翌日最大電力需要予測における最適なニューラルネットワーク構成の決定法

非会員 小野田 崇 (電力中研)
正員 大場 英二 (電力中研)

Selection of the Optimal Neural Network Architecture for Next Day Peak Load Forecasting

Takashi Onoda Non-member, Eiji Ohba, Member (CRIEPI)

In engineering fields, one of the most important applications of artificial neural networks is a non-linear parametric model that can approximate any continuous input-output relation. Especially, in next day peak load forecasting, the ability of approximation of artificial neural networks is very useful. However, an important but difficult problem exists in applying a neural network to next day peak load forecasting. This problem is to estimate the quality of approximation of a neural network. This quality depends on the architecture of the neural network applied, as well as on the complexity of the target relation. In other words, the problem is to determine the optimal number of parameters in the neural network.

This paper proposes a new method for the selection of the optimal neural network architecture for next day peak load forecasting. The proposed method is based on a new information criterion. This paper also applies the proposed method to next day peak load forecasting constructed by real data and shows the comparison of error estimation of some models for peak load forecasting.

キーワード：電力システム，需要予測，負荷予測，ニューラルネットワーク，情報量基準

1. はじめに

電力会社では、発電所で電力を生産し、送配電システムにより需要家に供給している。したがって、この電力システムは商品が電力の生産・流通システムである。しかし、他の生産・流通システムと際だって異なる特質をもっている。それは、商品である電力を貯蔵しておくことが極めて難しいということである。これは、電力が生産即消費で保存がきかないため、常に需要を満たすだけの供給力を確保しておかなければならないということを意味している。

需要家は、停電がなく、周波数および電圧に乱れの少ない、いわゆる高品質、高信頼性を有する電力の低コストでの供給を望んでいる。供給側である電力会社では、需要家が必要とする電力を適切な品質、信頼度、料金で供給できるように、長期的には発電所や送配電システム設備の建設計画を進めるとともに、短期的には既存の設備を、刻々変化する電力需要に追従させて適切かつ効率的に運用しなければならない。

このような設備開発計画や運用計画の立案の基となる最も重要で基礎的なデータは、電力需要の想定・予測値である。長期の設備開発計画には数年から数十年先の電力需要

想定値が必要となり、設備運用計画には数分程度から1年程度先までの電力需要予測値が必要となる。電力需要想定・予測は長期、短期を問わず、常に重要であるとともに、長期の予測・短期の予測で、それぞれ適用できる手法が当然違うものとなる。本論文では、さまざまな電力需要予測のなかで特に翌日最大電力需要の予測に焦点をあてる。

火力発電所などの設備は立上りに時間がかかるため、前日から準備しておく必要があり、そのため翌日の電力需要、特に最大電力需要を予測することが必要になる。最大電力需要の予測が過大、すなわち電源が余ってしまった場合は、火力発電所の出力低下による経済性低下をまねく。逆に予測が過小の場合は、揚水発電所稼働による経済性低下をもたらす、揚水発電の稼働による供給でも需要を満たせない場合は、停電を引き起こしかねない。したがって、翌日の最大電力を高い精度で予測することは、電力会社にとって極めて重要な課題となっている。

翌日最大電力需要予測には従来、回帰モデルを中心として研究がなされてきた⁽¹⁾。しかし、回帰モデルを中心とした研究では、気象条件と最大電力需要との非線形な関係を表現することが困難であったり、非線形関係を表現するた

めには、気象条件と最大電力需要との関係について熟知し、更に、回帰モデルについても熟知している必要がある。そのため、AICなどの統計尺度を利用して変数選択するなど、モデル作成労力の低減が研究されている。しかし、従来のAICなどの統計尺度を利用するためには、あらかじめモデルに制約を与えることとなり、その制約を満たすように人がモデルを考えなければならず、モデルの作成にコストがかかる。そこで、最近では、要求する処理に対して具体例を与えるだけで自動的にネットワーク内の結合荷重を変化させ、教えた信号に出力を調整する学習能力と、任意の非線形連続関数を任意の精度で近似できる能力をもつニューラルネットワーク⁽⁶⁾をこの翌日最大電力需要予測問題に適用し、上述のような課題を克服する研究が進められている⁽²⁾⁻⁽⁴⁾。その際、最大電力需要予測に適用されるニューラルネットワークの適切な構成をいかに選定するかが重要な課題となっている。この課題に対する研究としては、GAなどのヒューリスティックを用いる方法、クロスバリデーション手法やウェイトディケイ法などを用いる方法が提案されている。しかし、ヒューリスティックを用いる方法は、その方法の客観性の評価が困難であり、クロスバリデーション手法やウェイトディケイ法は計算コストがかかるという問題がある。

本論文では、ヒューリスティックや計算コストのかかるクロスバリデーション手法のような方法を用いず、作成されるモデルに対する制約の緩い統計尺度によって、観測された入出力のサンプルから、妥当な予測精度を保てる最適なニューラルネットワーク構成の選定方法を提案する。以下、第2章では翌日最大電力需要予測がどのような問題であるかを考察し、第3章で翌日最大電力予測において妥当な予測精度を保てる最適なニューラルネットワーク構成の選定方法を検討する。第4章では本論文で比較する三つの翌日最大電力需要予測モデルについて述べ、第5章で各々のモデルを用いた予測シミュレーション結果について報告する。第6章でまとめと今後の課題について述べる。

2. 翌日最大電力需要予測問題

電力会社の中央給電指令所では、火力発電所などの設備は立上りに時間がかかるため、当日午前中に翌日の最大電力需要を予測し、設備運用計画を作成しなければならない。このことは、最大電力需要予測問題が表1に示されているように、予測前日までの実績値と、予測を行う当日と予測される翌日との予報値に基づいて行われる予測問題であることを意味する。

翌日最大電力需要予測に図1に示す階層型ニューラルネットワークを適用することの有効性は、文献(2)～(4)などにおいて報告されている。しかし、ニューラルネットワークを用いる場合の問題の一つである、対象とする問題にニューラルネットワークを適用して近似したモデルの質をいかに測定するかについてはどの文献においても示されていない。この近似の質は、近似しようとする非線形で連続

表 1 翌日最大電力需要予測に利用できるデータ
Table 1. Input variables for forecasting next day peak load.

	翌日	当日	前日	...
最大電力需要	?	?	実績値	実績値
天気	予報値	予報値	実績値	実績値
平均気温	予報値	予報値	実績値	実績値
最高気温	予報値	予報値	実績値	実績値
最低気温	予報値	予報値	実績値	実績値
曜日	既知	既知	既知	既知

図中の?印はその値が未知であることを意味する。

図 1 階層型ニューラルネットワーク
Fig. 1. Multi-layered neural network.

な入出力関係の複雑さばかりでなく、適用するニューラルネットワークの構造にも依存する。この質の測定問題は、ニューラルネットワークの構造の観点からみると、ニューラルネットワークの最適なパラメータ数をどのように推定したらよいかという問題である。つまり、この問題は、入出力関係のサンプルだけから、非線形で連続な入出力関係を近似するのに必要なニューラルネットワークの中間ユニット数を推定するという問題に帰着する。

この問題の難しさは、パラメータの数を増加させれば学習データに対する出力誤差は減少するが、未学習のデータに対する誤差は増加するという点にある。一般にこのような現象は「過学習」と呼ばれる。例えば、次の二つのニューラルネットワークを考えてみる。一つは中間ユニット数10個のニューラルネットワーク、もう一つは中間ユニット数100個のニューラルネットワークを推定する。1,000個の学習データに対して十分な学習がすんだ後では、100個の中間ユニットを有する大きなニューラルネットワークのほうが、10個の中間ユニットを有する小さなネットワークより学習データに対する出力は良いものが得られる。しかし、未知のデータに対しては大きなニューラルネットワークのほうが小さなネットワークより良くない出力を導く。つまり、既知の入力データに対して精度の高い出力を生成しようとするのと、未知の入力データに対して精度の高い出力を予測することとの間にはトレードオフの関係が存在する(図2参照)。このような既知の入力データと未知の入力データ間の不均衡は、推定されるパラメータ数の増加とともに大きくなる。

特に、翌日最大電力需要予測の場合、予測日の気象要因と最大電力需要との関係が最も類似する予測日至近十数日のデータを用いて、ニューラルネットワークでモデルを構築する必要がある。そのため、学習データ数が少なく、上

図 2 中間ユニット数と未知および学習データに対する誤差の関係

Fig. 2. Relation between training and generalization error.

述の「過学習」を起こしやすい。そこで、少ない学習データに対して「過学習」していない最適なモデルをニューラルネットワークで構成する方法が必要となる。

推定されるニューラルネットワークのパラメータ数よりも、パラメータ推定に用いる学習データ数を明確に大きくできれば、「過学習」をそれほど考慮する必要がなくなる。そこで、「過学習」を避け、外挿予測に対処し、複雑な構造をモデルとして表現するため、翌日最大電力需要予測にニューラルネットワークを適用する際に、運去数年の実績データを利用して、学習データ数を増加させるという方法が従来採られている。例えば、文献(2)、(5)でもこの方法が採られている。

過去数年の実績データを、翌日最大電力需要予測を行うニューラルネットワークの学習データとして利用するためには、ニューラルネットワークへの入力情報が同じ場合に、過去の最大電力需要実績値と予測する年の最大電力実績値が一致するような過去の実績データを補正する必要がある。この補正方法は、文献(2)と文献(5)でも異なる方法が採られているように、さまざまな方法が考えられる。しかし、どのような方法を採用しても、予測する年の実績データがすべて既知ということはなく、過去の実績データを補正する際に必ず誤差を含むこととなる。そのため、外挿予測の際にも大きな誤差を含むこととなる。また、補正データを学習データとして構築されたニューラルネットワーク予測モデルが複雑であればあるほど、構築されたモデルに補正の際の誤差が強く反映されることとなる。

3. ニューラルネットワーク構成の最適化

過去数年の実績データを利用して、学習データ数を増加させることにより、「過学習」を避け、外挿予測にも対処する最適なニューラルネットワークを構築する方法では、過去の実績データを補正して学習データにする際に必ず誤差を含むこととなり、構築されたニューラルネットワーク予測モデルにもその誤差が反映されることとなってい

まう。

補正した学習データを作成することをせずに過学習を避け、最適なモデルを選定するためには、前章で述べた入力データと未知の入力データ間の不均衡と推定されるパラメータ数との関係を明確にする必要がある。統計的視点よりこの関係を明確にするアプローチとして、情報量基準がある。本章では翌日最大電力需要予測における、「過学習」を避けた最適なニューラルネットワーク構成の選定法となりえる情報量基準について検討する。

〈3・1〉 AIC 情報量基準と言え、回帰、重回帰モデルを作成する際のパラメータ数選定などに使われる以下の式で表現される AIC (Akaike's Information Criterion) が有名である⁽⁶⁾。

$$AIC = -2 \cdot (\text{max. likelihood}) + 2 \cdot m$$

ここで、 m : 推定されるパラメータ数

しかし、以下の理由により、ニューラルネットワークのパラメータ数設定に AIC を適用することは難しい。

ニューラルネットワークの場合、最適なパラメータと実際にニューラルネットワークの学習によって推定されるパラメータの間には、次の二つの揺らぎが存在する⁽⁶⁾。

(1) 統計的揺らぎ 最適パラメータ w_{opt} は、学習データが無限に与えられた場合に求められるパラメータである。実際には、有限個の学習データからある種の方法で最適パラメータの近似値である準最適パラメータを求めているにすぎない。このために起こる揺らぎ。準最適パラメータとは、有限個の学習データでの最適パラメータを意味する。

(2) 学習に伴う揺らぎ ニューラルネットワークの学習は一般に非線形連立方程式となるため、特殊な場合を除き解析的に解くことは困難である。そこで反復法を用いた近似計算によって準最適パラメータを求めることになる。しかし、一般に数値演算によって推定されたパラメータは初期値に依存し、必ずしも準最適パラメータと一致せず、推定されるパラメータは、準最適パラメータの周辺にばらつくことになる。このために起こる揺らぎ。

ニューラルネットワークの適切なパラメータ数を決定する情報量基準は、上記の二つの揺らぎを評価できる必要がある。

AIC では、モデルが faithful であるという条件の下で、統計的揺らぎを評価している。しかし、学習に伴う揺らぎを評価してはいない。また、ニューラルネットワークで翌日最大電力需要予測のモデルを構築する場合、モデルが faithful であるという条件を必ずしも満たしているわけではない。このため、AIC をニューラルネットワークの最適なパラメータ数選定に適用することは難しい。

ここで、モデルが faithful であるとは、真のシステムにおいて、任意の x が生成されたときに y が生成される条件付き確率を $q(x, y)$ とし、モデルが任意の x を入力として受けて、 y を生成する条件付き確率を $p(x, y; w)$ とするとき、以下の式を満たす w が少なくとも一つは存在す

ることを意味する。

$$q(x, y) = p(x, y; w)$$

〈3・2〉 IC(K, N) AICでは評価されていない学習に伴う揺らぎを、評価する情報量基準としてIC(K, N)がある⁽¹⁰⁾。IC(K, N)は次式で表現される。

$$\begin{aligned} \text{IC}(K, N) = & -\{l(w_N) - E_x[l(w_N)]\} - E_x[l(w_N)] \\ & + E_x[(r-1)l(w_l)] \\ & + E_x\left[l(w_l) - \frac{N}{N-l}l(w_l, N-l)\right] \end{aligned}$$

ここで、

$$r = \frac{\frac{N}{N-m}l(w_m, N-l) - \frac{N}{N-l}l(w_l, N-l)}{l(w_m) - l(w_l)}$$

である。 K は推定されるパラメータ数を表し、 $l(\cdot)$ は対数尤度を意味する。また、 w_N は N 個の学習データに基づき、求められた推定パラメータを表し、 $E_x[\cdot]$ は K 次元推定パラメータ w_N における分布での期待値を表す。 w_m は N 個の学習データから任意に m 個データを抽出して作られた学習データに基づき、求められた推定パラメータ、同様に w_l は N 個の学習データから任意に l 個データを抽出して作られた学習データに基づき、求められた推定パラメータである。

しかし、このIC(K, N)は統計的な揺らぎについて評価していない。また、IC(K, N)は以下の仮定の下に導出されており、この仮定を満たす学習データを観測することは難しい。

〔仮定〕 十分大きな学習データ N が与えられたとする。 N から l ($l \ll N$)を抽出して学習を行ったとき、これによって得られたパラメータ推定値の平均対数尤度は学習データ N から l を抜いた信号に対する前述で得られたパラメータ推定値での対数尤度の平均で十分よく近似できると期待できる。また、学習データ l より推定される推定パラメータと学習データ N より推定される推定パラメータとが互いに近傍に存在する。

〈3・3〉 NIC AICで必要とされるモデルがfaithfulであるという条件を必要としない情報量基準としてNICが提案されている⁽¹¹⁾。NICは次式で与えられる。

$$\text{NIC} = \langle S(q_N, w_N) \rangle + \frac{1}{N} \text{tr}(VH^{-1})$$

ここで、

$$S(q_N, w_N) = \frac{1}{N} \sum_{j=1}^N s(x_j, y_j; w_N)$$

$s(x_j, y_j; w_N)$ は推定パラメータ w_N でのニューラルネットワークのエネルギー関数であり、通常はニューラルネットワークの出力値と学習データの出力値との差の二乗を用いる。また、 $\langle \cdot \rangle$ は期待値を表し、 V と H は次の式で与えられる。

$$V = E_q[\nabla s(x, y; w_{\text{opt}}) \nabla s(x, y; w_{\text{opt}})^T]$$

$$H = E_q[\nabla \nabla s(x, y; w_{\text{opt}})]$$

ここで、 E_q ：分布 $q(x, y)$ に関する平均操作

$q(x, y)$ は、 x の生成確率 $q(x)$ と任意の x が生成され

たときに y が生成される条件付き確率 $q(y|x)$ を使用して以下のように表現される確率密度分布である。

$$q(x, y) = q(y|x)q(x)$$

このNICを適用するためには、AICの適用条件と同様に、準最適パラメータが常に求まる必要があり、学習に伴う揺らぎを評価することは難しい。

〈3・4〉 NNIC 文献(9)、(12)で著者が提案している情報量基準NNICは、統計的揺らぎと学習に伴う揺らぎの両方を考慮に入れ、モデルを評価する情報量基準である。このNNICの導出については、文献(9)および(12)に記述されているので、導出についての詳細は文献(9)、(12)を参照していただきたい。

そのNNICは次のように表現される。

$$\begin{aligned} \text{NNIC} = & S(q_N, w_N) + (t-1)S(q_N, w_N) \\ & + (1-t)\langle S(q_N, w_l) \rangle \\ & + \frac{1}{N} \text{tr}(V^*(w_N)H^{*-1}(w_N)) \end{aligned}$$

ここで、

$$t = \frac{\langle S(q_N, w_m) \rangle - \langle S(q_N, w_l) \rangle}{\langle S(q_m, w_m) \rangle - \langle S(q_m, w_l) \rangle}$$

また、 $\langle \cdot \rangle$ は期待値を表し、 $V^*(w_N)$ と $H^*(w_N)$ は次の式で与えられる。

$$V^*(w_N) = \frac{1}{N} \sum_{j=1}^N \nabla s(x_j, y_j; w_N) \nabla s(x_j, y_j; w_N)^T$$

$$H^*(w_N) = \frac{1}{N} \sum_{j=1}^N \nabla \nabla s(x_j, y_j; w_N)$$

∇ ：gradient

上式で表されるNNICは、その右辺第4項で統計的な揺らぎを評価し、右辺第2、3項で学習に伴う揺らぎを評価している。また、準最適パラメータを常に探索することができれば、NNICはNICに一致し、更に、モデルがfaithfulであれば、AICに一致することとなる。このNNICの値を最小にするニューラルネットワークのパラメータ数を選定すれば、学習データに基づく最適なニューラルネットワーク構成が得られる。

情報量基準AIC、NICは、統計的揺らぎを評価するために導かれた。また、IC(K, N)は学習に伴う揺らぎを評価するために提案された。これら三つの情報量基準は二つの揺らぎのうちの一つを評価しているが、二つを同時に評価していない。そのため、高い予測精度が必要とされる翌日最大電力需要予測を支援するニューラルネットワークの選定に、これらの情報量基準を適用することは難しい。一方、情報量基準NNICは、ニューラルネットワークによってモデルを構築する際の二つの揺らぎである、統計的揺らぎと学習に伴う揺らぎの両方を評価しており、ニューラルネットワークによって構築されるモデルを最も精度良く評価できる。高い予測精度が要求される翌日最大電力需要予測を支援するモデルをニューラルネットワークで構築するには、このNNICを適用した最適な予測モデルの決定が有効である。

4. 最適な予測モデルの構築

本章では、情報量基準 NNIC に基づくニューラルネットワークの最適化機構を組み込んだ、翌日最大電力需要予測モデルの構築法について述べる。

〈4・1〉 学習データ 学習データの項目選定のために最初に注意することは、第2章で述べたとおり、翌日最大電力需要予測がほとんど気象についての予報値を基に行われるため、予報値の予測精度が極端に悪いものは避けなければならないということである。例えば、夏季における湿度と最大電力需要との関係は相関が非常に高いが、湿度の予測誤差は平均10%以上と非常に大きいので、翌日最大電力需要の予測には利用しにくい。このようにして入力項目を絞り、絞られた項目と最大電力需要の変動との統計分析を基に以下のようなデータを学習データとして採用する⁽⁴⁾。

(1) 夏季の場合(6月末から9月末まで)、学習時には入力データとして、当日の平均気温、当日の最高気温、当日の最低気温の3種類を採用し、その値に実績値を使用する。また、予測時にはこれら気象データの予報値を採用する。

(2) 冬季の場合(11月から3月末まで)、学習時には入力データとして、前々日の最大電力需要、当日の天候、当日の平均気温、当日の最高気温と当日の最低気温の5種類を採用し、その値に実績値を採用する。また、予測時にはこれら気象データの予報値を採用する。

(3) 学習時の出力ユニットの教師データとしては、最大電力需要から特約分(産業用など大口需要家などに適用される特約分の電力需要。現在は、需給調整契約電力と言われる)を引き、休振りなど減電(企業グループなどの休業により減る電力需要)を加えた修正最大電力需要の実績値を採用する。

夏季と冬季についてのみ扱うのは、気象条件に対して最大電力の変動が大きく、予測誤差が大きくなる期間だからである。また、夏季と冬季の期間は最大電力需要と気象条件の相関、最大電力発生時、従来の運用上の慣習などを考慮して設定されている。修正最大電力需要を用いるのは、入力データとして入力層に入力されるデータが気象情報を中心としているので、気象条件に依存しない部分を削除するためである。

〈4・2〉 学 習 階層型ニューラルネットワークの学習には一般に誤差逆伝ば学習法が用いられる。しかし、この学習法は学習速度が遅い、極小解にとどまるなどの問題点がある。そこで、本研究ではニューラルネットワークの学習法として、一般的な誤差逆伝ば学習に、学習速度を速め、最小解への促進を図るための学習制御パラメータの最適化ルーチンを組み込んだ手法を採用した⁽⁷⁾。この学習制御パラメータの最適化ルーチンには、DSC 探索手法(Davis, Swann, Campey search method)を適用している⁽¹³⁾。

ニューラルネットワークの入力データには修正最大電力需要、平均気温など単位の違うデータを使用するため、実際の学習、予測の際には値が単位に依存しないように、上述した入力データの各値を $[-1, 1]$ 間に規格化したものを入力信号とした。また、学習データとしての出力値は、修正最大電力需要を同様に $[0, 1]$ 間に規格化したものを使用した。

学習データのニューラルネットワークへの提示、および予測は、夏季は10日分を1組として、冬季は15日分を1組として以下の手順を用いて行った。

(i) ニューラルネットワークの中間ユニット数を1に設定する。

(ii) ニューラルネットワークの結合荷重、しきい値を疑似乱数によって初期化する。

(iii) 予測日の至近10日(または、15日)分の学習データを学習させる。

(iv) 学習の停止条件を満足したら学習を止める。

(v) 学習終了時の結合荷重、収束値を用いて NNIC を算出する。

● 中間ユニット数が1の場合は、中間ユニット数を一つ増やして、(ii)へ。

(vi) 現在よりも中間ユニット数の少ない場合の NNIC の値と現在の NNIC の値を比較する。

● 現在よりも中間ユニット数の少ない場合の NNIC の値が現在の NNIC の値よりも大きい場合：現在の中間ユニット数を一つ増やして、(ii)へ。

● 現在よりも中間ユニット数の少ない場合の NNIC の値が現在の NNIC の値よりも小さい場合：現在の中間ユニット数より一つ少ないモデルを採用する。

(vii) 採用した予測モデルで予測を行う。

(viii) 予測対象日の最大電力需要を確認の後、以下の手順で学習データを更新する。

● 10日(または、15日)分の学習データよりいちばん古いものを削除し、実績値となった予測対象日の気象条件、最大電力需要を学習データとして加え、新たな10日(または、15日)分の学習データを作成する。

(ix) 夏季(または、冬季)期間が終了したら、学習、予測を終了、期間が残っている場合は、(i)へ。

上述のように10日(または15日)単位で学習を行ったのは、ニューラルネットワークにできるだけ至近の最大電力需要の変動を学習させるためと、この期間の気象条件と最大電力需要の相関が類似しているためである。

また、(v)で NNIC の計算を行うため、 N は10(または15)に、 m は9(または14)に、 l は8(または13)に設定した。学習の停止条件は、学習回数50,000に設定した。

5. 予測シミュレーション

実際に最大電力需要を予測する際に利用可能な情報のみを適用して予測シミュレーションを行い、出力された予測

表 2 夏季における各モデルの予測誤差
Table 2. Error estimation of forecasting in summer period.

年度	評価誤差	重回帰モデル	固定化した N.N.	最適化した N.N.
1988 年度	RMSE(MW)	668.4	519.2	507.0
	MAPE(%)	3.27	2.50	2.33
1989 年度	RMSE(MW)	665.7	605.5	564.4
	MAPE(%)	2.90	2.56	2.41

表 3 冬季における各モデルの予測誤差
Table 3. Error estimation of forecasting in winter period.

年度	評価誤差	重回帰モデル	固定化した N.N.	最適化した N.N.
1988 年度	RMSE(MW)	298.8	298.9	278.0
	MAPE(%)	1.58	1.59	1.48
1989 年度	RMSE(MW)	372.4	351.5	344.0
	MAPE(%)	1.90	1.80	1.72

図 3 1988 年度最大電力実績値と予測値
Fig. 3. Actual peak load and predicted peak load in 1988.

値と最大電力需要の実績値とを比較した結果を示す。データは、ある電力会社の 1988 年度および 1989 年度の実績データを用いた。シミュレーションは、夏季について 1988 年、1989 年の 2 ケース、冬季について 1988 年、1989 年の 2 ケースの計 4 ケースについて行った。本シミュレーションでの予測対象日は平日のみであり、学習時には、土、日曜日、お盆などの休日を除いたデータを用い、予測時には、気象データとして予報値を採用した。また、予測誤差の評価には、平均二乗誤差の平方根 (RMSE) と平均絶対パーセント誤差 (MAPE) を用いた。

ニューラルネットワーク構成を最適化することによって、未知データに対しても妥当な予測誤差で予測が可能であることを示すため、以下に示す三つの予測モデルの予測結果を比較した。

- (1) 重回帰分析に基づく予測モデル⁽¹⁾。
- (2) 中間ユニット数を夏季、冬季の期間中、実験的に予測誤差の小さくなるものに固定したニューラルネットワークに基づく予測モデル。夏季の場合は、中間ユニット数を 3 個とし、冬季の場合は 4 個とした。
- (3) 前章で述べたニューラルネットワーク構成の最適化を図った予測モデル。

表 2 に各モデルを用いた夏季の予測シミュレーション結果を、表 3 に冬季の予測シミュレーション結果を示す。また、1988 年度夏季の最大電力需要実績値と中間ユニット数を最適化したニューラルネットワークによる予測値、重回帰モデルによる予測値のグラフを図 3 に示し、1989 年度冬季の実績値と予測値を図 4 に示す。

夏季の場合、表 2 により、各モデルの予測結果を比較すると、ニューラルネットワークを用いた予測の MAPE が重回帰モデルを用いた場合より小さく、実績値に近い結果が得られていることが分かる。更に、ニューラルネットワークを用いた予測の RMSE が重回帰モデルを用いた場合よりも小さく、実績値に対する予測値の誤差分散がニューラルネットワークを用いた場合のほうが小さいことが分かる。また、中間ユニット数を NNIC によって最適化したニューラルネットワークの MAPE は、重回帰モデルの MAPE の値よりも約 1% 小さく、中間ユニット数を実験的に決めたニューラルネットワークよりも小さい値を示している。これは、最も予測誤差が小さい最適モデルが決定されていることを示している。RMSE についても、中間ユニット数を最適化したニューラルネットワークの値が他の二つのモデルによる値よりも小さく、最も予測誤差分

図 4 1989 年度最大電力実績値と予測値
Fig. 4. Actual peak load and predicted peak load in 1988.

散の小さいモデルとなっていることが分かる。

図 3 より中間ユニット数を最適化したニューラルネットワークを用いた予測が夏季の最大電力需要の大きな変動に十分に対応していることが分かる。

冬季の場合、表 3 より、中間ユニット数を固定したニューラルネットワークを用いた予測で、重回帰モデルによる予測と同等以上の結果が得られていることが分かる。ただし、1988 年度冬季の予測結果のように、重回帰モデルによる予測結果の MAPA と RMSE のほうが中間ユニット数を固定したニューラルネットワークを用いた予測結果より、やや良いという部分もある。表 3 の中の中間ユニット数を最適化したニューラルネットワークを用いた予測による MAPE は、重回帰モデルによる予測結果および中間ユニット数を固定したニューラルネットワークの予測結果より、小さい値が得られている。このことは、NNIC によって選定されたニューラルネットワークが、最も実績値に近い予測を行っていることを示している。

また、図 4 より冬季の場合についても、中間ユニット数を最適化したニューラルネットワークを用いた予測のほうが重回帰モデルを適用した予測よりも、最大電力需要の変動を十分に追従していることが分かる。

最適なニューラルネットワーク構成となる中間ユニット数は、学習データによって、1988 年度夏季については 2 個から 6 個まで変化し、1989 年度夏季については 2 個から 5 個まで、1988 年度冬季については 2 個から 5 個まで、1989 年度冬季については 2 個から 8 個まで変化した。中間ユニット数の変化は、モデルの構造的変化が必要とされる場合に起こっていた。この構造変化とは、夏季の場合、6 月下旬から 8 月初旬までは最大電力が増加する傾向があり、8 月初旬から 9 月末までは減少する傾向が現れるが、この増減傾向の変化のような状況をさす。

以上の予測シミュレーション結果より、NNIC に基づき、翌日最大電力需要予測のためのニューラルネットワ

ーク構成を選定すれば、予測精度の高いニューラルネットワークモデルが構築できることが分かる。

6. ま と め

本論文では、翌日最大電力需要予測における最適なニューラルネットワーク構成を情報量基準 NNIC に基づき決定する方法を提案した。また、提案した方法により、最適なニューラルネットワークの構成を選定することにより、重回帰モデルおよび実験的に構成を決めたニューラルネットワークより平均的に実績値に近い安定した予測ができることを示した。本論文で提案した方法は、予測分野ばかりでなく、ニューラルネットワークによって連続関数近似を行う問題には、一般的に有効である。本手法によれば、翌日最大電力需要予測は平均的な予測精度で 2% 以下の水準に達している。今後は、予測に用いる予報値の精度と予測モデルの精度とのバランスについて検討する必要がある。

最後に、本研究を進めるにあたり、貴重なコメントをして下さった(財)電力中央研究所 上之蘭専務理事に深謝いたします。

(平成 9 年 7 月 18 日受付, 同 9 年 12 月 17 日再受付)

文 献

- (1) 小野賢治・所 健一:「「通年モデル」による翌日最大電力予測」, 電中研報告(依頼報告), Y90502 (平 2)
- (2) 植木芳照・松井哲郎・遠藤 弘・加藤龍義・荒家良作:「ニューロ・ファジー応用最大電力予測システムの開発」, 電学論 B, 115, No. 9 (平 7-9)
- (3) 石田隆張・田村 滋:「ニューラルネットワークを用いた翌日電力需要予測」, 同上 B, 114, No. 11 (平 6-11)
- (4) T. Onoda: "Next Day Peak Load Forecasting based on an Artificial Neural Network", Proc. IJCNN '93, Vol. 1.2, 2029-2032 (1993)
- (5) 川合 桂・小野雅也:「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」, オペレーションズ・リサーチ, 41, No. 9, 481~486 (平 8)
- (6) 船橋賢一:「ニューラルネットワークの capability について」, 通信学会技報, MBE 88, No. 52, 127~134 (昭 63)
- (7) T. Onoda: "Next day peak load forecasting using an

- artificial neural network with modified back propagation learning algorithm", Proc. ICNN '94, 3766~3769 (1994)
- (8) 坂元慶行・石黒真木夫・北川源四郎: 情報量統計学 (昭58) 共立出版
 - (9) T. Onoda: "Neural network information criterion for the optimal number of hidden units", Proc. ICNN'95 (1995)
 - (10) 和田安弘・川人光男: 「新しい情報量基準と cross validation による汎化能力の推定」, 信学誌 D-II, **J74-D-II**, 955~965 (平3-7)
 - (11) N. Murata, S. Yoshizawa & S. Amari: "Network information criterion—determining the number of hidden units for an artificial neural network model—", *IEEE Trans. Neural Networks*, 5, No. 6, 865~872 (1994)
 - (12) 小野田崇: 「階層型ニューラルネットワークの情報量基準」, 人工知能学誌, **11**, No. 4, 574~584 (平8)
 - (13) L・C・W・ディクソン: 非線形最適化計算法 (昭49) 培風館

小野田 崇 (非会員) 1986年3月国際基督教大学教養学部理学科卒業。1988年3月東京工業大学大学院理工学研究科原子核工学専攻修士課程修了。1988年4月(財)電力中央研究所入所。主として、ニューラルネットワークの学習理論およびその信頼性に関する研究に従事。1996年度人工知能学会論文賞受賞。人工知能学会会員。

大場 英二 (正員) 1987年3月東北大学大学院工学研究科電気および通信工学専攻修士課程修了。1987年4月(財)電力中央研究所入所。主として、通信網の信頼性評価, 知識工学の適用などの研究に従事。電子情報通信学会会員。