

ニューロ・ファジイを用いた最大電力予測システムの開発

荒家 良作, 植木 芳照, 松井 哲郎

1. まえがき

電力需要予測は、電力の安定供給・経済運用に重要な役割を果たす。特に、1日の最大電力需要を予測する、翌日・当日の最大電力需要予測（日最大電力予測）の精度は、電力供給の経済性、供給信頼度に大きく影響するため、高い精度が要求されている。

電力の需要は、種々の気象条件や季節と密接な関連があるが、特に最大電力需要は、最高気温、最低気温、湿度、天候などとの相関が強い。従って、予測のためにはこれらの相関のモデル化が必要である。その手法として、従来から重回帰分析に代表される統計的手法を用いた研究・開発が行われている。

しかし、線形的相関性を仮定する範囲では、予測精度に限界があり、高精度のモデル化は難しい。

近年、統計的手法でも精度の高い手法が開発され、

その実用化が報告されるようになってきたが [1]、高精度のモデル開発には、多くの時間を要し容易ではないのが一般的である。

近年、このような多くの関連性あるデータの相関関係を学習できる新技術、ニューラルネットワーク技術が開発されその応用研究が進められている。電力需要予測の分野でも鋭意研究が進められ [2, 3]、実用化の段階に至っている [4-8]。

一方、ファジィ理論は、それまでモデル化が困難であった複雑なシステムに対する有効な手法として期待され、大きな発展を遂げている [9他]。

筆者らは、これらの手法を最大電力予測に応用し、その予測システムを開発したので報告する。

開発したシステムは、日最大電力予測だけでなく、週間、月間の最大電力需要の予測も行い、夏季や冬季の重負荷期のみならず、年間を通じて利用できる実用

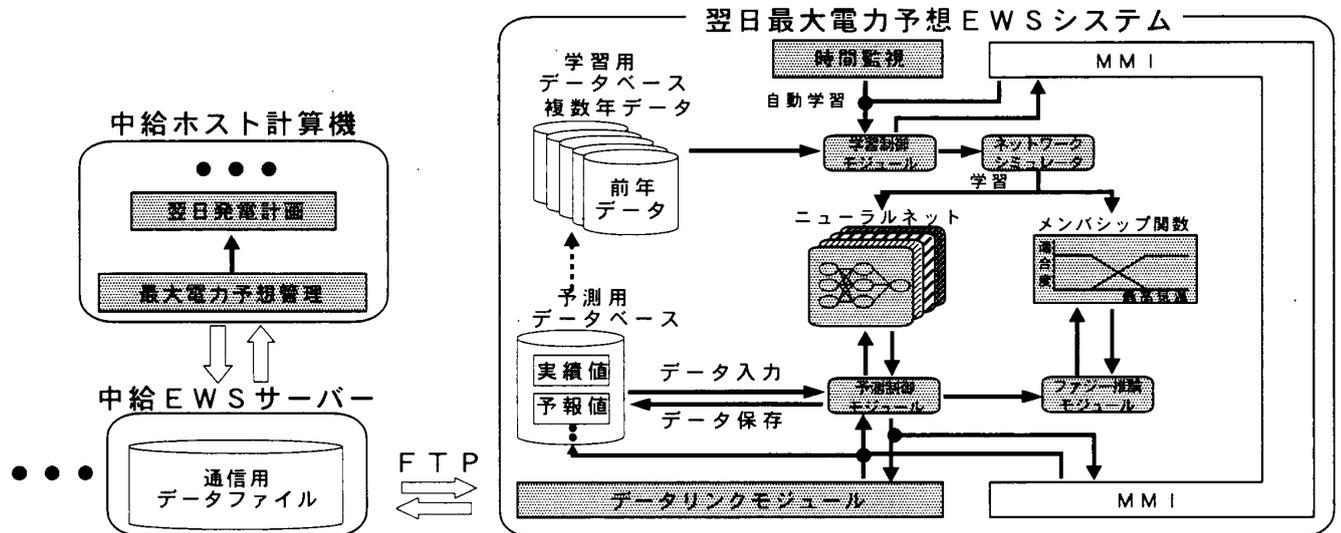


図1 システム構成図

あらや りょうさく 中部電力
うえき よしてゐる, まついでつろう 富士電機総合研究所

化システムとして開発され、現在、中部電力中央給電指令所において実稼働中である。

2. 最大電力予測システム

2.1 予測システムの概要

本システムは、エンジニアリング・ワークステーション上に構築されており、中央給電指令所の計算機ネットワークにイーサネットで結合されている(図1)。

学習には5年間分の実績データ、及び予測対象年度の至近実績データを使用する。本システムは、入力された気象実績値、電力実績値、気象予報値などから1日の最大電力需要(日最大電力)を予測する。

また、ホスト計算機との連携によるデータ自動更新、自動学習機能や、特約電力・夏季大口減電などのデータ管理機能、感度解析、統計指標計算機能など運用者への各種支援機能も有する。

2.2 ホスト計算機との連携

ホスト計算機と本予測システムの連携は、EWSサ

ーバーとのFTPによるファイル転送により行われる。具体的には、日替わり時、及び任意時の実績データ受信、最大電力予測用の予報気象データ受信、予測結果送信機能などがある。運用者は、ホスト計算機のコンソールから、予測要求を行う。これに対し最大電力予測システムは、予測計算を実行し、予測結果を送信する。予測結果は、ホスト計算機上の最大電力予測管理システムで管理され、翌日発電計画に反映される。

2.3 予測方式

多層型ニューラルネットワークにおけるニューロンの関数は、図2に示すように、一般にシグモイド関数と呼ばれる非線形モデルで表現され、学習はバックプロパゲーションアルゴリズムにより行われる。

この学習方法は、学習データが与えられる度に、教師値(学習用の最大電力実績値)と、対応する入力層の値及びネットワークの現在の重みに基づく出力値との差を最小にするようにニューロン間の結合重み係数(w)を更新する。学習済みのネットワークにより出力値を得る(想起する)場合は、ニューラルネットワーク

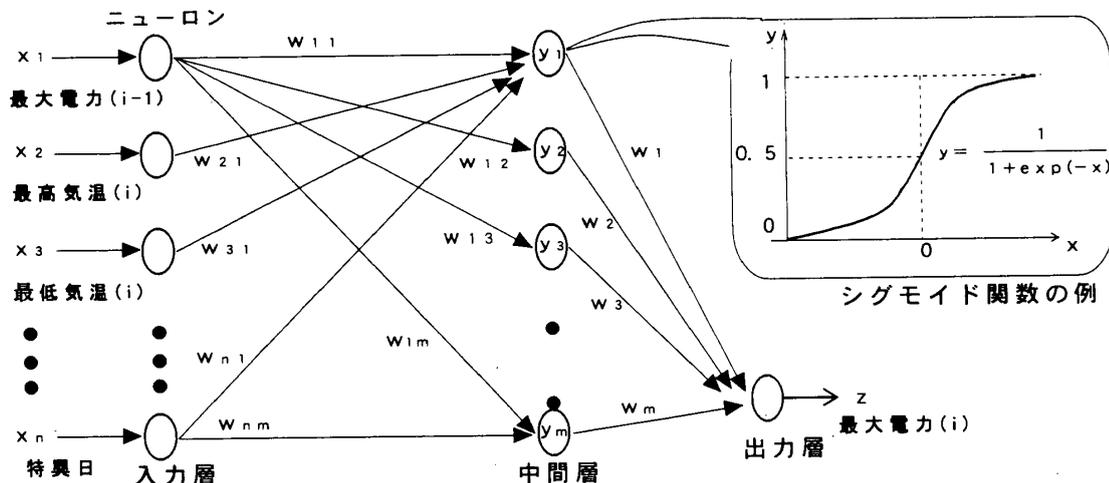


図2 多層型ニューラルネットワーク

表1 各ニューラルネットワークの入力変数

入力変数		季節			
		春季	夏季	秋季	冬季
電力	最大電力	当日予測： $i-1, i-7$, 翌日予測： $i-2, i-7$			
	最高気温				
気象	最低気温	$i \sim i-2$	$i \sim i-7$	$i \sim i-2$	$i \sim i-2$
	最小湿度				-
	天気				i
特異日 フラグ	土曜フラグ	$i \sim i-2$			
	休日フラグ				

(注) i は予測対象日を表す。また、週間・月間予測では最大電力は使用しない。

に、

$$x = (x_1, x_2, \dots, x_n) \quad (1)$$

が入力されたとする、以下の数式によってネットワークの出力値が計算される。

・中間層ニューロン j への入力

$$g_j(x) = \sum_{i=1}^n W_{ij} X_i \quad (2)$$

・出力層ニューロンへの入力

$$g(x) = \sum_{j=1}^n w_j y_j(x) \quad (3)$$

・中間層ニューロン j からの出力

$$y_j(x) = \frac{1}{1 + \exp(-g_j(x))} \quad (4)$$

・出力層ニューロンからの出力

$$z(x) = \frac{1}{1 + \exp(-g(x))} \quad (5)$$

開発したシステムで用いたニューラルネットワークは、中間層1層を含む3階層型ネットワークを使用し、ニューロンの伝達関数はシグモイド関数を用いている。

(1) 複数のニューラルネットワークによる構成

ここで用いられるニューラルネットワークは、春季、夏季、秋季、冬季それぞれに、当日予測用、翌日予測用、週間・月間予測用の3種類が構築されている。

また、各ニューラルネットワークの入力変数を表1に示す。入力変数は、各季節の特徴が反映できるよう、また実用化の観点から容易に得られるデータであることなどが考慮されて選択されている。

例えば、気象データでは、翌日予測、当日予測、週間・月間予測で、使用可能な実績データが異なる。

翌日予測では、予測対象日(i)の前日($i-1$)の午前中に予測作業が行われるため、予測作業時点では、予測対象日、予測対象日前日共に実績気象値が不明である。従って、いずれも予報値を使用する。当日予測では、予測作業時点で予測対象前日の実績気象が判明しているため、前日の実績値を使用する。

週間・月間予測は至近の実績気象が不明のため、平年値を基に予測する。

また、最大電力データは、翌日予測を行う時点では、一般にまだ予測対象前日の最大電力値が不明のため、予測対象前々日($i-2$)と予測対象日の前週の最大電力実績値を使用する。しかし、当日予測の予測作業時点では、既に予測対象前日の最大電力発生後なので、

その最大電力値と前週の値を使用する。週間・月間予測では、予測対象至近の最大電力値そのものが予測対象のため、最大電力は入力としない。

(2) 季節別ネットワークの構成

電力と気象の相関は複雑な非線形関係を示し、特に季節によりその相関が大きく異なる。このため、季節毎に学習データを用意し季節毎のネットワークを構築している(表2)。この区分は、電力と気象の相関、最大電力発生時、季節特有の使用可能データの有無、従来の運用上の慣習などを考慮して設定されている。

すなわち、夏季は電力と気象の相関(強い正の相関)及び、夏季大口減電分の使用可能期間から、冬季は電力と気象の相関(強い負の相関)、及び、午前中にピークが発生する期間から決定されている。春季、秋季は、夏季、冬季に挟まれた中間季と判断している。

(3) ネットワークの学習

学習は、バックプロパゲーションにより行われ、学習用データベースに蓄積された過去5年間の実績データを用いる。この学習用データは毎年度、更新されて用いられる。また、毎週、至近実績データを用いた追加学習が行われる。

表2 ネットワークの季節区分

季節	期間
春季	4月1日～6月30日
夏季	7月1日～9月15日
秋季	9月16日～10月31日
冬季	11月1日～3月31日

但し、各季節の年毎のベース増加分(年増加)は、気象以外の景気変動など社会要因が影響しているため学習対象外とする。このため、2年前～5年前の実績電力値は予測対象年前年相当に補正して学習に用いる。

また、実績データには特異な気象や気象以外の要因などで通常の電力実績値を示さない、学習に不適切なデータが含まれることがある。従って、学習時における前処理として、学習データに対してスクリーニングを行いデータの信頼性を確保する処理が実施される。

(4) ファジィ推論の適用

季節ごとのニューラルネットワークを統合する手法として、最も単純な方法は季節の境界日にネットワークを切り替える方式が考えられる。しかしこの方式で

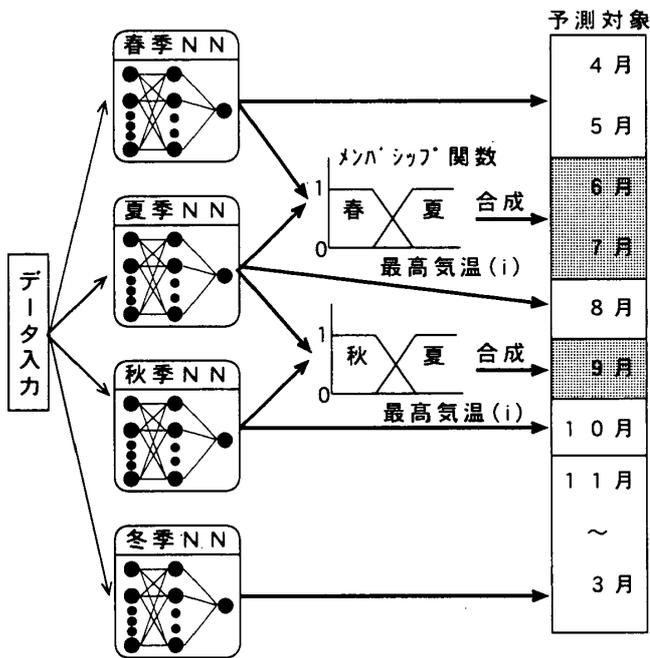


図3 メンバーシップ関数によるネットワークの統合

は、季節の境界付近である6月、7月や、9月頃の子測精度が悪化する場合がある。

開発システムではこのために、6月と7月に対し春季ネットワークと夏季ネットワークによるファジィ推論を適用し、9月に対し夏季ネットワークと秋季ネットワークによるファジィ推論を適用している(図3)。

本方式では、予測対象日に該当する各季節ネットワークによる予測値と各々の季節との適合度をメンバーシップ関数より求め、簡略法によるファジィ推論を用いて最終的な予測値が合成される(式(6)、式(7))。

$$6 \cdot 7 \text{月の場合: 予測値} = \mu_{\text{春}} Z_{\text{春}} + \mu_{\text{夏}} Z_{\text{夏}} \quad (6)$$

$$9 \text{月の場合: 予測値} = \mu_{\text{夏}} Z_{\text{夏}} + \mu_{\text{秋}} Z_{\text{秋}} \quad (7)$$

ただし、 μ : 各季節の適合度、

Z : 季節ニューラルネットワークの出力値

(5) メンバーシップ関数の導出

季節の適合度を表現するメンバーシップ関数の決定方法は、一般的には試行錯誤的に決定されていることが多いが、ここでは各季節ネットワークの学習データに基づいて作成している(図4)。

この場合の予測対象日と季節の適合度とは、予測対象日の気象条件と、該当する各季節ネットワークの学習データの気象条件との適合度と考える。また、各種気象要因のうち、適合度の指標として最も相関が強い最高気温を使用する。従って、各季節ネットワークの学習データにおける最高気温分布に基づきメンバーシップ関数を作成する。具体的には、各季節の最高気温

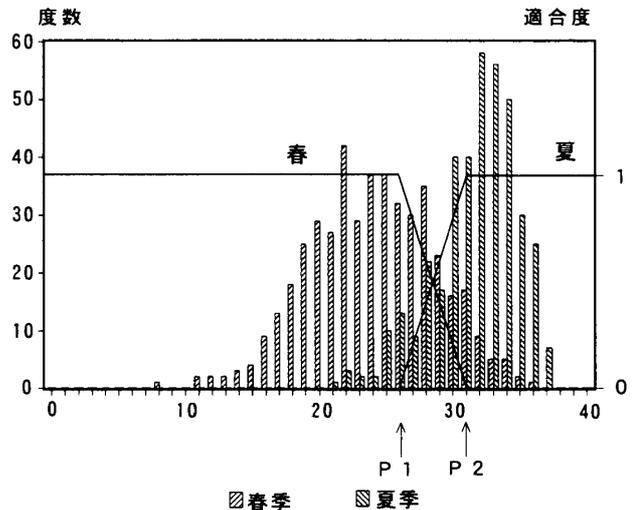


図4 メンバーシップ関数の例

が正規分布に従うと仮定した場合の母平均 μ の信頼係数90%の信頼区間を求め(式(8))、その信頼限界値をメンバーシップ関数の境界値とする(式(9)~式(11))。

母平均 μ の90%信頼区間は、下式で表される。

$$\bar{X} - 1.64\sigma \leq \mu \leq \bar{X} + 1.64\sigma \quad (8)$$

ただし、 \bar{X} : 過去5年の最高気温の平均値

σ : 過去5年の最高気温の標準偏差

従って、図4に示したメンバーシップ関数のパラメータP1、P2は下式で算出される(秋についても同様)。

$$P1 = \bar{X}_{\text{夏}} - 1.64\sigma_{\text{夏}} \quad (9)$$

$$P2 = \bar{X}_{\text{春}} + 1.64\sigma_{\text{春}} \quad (10)$$

ただし、ファジィ集合には以下の制約を加えている。

$$\mu_{\text{春}}(x) + \mu_{\text{夏}}(x) = 1 \quad (11)$$

図4の例では、予測対象日の最高気温が31°C以上であれば、夏との適合度が1であり完全な夏であると判断し、夏季ネットワークにより予測を行う。

一方、最高気温が26°C未満の場合は、春との適合度が1であり、春季ネットワークのみで予測する。26°C以上31°C未満の気温帯では、春季ネットワークの出力値と夏季ネットワークの出力値を用いてファジィ推論が行われ、最終的な予測値を得る。

3. 適用結果

中部電力(株)中央給電指令所において実稼働中の開発システムの平成5年6月~平成6年3月における適用結果を示す(表3、図5)。

表3 年間予測結果 (絶対平均誤差:平成5年平日)

評価指標 (%)	春季	夏季			秋季	冬季				
	6月	7月	8月	9月	10月	11月	12月	1月	2月	3月
月間	1.40 (2.09)	1.63 (2.54)	2.36 (3.07)	2.03 (2.83)	1.02 (1.02)	1.86 (1.58)	1.25 (1.33)	1.51 (1.62)	1.37 (1.51)	1.91 (1.95)
季節	1.40 (2.09)	1.87 (2.77)			1.41 (1.52)	1.60 (1.60)				
年間	1.63 (1.93)									

(注) 括弧内は当日予報気象使用時の予測結果

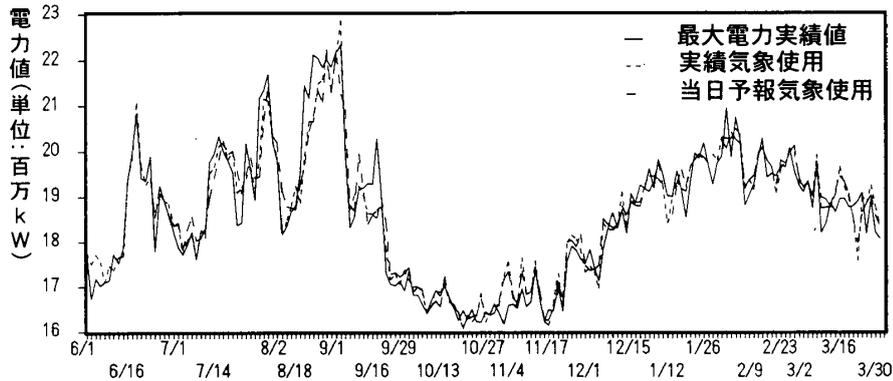


図5 最大電力実績値と予測結果 (平成5年)

特に電力需要がピークを迎える夏季の予測精度の向上が求められているが、平成5年夏季は、長い梅雨や台風の影響などで例年と大きく異なって冷夏であった。

夏季最大電力に最も強い相関を持つ最高気温は、昭和63年～平成4年までの夏季用学習データに比較して約3℃低く、春季・夏季への平均適合度がそれぞれ71%、29%であった。夏季ネットワークのみでは、低温傾向の学習データが少ないため、予測誤差が増大するところであった。しかし、ファジィ推論の効果により、誤差を低減できたと推察される。

システムの運用評価では、実績気象を使用した場合の絶対値平均誤差で、6月が1.4%、7月が1.6%、8月で2.4%と良好な予測精度であり、最も精度が要求される6月～8月で誤差1%台の予測精度が得られた。

また、その他の月でも、実績気象評価ではほぼ誤差1%台で予測が行われ、年間を通じて実績気象、当日予報気象ともに1%台で予測が行われている。

なお、平成6年、7年における年間の予測精度もそれぞれ、1.5%、1.6% (実績気象使用の場合) であり、ニューラルネットワークとファジィ理論を応用した方式の有効性が示された。

4. あとがき

ニューラルネットワークとファジィ推論を適用した最大電力予測システムを実用化し、フィールドでの運用の結果、3年間に渡って、誤差1%台の予測精度を実現し、その有効性を示した。

今後、実データを用いた運用を通じて更に改良を加え、より高精度のシステムを目指していく。

参考文献

- [1] 灰田, 武藤:「変数変換を用いた最大需要予測手法」, 平成5年電気学会電力技術研究会, PE-93-24, 1993.
- [2] T.M. Peng, N. F. Hunbele, G. G. Karady: "Conceptual approach to the Application of Network for Short-term Load Forecasting", Proc. of 1990, ISCAS, pp. 2342-2345, May, 1990.
- [3] D. C. Park, O. Mohammed, M. A. El-Sharkawi, R. J. Marks II: "An Adaptively Trainable Neural Network Algorithm and Its Application to Electric Load Forecasting", Proc. of 1991, ANNPS, pp. 7-11, July 1991.
- [4] T. Matsumoto, S. Kitamura, Y. Ueki, T. Matsui: "Short-term Load Forecasting by Artificial

Neural Networks Using Individual and Collective Data of Preceding Years”, Proc. of ANNPS'93, pp. 245-250, 1993.

[5] 松元, 北村, 植木, 松井, 遠藤:「ニューロ・ファジイを用いた最大電力予測システムの適用結果」, 平成5年電気学会電力技術研究会, PE-93-95, 1993.

[6] 松元, 北村, 植木, 松井, 遠藤:「ニューラルネットワークを用いた翌日最大電力予測システムの開発」, 平成5年電気学会全国大会, No.1222, 1993.

[7] 加藤, 植木, 松井, 遠藤:「ニューロ・ファジイを用いた最大電力予測システム」, 平成7年電気学会全国大会, No.1403, 1995.

[8] 植木, 松井, 遠藤, 加藤, 荒家:「ニューロ・ファジイ応用最大電力予測システムの開発」, 電気学会論文誌B, Vol.115-B, No.9, 1995.

[9] 伊藤:「プロセス制御分野におけるファジイ制御の意義と役割」, 日本ファジイ学会誌 vol.7, No.1, 1995.

シンポジウムルポ

権藤 元

小樽市で行われた春季研究発表会も無事すんで、5月17日の見学会がサッポロビール工場の見学を残すだけとなったときに、バスが北海道電力本社前に止まり数人のメンバーの方々がここで降りられた。これは、「電力のOR」研究グループ主催のミニ・シンポジウムに参加する人達である。会場に入ると同時にこのシンポジウムが始まった。まずは、このような配慮をしていただいた実行委員会の方々にお礼を申し上げる。

このシンポジウムは北海道大学の長谷川先生が企画されて、電力会社の日々の運用に欠かせない最大電力予測を支援するシステム開発の話題を5つ揃え、電力需要予測をテーマとして構成された。手法から見ると、回帰分析あり、ニューラルネットワークあり、さらに回帰分析とニューラルネットワークを融合した事例が用意された。発表順も配慮が行き届き、全体として非常に盛り上がりを見せた。

個々の発表内容は本誌に紹介されているので、ここではその雰囲気をお伝えしよう。

参加者は24名で、その内訳は電力関係13名、大学関係8名、その他3名である。1件の発表は30分で十分な時間が用意され、長谷川先生の司会ですすめられた。

第1の発表「重回帰手法に基づいた最大需要予測支援システムの開発について」は、この4月から運用を開始したシステムの紹介である。質疑討論が大変な賑わいを見せ、20分もオーバーするほどの白熱化したスタートであった。

これに続いて、「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」, さらに「ニューロ・ファジイを用いた最大電力予測システムの開発」が紹介された。これらも人間の知見をいかに学習過程に織り込むかなど熱心な討議がはずみ時間オーバーが続いた。しかし、時間を気にして若干討論を遠慮された方も見られたように思われた。

4番目は「電力予測におけるニューラルネットワーク構成の最適化」で、ニューラルネットワークに基づく予測を「統計的ゆらぎ」と「学習に伴うゆらぎ」の両方から評価する情報量基準の紹介で、このあたりになるとすでに2時間半は経過しており、さすが疲れも見られ、情報量の基準の有用性を感じながらも理論的な話題でもあり、討論は個別に懇親会の場へ移されたと思われた。

最後の発表「重回帰分析と階層型ニューラルネットワークによる翌日電力予測」は、回帰分析と階層型ニューラルネットワークを併用したモデルの紹介である。回帰分析は構造を明示しできるだけブラックボックス化を避けたい部分を分担し、階層型ニューラルネットワークは回帰分析では表しきれない難しく複雑な関係を分担し、それぞれの手法の役割を明確にして取り扱っており、これこそ個々の手法にとらわれず、両手法を融合して使いこなしているという感想をいただいた。

このあとの懇親会には大多数の方が参加して、シンポジウムの会場では論議し残した話題に花を咲かせた。

一見、回帰分析とニューラルネットワークとは対立して捉えられることが多いが、このシンポジウムでは融合するという立場が紹介された。このように個々の手法にとらわれないでモデル化するという手法の発展法を具体的に示したことは、実務へのORを適用する立場からその意義は大きいものと思われる。