

3N-5 2種類のニューラルネットワークの最適組み合わせによる最大電力需要予測

小西 弘恭 (株)四国総合研究所

泉田 正則 (愛媛大学)

村上 研二 (愛媛大学)

1. まえがき

本稿では、二つの独立したニューラルネットワークの組み合わせによる翌日最大電力需要予測手法を提案する。一方のニューラルネットワークは予測対象日至近の学習データを、他方のニューラルネットワークは過去年度の学習データを用いる。これら二つのニューラルネットワークによる予測値の線形結合を最終的な予測値とする。本手法により、単独のニューラルネットワークによる予測手法と比較して予測精度が向上したので概要を報告する。

2. 予測対象

予測対象は、四国地方、1995、1996年の台風襲来日などの特異日を除いた夏季(7/1から9/30)平日とする。最大電力需要は総需要から、予め需要の決められている工場などの特約分を除いた一般需要とする。気象データは、実績値を用い、四国4県の県庁所在地における観測値の各県の需要比に基づく荷重平均値を用いる。

3. ニューラルネットワーク

予測に用いる二種類のニューラルネットワークの概要を以下に示す。

(1) 短期ニューラルネットワーク (STNN)

このニューラルネットワークは予測対象日至近、短期間の学習データを用いるため、短期ニューラルネットワーク (STNN: Short Term Neural Network) と呼ぶ。予測対象日の気象は最近の状況と類似していると考えられるから、最近のデータを学習しているSTNNを用いれば、良い最大電力予測結果が得られると考えられる。しかし、対象日の気温の急変時には予測誤差が大きくなると考えられる。

(2) 長期ニューラルネットワーク (LTNN)

このニューラルネットワークは長期間(60日前後)の学習データを用いるため、長期ニューラルネット

ワーク (LTNN: Long Term Neural Network) と呼ぶ。LTNNでは過去年度の多くの学習データを用いるため、予測対象日の気象の急変に強い。しかし、猛暑、冷夏といったその年特有の気象による電力需要の変化の影響は受けやすいと考えられる。

3. STNN, LTNNによる予測

STNN, LTNN単独の予測実験を以下の条件で行った。

(1) 入力項目: 4項目 (最高気温 (Tx), 平均気温 (Ta), 最低気温 (Tm), 2日前最大電力需要 (P)) のすべての組み合わせ。

(2) 学習データ:

STNN: 予測対象日の前日から過去10日 (平日)

LTNN: 前年度平日 (7/1から9/30)

(3) 初期荷重: 乱数 (-0.01から0.01の範囲)

(4) 学習係数: 0.001

(5) 中間素子数: 20 (STNN), 2 (LTNN)

(6) 学習回数: 300万回 (STNN), 2000万回 (LTNN)

(7) 出力関数

・中間層: シグモイド関数 $f(x) = 1 / (1 + \exp(-x))$

・出力層: 線形関数 $f(x) = x$

(8) 学習方法: バックプロパゲーション法

なお、STNNでは学習データに優先度を持たせた、優先度付き学習法⁽¹⁾を用いた。中間素子数などのパラメータは予備実験で求めた最適なものを用いた。

表1 に2年平均において最も小さい予測誤差を与える入力項目でのSTNN, LTNNによる予測結果を示す。

表1 STNN, LTNNによる予測誤差

ニューラルネットワーク	入力項目	平均誤差 (%)		
		1995年	1996年	2年平均
STNN	Ta, P	2.02	2.03	2.03
LTNN	Tx, Ta, Tm, P	2.06	2.10	2.08

4. 組み合わせ予測手法 (CFM)

提案する予測手法は二つのニューラルネットワークの予測値の線形結合を最終的な予測値とするため、組み合わせ予測法 (CFM: Combination Forecasting Method) と呼ぶ。本手法の概要を図1 に示す。ここで O_s はSTNNによる予測結果, O_L はLTNNによる予測結果である。CFMでは最終的な予測結果 O_c は

次式で与えられる。

$$O_c = (1 - r)O_s + rO_L \quad (0 \leq r \leq 1)$$

r はLTNNによる予測結果とSTNNによる予測結果の線形結合の割合を決定する係数で、組み合わせ係数と呼ぶ。 r により、CFMによる予測結果にSTNN, LTNNのどちらを大きく反映させるか決定することができる。

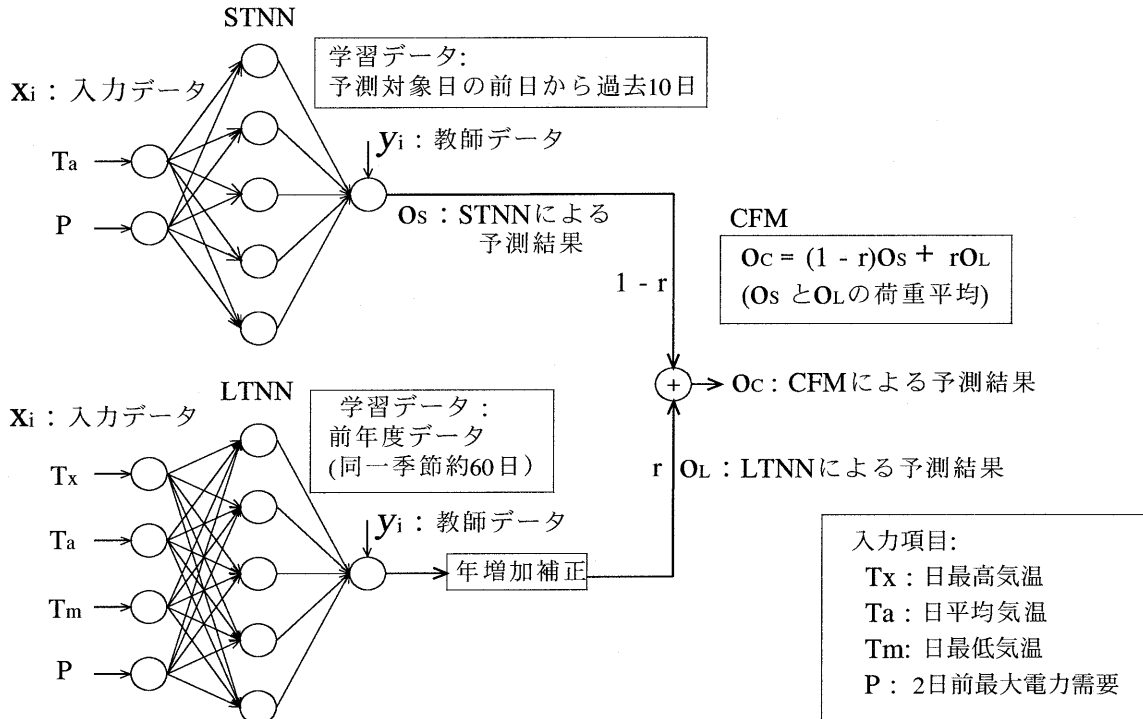


図1 組み合わせ予測法 (CFM) の概要

5. 組み合わせ予測法による予測

表2にCFMによる予測結果を示す。入力項目, 組み合わせ係数 r を変えて実験し, 2年平均の平均誤差の最も小さい場合の予測結果を示す。最も良い予測結果はSTNNの入力項目がTa, P, LTNNの入力項目がTx, Tm, Pで r が0.43の時である。

表2 CFMによる予測誤差

入力項目		平均誤差 (%)			r
STNN	LTNN	1995年	1996年	2年平均	
Ta, P	Tx, Tm, P	1.66	1.62	1.64	0.43

6. 結果

表1, 2の結果より, CFMはSTNN, LTNN単独の予測と比較して平均誤差を小さくできることが分かる。ST

NN, LTNNによる2年平均の平均誤差2.03, 2.08% に対してCFMは1.64% と約2割, 平均誤差が低減された。なお, r の値は厳密に設定しなくても0.4から0.5の範囲に設定すれば r を最適値とした場合とほぼ同様の予測結果が得られることが確認されている。

以上により, 組み合わせ予測法 (CFM) は単独のニューラルネットワークによる予測と比較して予測誤差を低減できることが示された。

参考文献: (1) H. Konishi, M. Izumida, K. Murakami "Next Day Electric Peak Load Forecasting Using Priority of Learning data" 1999 International Technical Conference on Circuits/Systems, Computers and Communications. Proceedings vol.1 pp. 72-75 (1999-7).