論文

ラジアル基底関数ネットワークと
簡略型ロバストフィルタによる
冷水負荷予測[†]坂和 正敏^{*1} 後呂 智^{*2} 加藤 浩介^{*1} 井上 拓也^{*1}

地域冷暖房システムでは、一括して作られた冷水、高温水が各顧客に供給されるので、運転効率を高め安定した熱供給を行うためにはその負荷予測は必要不可欠である。本論文では、このような地域冷暖房システムの冷水負荷予測を目的として、さまざまな要因により実際の冷水負荷データに含まれる異常値や欠測値の悪影響を低減するためのロバストフィルタに対して、ロバストフィルタの数値的安定性の問題を改善する簡略型ロバストフィルタの提案を行うとともに、時系列モデルとしてラジアル基底関数ネットワーク(RBFN)を用いた非線形自己回帰移動平均 RBF-NARMA モデルを提案する。さらに、本論文で提案する RBF-NARMA モデルと J. T. Connor らが提案したリカレント非線形自己回帰移動平均(NARMA)モデルを、現実の地域冷暖房システムで得られた異常値や欠測値を含む冷水負荷データを用いた冷水負荷の長期予測に適用して予測結果の比較を行うことにより、提案したモデルの有効性を検証する。

キーワード：冷水負荷予測、簡略型ロバストフィルタ、ラジアル基底関数ネットワーク(RBFN)、非線形自己回帰移動平均(NARMA)モデル、RBF-NARMA モデル

1. はじめに

都市の快適環境の保全とともにエネルギー利用分野における多様化、分散化および高効率化が図られる中で、高密度都市における地域冷暖房システムの導入が重視されてきている[1]。これにより、省スペース、省エネルギーならびに大気汚染や都市災害の防止といったさまざまな利点が期待できる。

地域冷暖房システムは、ある地域内の各施設の冷暖房や給湯に使用される冷水や蒸気等の熱源を地域冷暖房プラントで集中的に供給するシステムである。図1に地域冷暖房システムの概略図を示す。

プラントには大型の冷凍機やボイラ等の熱源機器が設置され、システムの効率的な運用のためには地域の熱負荷に応じた最適な熱源機器の運転が重要になる。そのためには、予め熱負荷を予測し、熱源の最適な運転パターンを決定し、熱源機器の立ち上がり時間を考慮した運転制御ができればシステムの高効率運転が可能になると考える。また、深夜電力を利用した蓄熱システムを有したプラントの場合、前日において翌日の熱負荷量が予測できれば、必要な熱量分のみの蓄熱運転が可能になり熱ロスのない効率の良い運転が可能

となる。

このように地域冷暖房システムにおいて熱負荷予測はシステムの高効率運転に対して重要な課題であり必要不可欠なものである。本論文では、このような地域冷暖房システムにおける冷水負荷予測を考察する。実際に得られる冷水負荷データには、さまざまな要因により、観測ノイズおよび異常値や欠測値が含まれている。そのような雑音成分を取り除くアルゴリズムはフィルタリングアルゴリズムとよばれる。代表的なフィルタリングアルゴリズムにカルマンフィルタがある[4]。カルマンフィルタは線形状態空間モデルを対象としているが、非線形状態空間モデルへも拡張されており、拡張カルマンフィルタとよばれている[5]。しかし拡張カルマンフィルタは観測ノイズは除去できるが、異常値や欠測値を除去することができない。

このような異常値、欠測値が含まれる時系列の予測に関して、R. D. Martin と D. J. Thompson によってロバストフィルタとよばれるアルゴリズムが提案され

図1 地域冷暖房システム

[†] Cooling Load Prediction through Radial Basis Function Network and Simplified Robust Filter
Masatoshi SAKAWA, Satoshi USHIRO, Kosuke KATO and Takuya INOUE

^{*1} 広島大学工学部第二類(電気系)

Faculty of Engineering, Hiroshima University

^{*2} 新菱例熱工業(株)

Shinryo Corporation

ている[2]. ロバストフィルタは線形状態空間モデルに基づき、データに欠測値や異常値があればそれを取り除く。さらに、近年、J. T. Connor と R. D. Martin によって、このロバストフィルタの非線形状態空間モデルへの拡張も提案されている[3].

ロバストフィルタは拡張カルマンフィルタと違い、ロバスト関数を適用することにより欠測値や異常値をも自動的に除去することができるフィルタリングアルゴリズムである。拡張カルマンフィルタおよびロバストフィルタはその複雑な行列演算による不安定さが報告されている[6]. 本論文では、ロバストフィルタの不安定さを取り除いた簡略型ロバストフィルタを提案する。

J. T. Connor と R. D. Martin はロバストフィルタに限定されたフィードバック結合のあるリカレントネットワークによって表された非線形自己回帰移動平均(NARMA)モデルを組み合わせたリカレント NARMA モデルによる時系列予測を行っている。本論文では、簡略型ロバストフィルタに学習の収束が速いといわれているラジアル基底関数ネットワーク(RBFN)を組み合わせたモデルを提案し、提案したモデルによる冷水負荷予測を試みる。なお、J. T. Connor らのモデルと同じく、非線形システムを NARMA モデルとみなし、提案モデルを RBF-NARMA モデル、使用するネットワークを RBF-NARMA ネットワークとよぶことにする。

本論文では、RBFN と簡略型ロバストフィルタによる冷水負荷予測を試みる。具体的なフィルタリング及び予測の流れを図2に示す。

簡略型ロバストフィルタを適用することにより、ロバストフィルタの複雑な行列演算を簡略化し、安定した予測システムの構築を試みる。さらに、J. T. Connor らが提案した限定されたフィードバック結合をもつリカレントネットワークとロバストフィルタによる予測システムであるリカレント NARMA モデルと予測結果の比較を行い、提案する予測システムの有効性の検証を行う。

図2 フィルタリング及び予測システム

2. フィルタリング

拡張カルマンフィルタはよく用いられるフィルタリングアルゴリズムであり、現在の状態推定および雑音成分の除去を行う。しかし、拡張カルマンフィルタでも欠測値や異常値を取り除くことはできない。そこで、予測値から大きくはずれた観測値は自動的に除外するアルゴリズムが R. D. Martin と D. J. Thompson によって提案されている。このアルゴリズムはロバストフィルタとよばれている。

拡張カルマンフィルタおよびロバストフィルタにおいては複雑な行列演算が行われるので、計算機の桁落ちなどにより不安定となり予測値が発散するという問題点が報告されている。この問題点に対する本質的な解決方法はまだ報告されていない。そこで本論文では、この複雑な行列演算を簡略化することにより数値的安定性を改善する簡略型ロバストフィルタを提案する。これにより、より安定したシステムの構築が期待される。

2.1 拡張カルマンフィルタ

非線形確率システム

$$\mathbf{x}_{t+1} = \mathbf{f}_t(\mathbf{x}_t) + \mathbf{G}_t \mathbf{w}_t \quad (1)$$

$$\mathbf{y}_t = \mathbf{H}_t \mathbf{x}_t + \mathbf{v}_t, \quad t=0, 1, \dots \quad (2)$$

について考察する。ここで、 $\mathbf{x}_t$ は n 次元状態列ベクトル、 $\mathbf{y}_t$ は p 次元観測列ベクトル、 $\mathbf{w}_t$ および $\mathbf{v}_t$ はそれぞれ m 次元および p 次元のガウス白色雑音ベクトル、 $\mathbf{G}_t$, $\mathbf{H}_t$ はそれぞれ $n \times m, p \times n$ の時刻 t のみに依存する行列である。また、 $\mathbf{w}_t, \mathbf{v}_t$ の平均値ベクトル、自己共分散行列および相互共分散行列は、それぞれ、

$$E\{\mathbf{w}_t\} = \mathbf{0}, E\{\mathbf{v}_t\} = \mathbf{0}, \quad (3)$$

$$E\{\mathbf{w}_t \mathbf{w}_s^T\} = \mathbf{Q}_t \delta_{ts}, E\{\mathbf{v}_t \mathbf{v}_s^T\} = \mathbf{R}_t \delta_{ts}, \quad (4)$$

$$E\{\mathbf{w}_t \mathbf{v}_s^T\} = E\{\mathbf{v}_t \mathbf{w}_s^T\} = \mathbf{0}, \quad (5)$$

である。ただし、

$$\mathbf{R}_t > \mathbf{0}, \quad (6)$$

$$\delta_{ts} = \begin{cases} 1, & t=s \\ 0, & t \neq s \end{cases} \quad (7)$$

である。さらに、 $t \geq s$ ならば、

$$E\{\mathbf{w}_t \mathbf{x}_s^T\} = \mathbf{0}, E\{\mathbf{v}_t \mathbf{x}_s^T\} = \mathbf{0}, \quad (8)$$

と仮定する。 $\mathbf{f}_t(\mathbf{x}_t)$ は

$$\mathbf{f}_t(\mathbf{x}_t) = \begin{bmatrix} f_t^1(x_t^1, \dots, x_t^n) \\ \vdots \\ f_t^n(x_t^1, \dots, x_t^n) \end{bmatrix} \quad (9)$$

で与えられる n 次元非線形ベクトル値関数であり、 $\mathbf{x}_t$

について微分可能であるとする。観測値 $Y_j = \{y_1, y_2, \dots, y_j\}$ が与えられている場合に状態 x_t を推定することを考える。

j と t との関係により、次の3つの場合にわけられる。 $j < t$ の場合は観測区間より先の将来の状態を推定する問題で、予測とよばれる。 $j = t$ の場合は現在の状態を推定する問題で、フィルタとよばれる。また $j > t$ の場合は現在までの観測値に基づいて過去の状態の推定を行う問題で、平滑化とよばれる。これらの状態推定は、観測値列 Y_j が与えられたときの状態 x_t の条件付き期待値を求めることに等しい。以下では、状態 x_t の条件付き期待値と共分散行列を

$$x_{t|j} \equiv E(x_t | Y_j) \quad (10)$$

$$V_{t|j} \equiv E\{(x_t - x_{t|j})(x_t - x_{t|j})^T\} \quad (11)$$

と表す。ここで、 x_t の条件付き期待値 $x_{t|j}$ は時刻 j における時刻 t の予測値となる。これらは拡張カルマンフィルタとよばれるアルゴリズムによって効率的に計算される。拡張カルマンフィルタでは、次のように $f_t(x_{t-1})$ を $x_{t-1/t-1}$ のまわりで線形化する。

$$f_t(x_{t-1}) \approx f_t(x_{t-1/t-1}) + Df_t(x_{t-1/t-1}) \cdot (x_{t-1} - x_{t-1/t-1})$$

$Df_t(x_{t-1/t-1})$ の i 行 j 列の要素は次式で与えられる。

$$Df_t^{ij}(x_{t-1/t-1}) = \left(\frac{\partial f_t^i}{\partial x_{t-1}^j} \right) (x_{t-1/t-1}) \quad (13)$$

一期先予測

$$x_{t|t-1} = f_t(x_{t-1/t-1}) \quad (14)$$

$$V_{t|t-1} = Df_t(x_{t-1/t-1}) V_{t-1/t-1} \cdot (Df_t(x_{t-1/t-1}))^T + G_t Q_t G_t^T \quad (15)$$

フィルタ

$$x_{t|t} = x_{t|t-1} + V_{t|t-1} H_t^T \cdot (H_t V_{t|t-1} H_t^T + R_t)^{-1} \cdot (y_t - H_t x_{t|t-1}) \quad (16)$$

$$V_{t|t} = V_{t|t-1} - V_{t|t-1} H_t^T \cdot (H_t V_{t|t-1} H_t^T + R_t)^{-1} H_t V_{t|t-1} \quad (17)$$

平滑化はフィルタに比べより多くの観測値を用いて推定を行っているため、平滑化を行えば一般にフィルタよりも精度の良い状態推定が行える。平滑化のアルゴリズムではカルマンフィルタの結果、すなわち $x_{t|t-1}, x_{t|t}, V_{t|t-1}, V_{t|t}$ が用いられる。従って、平滑化ではまずカルマンフィルタによって $x_{t|t-1}, x_{t|t}, V_{t|t-1}, V_{t|t}$, $t=1, 2, \dots, T$, を求める。その後、 $x_{N-1/N}, V_{N-1/N}$ から時間の逆方向に $x_{1/N}, V_{1/N}$ までを計算して行く。

平滑化

$$A_t = V_{t|t} (Df_t(x_{t|t}))^T V_{t+1/t}^{-1} \quad (18)$$

$$x_{t+1/N} = x_{t|t} + A_t (x_{t+1/N} - x_{t+1/t}) \quad (19)$$

$$V_{t+1/N} = V_{t|t} + A_t (V_{t+1/N} - V_{t+1/t}) A_t^T \quad (20)$$

このアルゴリズムは、 f_t が線形であればカルマンフィルタに帰着する。

2.2 ロバストフィルタ

拡張カルマンフィルタと同じく、式(1)、(2)の非線形確率システムを考える。ただし、 $p=1$ 、式(2)右辺の v_t は0とする。拡張カルマンフィルタによって状態を推定することにより、本来その時系列にとって意味のない雑音成分が取り除かれる。しかし、拡張カルマンフィルタでも欠測値や異常値を取り除くことはできない。そこで予測値から大きくはずれた観測値は自動的に除外するアルゴリズムはロバストフィルタとよばれ、次式で与えられる。

$$x_{t|t-1} = f_t(x_{t-1/t-1}) \quad (21)$$

$$y_{t|t-1} = H_t x_{t|t-1} \quad (22)$$

$$V_{t|t-1} = Df_t(x_{t-1/t-1}) V_{t-1/t-1} \cdot (Df_t(x_{t-1/t-1}))^T + G_t Q_t G_t^T \quad (23)$$

$$S_t^2 = H_t V_{t|t-1} H_t^T + R_t \quad (24)$$

$$x_{t|t} = x_{t|t-1} + \frac{V_{t|t-1} H_t^T}{S_t} \cdot \Psi\left(\frac{y_t - y_{t|t-1}}{S_t}\right) \quad (25)$$

$$V_{t|t} = V_{t|t-1} - \frac{V_{t|t-1} H_t^T H_t V_{t|t-1}}{S_t^2} \cdot w\left(\frac{y_t - y_{t|t-1}}{S_t}\right) \quad (26)$$

ここで、 $\Psi(\cdot)$ はロバスト関数で、 $w(\cdot)$ は重み関数である。その他の記号の意味は拡張カルマンフィルタの項で説明したものと同じである。ロバスト関数と重み関数は有界かつ連続で、原点から大きく離れると0となり、原点に対して対称な台をもつ必要がある。また $\Psi(r)$ は r の絶対値が小さいときには r に近いものでなければならない。このようなロバスト関数を使用すれば、観測値と予測値の誤差が異常値によって大きくなる場合には一期先予測をフィルタとみなし計算することになり、観測値と予測値の誤差が小さい場合には拡張カルマンフィルタと一致することになる。重み関数 w は

$$w(r) = \Psi(r)/r \quad (27)$$

のように定められ、このときのロバスト関数 Ψ として、図3のような Hampel psi function がしばしば用いられる。Hampel psi function は2つのパラメータ a, b をもち、これらのパラメータの設定値によりロバスト

図3 Hampel psi function

関数の振る舞いが決定されることになる。

2.3 簡略型ロバストフィルタ

式(21)～(26)を繰り返し実行すると、理論的にはあり得ないが、実際の数値計算においては $V_{t|t}$, $V_{t|t-1}$ の対称性や非負定値性がくずれることがある。このような場合には、推定値 $\mathbf{x}_{t|t}$, $\mathbf{x}_{t|t-1}$ が発散する可能性がある。その原因は、計算機の内部で桁落ちが生じて $V_{t|t-1}$ の精度が悪くなることにある。推定値および予測値の発散は実システムにおいては重大な支障をまねく可能性がある。本論文では、精度を犠牲にしても、行列演算を簡略化することにより、安定して動作する簡略型ロバストフィルタを提案する。

ロバストフィルタは、複雑な行列演算により求められる推定誤差共分散行列に基づいてフィルタリングを行うが、簡略型では単純に予測誤差の分散でフィルタリングを行う。また、ロバストフィルタと同じく Hampel psi function などのロバスト関数を用いることにより欠測値や異常値を取り除くことができる。

簡略型のロバストフィルタを次式で与える。なお、 V_0 はロバスト推定値の分散を表す。

$$\mathbf{x}_{t|t-1} = \mathbf{f}_t(\mathbf{x}_{t-1|t-1}) \quad (28)$$

$$\mathbf{y}_{t|t-1} = \mathbf{H}_t \mathbf{x}_{t|t-1} \quad (29)$$

$$\mathbf{x}_{t|t} = \mathbf{x}_{t|t-1} + \sqrt{V_0} \cdot \Psi\left(\frac{\mathbf{y}_t - \mathbf{y}_{t|t-1}}{\sqrt{V_0}}\right) \quad (30)$$

2.4 簡略型ロバストフィルタの特徴

簡略型ロバストフィルタはデータが定常であるという仮定のもとで議論を行っている。そのため取り扱うデータはある程度定常性があるものでなくてはならない。これに対してロバストフィルタはそのアルゴリズムからわかるように非定常なデータをも取り扱うことが可能である。また、簡略型ロバストフィルタは演算を簡略化しているためフィルタリング精度はロバストフィルタと比べ多少劣るのではないと思われる。

この簡略型ロバストフィルタを用いれば、従来のロバストフィルタの問題点である数値的安定性の問題は回避される。

3. ラジアル基底関数ネットワーク

ラジアル基底関数ネットワーク(RBFN)は、従来のモデルと比較して高速な学習能力や単純なモデル構造といった利点を備えており、勾配法による自己学習が可能である。また、本論文では、与えられたモデル誤差を実現するのに必要な比較的少数の基底関数とモデルパラメータを自動的に決定する最大絶対値誤差選択(MAE)法による自己増殖型アルゴリズム[9]を適用する。

3.1 RBFN の構成

入力 $\mathbf{x} = (x_1, x_2, \dots, x_n)^T \in R^n$, 出力 $\mathbf{y} = (y_1, y_2, \dots, y_p)^T \in R^p$ であるようなシステムの入出力関係 $\mathbf{y} = \mathbf{f}(\mathbf{x}) : R^n \rightarrow R^p$ を、 N 個の入出力データから定義される学習データ集合

$$\{(\mathbf{x}^s, \mathbf{y}^s) \in R^n \times R^p | s=1, \dots, N\} \quad (31)$$

が与えられたもとで近似することを考えよう。

RBFN では、入出力関係を表す写像 $\mathbf{f}(\mathbf{x})$ の各成分 $f_k(\mathbf{x})$, $k=1, \dots, p$ を、 $q (< N)$ 個のラジアル基底関数 $\mu_j(\mathbf{x})$, $j=1, \dots, q$ を用いて

$$f_k(\mathbf{x}) = \sum_{j=1}^q w_{jk} \mu_j(\mathbf{x}) \quad (32)$$

の形式で表現する。ここで、ラジアル基底関数 $\mu_j(\mathbf{x})$ としては、次のようなガウシアン関数

$$\mu_j(\mathbf{x}) = \exp\left(-\frac{\|\mathbf{x} - \mathbf{a}_j\|^2}{b_j^2}\right) \quad (33)$$

がよく用いられる。式(33)において、 $\mathbf{a}_j = (a_{1j}, \dots, a_{nj})^T$ は中心ベクトルであり、 b_j は幅パラメータである。ラジアル基底関数 $\mu_j(\mathbf{x})$ に含まれるこれらのパラメータ $\mathbf{a}_j, b_j, j=1, \dots, q$ は、データ $\mathbf{y}^s$ と $\mathbf{f}(\mathbf{x}^s)$ の平均二乗誤差

$$E = \frac{1}{2} \sum_{s=1}^N \|\mathbf{y}^s - \mathbf{f}(\mathbf{x}^s)\|^2 \quad (34)$$

$$= \frac{1}{2} \sum_{s=1}^N \sum_{k=1}^p (y_k^s - f_k(\mathbf{x}^s))^2 \quad (35)$$

を最小にするようなものが選ばれる。

3.2 学習法(勾配法)

平均二乗誤差 E は $a_{ij}, b_{ij}, i=1, \dots, n, j=1, \dots, q$ の非線形関数となり、 E を最小にする $a_{ij}, b_{ij}, i=1, \dots, n, j=1, \dots, q$ を陽に求めることは困難であるので、最急降下法により(近似)最小解を求める。

最急降下法における更新式は次式で与えられる。

$$a_{ij} = a_{ij} - \gamma \frac{\partial E}{\partial a_{ij}}, \quad i=1, \dots, n, j=1, \dots, q \quad (36)$$

$$b_j = b_j - \gamma \frac{\partial E}{\partial b_j}, j=1, \dots, q \quad (37)$$

$$w_{jk} = w_{jk} - \gamma \frac{\partial E}{\partial w_{jk}}, j=1, \dots, q, k=1, \dots, p \quad (38)$$

ここで、 γ は学習係数である。

基底関数がガウシアン関数のとき、 $\frac{\partial E}{\partial a_{ij}}, \frac{\partial E}{\partial b_j}, \frac{\partial E}{\partial w_{jk}}, i=1, \dots, n, j=1, \dots, q, k=1, \dots, p$, はそれぞれ次のようになる。

$$\frac{\partial E}{\partial a_{ij}} = -\frac{2}{b_j^2} \sum_{s=1}^N \sum_{k=1}^p w_{jk} \cdot \mu_j(\mathbf{x}^s) \cdot (y_k^s - f_k(\mathbf{x}^s)) \cdot (x_i^s - a_{ij}) \quad (39)$$

$$\frac{\partial E}{\partial b_j} = -\frac{2}{b_j^3} \sum_{s=1}^N \sum_{k=1}^p w_{jk} \cdot \mu_j(\mathbf{x}^s) \cdot (y_k^s - f_k(\mathbf{x}^s)) \cdot \sum_{i=1}^n (x_i^s - a_{ij})^2 \quad (40)$$

$$\frac{\partial E}{\partial w_{jk}} = -\sum_{s=1}^N \mu_j(\mathbf{x}^s) \cdot (y_k^s - f_k(\mathbf{x}^s)) \quad (41)$$

3.3 最大絶対値誤差選択(MAE)法による自己増殖型アルゴリズム

各基底関数 $\mu_j(\mathbf{x})$, $j=1, \dots, q$, に対して、重み係数 w_j のみならず中心ベクトル $\mathbf{a}_j$ と幅パラメータ b_j をも更新する最大絶対値誤差(MAE)に基づく自己増殖型アルゴリズムは次の2つの過程から構成される。

- (1) 基底関数が q 個に固定されたもとの勾配法による学習過程 (ν 回目の平均二乗誤差 $E_q(\nu)$ が $E_q(\nu) < \epsilon_0$ (ϵ_0 : 定数) を満たしたとき学習終了)。
 - (2) 学習による誤差の減少度合いがある閾値以下になった段階で、推論誤差の絶対値が最大となる学習データの入力値を初期値とする新たな基底関数を逐次的に発生させる自己増殖過程。
- (2) の評価関数として、誤差関数の減少を

$$D_q(\nu+1) \equiv |(E_q(\nu+1) - E_q(\nu)) / E_q(\nu)| \quad (42)$$

を採用し、

$$D_q(\nu+1) < \epsilon_1 \quad (\epsilon_1: \text{定数}) \quad (43)$$

のとき、新規基底関数を発生させる (ν は学習回数)。

新規基底関数の初期値は、 N 個の入出力データ $(\mathbf{x}^s, \mathbf{y}^s)$, $s=1, \dots, N$, のうちですでに基底関数の中心値として選択されたものを除いたものの中で、絶対値誤差が最大となる入出力データを $(\mathbf{x}^s, \mathbf{y}^s)$ とする。このとき、 $(q+1)$ 個目の新規基底関数は、次式に従って発生させる。

$$\mathbf{a}_{q+1} = \mathbf{x}^s, \quad (44)$$

$$b_{q+1} = \bar{b}, \quad (45)$$

$$\mathbf{w}_{q+1} = \mathbf{y}^s - \mathbf{f}(\mathbf{x}^s) \quad (46)$$

ただし、 $\bar{b}$ はあらかじめ与えられている定数とする。

4. RBF-NARMA モデル

J. T. Connor らは時系列データの予測システムのモデルとしてリカレント NARMA モデル[3]を提案している。この予測システムでは限定されたフィードバックをもつリカレントニューラルネットワークによって表された NARMA モデルが用いられている。また、予測の前処理として時系列データに対してロバストフィルタを用いたフィルタリングを行っている。

本論文では予測システムのモデルとして構造が簡単で高速な学習が可能である RBFN によって表された NARMA モデルを、フィルタリングアルゴリズムとして数値的安定性をもつ簡略型ロバストフィルタを用いる。

自己回帰次数 k , 移動平均次数 l の非線形自己回帰移動平均(NARMA)モデルは次式のように表される。

$$x_t = f(x_{t-1}, x_{t-2}, \dots, x_{t-k}, e_{t-1}, e_{t-2}, \dots, e_{t-l}) + e_t \quad (47)$$

このモデルは NARMA(k, l) と表され、状態空間は $k+l$ 次元である。

本論文では NARMA モデルとして次式を考える。

$$x_t = f(x_{t-24}, x_{t-25}, \dots, x_{t-24-(k-1)}, e_{t-24}, e_{t-25}, \dots, e_{t-24-(l-1)}) + e_t \quad (48)$$

これは24期先予測モデルと考えることができる。このモデルでは自己回帰の次数は k , 移動平均の次数は l であり、NARMA(k, l) と表され、 $k+l$ 次元の状態空間ベクトルによって

$$\mathbf{x}_t = \mathbf{f}(\mathbf{x}_{t-24}) + \mathbf{e}_t \quad (49)$$

$$\mathbf{y}_t = \mathbf{H}\mathbf{x}_t, t=0, 1, \dots \quad (50)$$

と書き表すことができる。ここで $\mathbf{H}$ は $(k+l)$ 次元行ベクトル、 $\mathbf{x}_t, \mathbf{f}(\mathbf{x}_{t-24}), \mathbf{e}_t$ は $(k+l+2)$ 次元列ベクトルでそれぞれ次のように与えられる。

$$\mathbf{H} = (1, 0, \dots, 0) \quad (51)$$

$$\mathbf{x}_t = (x_t, x_{t-24}, \dots, x_{t-24-(k-1)}, e_t, e_{t-24}, \dots, e_{t-24-(l-1)})^T \quad (52)$$

$$\mathbf{f}(\mathbf{x}_{t-24}) = (f(\mathbf{x}_{t-24}), x_{t-24}, \dots, x_{t-24-(k-1)}, 0, e_{t-24}, \dots, e_{t-24-(l-1)})^T \quad (53)$$

$$\mathbf{e}_t = (e_t, 0, \dots, 0, e_t, 0, \dots, 0)^T \quad (54)$$

なお、式(54)右辺の2つ目の e_t は $(k+2)$ 番目に位置する。したがって、時刻 $t-24$ における24期先の予測は

$$\mathbf{x}_{t/t-24} = \mathbf{f}(\mathbf{x}_{t-24/t-24}) \quad (55)$$

$$\mathbf{y}_{t/t-24} = \mathbf{H}\mathbf{f}(\mathbf{x}_{t-24/t-24}) = \mathbf{f}(\mathbf{x}_{t-24/t-24}) \quad (56)$$

となる。また、簡略型ロバストフィルタによる推定値は

$$x_{t/t} = f(x_{t-24/t-24}) + \sqrt{V_0} \Psi\left(\frac{y_t - y_{t/t-24}}{\sqrt{V_0}}\right) \quad (57)$$

となる。

非線形関数 $f(\mathbf{x})$ は図4に示すような RBFN を用いて同定される。この関数は白色雑音 e_t を引数にもつが、実際に計算するときには、 $e_{t/t} = x_{t/t} - \hat{x}_{t/t}$ として求められる推定値を用いる。したがって $f(\mathbf{x})$ は次のように表される。

$$f(\mathbf{x}) = \sum_{j=1}^q w_j \mu_j(\mathbf{x}) \quad (58)$$

5. 冷水負荷予測問題への適用

これまでは予測の対象となっているデータの過去の値のみを予測に用いてきた。これに対し外部変数すなわち予測の対象となっているデータ以外のデータを予測に用いることについて考える。

外部変数は状態空間モデルにおける状態ベクトルに加える。s 個の外部変数を導入した場合、状態ベクトル $\mathbf{x}_t, f(\mathbf{x}_{t-24}), \mathbf{e}_t$ には、それぞれ、 $(\mathbf{x}_t, x_t^1, \dots, x_t^s)^T$, $(f(\mathbf{x}_{t-24}), g(x_{t-1}^1), \dots, g(x_{t-1}^s))^T$, $(\mathbf{e}_t, 0, \dots, 0)^T$ のように s 個の要素が付け加えられる。ここで $g(\cdot)$ は時刻を1進めるオペレータである。

冷水負荷予測問題の場合では外部変数として次の日の予測最高気温、曜日を用いる。次の日の予測最高気温というのは気象庁などの他の機関から提供されるものを用いる。ただし、実験の段階では、過去のデータより取り出した予測したい日の実際の最高気温を用いた。冷水負荷や外部変数はすべて0~1で正規化しておく。また、ネットワーク側では曜日の種類だけ入力ユニットを用意し、対応する入力ユニットには1を、その他の入力ユニットには0が入力される。

これより実際の運用時における予測の手順について説明する。予測の過程は初期学習の部分と、1日毎の学習の部分、1日毎の予測の部分にわけられる。冷水負荷のデータは1時間毎にとりだす。したがって、長時間予測では現時点から24個のデータを予測するということになる。夜間蓄熱との関係から22時から翌日の21時までの予測を行う。蓄熱開始時刻などを考慮すれば、1日の予測を行う時間は1時間程度に抑える必要がある。本論文で用いる RBFN は MAE 法により最初にネットワークを構築する必要がある。また、これによりある程度の同定は行われる。これが初期学習の部分である。

図4 RBF-NARMA ネットワーク

初期学習を行うことによって1日毎の学習は比較的少ない回数で済ませることができる。1日毎の学習が終われば、1日分の予測すなわち22時から翌日の21時までの予測を行う。

初期学習では4週間分の冷水負荷の観測値と外部要因を用いて学習を行う。まず、冷水負荷の生データを教師信号として学習を行う。ここで生データとは平滑化といった加工が何もされていないデータのことである。この結果を利用して、生データに対して簡略型ロバストフィルタをかける。最後にフィルタリングしたデータを教師信号として再度学習を行う。フィルタリングしたデータを教師信号として学習を行うのは欠測値や異常値が生データに含まれていた場合、それを含めて学習が行われるので不必要なものまで学習してしまうからである。フィルタをかけるときに非線形関数 $f(\cdot)$ を使用するの、ある程度 $f(\cdot)$ が同定されていなければ、うまくフィルタをかけることができない。そのため、最初の生データを教師信号とした学習も必要である。

1日毎の学習ではまずフィルタをかけ、その後フィルタリングを行う。そして、そのフィルタリングしたデータを教師信号として学習する。このときの学習回数は初期学習の時の学習回数より少なくて良い。

1日毎の予測では前に述べたように現時刻より24時間分の予測を行う。これは現時刻を N とすれば、 $x_{N+1/N-23}, \dots, x_{N+24/N}$ を求めるということであり

$$x_{N+24-i/N-i} = f(\mathbf{x}_{N-i/N-i}), \quad i=0, \dots, 23 \quad (59)$$

と求める。

6. 実行結果

実際に、欠測値、異常値を含む冷水負荷データの中
の4週間分を初期学習用データ、次の1週間分を検証用
データとして用いて実験を行った。この際、入力とし
て24時間分の冷水負荷データ、曜日データおよび気温
データを与えた。また、NARMA のモデルの次数は
 $k=24, l=24$ とし、RBF-NARMA モデルにおけるパ
ラメータ値はいくつかの設定の中でもっともよい結果
を与えた $\varepsilon_0=0.3, \varepsilon_1=0.001$ とした。

まず、簡略型ロバストフィルタでフィルタリングし
た結果を図5に示す。

この結果から、簡略型ロバストフィルタが時刻376付
近の欠測値や時刻354付近の異常値を除去している様
子が観察できる。しかしながら、図5の時刻349のと
ころの突起のように異常値ではないのにフィルタの出力
と原データとの間に大きな差異が生ずることもあり、
この問題点の解決は今後の課題である。

また、本論文で提案している RBF-NARMA モデル
と J. T. Connor らのリカレント NARMA モデル[3]
を実冷水負荷データを用いた予測に適用した際、RBF-
NARMA モデルによる予測における学習は、リカレン
ト NARMA モデルによる予測における学習に比べて、
約1.5倍速く収束した。これは、RBF-NARMA モデル
による提案予測手法では簡略型ロバストフィルタが採
用されており、演算が簡素化された効果であると考え
られる。このときの予測結果を、それぞれ、図6,7に示

図5 簡略型ロバストフィルタによるフィルタリング

表1 予測結果

	正規化された 平均二乗誤差	1800 Mcal 以内の割合
リカレント NARMA モデル	3.22×10^{-3}	81.5 %
RBF-NARMA モデル	1.93×10^{-3}	92.9 %

す。これらの図から、RBF-NARMA モデルによりリ
カレント NARMA モデルよりも良い予測が得られて
いることが視覚的に確認できる。

さらに、正規化された平均二乗誤差、および、実測
値と予測値の差が実システムにおける誤差の許容範囲
である1800Mcal 以内であった割合を表1に示す。これ
らの図および表は、RBF-NARMA モデルによる予測
がリカレント NARMA モデルによる予測より精度の
面においても同等以上であることを示している。しか
しながら、図において、手法によって予測値の波形が

図6 RBF-NARMA モデルによる予測結果

図7 J. T. Connor らのリカレント NARMA モデルによる予測結果

大きく異なっているが、この理由については現在解析中であり、今後の課題である。

7. おわりに

本論文では、地域冷暖房システムの冷水負荷予測を目的として、ロバストフィルタの数値的安定性の問題を改善した簡略型ロバストフィルタの提案を行った。また、非線形時系列予測システムとしてRBF-NARMAモデルを提案した。これは非線形予測手法としてRBFNを用い、それにより同定した関数を用いて簡略型ロバストフィルタがフィルタリングを行うというシステムである。さらに、提案手法の有効性を検証するために、実データを用いて、J. T. ConnorらのリカレントNARMAモデルと予測結果の比較を行い、RBF-NARMAモデルの有効性を示した。

ただし、簡略型ロバストフィルタにおいては、データの定常性を暗に仮定していることに注意すべきであるが、実システムにおける運用を考える場合に安定性は非常に重要な要因であるので、精度を多少犠牲にしてもロバストフィルタのような複雑な演算を用いない単純で安定した簡略型ロバストフィルタは特に有効であると考えられる。

参 考 文 献

- [1] “特集地域冷暖房プラントの冷水負荷予測”, 空気調和・衛生工学, Vol.67, pp.583-634, 1993.
- [2] R. D. Martin and D. J. Thompson, “Robust-resistant Spectrum Estimation”, Proc IEEE, Vol.70, pp.1097-1115, 1982.
- [3] J. T. Connor and R. D. Martin, “Recurrent Neural Networks and Robust Time Series Prediction”, IEEE Trans. on Neural Networks, Vol.5, pp.240-254, 1994.
- [4] R. E. Kalman, “A New Approach to Linear Filtering and Prediction Problems”, Trans. ASME, J. Basic Eng., Vol.82d, No.1, pp.35-45, 1960.
- [5] 榎木義一, 片山徹, “非線形制御系の状態変数の推定について”, 制御工学, Vol.11, No.7, pp.361-368, 1967.
- [6] 片山徹, “応用カルマンフィルタ”, 朝倉書店, 1983.
- [7] 坂和正敏, 田中雅博, “ニューロコンピューティング入門”, 森北出版, 1997.
- [8] 丸山稔, “Radial Basis Functionsを用いた学習ネットワーク—ニューロコンピューティングに対する新しいアプローチ”, システム/制御/情報, Vol.36, No.5, pp.322-329, 1992.
- [9] 片山立, “ファジィ・ニューラルネットワークモデルによる同定手法とその応用に関する研究”, 慶応義塾大学博士論文, 1995.

(1998年1月22日 受 付)

(1998年6月11日 再 受 付)

(1998年8月12日 再々受付)

[問い合わせ先]

〒739-8527

東広島市鏡山1-4-1

広島大学工学部第二類(電気系)

計数管理工学講座

坂和 正敏

TEL : 0824(24) 7694, (22) 7159

FAX : 0824(24) 7694, (22) 7195

E-mail : sakawa@msl.sys.hiroshima-u.ac.jp

著 者 紹 介

坂和 正敏 (さかわ まさとし)

広島大学工学部第二類(電気系)計数管理工学講座

昭和45年 京大・工・数理卒, 昭和50年 神大・工・システム助手, 昭和56年 同助教授, 昭和62年 岩手大・工・教授を経て, 平成2年 広島大・工・第二類(電気系)計数管理工学講座教授となり現在に至る。大規模システム, 多目的システム, ファジィシステムにおける意思決定手法とその応用に関する研究に従事。工博。著書線形システムの最適化, 非線形システムの最適化, ファジィ理論の基礎と応用, 経営数理システムの基礎(森北出版), ソフト最適化, 遺伝的アルゴリズム(朝倉書店), Fuzzy Sets and Interactive Multiobjective Optimization (Plenum Press)等。

後呂 智 (うしろ さとし)

新菱冷熱工業(株)

昭和57年 京工織大・建築工芸学専攻修士課程了。昭和57年 新菱冷熱工業(株)入社, 技術開発部(現中央研究所)にて, 気流シミュレーションの研究に従事。昭和61年より中央監視システムの開発に従事し, 現在に至る。空気調和衛生工学会会員。

加藤 浩介 (かとう こうすけ)

広島大学工学部第二類(電気系)計数管理工学講座

平成3年 阪大・基礎工・生物工卒。平成5年 同大学大学院博士課程前期了。平成6年 同後期退学。平成6年 広島大・工・第二類(電気系)計数管理工学講座助手となり現在に至る。データ圧縮, 遺伝的アルゴリズムおよびシステム最適化手法とその応用に関する研究に従事。

井上 拓也 (いのうえ たくや)

広島大学工学部第二類(電気系)計数管理工学講座

平成8年 広島大・工・第二類(電気系)卒。平成8年 同大学院博士課程前期入学。現在に至る。ニューラルネットワークを用いた冷水負荷予測に関する研究に従事。

Cooling Load Prediction through Radial Basis Function Network and Simplified Robust Filter

by

Masatoshi SAKAWA, Satoshi USHIRO, Kosuke KATO and Takuya INOUE

Abstract :

Cooling load is the heat value of chilled water used for air-conditioning in a district heating and cooling system. Cooling load prediction is indispensable for operating a district heating and cooling system. For several reasons, the real data sets usually involve some outliers and missing data. In this paper, we focus on cooling load prediction problems in a district heating and cooling system. For dealing with such real data sets, a simplified robust filter which improves a numerical stability problem of a robust filter is proposed for filtering. Then RBF-NARMA model, which is a nonlinear autoregressive moving-average (NARMA) model through a radial basis function network (RBFN), is presented for time series prediction. The effectiveness of the prediction method proposed in this paper is demonstrated by applying both the proposed method and the recurrent NARMA model based method proposed by J. T. Connor et al.

Keywords : Cooling Load Prediction, Simplified Robust Filter, Radial Basis Function Network (RBFN), Nonlinear Auto Regressive Moving Average (NARMA) Model, RBF-NARMA Model

Contact Address : **Masatoshi SAKAWA**

Faculty of Engineering, Hiroshima University
1-4-1, Kagamiyama, Higashi-Hiroshima, 739-8527 Japan
TEL : 0824-24-7694/22-7159
FAX : 0824-24-7694/22-7195
E-mail : sakawa@msl.sys.hiroshima-u.ac.jp