

構造的GAによるGMDHを用いた翌日最大電力需要予測

正員 雪田 和人* 学生員 加藤 慎也*
 正員 後藤 泰之* 正員 一柳 勝宏*
 正員 川島 靖弘**

Daily Peak Load Forecasting by Structured Representation on Genetic Algorithms for Non-linear Function Fitting

Kazuto Yukita*, Member, Shinya Kato*, Student Member, Yasuyuki Goto*, Member,
 Katsuhiko Ichiyonagi*, Member, Yasuhiro Kawashima**, Member

Recently, the independent power producers (IPPs) and the distributed power generations (DGs) are increase on by the electric power system with the power system deregulation. And the power system becomes more complicated. It is necessary to carry out the electric power demand forecasting in order to the power system is operated for the high economical and the high-efficient. For the improvement of electric power demand forecasting, many methods, such as the methods using fuzzy theory, neural network and SDP data, are proposed.

In this paper, we proposed the method using STROGANOFF (Structured Re-presentation on Genetic Algorithms for Non-linear Function Fitting) that approximate the value of predictive to the future data by the past data is obtained. Also, the weather condition was considered for the forecasting that is improvement, and the daily peak load forecasting in next day on Chubu district in Japan was carried out, and the effectiveness of proposed method was examined.

キーワード：最大電力需要，構造的GA，GMDH，曜日係数，気象係数

Keywords: daily peak load, structured representation on genetic algorithms, GMDH, week coefficient, weather coefficient

1. まえがき

近年，電力系統は電力市場の自由化及び規制緩和に伴い独立系発電事業者や分散電源が増加することが予想され，より複雑化の傾向にある。このような状況下で，電力需要の予測を正確に行うことは，発電，送電ならびに配電から構成されるシステムを高効率かつ経済的に運用するために必要不可欠であると思われる。これまでに，この電力需要予測精度向上のために，ファジー理論やニューラルネットワーク，天気図，SDP データなどを用いた手法が数多く提案さ

れている^{(1)~(10)}。

著者らも，これまでに電力需要予測の精度向上を図るために，未来のデータの値を過去のデータの値を用いて，近似関数を求め予測することのできる構造的GAによるGMDH (Structured Representation On Genetic Algorithms for Non-linear Function Fitting: STROGANOFF と略記。) ^{(11)~(14)} を用いる手法を提案してきた⁽¹⁵⁾⁽¹⁶⁾。

特に文献(15)では，予測日前日までの電力需要値と予測日当日の曜日係数を用いて翌日最大電力需要予測を行った。本論文では，さらに文献(15)で提案した手法の予測精度の向上を目指し，予測日の気象条件を導入した。提案手法の有効性を検討するために，年間を通しての中部地区における翌日最大電力需要予測を実施し検討を行った。

2. 構造的GAによるGMDH(STROGANOFF)

本論文では文献(11)~(14)で提案されている構造的GAとGMDHを統合した手法であるSTROGANOFFを用いる。まず構造的GAは，遺伝的アルゴリズム(Genetic Al-

* 愛知工業大学工学部電気工学科電力システム研究室
 〒470-0392 豊田市八草町八千草 1247
 Electrical Engineering PowerSystem Lab., Aichi Institute of Technology

1247, Yachigusa, Yagusa-cho, Toyota 470-0392

** 中部電力(株)
 〒460-8680 名古屋市中区東新町 1
 CHUBU Electric Power Co., Inc.

1, Toshin-cho, Higashi-ku, Nagoya 461-8680

gorithms : GA) を構造的な表現を扱えるよう拡張したものであり、通常の GA とは異なり木構造をなしている。次に、GMDH (Group Method of Data Handling) は、多変量解析手法であり、ある変数群から適当な 2 つの変数を選択し、重回帰分析から二次式を構成する。そして、この二次式より算出された値を新たな変数とみなして変数群に加え、変数群が目標とする近似精度を得るまで変数の選択と生成を繰り返す手法である。

図 1 は、本論文で用いた初期世代における GMDH ネットワークであり、 $x_1 \sim x_n$ の入力から出力関数 P を近似するよう構成している。このとき、各ノードの表す関数は次式に示すように、2 入力変数の二次式である。

$$G_{x_i, x_j}(x_i, x_j) = a_0 + a_1 x_i + a_2 x_j + a_3 x_i x_j + a_4 x_i^2 + a_5 x_j^2 \dots \dots \dots (1)$$

ただし、 x_i と x_j はそれぞれ i 番目と j 番目の入力である。また $a_0 \sim a_5$ は、最小二乗法により算出される係数である。

そして STROGANOFF の基本原理より、図 1 の GMDH で与えられる初期の完全形は図 2 に示す木構造で表現される^{(11)~(14)}。本論文においても、同図に示す木構造を用いている。ここで第 (1) 式の係数 $a_0 \sim a_5$ は多重回帰分析手法を用いて最小二乗法により新しく木構造が生成されるたびに逐次算出している。また、各中間ノードは、次式に従い算出されている。

$$\bar{y} = G_{x_n, z_{n-1}}(x_n, z_{n-1}) \dots \dots \dots (2)$$

$$z_{n-1} = G_{x_{n-1}, z_{n-2}}(x_{n-1}, z_{n-2}) \dots \dots \dots (3)$$

⋮

$$z_1 = G_{x_1, x_2}(x_1, x_2) \dots \dots \dots (4)$$




図 1 GMDH ネットワーク
Fig. 1. GMDH network.




図 2 GMDH の 2 分木表現
Fig. 2. Equivalent binary tree.

そして、本論文においてこの入力 x_n は、予測日より過去の電力需要実績値を用いる。さらに予測精度を向上させるために、予測日の曜日と気象条件を考慮する。従って、曜日係数を α 、気象係数を β とすると、このシステムにおける翌日最大電力需要予測値は次式で算出される。

$$\bar{P} = \alpha \times \beta \times \bar{y} \dots \dots \dots (5)$$

ここで、GA における適合度計算には次式に示す MDL に基づき算出している。

$$MDL = 0.5N \log S_N^2 + 0.5k \log N \dots \dots \dots (6)$$

ただし、 N はデータ数、 k は木のパラメータ数、 S_N^2 は最小二乗誤差で次式で表される。

$$S_N^2 = \frac{1}{N} \sum_{i=1}^N |\bar{P}_i - P_i| \dots \dots \dots (7)$$

P_i は電力需要実績値の真値である。

3. STROGANOFF における入力の検出

本論文で用いた基準ネットワークを図 3 に示す。このネットワークを本論文では、図 4 に示すように入力上限を 128 個、階層を 7 層、初期入力、底辺入力層の 1, 2, 4, 8, 16, 32, 64, 128 の 8 箇所 (それ以外の入力は 0 とし実現している。)とし初期個体を実現した。ここで入力の 8 箇所に関しては、1, 2, 4, 8, 16, 32, 128 番目であるが、この番号に対応した入力値に関しては、各個体を発生させる時に乱数を用いて各入力値の場所を設定している。従って、初期個体に関しては各々異なった 8 箇所に入力値の設定がなされている。

入力に用いるデータは、予測日前日から 7 日前までの最大電力実績値の 7 入力と、予測値と相関性が強いと予想される予測日前日の 21 時から 23 時時点までの電力需要実績




図 3 基本形の概念図

Fig. 3. Basis of GMDH network.




図 4 構造図

Fig. 4. Structure figure.




図 5 21 時電力と翌日最大電力の相関 (夏期)
Fig. 5. Correlation between daily peak load and daily load of 21:00 in a last day (Summer period).




図 7 23 時電力と翌日最大電力の相関 (夏期)
Fig. 7. Correlation between daily peak load and daily load of 23:00 in a last day (Summer period).




図 6 22 時電力と翌日最大電力の相関 (夏期)
Fig. 6. Correlation between daily peak load and daily load of 22:00 in a last day (Summer period).

表 1 決定係数 R^2

Table 1. Decision coefficient R^2 .

		21 o'clock	22 o'clock	23 o'clock
December	Mon	0.7808	0.7783	0.7834
	Tue-Fry	0.7196	0.7505	0.754
February	Holiday	0.809	0.8067	0.8096
	Average	0.7698	0.7785	0.7823
March	Mon	0.7845	0.7802	0.7791
	Tue-Fry	0.7806	0.7741	0.7673
May	Holiday	0.8646	0.8768	0.883
	Average	0.8099	0.8104	0.8098
June	Mon	0.8886	0.8886	0.8883
	Tue-Fry	0.8972	0.898	0.8876
September	Holiday	0.8743	0.8694	0.8598
	Average	0.8867	0.8853	0.8786
October	Mon	0.4255	0.392	0.386
	Tue-Fry	0.5144	0.5104	0.4748
November	Holiday	0.9334	0.9294	0.9233
	Average	0.6244	0.6106	0.5947

値のいずれかの 1 入力とし合計 8 入力とする。これらの入力値に関しては、図 3 に示す概念図のように入力して実際に用いる電力実績データを、類似傾向ならびに中部地区の気温傾向などから経験的に 12 月～2 月, 3 月～5 月, 6 月～9 月, 10 月～11 月の 4 期間に分類し、その各期間で STROGANOFF の学習及び予測を実施する。

ここで、予測日前日の 21 時から 23 時の電力需要実績値に注目し、予測日最大電力需要値と予測日前日 21 時から 23 時電力実績値との相関性の検討を行った。検討に用いた中部地区電力需要データは 1995～1997 年の 3 年間で、電力需要値の特異性より月曜日, 火～金曜日, 土日祝の 3 区分に分けてそれぞれ実施した。また、相関関係を二次関数で近似し、このときの決定係数 R^2 を各々算出した。決定係数 R^2 の算出には重相関係数 R における次式を用いた。

$$R = \sqrt{\frac{\sum(Y_i - \bar{y})^2}{\sum(y_i - \bar{y})^2}} \dots\dots\dots (8)$$

Y_i : 近似値, y_i : 実測値, \bar{y} : 平均値

ここで、一例として 6 月から 9 月 (夏期) の火～金曜日の結果を図 5～図 7 に示す。また、本論文で学習に用いた各データの決定係数 R^2 を表 1 に示す。これらより夏期においては、どの時間帯においても翌日最大電力値と相関性が高いことが分かる。そこで、 R^2 値の平均が最も高い 21 時を夏期の入力として選び学習を行った。その他の期間においても、表 1 の結果より、12～2 月は 23 時, 3～5 月は 22 時, 10～11 月は 21 時を用いることにした。

次に、予測日当日における最大電力需要値と予測日当日の各種気象条件との相関性を検討した。




図 8 12 月～2 月の予測日の気温と最大電力量との相関

Fig. 8. Correlation between daily peak load and temperature from December to February.

用いたデータは、愛知県名古屋地区データである。図 8～図 11 に平日の予測日における最高気温と最大電力量, 最低気温と最大電力量の各相関を各々示す。

図 8～図 11 を比較してみると、図 10 を除いた各相関図においては、気温に対して相関性があまり強くないものと思われる。それに対し夏期である図 10 では、最高気温, 最低気温ともに相関性が高いことを示している。具体的には、図 10 における決定係数 R^2 は最高気温では 0.7935, 最低気温では 0.7749 となっているこのことから、夏期に対して気象係数で予測値を補正することで良好な結果が得られることが期待される。




図 9 3月～5月の予測日の気温と最大電力量との相関

Fig. 9. Correlation between daily peak load and temperature from March to May.




図 10 6月～9月の予測日の気温と最大電力量との相関

Fig. 10. Correlation between daily peak load and temperature from June to September.




図 11 10月～11月の予測日の気温と最大電力量との相関

Fig. 11. Correlation between daily peak load and temperature from October to November.




図 12 12月～2月の予測日における不快指数と最大電力量との相関

Fig. 12. Correlation between daily peak load and discomfort index from December to February.

次に平日の予測日における不快指数と最大電力量の相関性について検討した。結果を図 12～図 15 に示す。図 12～図 15 を各々比較した結果、不快指数についても夏期における決定係数 R^2 値が 0.8465 であることから相関性が高い




図 13 3月～5月の予測日における不快指数と最大電力量との相関

Fig. 13. Correlation between daily peak load and discomfort index from March to May.




図 14 6月～9月の予測日における不快指数と最大電力量との相関

Fig. 14. Correlation between daily peak load and discomfort index from June to September.




図 15 10月～11月の予測日における不快指数と最大電力量との相関

Fig. 15. Correlation between daily peak load and discomfort index from October to November.

ことがわかる。

これらの検討より、気象係数 β を用いると夏期において最も効果を発揮するものであると期待できる。

4. 予測結果及び考察

本論文では、中部地区の 1992 年 12 月から 1997 年 11 月までの 5 年間の電力需要実績データを用いて学習を行い、学習によって得られた各種係数を用いて 1997 年 12 月から 1998 年 11 月について、予測を実施した。GA のパラメータは、個体数を 60、交差率と淘汰率をそれぞれ 40%、最大世代数を 100 世代と経験的に設定したまた曜日係数 α 並びに気象係数 β は以下に示すように設定した。

□ 4.1 □ 曜日係数 α 並びに気象係数 β の決定 本論文では、曜日係数 α は各期間において第 (6) 式が最小になるよう表 2 に示すように設定した。

気象係数 β は、基本的には 1.00 とし、以下に示す条件に

表 2 曜日係数 α Table 2. Week coefficient α .

December	Mon	1.17	June	Mon	1.23
?	Tue-Fri	1	?	Tue-Fri	1.05
	Sat	0.89		Sat	1
	Sun	0.84		Sun	0.85
February	Holiday	0.86	Septemeber	Holiday	0.88
March	Mon	1.14	October	Mon	1.03
?	Tue-Fri	1	?	Tue-Fri	1.02
	Sat	0.86		Sat	0.96
	Sun	0.79		Sun	0.91
May	Holiday	0.85	November	Holiday	0.87

従い予測日に対応させ変更をする。夏期以外の3期間においては、基準値から極端に異なる値のみを補正するようにした。

まず、12月から2月の冬期において検討をする。この期間においては、名古屋の平年値より最高気温の3ヶ月平均は9.9度、最低気温の3ヶ月平均は1.2度である。ここで、図8において平均気温基準で注目すると最高気温が平均値より約5度上がっている場合は、約1500MW低くなっていることがわかる。ここで電力需要を20000MW基準とした場合、約7.5%も低くなっていることがわかる。また、最低気温についても基準値より約3度低くなると、電力需要値は約1200MW(約6.0%)の誤差を生じる。

電力需要予測に至っては、誤差1~2%で大型火力発電機約1機分とも言われるほど大きな誤差になる。このため予測精度向上のために、気象係数 β を用いて第(6)式が最小になるように調整をする。調整を実施した結果、予測日最高気温がこの期間における平均最高気温より5度以上高い場合は、 β を-0.05すなわち0.95とする。同様に予測日最低気温がこの期間における平均最低気温より3度以上低い場合は、 β を+0.03とし、1.03とする。

次に、3月から5月の春期において検討をする。この期間における3ヶ月平均最高気温は18.8度であり、3ヶ月平均最低気温は8.9度である。図9において、気温が28度以上になると若干ではあるが電力需要値が上昇しており、約1000MW(20000MWの基準で約5.0%)の誤差となる。また、最低気温に関しても気温が2度以下になると、約1500MW(約7.5%)の誤差になる。

従ってこの期間においても、冬期同様に β を第(6)式が最小になるよう調整する。この場合は、最高気温が約28度以上の場合は β を+0.03である1.03とし、最低気温が約2度以下の場合は、 β を+0.04して1.04とする。

次に、10月から11月における秋期について検討を行う。この期間においては2ヶ月平均最高気温は19.5度であり、2ヶ月平均最低気温は10.5度である。このとき図11から、最低気温が6度以下では、若干ではあるが電力需要の増加があることがわかる。また、学習値が一週間前の電力需要値に非常に依存していることから、一週間前比を取り入れ、最高気温において基準値に対して5度の差があると、約1000MW(約5.0%)の差が生じる。そこで、この期間

表 3 気象係数 β Table 3. Weather coefficient β .

Dec	comparison	High	-0.05	Jun	max	~22.0°C	-0.04
Feb	normal year of	Over	+0.03	Sep	temperature	22.1~25.0°C	-0.03
	max temperature	5°C			25.1~28.0°C	-0.02	
	comparison	Low			28.1~31.0°C	0	
Mar	normal year of	over	+0.04	before 7 days of	max temperature	31.1~34.0°C	+0.02
	min temperature	3°C			34.1~37.0°C	+0.03	
	max temperature	28°C			37.1°C~	+0.04	
May	min temperature	Below	+0.03	comparison	High over 5°C	+0.03	
	temperature	2°C			Low over 5°C	-0.03	
Oct	comparison	Low	-0.03	min	temperature	23.1~26.0°C	+0.005
	before 7 days of	over			26.1~29.0°C	+0.010	
Nov	max temperature	5°C	+0.03	discomfort	29.1°C~	+0.020	
	min temperature	Below			index	80~85	+0.010
		6°C			86~90	+0.015	
					91~	+0.020	

においては、 β を最低気温が6度以下の場合は、+0.03し1.03とする。また予測日最高気温が一週間前値より5度以上低下すると β を-0.03して0.97する。

次に、6月から9月における夏期において検討を行う。夏期における電力需要は、図10から分かるように気温に大きく影響をされるため、 β を詳細に調整し予測精度の向上を行う。ここで、図10に示すように最高気温に約3度のずれがあった場合に約1500~2000MW(約7.5~10.0%)の差が生じる。このために β を表3に示すように最高気温の平均値を基準とし約3度ごとに変更をすることにする。この期間における4ヶ月平均最高気温は29.4度であり、4ヶ月平均最低気温は21.2度である。

また、この期間においても一週間前の気温が予測日に大きく影響していることから、予測日最高気温が一週間前値より5度以上高い場合は β を+0.03とし、5度以上低い場合は、 β を-0.03とする。最低気温については、図10に示すように平均気温である約21度より低下しても、電力需要に大きな変化はないように思われる。しかし、最低気温が約4度上昇すると約1300~800MW(約6.5~9.0%)の差を生じる。このために β の値に関しては、約4度ごとに β を調整する。

そしてさらに、この期間においては不快指数についても相関が見られるために、この不快指数も考慮し予測精度の向上を目指した。図12~図15において、不快指数は75までは快適、75~80まではやや不快、80~85までが不快、それ以外が非常に不快という仮定をする。これより区間を80~85, 86~90, 91以上の3区間に分類している。特に区間に見る電力需要差は約2000~3000MW(約10.0~15.0%)となっている。よって、先の気温による β の補正値も考慮して、図14より不快指数が80~85のときは β を+0.01, 86~90までは+0.015, 91以上は+0.02とする。特に、夏期においては、上述した条件が複数重なることが考えられる。この場合は、 β の値に適合した条件を各々加え算出し用いる。

□4.2□ 予測結果及び考察 本論文で用いた構造的GAとGMDHを用いた翌日最大電力需要予測結果を図16~




図 16 予測結果 (1997 年 12 月～1998 年 2 月)

Fig.16. The forecasting result from December, 1997 to February, 1998.




図 18 予測結果 (1998 年 6 月～9 月)

Fig.18. The forecasting result from June, 1998 to September, 1998.




図 17 予測結果 (1998 年 3 月～5 月)

Fig.17. The forecasting result from March, 1998 to May, 1998.




図 19 予測結果 (1998 年 10 月～11 月)

Fig.19. The forecasting result from October, 1998 to November, 1998.

図 19 に示す。ただし、年末年始、ゴールデンウィーク、お盆期間等の特殊日はそれぞれ省いている。そして、各期間において提案手法を実施した後の平均予測誤差率を求めた。ここで、算出された各期間における最終世代の遺伝子列を表 4 に示す。最終個体のノード関数における係数値をすべて表示することは、困難であるため一例として 6 月～9 月期間における最適個体の代表的なノード係数を示している。このノード係数は、図 4 に示すノード a, b, c における各係数値であり、各値を表 5 に示す。ここで、表 4 に示す A～H の記号は、過去の最大電力需要値を示している。

提案手法の有効性を検討するために、GMDH のみの場合、曜日係数 α のみを用いた場合、多層パーセプトロンを用いた場合を比較検討した (本論文で比較のために用いた多層パーセプトロンに関しては、付録を参照して頂きたい)。このときの平均誤差、最大誤差を表 6 に示す。

表 6 より、各手法について比較検討をしてみる。最大誤差について注目すると約 10～30%であることがわかる。また平均誤差については、約 3.0～9.0%であることがわかる。特に GMDH のみの場合においては、最大誤差が平均約 25.4%あったが提案手法では約 13.4%にまで低減しており提案手法の有効性がわかる。またこの値は多層パーセプトロンと比較した場合にも低い値となっている。

提案手法と多層パーセプトロンとを比較すると、提案手法は、特に夏期 (6 月～9 月) においては、多層パーセプト

表 4 最終世代の遺伝子列

Table 4. The gene of the last generation.

December	GOAABGCHHEDHBABAHBBCEGFBGDGDDCCBCCFAACGAAG
February	FFCAGBFODEOOHGFABHDBEGFDCDBAFBCCAABGHHEGBCA
	EACAHOBBFDBCCBFCCGFOFCGBGFBGFGEAFFBEHEHOAO
March	AAAABBCBAFFDCHHAGDFGAGCAFHCFAEHEHDCFCFEECEGF
May	CAFBBAHFEFFAFGDGAFAEGBAAAAEAHDCBEDDFCABFHFD
	GCFHOEEGGBAAAAEAHDCBEDDFCABFHFDGCFHOEEG
June	GOAABGCHHEDHBABAHBBCEGFBGBOBFCAGBAEHFAEACBEFC
September	BDBFEDGFBGDFGDDGGFHCDBEGCCHEDDOGBCGEEGECDBE
	DAHOBBDDBCCHBFCEGFOFFGACHCCGABOAFBEGCFBCAO
October	OBAAEGEHAAGEHCBAHHEHABGBFEBFCADCBBCEHFBGACD
November	CBFGGHGGAEFFAFFAGFFFFECAHDBECGOFEFHCFEAFCD
	BFEGAGBEGBBDHHEACDECDBGFBEGFEAFBEDAEHFFFO
A : Before 7 days, B : Before 6 days, C : Before 5 days	
D : Before 4 days, E : Before 3 days, F : Before 2 days	
G : Before 1 days, H : X-time before 1 days, O : Zero	

表 5 ノード係数 (6 月～9 月)

Table 5. The node coefficient.

	Node A	Node B	Node C
a_0	0.00000000	0.31309087	0.24814783
a_1	1.00000000	0.23062737	0.18278936
a_2	0.00000000	0.16642546	0.18278936
a_3	0.00000000	0.12259145	0.13464535
a_4	0.00000000	0.16988353	0.13464535
a_5	0.00000000	0.08846452	0.13464535

表 6 平均予測誤差率

Table 6. The average of forecasting error.

	GMDH		$\alpha \times$ GMDH		Proposed method($\alpha \times \beta \times$ GMDH)		Neural Network	
	Max Error	Error Average	Max Error	Error Average	Max Error	Error Average	Max Error	Error Average
98/3-5	33.118	9.942	17.144	3.374	13.391	3.136	20.547	4.209
98/6-9	28.569	10.037	17.259	5.050	11.310	3.708	14.693	3.040
98/10-11	21.807	6.967	17.355	3.481	17.355	2.939	15.235	3.578
98/12-2	26.359	8.954	11.708	3.053	11.708	2.812	17.802	3.909
Total Average	27.463	8.975	15.866	3.740	13.441	3.149	17.069	3.684

ロンより平均誤差が約 0.66% 大きい。しかしながら、春期、秋期、冬期においては、提案手法が多層パーセプトロンよりも 0.6% 以上平均誤差を低減しており提案手法の有効性がわかる。

これらの結果より、提案手法は良好な結果が得られたものと思われる。しかしながら、夏期期間において最大予測誤差が 10% 以上になる部分があり、他の期間においても大きな誤差がみられる箇所があるので、最大誤差を低減させることが今後の課題であると思われる。

5. あとがき

本論文では、過去のデータより近似関数を求め未来のデータ値を予測する構造的 GA と GMDH(STROGANOFF)を用いて翌日最大電力需要予測を行った。特に、電力需要値は曜日や気象条件に大きく依存するために、STROGANOFF にこの要素を導入し予測精度の向上を目指した。また、このシステムに用いる入力データに関して、最大電力量の気象データ等との相関性についても検討をした。今後は、STROGANOFF に用いる入力データと翌日最大電力需要との相関性について詳細な検討を行なう予定である。

謝 辞

本研究を遂行するにあたり、貴重なデータを頂いた中部電力(株)システム運用部に厚くお礼を申し上げます。

また、多層パーセプトロンによるデータ収集などを実施して頂いた高岳製作所宮藤敏浩、大学院生修士 1 年中島幸一君に感謝をいたします。

(平成 14 年 10 月 2 日受付、平成 15 年 7 月 23 日再受付)


文 献

- (1) H. Mori and N. Kobayashi: "A Fuzzy Inference Approach to Short-term Load Forecasting in Power Systems", *T. IEE Japan*, Vol.116-B, No.11, pp.1354-1360 (1996-11) (in Japanese)
森 啓之・小林秀典:「ファジィ推論を用いた短期電力負荷予測」, 電学論 B, 116, 11, pp.1354-1360 (1996-11)
- (2) H. Mori, Y. Sone, D. Moridera, and T. Kondo: "Accumulation Effect of Discomfort Index for Fuzzy Short-term Load Forecasting", *Int'l J. Engineering Intelligent Systems*, Vol.7, No.4, pp.233-238 (1999-12)
- (3) H. Mori and N. Kosemura: "Optimal Regression Tree Based Rule Discovery for Short-term Load Forecasting", Proc. of 2001 IEEE PES Winter Meeting (CD-ROM), Columbus, USA (2001-1)
- (4) H. Mori and N. Kosemura: "A Data Mining Method for Short-Term Load Forecasting in Power Systems", *T. IEE Japan*, Vol.121-B, No.2, pp.234-241 (2001-2) (in Japanese)

- (5) 森 啓之・小瀬村紀之:「データマイニング手法による短期電力負荷予測」, 電学論 B, 121, 2, pp.234-241 (2001-2)
- (5) O. Ishioka, Y. Sato, T. Ishihara, Y. Ueki, T. Matsui, and T. Iizaka: "Development of Electric Load Forecasting System using Neural Networks", *T. IEE Japan*, Vol.120-B, No.12, pp.1550-1557 (2000-12) (in Japanese)
石岡 修・佐藤佳彦・石原 徹・植木芳照・松井哲郎・飯坂達也:「NN 応用電力需要予測システムの開発」, 電学論 B, 120, 12, pp.1550-1557 (2000-12)
- (6) Y. Sugai, H. Horibe, and T. Kawase: "Forecast of Daily Maximum Electric Load by Neural Networks using the Standard Electric Load", *T. IEE Japan*, Vol.117-B, No.6, pp.872-879 (1997-6) (in Japanese)
須貝康雄・堀部 浩・川瀬太郎:「基準需要を利用したニューラルネットワークによる翌日最大電力需要予測」, 電学論 B, 117, 6, pp.872-879 (1997-6)
- (7) T. Haida, S. Muto, Y. Takahashi, and Y. Ishi: "Peak Load Forecasting Using Multiple Years Data with Trend Data Processing Techniques", *T. IEE Japan*, Vol.117-B, No.8, pp.1101-1108 (1997-8) (in Japanese)
灰田武史・武藤昭一・高橋芳雄・石井康貴:「多年度データのトレンド処理に基づいた最大電力予測」, 電学論 B, 117, 8, pp.1101-1108 (1997-8)
- (8) T. Onoda and E. Ohba: "Selection of the Optimal Neural Network Architecture for Next Day Peak Load Forecasting", *T. IEE Japan*, Vol.118-B, No.5, pp.497-504 (1998-5) (in Japanese)
小野田崇・大場英二:「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」, 電学論 B, 118, 5, pp.497-504 (1998-5)
- (9) 角田典男・後藤泰之・水野勝教・一柳勝宏・横水康伸・松村年郎:「類似気象データを用いたニューラルネットワークによる翌日最大電力需要予測」, 平成 9 年電気学会全国大会, No.1383 (1997-3)
- (10) 角田典男・宮藤敏浩・後藤泰之・雪田和人・水野勝教・一柳勝宏・横水康伸・松村年郎:「SDP データを活用したニューラルネットワークによる翌日最大電力需要予測」, 平成 10 年電気学会全国大会, No.1375 (1998-3)
- (11) 伊庭斉志: 遺伝的アルゴリズムの基礎, オーム社 (1994-9)
- (12) 伊庭斉志: 遺伝的プログラミング, 東京電機大学出版局 (1996-6)
- (13) 伊庭斉志:「セミナー 遺伝的アルゴリズム/ニューラルネット/ファジィの新しい展開を探るテキスト」, システム制御情報学会 (1993)
- (14) 伊庭斉志: 進化論的計算の方法, 東京大学出版会 (1999)
- (15) Y. Goto, K. Yukita, K. Mizuno, and K. Ichianagi: "Daily Peak Load Forecasting by Structured Representation on Genetic Algorithms for Function Fitting", *T. IEE Japan*, Vol.119-B, No.6, pp.735-736 (1999-6) (in Japanese)
後藤泰之・水野勝教・雪田和人・一柳勝宏:「構造的 GA による GMDH を用いた翌日最大電力需要予測」, 電学論 B, 119, 6, pp.735-736 (1999-6)
- (16) S. Kato, K. Yukita, Y. Goto, and K. Ichianagi: "Daily Peak Load Forecasting by Structured Representation on Genetic Algorithms for Function Fitting", Proc. of 2001 Annual Conference of Power & Energy Society, IEE Japan, No.187 (2001-8) (in Japanese)
加藤慎也・雪田和人・後藤泰之・一柳勝宏:「構造的 GA と GMDH を用いた翌日最大電力需要予測手法の開発」, 平成 13 年電気学会 B 部門大会, No.187 (2001-8)

付 録

本論文で提案手法との比較に用いた多層パーセプトロンの概念図を付図 1 に示す。付図に示すように入力層、中間



付図 1 多層パーセプトロン

app. Fig. 1. Multi-layered perceptron.

付表 1 多層パーセプトロンのパラメータ値

app. Table 1. Parameter value of Multi-layer Perceptron.

(a) Input value

	Input layer(Spring)	Input layer(Summer)	Input layer(Autumn)	Input layer(Winter)
No.1	Maximum demand power one day before.	Maximum demand power one day before.	Maximum demand power one day before.	Maximum demand power one day before.
No.2	Maximum demand power two days before.	Maximum demand power two days before.	Maximum demand power two days before.	Maximum demand power two days before.
No.3	Maximum demand power three days before.	Maximum demand power three days before.	Maximum demand power three days before.	Maximum demand power three days before.
No.4	Maximum demand power four days before.	Maximum demand power four days before.	Maximum demand power four days before.	Maximum demand power four days before.
No.5	Maximum demand power five days before.	Maximum demand power five days before.	Maximum demand power five days before.	Maximum demand power five days before.
No.6	Maximum demand power six days before.	Maximum demand power six days before.	Maximum demand power six days before.	Maximum demand power six days before.
No.7	Maximum demand power seven days before.	Maximum demand power seven days before.	Maximum demand power seven days before.	Maximum demand power seven days before.
No.8	Maximum demand power at 22:00 one day before.	Maximum demand power at 21:00 one day before.	Maximum demand power at 23:00 one day before.	Maximum demand power at 21:01 one day before.
No.9	Judgment value by the day of the week	Judgment value by the day of the week	Judgment value by the day of the week	Judgment value by the day of the week
No.10	-	Maximum temperature in a prediction day	-	-
No.11	-	Minimum temperature in a prediction day	-	-
No.12	-	Discomfort index in a prediction day	-	-

(b) Hidden layer value

Hidden layer(Spring)	Hidden layer(Summer)	Hidden layer(Autumn)	Hidden layer(Winter)
11	14	11	11

(c) Output layer value

Output layer(Spring)	Output layer(Summer)	Output layer(Autumn)	Output layer(Winter)
The maximum demand power of a prediction day	The maximum demand power of a prediction day	The maximum demand power of a prediction day	The maximum demand power of a prediction day

(d) The number of times of training

The number of times of training	The number of times of training	The number of times of training	The number of times of training
28000	28000	28000	28000

層,出力層の3層構造をしている。ここで多層パーセプトロンにおいての入力値に関しては,付表に示す値を用いた。入力値に関しては,夏期において14入力,春期,秋期,冬期においては9入力とした。また中間層については夏期のみ14,それ以外は11とした。出力値は翌日最大電力予測値とし,学習回数は経験的に28000回としている。

雪田 和人 (正員) 1967年生。1997年3月東海大学大学院工学研究科博士課程修了。同年愛知工業大学助手。1998年同大学講師。2003年同大学助教授。現在に至る。博士(工学)。主として電力システムの運用・制御に関する研究に従事。電気学会,IEEEなどの各会員。



加藤 慎也 (学生員) 1976年生。2000年3月愛知工業大学電気電子工学卒業。2003年4月株式会社日立システムアンドサービスに入社。現在に至る。在学中は,主として電力システムにおける電力需要予測に関する研究に従事。



後藤 泰之 (正員) 1958年生。1985年3月東海大学大学院工学研究科博士課程満了。同年同大学助手。1988年同講師。1991年4月名古屋大学工学部講師。1994年4月愛知工業大学助教授。2000年10月同大学教授,2003年10月中国東南大学客座教授。現在に至る。工学博士。主として電力システムの解析・制御に関する研究に従事。電気学会,日本ファジィ学会,IEEE,各会員。



柳 勝宏 (正員) 1945年生。1974年3月愛知工業大学大学院工学研究科修士課程修了。同年愛知工業大学助手。その後,同講師,助教授を経て,1993年4月教授,現在に至る。工学博士。主として電力システムの安定度に関する研究,自然エネルギーの有効利用に関する研究に従事。電気学会,IEEEなどの各会員。



川島 靖弘 (正員) 1952年。1976年3月名古屋大学工学部電気学科卒業。同年4月中部電力(株)入社。主に電力系統監視制御システムの開発・保守に従事。現在,同社三重支店三重系統運用センター所長。

