(s, i) \quad (5)$$

さらに、得られた予測値に換算係数を乗じることによって特殊日の予測値が算出される。

2.3 シミュレーション結果

'90年~'92年の北海道地方の大口需要家および所内需要を除いたその他の電力需要合計量に対して、実績データに基づいた予測シミュレーションを行った。ただし、実際の予測では、予測日の気象データとしては予報値を用いるべきであるが、ここでは観測値を使用した。すなわち、天気予報の誤差は考慮していない。

平均誤差でみる限り、夏期以外ある程度満足できる結果となったが、予測日によってはかなり大きな誤差が生じることが確認された。最大誤差についてみると、約半数が祝日、特殊期間の影響によるものとなっている。特に、特殊な特殊日、つまり祝日や特殊期間が土・日・月曜と重なった場合は、誤差が大きくなりやすい傾向にあり、平日値換算係数の求め方に工夫が必要である。因みに、土・日・月曜の換算係数に関しては前年のデータだけで、祝日に関しては入手可能な過去5年分のデータから、また、盆、年末年始、ゴールデンウィークに関しては同じく過去10年分のデータから算出した値を用いている。

また、曲面近似による重回帰分析は、観測データの平均的な値でモデル化することになるため、特殊な気象状況、特に天候の変化が大きな場合に誤差が大きくなる傾向が認められた。平日で 200MW 以上の誤差が生じた日における雲量の変化を調べると、約半数がこ

の場合に該当する。

3. 階層型ニューラルネットを用いた補正用モデル

前節で指摘した天候の変化が大きいときに発生しやすい大きな誤差を抑制するために、また重回帰モデルでは表しきれない需要と気温や雲量(天候)との間の定量的評価の難しい関係を自動的に求めるために、階層型 NN を用いて予測値を補正する機構を加えた予測モデルを採用する。この予測モデルの概念図を図1に示す。なお、NNのみで予測モデルを作成することは、以下の理由から考えていない。

- ①重回帰モデルである程度満足できる予測精度を得ているので、これを継承することは有効である。
- ②モデルのブラックボックス化を避ける。

3.1 階層型 NN の構成

階層型 NN の構造を図2に示す。準線形ニューロンモデルの入出力特性は、次式のシグモイド関数に従う。

$$f(I) = 1 / (1 + e^{-I}) \quad (6)$$

ここに、 I : 素子への入力、 $f(I)$: I に対する素子の出力。

入力層に与える入力としては、時系列データをバッファネットワーク上に与え、ダイナミクス学習を行わせる。入力層素子数は24であり、それぞれの素子に与える入力としては、予測対象日とその前3日間の最高気温、最低気温、9・12・15・18時の雲量を使用する。実際の運用を考えると、予測対象日とその前日の午後に関しては雲量の入手は困難であるので、雲量の代わりに予想される天候を数値化したものを入力とする。

中間層の数は1層とし[6]、その素子数は後述する「中間層素子数自動決定アルゴリズム」[7] - [11] によって決定する。

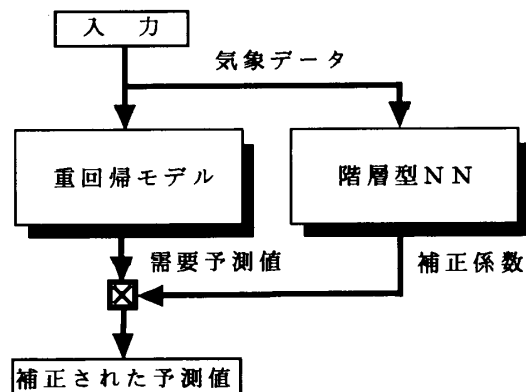


図1 電力需要予測モデル

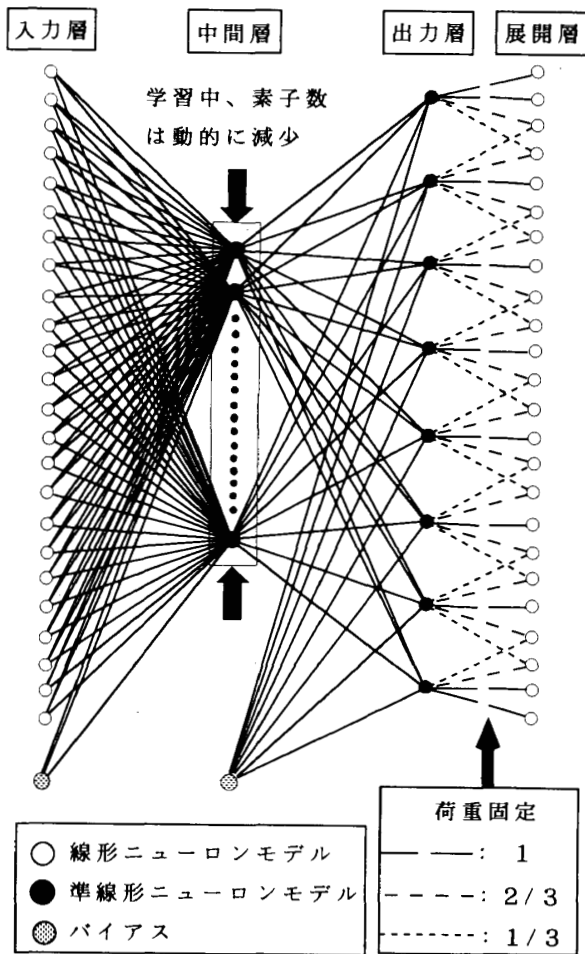


図2 補正用階層型 NN の構造

出力層素子数に関しては、1時間ごとの補正値を出力する24個が必要になる。しかしながら、入力データが1時間ごとの値を示すものではないこと、1時間ごとの補正値では時間推移に対してばらつきがみられることを考慮して、3時間ごとの平均的な補正値を出力する8個とする。学習されたネットワークを用いて実際に適用する際には、荷重があらかじめ固定されている、線形ニューロンモデルからなる層（展開層と呼んでいる）を付け加えて24時間展開を行い、1時間ごとの補正値を出力する。

3.2 基本バックプロパゲーション法の改良

基本バックプロパゲーション(BP)法に基づく一括修正法は、(7)式で表されるパターン対全体の NN 出力と教師信号の誤差の自乗和 F を評価関数とし、これを最小化するように学習率(探索幅) η を一定として最急降下法を適用したものである((8)式)。

$$F(w) = \sum_{p=1}^{PN} F^p(w) = \sum_{p=1}^{PN} \sum_{l=1}^{ON} (1/2) (t_l^p - o_l^p)^2 \quad (7)$$

$$\Delta w_i = -\eta \sum_{p=1}^{PN} (\partial F^p(w) / \partial w_i) / PN \quad (8)$$

ここで、 $F^p(w)$: パターン p に対する誤差の自乗和、 w : 荷重ベクトル、 t_l^p , o_l^p : パターン p に対する l 番目の出力層素子の教師信号と出力値、 Δw : 荷重修正量、 PN : パターンの数、 ON : 出力層素子数、 i : 現在の学習回数。

このアルゴリズムによって学習された NN は、線形分離不可能なパターンをも分類できるという優れた能力を有する反面、以下に示すような学習上の問題点が存在する。

- ①学習率・中間層素子数・荷重初期値に対する試行錯誤的学習
- ②局所解へのトラップ
- ③学習時間の長大化

そこで、様々な手法を用いて、これらの問題を可能な限り克服する。

まず、中間層素子数決定に関する試行錯誤を排して学習時間の短縮を図るため、素子数を自動決定する機能を加える。このアルゴリズムでは、素子削除のための基準 ξ に関しても自動的に決定されるという点が、従来のアルゴリズムとは異なっている。ここでは学習回数 $N=300$ 、中間層素子数の初期値を30とした。素子の有効度算出に関しては、能力的に優れ演算量も少なくて済む Effectiveness factor [9] と呼ばれる評価関数を採用する。詳細は、文献 [2] を参照されたい。

また、既に提案されている動的最適学習率決定機構である改良型 DSC サーチ [12]、荷重の初期値への依存度を減らして安定な学習を行わせるための荷重初期値設定法[13]、さらに、非線形最適化手法において大域的な最適降下方向を与える共役勾配法を適用する。

3.3 教師信号のバンド化

階層型 NN の教師信号となる補正係数は、入力が気温と雲量(天候)なので、これらだけに依存する値にすることが要求される。いま、(9)式で示される1時間ごとの見かけの補正係数を t_0 とする。この値が(6)式で示されるシグモイド関数の非飽和な値域に入るように、(10)式によって t_0 に線形変換する。

$$t_0(k, i) = P(k, i) / P^*(k, i) \quad (9)$$

$$t_a(k, i) = 2.5 t_0(k, i) - 2 \quad (10)$$

これから各時間帯の補正係数 t を(11)式に従って算出する。

$$t(k, i) = \frac{\sum_{i=3n-2}^{3n} t_a(k, i)}{3} \quad (11)$$

この t の値は、気象要因以外にも、突発的な出来事、

イベント等の不規則な要因が複雑に絡み合ったものを反映していると考えられるので、 t から気温と雲量(天候)だけに依存した補正係数 t_w を厳密に求めることは不可能である。したがって、 t_w として、(12)式のように t にある幅を持たせたものを考える。

$$t(k, n) - \epsilon \leq t_w(k, n) \leq t(k, n) + \epsilon \quad (12)$$

ここに、 $n=1, 2, \dots, 8$: 出力層の時間帯。

したがって、教師信号とネットワーク出力値の差で表されるエラー値 e は図3のようになり、 $\pm\epsilon$ の不感帯を考慮することと等価である。また、実際の予測においても、出力値 o に対して不感帯分を差し引いた値に変換して適用する。結局、この手法では重回帰モデルにおいて精度良い予測値が得られる場合には、何も補正が行われなくなる。なお、試算では ϵ の値を0.025と設定したが、この値は、(10)式に基づいて逆算すると、重回帰モデルで生じた相対誤差 $\pm 1\%$ を気温・雲量(天候)に依存する部分と考えることに相当する。

3.4 シミュレーション結果

重回帰モデルの場合と同様に、1年を6つの期間に分割し、期間ごとに過去2~3年の実績データを用いて前述の学習を行い補正用NNを作成する。重回帰モデルにおいて、祝日や特殊期間に発生しやすい大きな誤差は、一般に気象に起因するものではないことから、これらの日のデータは訓練集合から除外する。また、信頼性を向上させるために、異なる5つの初期値で学習させたNNの出力の平均値を実際の補正值とした。

(1) 学習結果

前述のようなさまざまな工夫によって、異なる初期値から学習を開始しても最終的な中間層の数およびRMSエラー値はほぼ同じになることが確認された。学習時間に関しては、期間ごとに訓練パターン数が異

なるのでバラツキがみられるが、EWSで数分程度である。

中間層素子数とRMSエラー値の推移の一例を図4に示す。素子の削除される間隔が一般に短いのは、ネットワークのfault tolerantな性質によるものと考えられる。これにより、総合的な学習時間は、従来の試行錯誤的学習より明らかに短縮されている。

(2) 適用結果

ここでも、NNへの入力としては、気温や天候などの予報値の代わりに観測値をそのまま利用した。

まず、気象の変化が大きい日に対する予測結果の一例を図5に示す。すべての場合において補正がうまくいくとは限らないが、この例のように実績値にかなり近づくケースが認められた。

予測シミュレーションで得られた結果をまとめると以下ようになる。

- (1) 重回帰モデルで精度が劣っている夏の期間に対して、顕著な改善効果が認められた。
- (2) 教師信号のバンド化を行わないケースでは、補正量が大きめになるので、正しく補正されている場合には改善の度合いが大きい反面、補正が逆の方向に働いた場合には悪化の度合いも大きい。
- (3) 教師信号のバンド化を行ったケースでは、控えめな補正を行うことになるので、悪化を防ぐ効果が認められる。特に平均誤差に関しては、すべての期間で改善されている。また、バンド化によって、約4割の時間帯で補正が行われていないことが確認されている。重回帰モデルによってある程度精度良い予測値が得られていること、補正によって予測精度が逆に悪化するのを避けたいなどの点を考慮すると、予測値補正用NNにおける教師信号のバンド化は有効といえる。




図3 教師信号のバンド化




図4 RMSエラー値と中間層素子数の推移例




図5 予測結果の一例 ('92/9/24)

4. あとがき

ここで述べた翌日電力需要予測手法は、統計的モデルと階層型 NN モデルとの融合モデルの一形態と考えられる。統計的モデルによって、ある程度の精度が得られるが、気象の変化が大きな場合に比較的大きな誤差が生じる傾向がみられた。これは、予測モデルが線形であり、需要とその決定要因との間の複雑な関係を表現することが難しいことによると考えられる。

そこで、解析的にこの関係を求める代わりに、過去のデータの学習によってこの関係を自動的に獲得する階層型 NN を導入し、予測値の補正を行うこととした。この階層型 NN モデルの導入に際しては、基本 BP 法の学習上の問題点をできるかぎり克服するためにさまざまな機能を追加した。また、入力である気温・雲量(天候)に依存する出力値を得るように、教師信号のバンド化を行った。シミュレーションの結果より、バンド化の有効性が確認された。

参考文献

[1] 電力系統の需給制御技術調査専門委員会：「電力系統の需給制御技術」，電気学会技術報告(II部)，第302号，1989。

[2] 佐藤，田中，長谷川：「階層型ニューラルネットワークによる補正を考慮した翌日電力需要予測」，電気学会論文誌B，114巻，10号，1994。

[3] 久米，飯塚：「回帰分析」，岩波書店，1987。

[4] D. E. Rumelhart, J. L. McClelland, and the PDP Research Group: "Parallel Distributed Processing", The MIT Press, Vol. 1, pp. 318-362, 1986.

[5] 中村，山城，宮本：「重回帰分析に基づく翌日負荷予測モデルの構築」，平成3年電気学会電力・エネルギー部門大会論文集(論文I)，No. 5。

[6] 船橋：「ニューラル・ネットワークの capability について」，電子情報通信学会技術報告，MBE88-52，1988。

[7] 萩原：「淘汰機能を有するバックプロパゲーション-中間層ユニット数の削減と収束の高速化」，電子情報通信学会技術報告，NC89-104，1990。

[8] 松永，中出，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」，電子情報通信学会技術報告，NC91-2，1991。

[9] 真島，吉村，永野：「層状ニューラルネットにおける中間層素子削減方法の検討」，電子情報通信学会技術報告，NC92-110，1993。

[10] Y. Hirose, K. Yamasita, and S. Hijiya: "Back Propagation Algorithm Which Varies the Number of Hidden Units", *Neural Networks*, Vol. 4, pp. 61-66, 1991.

[11] 松岡，編：「ニューロコンピューティング」，朝倉書店，1992。

[12] 高木，阪上，戸川：「ニューラルネット学習における非線形最適化手法の効果」，電子情報通信学会論文誌D-II，Vol. J74，No. 4，pp. 528-535，1991。

[13] 神原，三谷，大堀，渡辺：「3層ニューラルネットにおける結合係数初期値設定法」，平成5年度電気関係学会北海道支部連合大会論文集，No. 265。