

# ニューラルネットワークと GA を用いた種子島の翌日電力需要予測

高田 等\*・園田 克治\*\*・八野 知博\*

## Daily Electric Load Forecasting Using ANN and GA in Tanegashima

Hitoshi TAKATA, Katsuzi SONODA and Tomohiro HACHINO

In electric power systems, it is necessary to forecast the following day's load curve accurately for stable services.

We report on simulation results of this forecasting for the Tanegashima power system based on an artificial neural network, the initial values of which are estimated by GA.

### 1. まえがき

電力系統は、貯蔵機能が乏しいため、生産と消費を同時に行わなければならない。そこで、常に需要を満たすための供給力を適正に確保する必要がある。特に十分な供給力を確保するためには、翌日の需要量を的確に予測することが重要である。一般に、電力需要量とそれに影響を及ぼす要因には非線形的な関係があり、また経済性及び信頼性を向上させるためには、高精度な需要予測が必要である。従来の線形回帰分析を用いた手法では、非線形性の適切なモデル化に限界がある。そこで、筆者らは3階層型ニューラルネットワークに着目した。ニューラルネットワークは、過去のデータを学習させることにより、自動的に非線形な関係を求める能力がある。また、天気などのような不連続性の影響要因を取り入れることも可能であるなどの特長がある。しかし、ニューラルネットワークは、初期値によって局所解に陥りやすいという欠点もある。

そこで本稿では、遺伝的アルゴリズム (GA)<sup>1)</sup> による初期値設定を伴う3階層型ニューラルネットワークを用いた翌日電力需要予測について考察した。その際、曜日分けと、電力量、天候、及び気温の入力を用いた。種子島電力系統に対して計算機シミュレーション実験による電力需要予測を行い、本手法の有効性を確かめた。

平成10年5月31日受理

\*電気電子工学科

\*\*博士前期課程電気電子工学専攻

### 2. 翌日電力需要予測

#### 2.1 ニューラルネットワークモデルの構築

一般に電力需要に影響を及ぼす要因にはさまざまなものがあり、それら全ての影響要因を入力変数に選べば必然的にネットワークは膨大となり、実用上好ましくない。さて、需要に影響を及ぼす要因には図1のような曜日ごとのパターンの特徴がある。そこで、少ない学習データ




図1 曜日毎の電力需要傾向

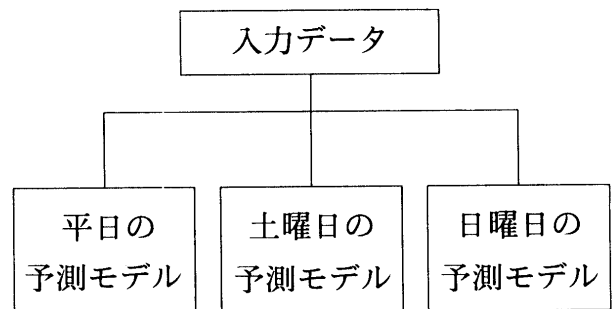


図2 曜日別分割モデル

から有効な予測を得るため、図2のように平日、土曜日、日曜日ごとにパターン分けしたモデルを構築した<sup>2)</sup>。ここで用いるネットワークは中間層を1層含む3階層型ニューラルネットワークとした。学習方法は、誤差逆伝播法 (BP) を用いる。ネットワークの入出力関係は、次式によって与えられる。

$$o_{lj}^k = f \left( \sum_{i=1}^{N_{k-1}+1} w_{i,j}^{k-1,k} o_{li}^{k-1} \right) \quad (1)$$

$$f(x) = \frac{1}{1 + \exp(-\varepsilon x)} \quad (2)$$

ここで  $o_{lj}^k$  はパターン  $P$  のときの第  $k$  層のユニット  $j$  の出力値、 $w_{i,j}^{k-1,k}$  は第  $k-1$  層の  $i$  番目と第  $k$  層の  $j$  番目のユニットとの結合係数、 $N_k$  は第  $k$  層のユニット数、 $\varepsilon > 0$  はシグモイド関数  $f(\cdot)$  の傾きである。

BP学習法では、学習の評価関数として、教師信号と出力層の2乗誤差  $E_q$  を選ぶ。本評価関数を最小にする結合係数の修正量  $\Delta p w_{i,j}^{k-1,k}(m)$  は、次式で計算される。

$$\begin{aligned} \Delta p w_{i,j}^{k-1,k}(m) &= \eta \delta_{lj}^k o_{li}^{k-1} \\ &\quad + \alpha \Delta p w_{i,j}^{k-1,k}(m-1) \end{aligned} \quad (3)$$

$(k=1, 2, 3)$

$$\delta_{lj}^3 = \varepsilon (t_{lj} - o_{lj}^3) o_{lj}^3 (1 - o_{lj}^3) \quad (4)$$

$$\begin{aligned} \delta_{lj}^k &= \varepsilon o_{lj}^3 (1 - o_{lj}^3) \cdot \\ &\quad \sum_{s=1}^{N_{k+1}} (\delta_{ls}^{k+1} w_{j,s}^{k,k+1} (m-1)) \end{aligned} \quad (5)$$

$(k=1, 2)$

ここで  $t_{lj}$  はパターン  $P$  のときの出力層の  $j$  番目ユニットの教師信号、 $\Delta p w_{i,j}^{k-1,k}$  はパターン  $P$  のときの結合係数  $w_{i,j}^{k-1,k}$  の修正量、 $\eta$  は学習係数、 $\alpha$  は慣性項係数、 $m$  は学習回数である。

## 2.2 初期値決定

BP学習法などのニューラルネットワークは一般に結合係数の初期値の値に依存し、局所解に収束しやすい。そこで本稿では、大域的探索能力に優れている  $GA$  を用いて、結合係数の初期値を決定する方法<sup>3)</sup>を考えた。これより、ニューラルネットワークの近似的大局解への収束を可能にした。以下に  $GA$  の一般的手法を示す。

**Step 1:** 初期候補集団発生

ランダムに  $Q$  個の個体を生成して初期集団  $P(0)$  を作り、世代  $g=0$  とする。

**Step 2:** デコード化

各個体を遺伝子型から表現型にデコード化する。ここで、各変数  $w_i (i=1, \dots, n)$  の部分に対応する  $L_i (i=$

$1, \dots, n)$  ビットの二進表現文字列  $W_i (i=1, \dots, n)$  から十進表現に変換した値を  $\chi_i (i=1, \dots, n)$  とすると、

$$w_i = \frac{w_{max,i} - w_{min,i}}{2^{L_i} - 1} \chi_i + w_{min,i} \quad (6)$$

によってデコード化される。ただし、各変数  $w_i$  の探索範囲を  $[w_{max,i}, w_{min,i}]$  とする。

**Step 3:** 適応度計算

個体集団  $P(g)$  内の各個体について、その目的関数  $J_q (q=1, \dots, Q)$  を計算し、 $J_q$  を適応度  $F_q (q=1, \dots, Q)$  に変換する。

$$J_q = \sum_{M=1}^M \sum_{k=1}^K \left\{ \frac{|P_k - \tilde{P}_k|}{P_k} \right\} \quad (7)$$

$$F_q = \frac{1}{\beta + J_q} \quad (8)$$

ただし、 $M$  はデータ日数、 $P_k$  は実績値、 $\tilde{P}_k$  は予測値、 $\beta \geq 0$  は実数値である。

**Step 4:** 複製

適応度に比例した選択確率で複製を行う適応度比例戦略を用いる。すなわち、各個体は  $F_q / \sum_{j=1}^Q F_j$  の確率で複製される。

**Step 5:** 交叉

ランダムに個体のペアを  $Q/2$  個作成し、交叉確率  $P_c$  で交叉を行う。すなわち、ランダムに交叉点を選び、交叉点の前後で文字列を入れ換える。

**Step 6:** 突然変異

突然変異確率  $P_m$  で個体の各遺伝子 (0 あるいは 1) を反転させる。

**Step 7:** 繰り返し

停止条件を満たさなければ  $g=g+1$  として  $Step 2$  へ。満たすならば終了し、全世代のうち最大適応度を持つ個体を解とする。

## 3. 計算機シミュレーション

### 3.1 予測結果の評価関数


翌日電力需要予測の評価として次式に示す平均予測誤差  $E$  を用いる。

$$E = \frac{1}{24} \sum_{k=1}^{24} \left\{ \frac{|P_k - \tilde{P}_k|}{P_k} \times 100 \right\} \quad (9)$$


ここで、 $P_k$  は実績値、 $\tilde{P}_k$  は予測値である。

### 3.2 シミュレーション実験


予測データとしては、種子島の1994年の7、8、9月の電力需要量及び天候と気温の実績値を使用した。また




(a) 7月29日の予測結果



(a) 7月29日の予測誤差



(b) 8月1日の予測結果



(b) 8月1日の予測誤差

図3 予測結果

図4 予測誤差

表1 平均予測誤差 E[%]

	GA+NN	NN
7月17日(日)	6.16	6.51
7月23日(土)	10.0	10.12
7月28日(木)	1.14	0.95
7月29日(金)	2.82	4.27
8月1日(月)	3.94	8.50
8月2日(火)	1.67	1.50
8月3日(水)	2.06	1.86
8月4日(木)	2.12	1.94
8月7日(日)	3.62	4.00
8月27日(土)	6.37	10.12
9月10日(土)	6.49	10.17
9月11日(日)	5.66	6.78

ニューラルネットワークだけを使った予測法 (NN) と、本稿提案の初期値をGAで決定した予測法 (GA+NN) の比較を行う。

数値実験ではニューラルネットワークを

入力層：10ユニット

中間層：4ユニット

出力層：24ユニット

学習係数：0.2

慣性項係数：0.4

シグモイド関数の傾き：0.9

またGAにおいて、

全個体数：200

世代数：500

交叉確率：0.8

突然変異確率：0.03

とした。

図3に7月29日と8月1日の予測結果と図4にその予測誤差を示す。表1より全体平均誤差でそれぞれNNが5.93%、GA+NNが4.50%であった。詳細にはそれぞれ平日平均誤差が3.17%と2.30%、土曜日平均誤差が10.74%と8.23%、日曜日平均誤差が6.65%と5.15%であった。以上から、ニューラルネットワークのみの予測法NNより本予測手法GA+NNの方が優れていることが

実証された。

#### 4. まとめ

以上、GAによる初期値設定型ニューラルネットワークによる翌日電力需要予測について考察した。計算機シミュレーション実験より、ニューラルネットワークの結合係数の初期値をGAによって決定することで、局所解を避けて、大域的な最適解を得ることができた。ニューラルネットワークの最適構造の決定などによる、より高精度な予測法の開発などは、今後に残された研究課題である。

#### 参考文献

- 1) 北野 宏明編：“遺伝的アルゴリズム”，産業図書，1993
- 2) 石田，田村：“ニューラルネットを用いた翌日電力需要予測” T.IEE Japan, Vol.114-B, No.11, '94, p1109/1115
- 3) 高田，八野，園田，松山：“ニューラルネットワークを用いた種子島における翌日電力需要予測”平成9年度計測自動制御学会九州支部学術講演会予稿集，pp. 321-322, (1997)