

ニューラルネットワークを応用した 電力需要予測システムの開発

川合 桂, 小野 雅也

1. はじめに

近年、電力システムの規模拡大・複雑化・大容量化は年々増加する傾向にある。また、情報化社会の発展にともない、電力システムの信頼性、質的向上への要請がますます強まっている。更に、電力コストの低減が強く望まれている。このため電力の効率的かつ、信頼度の高い供給が電力各社の課題となっている。しかし、現在の技術では電力の大容量の貯蔵が困難であるため、需要と供給のバランスを見ながら発電を調整しなければならない。従って、信頼性と経済性を満足した電力供給のためには、正確な電力需要予測を行う必要がある。

電力需要予測とは天候や気温などの気象データをもとに、翌日の最大需要量や翌日電力需要カーブ（時間帯別の電力需要の変化）の予測を行ったり、当日の電力需要の変化に合わせて電力需要カーブの予測値の修正を行う機能である。この需要予測結果によって翌日の発電計画がたてられ電力システムの信頼性と経済性を維持する。このように当日及び翌日といった短期的な需要の傾向を予測するものを短期需要予測と呼び、年間などの長期的な需要の傾向を予測するものを長期需要予測と呼ぶ。本論文では短期的電力需要予測について報告する。

また、冷暖房需要の増加に伴い、電力需要は季節毎の気象要因の影響を強く受けるようになった。そのため、各気象要因と需要との関係を統計的に求め、その関係を用いて需要を予測する方法がよく用いられている。一般に、各気象要因と需要との関係は非線形であるので、非線形な関係をデータの学習により抽出する能力を持つニューラルネットワークが注目され、その

適用が検討されてきた（例えば [1]）。ニューラルネットワークは学習データの内挿により未学習データの推定を行うので、高精度の予測を実現するためには様々な状況に対応した大量のデータを学習する必要がある。

ところが、種類、数量ともに十分な学習データを用意することは、需要予測に関しては困難である。なぜなら、曜日、季節によって、気象要因と需要との関係は異なるからである。また、電力需要量は年々増加しており過去年度のデータを使用して学習を行ってもそのままでは予測に使うことはできない。もし、これらの傾向の異なるデータをそのまま併せて学習すれば、予測する期間とは異なった関係が学習されてしまう。また、傾向が等しいと思われるデータのみを学習すれば学習データ数は極端に少なくなってしまう。どちらの場合も、ニューラルネットワークによる高精度な予測は困難である。そこでこの問題を解決するために、北陸電力(株)と共同で研究を行ってきた2段階学習法を提案する。

2段階学習法とは、気象要因の変化に対する需要の変化率が、年度によって大きく変わらない特徴を利用し、過年度のデータを学習した後に予測年度のデータでニューラルネットワークの出力を調整するものである。予測日至近のデータを追加学習する方法に関する研究は行われているが [2]、一般的な学習方法であるバックプロパゲーション法を用いた場合、新たなデータの学習によりすでに学習した内容が破壊されてしまうという問題があった。この問題に対して本論文では、ニューラルネットワークの荷重値の変化に制限を加えることによって、学習内容の保護と新規データの学習の両立を図る。

これらの方法を評価するために、北陸電力の夏季の需要データにより翌日最大需要予測の検証を行った。

本論文の構成は以下の通りである。まず、今回用いるニューラルネットワークの概要を述べ、次に、新し

かわい かつら, おの まさや
㈱東芝 府中工場
〒183 府中市東芝町1

いニューラルネットワークの学習方法である2段階学習法を提案する。これらの方法を1989年度と1990年度の夏季の需要予測に適用する。その予測結果から2段階学習法を用いたニューラルネットワークの有効性について評価する。最後に今後の課題について述べる。

2. ニューラルネットワークの構成および入出力変数

ニューラルネットワークの構造は、3層パーセプトロン型とする。入力層は3ユニット、中間層は12ユニット、出力層は1ユニットから成る(図1参照)。予測の内容は、過日の気象変数および需要のデータから気象変数と需要との関係性を求め、その関係性と予測当日の気象変数の値より需要を予測するというものである。

ここでは気象変数と需要との関係づけにニューラルネットワークを用いるので、その入出力変数は次のように設定する。

入力変数：

- ・予測当日の最高気温(夏)または最低気温(冬)(単位℃)
- ・予測当日の天候
- ・予測前日の平均気温(単位℃)

出力変数：

一般需要における予測日の最大値(単位MW)

各変数の規格化は次のように行う。

- ・気温 学習データの中の最小値を0, 最大値を1にするように変換

- ・天候 晴のとき0, 曇のとき0.5, 雨・雪のとき1になるよう変換
- ・需要 学習データの中の最小値を0.2, 最大値を0.8にするように線形変換

学習方法はバックプロパゲーション法で、複数年度を通して成りたつ需要の一般的傾向と、予測日至近の需要の傾向とをあわせて学習できるように学習を2段階に分けて実施する。第1段階では前年度ベースに補正された過去年度データで学習し、第2段階では予測日至近2週間のデータを追加学習する。追加学習の際にはオーバーフィッティングを防ぐためにニューラルネットワークの荷重値変更制限を加える。

3. 制限付き2段階学習法

3.1 目的

この学習方法は、気象変数の変化に対する需要の変化率(感応度)が年度によって大きく異なる点に着目し、過年度のデータを用いて学習を行い、その後、予測日至近のデータにより出力レベルと感応度の調整を行うというものである。これは、過年度のデータの利用により感応度の学習に必要な学習データを確保し、予測日至近のデータ不足による感応度学習の不良に対処することを目的としている。

ところが、多層パーセプトロン型ニューラルネットワークの一般的な学習方法であるバックプロパゲーション法では、学習時に提示されるデータに対する誤差を減らすという条件のみによって荷重値が更新される。すなわちそのニューラルネットワークが過去にどのような内容を学習したかということは新たな学習には反映されない。そのため、過去に学習した内容に追加して新たなデータを学習するためには、過去に学習したデータと新たに学習するデータを併せて学習しなければならない。しかしこれには過年度のデータを年度補正して予測年度のレベルに合わせる必要があり、予測年度のデータが少ない状況で補正量を求めることは困難である。

そこでこの問題を解決するために、新たなデータの学習によるニューラルネットワークの荷重値の変化に制限を加えることで、過去に学習した内容の破壊を防ぐことを行っている。

今回報告する制限付き2段階学習方法は、需要の長期傾向と短期傾向をデータの特別な前処理無しに学習するために、従来のニューラルネットワークの学習方法を改良したものである。この学習方法のポイントは、




図1 ニューラルネットワークの構成

長期傾向を学習したニューラルネットワークが短期傾向を学習するときに、新たなデータの学習によるニューラルネットワークの荷重値の変化に制限を加え、初めに学習した内容を保持することである。具体的には以下の2つのステップからなる。

3.2 学習手順

ステップ1

予測年度より過年度のデータを学習する。例えば、1990年度の予測を行う場合、1988年度、1989年度といったデータを学習する。ここでのニューラルネットワークの学習方法は、最も一般的なバックプロパゲーション法を採用し、荷重値の変化に制限は加えない。この際、ステップ1で用いる学習データ数はニューラルネットワークの荷重値の数よりも十分に多いため、通常の学習方法でもオーバーフィッティングは起こらず、需要の長期的な傾向を抽出できる。

ステップ2

過年度のデータを学習したニューラルネットワークに、予測日の2週間前から前日までのデータを学習させる。例えば、1990年の7月31日の予測を行う場合、2週間前である17日から前日の30日までのデータを学習する。このとき新たなデータの学習によってニューラルネットワークの入出力特性が変化できる範囲が設定され、この値より荷重値の変化できる範囲が計算される。ニューラルネットワークは、この範囲内でバックプロパゲーション法により荷重値を更新する。これにより、需要の長期的な傾向を保持したまま、短期的な傾向を抽出する。

この学習ステップをニューラルネットワークの入出力曲線により示したのが図2である。図2の横軸はニューラルネットワークの入力変数の1つの値(気象変数)、縦軸は出力(需要)である。まず、ステップ1で過年度のデータを用いて気象変数と需要との関係が学習される。ここで学習された需要のレベルおよび入力に対する出力の感応度は、過年度のデータのものである。次に、ステップ2で予測日至近のデータを用いてニューラルネットワークの出力レベルおよび感応度の調整が行われる。出力レベルについては予測日至近デー

タのレベルに合うまで荷重値が更新されるが、感応度については設定された範囲内でのみ荷重値が更新される。これは、少数の予測日至近のデータを過剰に学習することによってニューラルネットワークがデータ本来の傾向とは異なる入出力特性を学習することを抑制するものである。

3.3 入出力特性の変化量と荷重値の変化量との関係

ここではニューラルネットワークの入出力特性の変化と荷重値の変化との関係を明らかにする。この関係は、実際の学習時に入出力特性が変化できる範囲から荷重値の変化に対する制限量を求める際に用いられる。入出力特性の学習の中でも制限が加えられるのは感応度の部分であり、これはニューラルネットワークにより実現される出力関数の微分係数の変化に制限を加えることに相当する。

ニューラルネットワークのパラメータを以下のように設定する。

ユニット数：

入力層 N_1 個

中間層 N_2 個

出力層 N_3 個

荷重値：

入力層から中間層

ステップ2学習前 $w^1_{ij}(i=1, \dots, N_1, j=1, \dots, N_2)$

ステップ2学習後 $w'^1_{ij}(i=1, \dots, N_1, j=1, \dots, N_2)$

中間層から出力層

ステップ2学習前 $w^2_{jk}(j=1, \dots, N_2, k=1, \dots, N_3)$

ステップ2学習後 $w'^2_{jk}(j=1, \dots, N_2, k=1, \dots, N_3)$

(需要量)




図2 2段階学習法

しきい値：

入力層から中間層

ステップ2学習前 $h^1_j (j=1, \dots, N_2)$

ステップ2学習後 $h'^1_j (j=1, \dots, N_2)$

中間層から出力層

ステップ2学習前 $h^2_k (k=1, \dots, N_3)$

ステップ2学習後 $h'^2_k (k=1, \dots, N_3)$

入力層の i 番目のユニットへの入力：

$I_i (i=1, \dots, N_2)$

中間層の j 番目のユニットの出力：

ステップ2学習前 $u_j (j=1, \dots, N_2)$

ステップ2学習後 $u'_j (j=1, \dots, N_2)$

出力層の k 番目のユニットの出力：

ステップ2学習前 $o_k (k=1, \dots, N_3)$

ステップ2学習後 $o'_k (k=1, \dots, N_3)$

中間層のユニットの出力関数：

$f(x) = 1/(1 + \exp(-x))$

出力層のユニットの出力関数：

$g(x) = x$

一般的な3層パーセプトロン型のニューラルネットワークと本ニューラルネットワークとの違いは、出力層ユニットの出力関数がシグモイド関数ではなく線形関数になっていることである。出力関数を線形にした理由は、荷重値変化量と入出力特性の変化との関係の導出を容易にすることである。今回のように、ニューラルネットワークの出力値を直接需要量に対応させ、0から1までの連続変数として処理する場合は出力ユニットにおける非線形性を利用していないので、出力ユニットの出力関数を線形に変えることも可能である。ただしこの場合は学習の収束性が保証されないため、学習係数を小さくするなどの措置は必要である。

以上の定義から、中間層および出力層の各ユニットの出力は次式で与えられる。

学習前：

$$o_k = \sum_{j=1}^{N_2} w^2_{jk} u_j - h^2_k \quad (1-1)$$

$$u_j = f\left(\sum_{i=1}^{N_1} w^1_{ij} I_i - h^1_j\right) \quad (1-2)$$

学習後：

$$o'_k = \sum_{j=1}^{N_2} w'^2_{jk} u'_j - h'^2_k \quad (1-3)$$

$$u'_j = f\left(\sum_{i=1}^{N_1} w'^1_{ij} I_i - h'^1_j\right) \quad (1-4)$$

すると、出力関数の微分係数の変動量は、 i 番目の

入力と k 番目の出力に対しては、

$$\frac{\partial o'_k}{\partial I_i} - \frac{\partial o_k}{\partial I_i}$$

で表される。この変動量への制限を、変動量の最大値を定められた範囲内に抑えるという形で加える場合、 k 番目の出力に対する制限は次式で与えられる。

$$\max_{1 \leq i \leq N_1} \left\{ \max_{(I_i \leq I_i \leq I_k)} \left| \frac{\partial o'_k}{\partial I_i} - \frac{\partial o_k}{\partial I_i} \right| \right\} \leq \Delta \quad (2)$$

上式で、入力 I_i は下限 I_i 、上限 I_k の間で連続的に変動するものとする。ここで出力関数の微分係数の変動可能な範囲 Δ が設定されたとき、(2)式を満たすような荷重修正量の最大値 W_k

$$\max_{1 \leq j \leq N_2} |w'^2_{jk} - w^2_{jk}| \equiv W_k \quad (3)$$

を求める。

今、簡単のため入力層と中間層との荷重値 w^1_{ij} およびしきい値 h^1_j を固定する。すなわち、

$$w^1_{ij} = w^1_{ij} (i=1, \dots, N_1, j=1, \dots, N_2) \quad (4-1)$$

$$h^1_j = h^1_j (j=1, \dots, N_2) \quad (4-2)$$

である。(1-1)、(1-2)、(1-3)、(1-4)より、

$$\begin{aligned} \frac{\partial o_k}{\partial I_i} &= \sum_j \frac{\partial o_k}{\partial u_j} \frac{\partial u_j}{\partial I_i} \\ &= \sum_j w^2_{jk} \frac{\partial u_j}{\partial I_i} \end{aligned} \quad (5-1)$$

$$\frac{\partial o'_k}{\partial I_i} = \sum_j w'^2_{jk} \frac{\partial u'_j}{\partial I_i} \quad (5-2)$$

であるが、(4-1)、(4-2)より、 $u'_j = u_j (j=1, \dots, N_2)$ なので、(5-1)、(5-2)より、

$$\begin{aligned} \frac{\partial o'_k}{\partial I_i} - \frac{\partial o_k}{\partial I_i} &= \sum_j (w'^2_{jk} - w^2_{jk}) \frac{\partial u_j}{\partial I_i} \end{aligned} \quad (6)$$

となる。(3)、(6)より、

$$\begin{aligned} &\left| \frac{\partial o'_k}{\partial I_i} - \frac{\partial o_k}{\partial I_i} \right| \\ &\leq \sum_j |w'^2_{jk} - w^2_{jk}| \cdot \left| \frac{\partial u_j}{\partial I_i} \right| \\ &\leq \sum_j w_k \left| \frac{\partial u_j}{\partial I_i} \right| \end{aligned} \quad (7)$$

となる。

$$\begin{aligned} &\left| \frac{\partial u_j}{\partial I_i} \right| \\ &= |f'(w^1_{ij} I_i - h^1_j) w^1_{ij}| \end{aligned}$$

であるが、 $0 \leq f'(x) \leq 1/4$ なので、

$$\left| \frac{\partial u_j}{\partial I_i} \right| \leq \frac{|w^{1ij}|}{4} \quad (8)$$

となる。よって、(7),(8)より、

$$\left| \frac{\partial o'_k}{\partial I_i} - \frac{\partial o_k}{\partial I_i} \right| \leq \frac{w_k \sum_j |w^{1ij}|}{4}$$

となる。したがって、

$$\begin{aligned} & \max_{1 \leq i \leq N_i} \left\{ \max_{(I_i \leq I_i \leq I_k)} \left| \frac{\partial o'_k}{\partial I_i} - \frac{\partial o_k}{\partial I_i} \right| \right\} \\ & \leq \frac{w_k}{4} \max_{1 \leq i \leq N_i} \sum_j |w^{1ij}| \end{aligned}$$

が成立するので、学習前の入力層と中間層の荷重値 w^{1ij} の値より、

$$w_k = \frac{4 \Delta}{\max_{1 \leq i \leq N_i} \sum_j |w^{1ij}|} \quad (9)$$

のように荷重値修正量の範囲を設定すれば、出力関数の微分係数の変動量を Δ 以内に抑えることができる。

また、本ニューラルネットワークは、出力層ユニットの出力関数が線形なので、出力層ユニットのしきい値を学習することにより、任意の出力レベルへの調整が可能である。ここで、しきい値の変化量と出力レベルの変化量とは等しくなるので、ニューラルネットワークの出力レベルの変化に対して制限を加える場合は、出力層ユニットのしきい値が変化できる範囲を出力レベルの変動範囲と等しく設定すればよい。

4. 検証結果

北陸電力の需要データによる検証結果を示す。予測対象期間、予測に用いる変数、学習方法、予め学習する過年度データは以下の通りである。

予測対象期間：

1989年、1990年の夏季
(7月15日～9月10日)

予測に用いる変数 (ニューラルネットワークの入力変数)：

- ・ 予測当日の最高気温
- ・ 予測当日の天候
- ・ 予測前日の平均気温

学習方法：2段学習方法とする。

第1段階で学習する過年度データ：

- ・ 1989年度予測の場合
1988年度データを学習
- ・ 1990年度予測の場合
1988年度データを1989年度レベルへ年度補正し、

1996年9月号

表1 荷重値変化の許容範囲と予測結果との関係

予測年度	荷重値変化の許容範囲	絶対誤差(MW) 最大値/平均値	相対誤差(%) 最大値/平均値
1989	0.0	192.0/69.9	7.3/2.01
	0.1	224.0/74.8	6.0/1.95
	1.0	426.0/87.8	14.4/2.70
1990	0.0	339.0/80.5	7.2/2.23
	0.1	340.0/76.5	6.4/2.05
	1.0	340.0/86.5	9.8/2.40

表2 予め学習する過年度データと予測結果との関係

予測年度	予め学習する過年度データ	絶対誤差(MW) 最大値/平均値	相対誤差(%) 最大値/平均値
1989	1988	186.0/71.4	6.0/1.95
1990	1989	223.0/77.8	6.4/2.05
	1988+1989	203.0/69.2	5.7/1.90

2年分のデータを学習

第2段階では予測日至近2週間分のデータを使い追加学習する。

まず、荷重値の変化できる大きさによる予測結果の比較を表1に示す。次に、予め学習する過年度データに対する予測結果の比較を表2に示す。

表1を見ると、予測日至近データの追加学習における荷重値変化の許容範囲を大きくすることにより、1989年度の予測誤差が顕著に増大していることが分かる。

また、表2の予め学習する過年度データで見ると、1990年度の予測結果では、1989年のみを学習した場合よりも、1988年、1989年の2年分のデータを学習した場合の方が予測精度が高い。これは、年度による需要傾向のばらつきが、複数年度のデータを学習することによって平均化されたためであると考えられる。

5. おわりに

本論文では、気象変数と最大需要との関係抽出にニューラルネットワークを適用した。特徴としては制限付き2段学習法を用いており、最大誤差7%、平均誤差2%の予測精度を実現できた。電力需要予測へニューラルネットワークを適用する際に、季節を通しての全般的な入出力特性の抽出と、予測日至近の需要レベルおよび入出力特性の調整とを、2段階に分けて行う学習方法を検討した。この学習方法のもとにあるのは、気象変数との全般的な傾向が年度によって大きくは変わらないという電力需要の特徴である。新たなデータ

の学習による入出力特性の変化できる範囲を今回は気温感応度より概算したが、予測年度の需要傾向に関する知識、たとえば気象状況や景気の動向などを利用することができれば、さらにこの範囲を正確に見積もることが可能であろう。また、予測年度データの蓄積に伴って、過年度と予測年度の需要傾向の差を補正していくことも考えられる。これらについてはさらに需要の傾向を分析する必要がある。

本システムは95年11月30日より北陸電力株式会社中央給電指令所の自動給電システムの一機能として運用を開始している。

今後さらに予測精度の向上、特に誤差値の大きい事例の減少を図るためには、個々の誤差事例の要因を明らかにし、それらの影響を取り込むことが重要であろう。

終わりに、本論文を作成するにあたり貴重な資料の提供をいただいた、北陸電力(株)殿に感謝いたします。

参考文献

- [1] D. C. Park, M. A. El-Sharkawi, R. J. Marks, L. E. Atlas, and M. J. Damborg, "Electric Load Forecasting Using An Artificial Neural Network," *IEEE Trans. Power Systems*, Vol. 6, No. 2, May 1991.
- [2] 櫻井, 野尻, 横山, 関根, 「ニューラルネットワークを用いた翌日最大負荷予測」, 平成4年電気学会全国大会, No: 1008.
- [3] Y. Shimakura, Y. Fujisawa, Y. Maeda, R. Makino, Y. Kishi, M. Ono, J-Y. Fann, and N. Fukushima, "Short-Term Load Forecasting using an Artificial Neural Network," *IEEE. Application of Neural Networks to Power Systems (ANNPS'93)*, 93 TH0532-2.