

翌日最大電力予測の2つのアプローチ

小野 賢治, 小野田 崇

1. はじめに

電気は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。火力発電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、特に最大電力需要量を予測することが必要になる。

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。逆に予測が過少の場合は揚水発電所稼働による経済性低下をもたらす、さらに不足した場合は大事故の発生にもつながりかねない。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、電力会社にとってきわめて重要な課題となっている。

翌日最大電力を予測する伝統的な方法としては、曜日や気象条件が対象日と類似した至近の過去の日を選び出し、それらの日の最大電力実績と予測対象日の気象予測をもとに、予測担当者が経験と勘で予測値を推定するというものが主流である。しかし、近年の電気冷暖房機器の普及による気温感応負荷の増加や予測業務の自動化の要請により、客観的で精度の高い予測手法の開発が求められるようになってきており、統計モデルを中心として種々のアプローチによる数多くの研究がなされている。

本稿では、当所において行なっている翌日最大電力予測に関する2つのアプローチによる研究について紹介する。1つは統計モデルによるもの、もう1つはニューラルネットワークを用いたものである。

2. 気象変量と時間変量にもとづく統計モデル[2]

2.1 日最大電力の変動の特徴

図1はある電力会社(X社とする)の年間の日最大電力の推移を示したものである。日最大電力の変動には以




図1 日最大電力の推移(X社, 平成元年度)

下のような特徴がみられる。

- (1) 直線的な傾向変動(トレンド)
これは景気等の経済的要因によるところが大きい。
- (2) 季節変動
夏・冬に高く、春・秋に低い。これは冷暖房需要の影響である。
- (3) 週周期の変動
土曜、日曜には最大電力が落ち込む。祭日も同様である。これは工場等の休業によるところが大きい。
- (4) 特殊期間
ゴールデンウィーク、盆期間、年末年始には平日でも最大電力が落ち込む。これも工場等の休業が主要因である。

気象は電力需要に大きな影響をおよぼす[1]。図2は、平日(土曜、日曜、祭日、特殊期間以外の日)について、日最大電力と日平均気温との関連を示したものである。両者の間には非常に強い関連があることがわかる。

気温以外では、夏季において湿度が、夏季以外において天候が、それぞれ日最大電力に影響する。湿度の影響は蒸し暑さによる冷房需要の増加であり、天候の影響は曇天や雨天の時は照明の需要が増加することと、温室効果(冬季に晴れると建物の中は暖まり暖房需要が減る)によるものと考えられる。

2.2 モデル構築の基本方針

前章における日最大電力の変動の特徴を踏まえて、ここでは以下の方針により、日最大電力の時系列的変動を

おの けんじ, おのだ たかし (財)電力中央研究所
〒100 千代田区大手町1-6-1




図 2 日最大電力と日平均気温との関連 (X社, 平成元年度, 平日)

説明する回帰モデルを構築した。

- (1) 平日のみを分析の対象とした。この理由は、土曜、日曜、祭日、特殊期間の負荷の減少量にはある程度の規則的なパターンはあるもののそのパターンは非常に複雑であり、各パターンに該当する日数が少ないため統計的な推定が難しいためである。また、実際の予測においてもこれらの特殊日の最大電力の予測は平日ほどの精度は必要としない場合が多い。
- (2) 日最大電力の変動を、年間を通して1つのモデルで説明することとした。季節毎に別々のモデルを構築した方が各季節の特徴を反映できるため正確な予測が行なえるとも考えられるが、季節の変わり目の時期にどちらのモデルを用いるかという点が問題となる。
- (3) 説明変数として過去の日最大電力を用いる自己回帰型のモデルではなく、時間変数と気象変数のみで日最大電力の変動を説明することとした。これは、ここで扱っている翌日の最大電力の予測作業を当日の午前中に行なうことを前提としているため、1時点前の値が利用できないので、自己回帰型のモデルは不適切と考えられるからである。

2.3 モデルの構造と特徴

上記の基本方針のもとに、以下のような回帰モデルを構築した。このモデルは試行錯誤的な変数選択の結果得られたものである。

$$\begin{aligned}
 y_t = & a_1 + a_2 t + a_3 \max(x_{t-16}, 0) \\
 & + a_4 \max(x_{t-21}, 0) + a_5 \min(x_{t-16}, 0) \\
 & + a_6 \max(\bar{x}_{t-16}, 0) + a_7 \min(\bar{x}_{t-16}, 0) \\
 & + a_8 x_t^* + a_9 w_t \\
 & + a_{10} \min(\bar{x}_t - \bar{x}_{t-105}, 0) + e_t
 \end{aligned}$$

t : 分析対象の第1日目を1とする経過日数
(サンプル番号とは異なる)

y_t : t 日の最大電力

x_t : t 日の平均気温

(ここでは(最高気温+最低気温)/2)

\bar{x}_t : $t-10$ から $t-2$ までの日の平均気温の移動平均

x_t^* : t 日の最高気温と最低気温の差

w_t : t 日の最大電力発生時の天候に関する変数

$x_t \geq 19$ または晴れるとき0, $x_t < 19$ でかつ薄曇りのとき1, $x_t < 19$ でかつ曇りのとき2, $x_t < 19$ でかつ雨・雪のとき4の値をとる。

e_t : 誤差項

このモデルの特徴は以下のとおりである。

- (1) 説明変数として過去の負荷を用いず、時間変数と気象変数のみで最大電力を説明している。
- (2) 当日の気温だけでなく、移動平均により至近の過去の気温の影響も考慮している。
- (3) 冷房と暖房の気温感応を別々のパラメータで表わしさらに夏季において高気温帯で感応度が高くなる折れ線モデル [1] の構造を取り入れている。
- (4) 至近時点と直前の季節(ここでは105日前)との気温レベルの差によって、負荷の気温感応の時期による違いを考慮している。
- (5) 気温の他に天候の影響(夏季以外)を取り入れている。なお、パラメータ数をなるべく減らすため天候変数を1つに集約した。

2.4 予測シミュレーション

上記のモデルを用い、現場(中央給電指令所)で実際に予測作業を行なう時点で利用可能な情報のみを用いるという前提で予測値を計算するシミュレーションを行なった。モデルのパラメータ推定のためのデータ数は270とし、パラメータ推定は毎日更新することとした。

平均絶対パーセント誤差(MAPE)と、予測誤差に占める気象予測誤差の割合(気象予測に誤差がなかったとした場合に最大電力の予測誤差が何%減少するか)は表1のとおりである。本研究では過去の最大電力を説明変数として用いるモデルについても種々検討したが、この統計モデルはそれらと比較して精度的にも高い水準にあり、しかも最大電力に欠測データがある場合にも合理的に予測が行なえる。表1の右列より、モデルの改善と同時に、特に夏季については気象予測の精度向上が重要な課題であることがわかる。

2.5 応用と課題

この統計モデルは翌日最大電力の予測用に構築したが、短期の予測だけでなく、構造分析、長期(数か月先まで)の予測、欠測値の補間にも応用できる。

表 1 予測誤差とその中に占める気象予報誤差の割合

期間	予測誤差 (MAPE)	気象誤差の割合
昭和62年度夏季	3.20	45.3
昭和63年度夏季	3.00	49.7
昭和63年度冬季	1.60	15.3
平成元年度夏季	2.83	37.1
平成元年度冬季	1.87	29.4
平成2年度夏季	3.04	37.2

この統計モデルによる予測精度を実際の現場（中央給電指令所）の予測精度と比較すると、表1の各行のケースについて、%誤差の差が上から順に0.64, -0.15, 0.21, 0.23, 0.08, 0.34となっており、モデルによる誤差の方が全般に大きい。しかし、現場では経験則を利用している等、統計モデルとでは予測の際に利用する情報がかかなり異なっており、単純な比較はできない。

今後予測精度の向上を図るためには、社会的イベントや経験則等、モデルでは扱えない要因をいかにとりこむかが課題である。また、統計モデルによる予測は現場に比べて「大はずれ」しやすい傾向があり、この点の克服も課題である。

3. ニューラルネットワークを適用する目的

現在、翌日の最大電力を予測する方法としては、前述のように、比較的単純なモデルの構造をあらかじめ定め、その構造係数（パラメータ値）を統計的手法や経験的ノウハウにより効率的に推定していくものが大部分である。

このようにして推定されたモデルによる予測結果と実際の値との差が大きい場合は、あらかじめ定めたモデルの構造が不適切である場合が多い。適切にモデルの構造を定めるには、データの十分な分析や経験により対象とする問題についての深い洞察が不可欠であり容易ではない。

もう1つのアプローチとして、表現力の高いモデルの構造を仮定し、与えられたデータを良く説明できる構造係数を自動的に求める、経験的ノウハウを必要としない手法がある。その1つとして、ニューラルネットワークを用いた、最大電力予測を検討した。




図 3 ニューロンモデル

4. ニューラルネットワークを用いた最大電力予測

4.1 最大電力予測に用いるニューラルネット

脳の神経細胞（ニューロン）をモデル化すると図3のようになる。他のユニットから入力を受ける部分には、結合荷重 w をつける。この荷重がユニット間の結合の種類や強さを決めることになる。この荷重の値が変わることにより出力の値が変わる。この荷重 w の値を適切に変えることが学習である。ユニット j には以下に示す内部ポテンシャル r_j が蓄積される。

$$r_j = \sum_{i=1}^{n_i} (W_{ji} \cdot x_i) - \theta_j$$

W_{ij} : i ユニットと j ユニット間の結合荷重

θ_j : j ユニットのしきい値

n_i : ユニットに入力される入力信号数

ユニットの出力 y_j は、

$$y_j = f(r_j) = 1 / \{1 + \exp(-r_j/T)\}$$

T : sigmoid 関数の形状パラメータ

このようなユニットを用いて図4のような階層型のニューラルネットワークを構成し、定式化を行なった[6][7]。

図4のような3階層のニューラルネットワークを用いてユニット数などを適切に構成すれば、任意の連続写像を近似できる（表現力が高い）ことが証明されている[3][4]。




図 4 階層型ニューラルネットワーク

ニューラルネットワークは、入力信号を受け取ると入力層、中間層、出力層と信号が伝わり、最終的に出力信号を出力する。最終的に出力される出力信号と教師信号との間に誤差が生じるが、この誤差を減らすために各層間の結合荷重、および、各ユニットのしきい値が修正される。この修正過程が、出力層から中間層へ、中間層から入力層へと最急降下法により進められることから、誤差逆伝播学習と呼ばれている[6][7]。

以下に、この学習過程を示す。まず、学習データ p に関して出力層における教師信号と出力信号との2乗誤差関数 E_p を定義する。

$$E_p = \sum_{k=1}^{n_k} (T_{pk} - O_{pk})^2 / 2$$

n_k : 出力層のユニット数

T_{pk} : 学習データ p に関する k ユニットの教師信号

O_{pk} : 学習データ p に関する k ユニットの出力信号

$$O_{pk} = f(q_k)$$

$$q_k = \sum_{j=1}^{n_j} (v_{kj} \cdot y_j) - \eta_k$$

q_k : k ユニットの内部ポテンシャル

n_j : 中間層のユニット数

V_{kj} : j ユニットと k ユニット間の結合荷重

η_k : k ユニットのしきい値

この E_p を最急降下法を用いて極小化する。最急降下法にもとづいて任意の状態から2乗誤差関数 E_p の極小値に到達させるには、学習データ p が入力された時、結合荷重 V_{kj} を ΔV_{kj} だけ修正すればよい。

$$\Delta V_{kj} = -\alpha \partial E_p / \partial V_{kj} = -\alpha (T_{pk} - O_{pk}) f'(q_k) y_j$$

α : 学習制御パラメータ ($\alpha > 0$)

f' : 応答関数 f の1階微分

同様に、以下のしきい値 η_k の修正量 $\Delta \eta_k$ も得ることができる。

$$\Delta \eta_k = \beta \cdot (T_{pk} - O_{pk}) \cdot f'(q_k)$$

β : 学習制御パラメータ ($\beta > 0$)

さらに、出力層と中間層の結合荷重、出力層のしきい値だけでなく、中間層と入力層の結合荷重、中間層のしきい値についても同様の修正が行なえる。

また、学習速度を速めるために学習制御パラメータの最適化として DSC search (Davis, Swann, Campey search method) を誤差逆伝播法に組み込んだ[8]。

以上の修正過程を全学習データに対して繰り返すことにより2乗誤差の総和 E の極小化 (理想的には最小化) が図られることになる。

表2 入力信号・教師信号のデータ項目

入力信号に利用した項目	入力信号としての扱い方
最大電力	($t-2$)日から t 日への最大電力増減
天候	t 日の天候(晴, 薄曇り, 曇り, 雨・雪)
気温	($t-1$)日から t 日への平均気温の増減, t 日の平均気温.
不快指数	($t-1$)日から t 日への不快指数の増減, t 日の不快指数.
大口需要家の操業計画	t 日の大口需要家の操業計画.

t : 予測該当日.

注: t 日に既知の値がない場合、予報値を使用する。最大電力に関しては、 t 日の値は教師信号。

$$E = \sum_{p=1}^{n_p} E_p$$

n_p : 学習データの総数

4.2 データ形式と写像形成

負荷需要予測にニューラルネットワークを適用する際には、0/1のビットパターンを用いた方が、負荷需要の状態(低い・普通・高い)を識別するには良いとの報告がある[5]が、最大電力予測の場合、翌日の最大電力が高い・普通・低い予測でなく、翌日の最大電力の値がどれくらいになるかが問題となるので、本研究の最大電力予測には、入力信号を[0,1]の実数とする方式を採用した。

実際に入力として入力層の各ユニットに与えたデータ項目と教師信号として与えたデータ項目を表2に示す。

表2に示した7つのデータを予測日に最も近い3日分を入力データとして採用することとし、入力層のユニット数は21ユニットとした。また、中間層はケーススタディの結果から11ユニットとし、出力層は1ユニットとした。

4.3 予測シミュレーション

ある年の5月中旬~9月初旬のシミュレーション結果の場合を見ると、統計的手法を用いたモデル推定による予測誤差は約3.3%であり、ニューラルネットワークを用いた場合は約3.4%であった。なお、予測誤差の評価基準としては、平均絶対値パーセント誤差を用いた。

4.4 今後の課題

ニューラルネットワークを用いてある程度高精度な予測を行なえることが確認された。

今後予測精度をさらに向上させるためには、最大電力に影響力を有する要因をいかにうまく入力信号とできるかが課題である。また、ニューラルネットワークの学習

速度の向上, 最適な中間層数の決定法と作成した画像の信頼性評価・検証なども課題である。

5. おわりに

翌日最大電力の予測問題は, ここまでで充分というような水準はなく, より精度が高く客観的な予測手法が常に求められる。したがって, 今後も種々のアプローチによる活発な研究が行なわれることが望まれる。

参考文献

- [1] 小野賢治: 気象と電力需要. オペレーションズ・リサーチ, Vol.34, No.6(1989), 252-256.
- [2] 小野賢治, 今泉 忠, 渡辺則生: 気象変量と時間変量に基づく最大電力予測モデル, 1992年度OR学会春季研究発表会予稿集, 204-205.
- [3] 船橋賢一: ニューラル・ネットワークによる連続画像の近似的実現について, 電子情報通信学会技術研究報告, MB E88-52, 1988.7
- [4] 船橋賢一: 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研究報告, MB E88-52, 1988.7
- [5] 松川文彦, 豊田淳一: ニューラル・ネットを用いた負荷予測, 電気学会電力技術研究資料, PE-88-37, 1988
- [6] Rumelhalt, D.E., McClelland, J.L. and the PDP Research Group: Parallel Distributed Processing-Volume 1: Foundations, pp.318-362, MIT Press, 1986
- [7] Rumelhalt, D.E., Hinton, G.E. and Williams, R. J.: Learning Representations by Back-Propagating Errors, Nature, Vol.323, No.9, pp.533-536, 1986.9
- [8] 高木英行, 阪上茂生, 戸川隼人: 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, 電子情報学会論文誌, D-II, Vol.J74-D-II, No.4, pp.528-535, 1991.4

最新刊

ゲームと競技の数学

J.D. ピースリー著/中村義作訳 定価2266円
様々なゲームや競技の構造・戦略等について, その数学的な解析を試みた書。

主要目次 手札の運, 不運 ミスを犯すのが人間 実力, 段位, 環境 相手の裏をかく作戦 パズルの解析 勝利に導く確実な手順 ゲームを測る尺度 難解なゲームの考察他

グラフ理論入門

Pearls in Graph Theory

ハーツフィールド他著/鈴木晋一訳 定価2575円
数学のみならず多方面に応用されつつある数学を易しく解説。図形についての話題も豊富で, グラフの幾何学的な面白さも味わえる。

主要目次 グラフ理論の基礎 グラフの彩色 回路とサイクル 極値回路 数え上げ他

コンピュータサイエンスのための離散数学

守屋悦朗著 A5・定価2472円
理論的コンピュータサイエンスの各分野で必要な離散数学の中からとくに基礎的な事項を解説。
主要目次 集合と写像 関係 数学的帰納法と再帰的定義 グラフ 数理論理学とブール代数 順列と組合せ

新時代のコンピュータ総合誌

隔月刊

Computer Today

9月号/発売中/定価930円

lexと yacc

月刊誌

数理科学

9月号/発売中/定価980円

宇宙のパースペクティブ

定価は税込みです。

サイエンス社

東京都千代田区神田須田町2-4 安部徳ビル
☎03(3256)1093 振替 東京7-2387