

ニューラルネットワークによる説明変数をもつ時系列データの予測における学習データの選定方法

下平 丕作[†]

多層フィードフォワード型ニューラルネットワークを用いた時系列データの予測における予測精度は、過去のデータからどのようなデータを選定し学習するかに依存する。学習データの選定方法としては、従来からよく用いられている移動窓データ学習法 (MWDL 法) のほか、予測の基礎となるデータと類似したデータをその間の距離に基づいて選定する類似データ選定学習法 (SDSL 法) が提案されている。筆者は、先に、その距離の計算において、相関係数のべき乗の関数で重みづけを行う方法 (CSDS 法) を提案し、1 変数の時系列データについて、数値実験により CSDS 法の有効性を示した。本論文では、説明変数をもつ時系列データについて、CSDS 法を拡張するとともに、ビルの空調の予熱時間と予冷時間のデータを用いて、これらの方法の予測精度の比較を行っている。数値実験の結果によると、CSDS 法は、1 変数の場合と同様に、変わりやすい性質の予熱時間データの場合に予測精度の向上にかなり有効であり、最も適切に用いた場合、MWDL 法よりもかなり予測精度がよいことが分かった。これらの結果から、CSDS 法を用いた SDSL 法は、変わりやすい時系列データについての学習データ選定法として有力な方法となり得るものと考えられる。

A Method of Selecting Learning Data in the Prediction of Time Series with Explanatory Variables Using Neural Networks

HISASHI SHIMODAIRA[†]

In the prediction of time series using multilayer feedforward neural networks, the prediction accuracy depends on how to learn the past data. As the method of selecting learning data, methods have been proposed such as the moving window data learning method (MWDL method) and the similar data selective learning method (SDSL method). In a previous paper, we proposed the CSDS method which uses correlation coefficients of the time series as weights in the equation for defining the distance for selecting similar data in the SDSL method, and showed the effectiveness of the CSDS method by numerical simulations concerning single variable data. In this paper, we expand the CSDS method to the case of time series with explanatory variables and show the results of numerical simulation. According to the results, in the case of a time series for heating warming-up time whose nature is choppy, the CSDS method was considerably effective to improve the prediction accuracy, and the accuracy by the SDSL method using the CSDS method was superior to that by the MWDL method. Thus it seems to be concluded that the SDSL method using the CSDS method is useful in the case of time series whose nature is choppy.

1. ま え が き

多層ニューラルネットワークを用いた時系列予測について、フィードフォワード型とリカレント型のニューラルネットワークを比較した例¹⁾によると、フィードフォワード型ではかなり精度のよい予測値が、また、リカレント型ではきわめて精度のよい予測値が得られているが、リカレント型はフィードフォワード型に

比べて、きわめて多大な学習時間を要している。実際に産業への応用を考えると、構成が簡単で学習時間が比較的短いフィードフォワード型のニューラルネットワークを用いて、できるだけ精度のよい予測値が得られる方法の開発が望まれる。本論文では、この観点から、学習データの選定方法について検討する。

多層フィードフォワード型ニューラルネットワークを用いた時系列データの予測において、精度のよい予測値を得るためには、規模の大きなネットワークに数多くのデータを学習させればよいというものではなく、データの性質に応じた適切な規模のネットワー

[†] 日本メックス株式会社 研究開発部
Research and Development Department, Nihon MECCS Corp., Ltd.

くに、過去のデータベースから適切なデータを選定して学習させることが必要である。学習データの選定方法として、従来よく用いられている移動窓データ学習法 (MWDL 法: Moving Window Data Learning Method)²⁾では、予測すべき時点の直近に学習データを選定する一定の大きさの窓を設定し、その範囲のデータをすべて学習する。この窓は、予測すべき時点に応じて、徐々に移動していく。また、類似データ選定学習法 (SDSL 法: Similar Data Selective Learning Method)^{3),4)}では、予測時点直近の予測の基礎となるデータと類似したデータを、過去のデータベースから選定して学習する。Peng ら³⁾は、説明変数をもつ時系列データの予測について、入力変数による出力変数の微分値を用いて重みづけした距離に基づいて類似データを選定する方法を提案し、その方法は MWDL 法よりも予測精度が優れていると述べているが、具体的な比較は示されていない。

筆者⁴⁾は、類似データを選定する際の距離の計算において、時系列データの相関係数のべき乗の関数で重みづけを行う CSDS 法 (Correlation Coefficient Based Similar Data Selection Method) を提案した。1 変数の時系列データについて、数値実験により MWDL 法と SDSL 法の予測精度を比較し、CSDS 法がわかりやすい時系列データの場合に予測精度向上の効果があることを示した。しかし、説明変数をもつ場合については、将来の研究課題として残されていた。そこで、本論文では、説明変数をもつ時系列データの場合について CSDS 法を拡張するとともに、数値実験により、CSDS 法を用いた SDSL 法と MWDL 法の予測精度を調べることとする。数値実験に用いたデータは、建物の空調の予熱・予冷時間に関するデータである。予熱・予冷時間とは、ある部屋の空調装置を起動してから、室温等が目標値になるまでの時間をいう。予熱・予冷時間の予測は、無駄なエネルギーを消費しないで、その部屋の使用開始時に室温等が目標値になるようにするために必要である。

2 章では、多層フィードフォワード型ニューラルネットワークによる時系列データの予測方法の概要と、CSDS 法を用いた SDSL 法と MWDL 法について述べる。3 章では、数値実験の結果を示し、4 章では、本論文と既往の研究との関連について述べる。5 章では、まとめと今後の課題について述べる。

2. 予測方法と学習データの選定方法

2.1 予測方法の概要

ここでは、応答変数 y_i ($i = 1, \dots, t, \dots, \infty$) に対

して、一つの説明変数 x_i ($i = 1, \dots, t, \dots, \infty$) がある場合について説明する。説明変数が複数ある場合には、それに対応する項を追加すればよい。後の数値実験のデータに対応させて、応答変数については y_{t-1} までの、説明変数については x_t までの値が観測されているものとし、1 時点先の y_t を予測する場合を扱う。説明変数と応答変数についてそれぞれ時点 t の直近の d 個および $(d-1)$ 個のデータ (予測用データグループとよぶ) に基づいて、 y_t を予測するものとする、

$$\begin{aligned} (x_{t-d+1}, \dots, x_{t-1}, x_t, y_{t-d+1}, \\ \dots, y_{t-2}, y_{t-1}) \longrightarrow Y_t \end{aligned} \quad (1)$$

ここで、 Y_t は y_t の予測値である。予測時には、入力層のノードに式 (1) の左辺のデータが入力され、出力層のノードに Y_t が出力される。このような予測値を出力するために、過去のデータを学習してネットワークの重みの値を求める。学習時には、教師データを $y_{t'}$ とすれば、説明変数と応答変数についてそれぞれ時点 t' の直近の d 個および $(d-1)$ 個のデータ (学習用データグループとよぶ) を用いて、次式のように $Y_{t'}$ を出力する。

$$\begin{aligned} (x'_{t'-d+1}, \dots, x'_{t'-1}, x_{t'}, y'_{t'-d+1}, \\ \dots, y'_{t'-2}, y'_{t'-1}) \longrightarrow Y_{t'} \end{aligned} \quad (2)$$

誤差逆伝播法⁵⁾により、 n 個の学習用データグループを用いて、出力値と計測値の差の 2 乗和の 1/2 が最小になるように、繰り返し計算によって重みの値を求める。

予測値の精度は、学習用データを選定する範囲、学習・予測に用いる各変数のデータ数 d 、学習用データグループ数 n に依存する。また、適切な隠れ層のノード数 h は、データの性質や d 、 n によって異なる。 d 、 n 、 h の最適値は、対象とする時系列データの性質によって異なり、理論的には求められないので、既存の計測値を用いて、数値実験において試行錯誤により定める。

2.2 類似データ選定学習法 (SDSL 法)

この方法では、予測用データグループに類似したデータグループを、学習データ選定範囲内から類似度が高い順に選定して学習する。類似度の尺度として、重み付き距離⁶⁾を用いる。異なった単位のデータを用いた距離の計算を意味のあるものにするために、次式により、学習データ選定範囲内のデータの無次元化と基準化を行う (添字 s により基準化した値を表す)。

$$x_i^s = (x_i - m_x) / d_x \quad (3)$$

$$y_i^s = (y_i - m_y) / d_y \quad (4)$$

ここに、 m_x と m_y はそれぞれ説明変数と応答変数

の平均値である。\$d_x\$ と \$d_y\$ は、次式によって表されるそれぞれの変数の平均絶対偏差である。

$$d_x = \frac{1}{n_x} \sum_{i=1}^{n_x} |x_i - m_x| \quad (5)$$

$$d_y = \frac{1}{n_y} \sum_{i=1}^{n_y} |y_i - m_y| \quad (6)$$

\$n_x\$ と \$n_y\$ は、それぞれの変数のデータの個数である。式(3)と(4)において、平均絶対偏差の代わりに標準偏差を用いることもできるが、標準偏差はあるデータとその平均値の差の2乗によって計算されるので、値の大きなデータの影響が強く表れる。

予測用と学習用のデータグループにおける説明変数と応答変数のデータをそれぞれ \$d\$ および \$(d-1)\$ 次元のユークリッド空間における点と考えると、その間の距離の総和を計算する。その距離が小さいほど類似度が高いものと考え、距離が小さい順に \$n\$ 個の学習用データグループを選定する。筆者が提案した CSDS 法⁴⁾ をこの場合に拡張すれば、次のようになる。

予測用と学習用のデータグループの間の重みつきマンハッタン距離は、次式で表される。

$$D = \sum_{i=0}^{d-1} |\rho_{xi}|^m |x_{t-i}^s - x_{t'-i}^s| + \sum_{i=1}^{d-1} |\rho_{yi}|^m |y_{t-i}^s - y_{t'-i}^s| \quad (7)$$

また、重みつきユークリッド距離は次式で表される。

$$D = \left\{ \sum_{i=0}^{d-1} |\rho_{xi}|^m (x_{t-i}^s - x_{t'-i}^s)^2 \right\}^{\frac{1}{2}} + \left\{ \sum_{i=1}^{d-1} |\rho_{yi}|^m (y_{t-i}^s - y_{t'-i}^s)^2 \right\}^{\frac{1}{2}} \quad (8)$$

ここで、\$\rho_{xi}(0 \le \rho_{xi} \le 1)\$ は \$y_t\$ と \$x_{t-i}\$ の間の相関係数であり、\$\rho_{yi}(0 \le \rho_{yi} \le 1)\$ は、\$y_t\$ と \$y_{t-i}\$ の間の自己相関係数である。これらを \$m\$ 乗しているのは、距離の計算においてその値の大小による重みづけの度合を調整するためであり、その望ましい値は数値実験において試行錯誤により定める。

自己相関係数 \$\rho_{yi}\$ は、\$y_t\$ が \$y_{t-i}\$ に依存する度合を表しており、その値が大きいほど \$y_t\$ は \$y_{t-i}\$ の影響を強く受ける。相関係数 \$\rho_{xi}\$ は、\$y_t\$ が \$x_{t-i}\$ に依存する度合を表しており、その値が大きいほど \$y_t\$ は \$x_{t-i}\$ の影響を強く受ける。式(7)と(8)は、その距離の計算において、\$\rho_{xi}\$ と \$\rho_{yi}\$ が大きい座標軸ほどその座標値を大きく扱うことを表している。これは、データグ

ループの類似度の計算において、先験的知識に基づいて、より重視するデータの座標値により大きな重みづけを行うテクニック⁶⁾と同じ考え方である。これにより、予測すべき値により強い影響を持つデータを重視した距離が計算される。

学習データ選定範囲の始点を \$x_s\$ および \$y_s\$ とすれば、\$\rho_{xi}\$ は、厳密には、\$(x_s, y_{s+i}), (x_{s+1}, y_{s+i+1}), \dots, (x_{t-i-1}, y_{t-1}), (x_{t-i}, y_t)\$ のデータの組によって計算すべきであるが、\$y_t\$ は未知であるから、\$(x_{t-i}, y_t)\$ を除いたデータの組によって計算する。また、\$\rho_{yi}\$ は、厳密には、\$(y_s, y_{s+i}), (y_{s+1}, y_{s+i+1}), \dots, (y_{t-i-1}, y_{t-1}), (y_{t-i}, y_t)\$ のデータの組によって計算すべきであるが、\$y_t\$ は未知であるから、\$(y_{t-i}, y_t)\$ を除いたデータの組によって計算する。

式(7)と(8)では、\$y_t\$ と \$x_{t-i}\$ および \$y_{t'}\$ と \$x_{t'-i}\$ についての相関係数が同一であることを前提としている。\$y_t\$ と \$y_{t-i}\$ および \$y_{t'}\$ と \$y_{t'-i}\$ についての自己相関係数についても同様である。このような前提がほぼ成立する場合には、学習データ選定範囲の始点を固定し、計測されたデータが増えるに従って、学習データ選定範囲を拡大していくことにより、過去のデータを有効に活用できる。この方法を、学習データ選定範囲拡大法とよぶ。上記の前提が成立しない場合には、相関係数および自己相関係数が大幅に異なる範囲で学習データ選定範囲の大きさを設定し、予測すべき時点に応じて、順次これを移動していく(始点を前方にずらしていく)方法を考える。これを、学習データ選定範囲移動法とよぶ。

式(7)のマンハッタン距離では、座標値の差そのものが考慮されるのに対し、式(8)のユークリッド距離では、その2乗が考慮される。したがって、ユークリッド距離ではマンハッタン距離に比べて、座標値の差の大きなものがより大きな影響を与えることとなる。用いる距離の定義が予測精度に及ぼす影響を、数値実験により調べることにする。

2.3 移動窓データ学習法 (MWDL 法)

MWDL 法では、予測時点 \$t\$ の直近に設けた移動窓内のデータを、式(2)のような関係でグループ化して、すべて学習する。本論文では、学習用データグループ数 \$n\$ と \$d\$ によって移動窓の大きさを定義する。

3. 数値実験

3.1 数値実験の方法

本章では、計測された室温等に基づいて求めた予熱・予冷時間とその説明変数についての時系列データを用いて、SDSL 法と MWDL 法により数値実験を行った

結果について述べる。

予熱時間については山形市内の A ビル, 予冷時間については東京都内の B ビルにおいて計測された特定の部屋の温度, 湿度等を用いた。これらのデータは 1 時間ごとに計測されているため, 空調装置の起動時刻の温度等は直前の計測時点の値に等しいものとして, 起動時と計測時および計測時と計測時の間を直線で補間して, 目標温度等になるのに要する時間を求め, 近似的な予熱・予冷時間の計測値として用いた。2 章で述べたように, 応答変数 (予熱・予冷時間) について予測日前日までの $(d-1)$ 個の値, および各説明変数について予測日を含む d 個の値を用いて, 当日の応答変数の値を予測した。土・日曜日等の休日には空調装置を運転しないので, 休日は予測の対象から除いている。

予測の実験に先立って, データの性質を調べるために, 応答変数の全データを用いて自己相関係数を計算した。自己相関係数は, 時系列データの本質的な滑らかさ (essential smoothness) を表している⁷⁾。滑らかな (smooth) 時系列データでは, 時差 (τ) が大きくなっても大きな自己相関係数を呈する。変わりやすい (choppy) な時系列データでは, τ が大きくなると急速に自己相関係数はほとんどゼロに近い値になる。また, 説明変数と応答変数の間の相関係数を計算して, 入力として用いるべき説明変数の選定の参考にした。

用いたニューラルネットワークは, 3 層のフィードフォワード型のものである。入力層のノード数は, 説明変数の数を k とすれば, $(k+1)d-1$ に等しい。隠れ層と出力層の活性化関数として, ロジスティック関数 ($g(x) = 1/(1+e^{-x})$) を用いた。予測時点ごとに, 入力データ (学習用データグループおよび予測用データグループのデータ) を $[0.2, 0.8]$ の範囲内の値になるようにスケーリングした。このようなスケーリングを行うことによって, 各予測時点で扱う数値の大きさの程度をそろえることができる。

誤差逆伝播法においては, すべての学習用データグループについての誤差の和を一括して逆伝播させる方法を用いた。学習率は 0.1, 慣性項の係数は 0.9 とした。収束条件は, 出力ノードの誤差の 2 乗和の $1/(2n)$ があらかじめ定めた値になったときとした。予測精度との関係を調べた予備実験の結果から, 予熱時間と予冷時間の予測について, それぞれ 0.001 と 0.0005 を用いた。

SDSL 法では, 予備実験によると, 予熱・予冷時間の予測の両者とも, データ選定範囲拡大法よりもデータ選定範囲移動法の方が予測精度がよいことが分かっ

たので, 後者を用いた。学習データ選定範囲の大きさを 40 日とし, 予測開始日のその始点を全データの先頭とした。予測開始日との関係で予測日が 40 日以内にある場合には, データの先頭から予測日 (応答変数ではその前日) までとした。距離の計算方法として式 (7) と (8) を用いて, 相関係数を考慮しない場合, および m を整数値として変化させて相関係数を考慮した場合について, 学習・予測に用いる各変数のデータ数 d , 学習用データグループ数 n , および隠れ層のノード数 h を少しずつ変化させて, 予測精度が最もよい組合せを探した。

MWDL 法では, 指定した予測日から, 順次, 学習と予測計算を行った。SDSL 法と同様にして, 予測精度が最もよい d, n, h の組合せを探した。

予測精度の評価のための尺度として, 計測値と予測値の間の相関係数 CRC , 絶対誤差 ABE の平均値 (mean) と標準偏差 (σ), 相対誤差 RLE の平均値 (mean) と標準偏差 (σ) を計算した。計測値と予測値の間の相関係数は, 個々の値が合っているかどうかよりも, 全体としての変化の傾向がどの程度類似しているかを表すものである。絶対誤差は, 次式で計算した。

$$ABE = |Y_i - y_i| \times 100/y_{max} \quad (9)$$

ここで, y_{max} は予測したデータの範囲内における計測値の最大値である。 y_{max} に対する比を求めているのは, 計測値の最大値に比べて, 個々の誤差がどの程度であるかをみるためである。相対誤差は, 次式で計算した。

$$RLE = |Y_i - y_i| \times 100/y_i \quad (10)$$

予測値が時系列データの下限に近い小さい値であるときは, 上式の分母と分子が同程度の大きさになることがあるため, 相対誤差の平均値と標準偏差はかなり大きな値になる場合があることに注意すべきである。

3.2 予熱時間の予測

1993 年 12 月および 1994 年 1 月から 3 月までの 76 日分のデータを用いた。空調装置は, その日の寒暖に応じて午前 8 時から 9 時までの間に起動された。目標温度を 20°C とし, 前述のようにして予熱時間の計測値を求めた。図 1 に, 各予測日 (横軸) の予熱時間の計測値を折れ線グラフで示す。図の横軸の, たとえば 94.1 は予測日が 94 年 1 月に属することを示している。説明変数として, 当日の午前 8 時の室内の温度と湿度, および前日 (空調装置の運転のいかんにかかわらず) の午前 12 時の室温を用いた。通常, 休日の翌日には建物が冷えきっているため, 予熱時間が長くなる。前日 12 時の室温は, 前日の室温とともに空調装置が運転されていたかどうかを考慮するために用いた。




図1 予熱時間の計測値の時系列データとその予測値の比較
Fig. 1 Time series data for warming-up time vs. its predicted values.


図2に、時差(τ)と相関係数(ρ)の関係を示す。この時系列データでは、自己相関係数は5日の周期を示しているが、 τ が1以上では小さな値であり(図2(a)), 時間的にも変化が激しい(図1)ことから、極めて変わりやすい性質を持っているといえよう。用いた説明変数の相関係数は、 $\tau=0$ でかなり大きな値となっており(図2の(b), (c), (d)), 予熱時間とかなり強い相関関係を持っているが、 τ が1以上では小さな値となっており、ごく狭い範囲の過去の値が影響することが分かる。これ以外のデータ(午前8時の外気の温度等)の相関係数の値は比較的小さいため、説明変数として用いなかった。

予測開始日をデータの先頭から24番目の日として、予測計算を行った。表1に、最もよい予測精度が得られた場合のパラメータの値を示す。表1で、たとえば、7-11-1は入力層、隠れ層、および出力層のノード数が、それぞれ7, 11, 1であることを示す。表2に、このようなパラメータ値を用いた場合の、SDSL法による予測結果を示す。表中の記号で、 $DST=1$ はマンハッタン距離を、 $DST=2$ はユークリッド距離を表す。また、 $COR=0$ は式(7)と(8)の距離の計算で相関係数を考慮しないことを、 $COR=1$ は考慮することを表す。以下の表においても、同様である。この結果から、距離の計算において相関係数による重みづけをしない場合に比べて、CSDS法により適切な次数 m によりこれを考慮すれば、かなり予測精度が向上す


ることが分かる。適切な m は、マンハッタン距離とユークリッド距離の両者について2である。距離の定義による差はあまり大きくはないが、ユークリッド距離で $m=2$ とした場合の予測精度が最もよい。この場合の予測値の時間的変化を、図1(a)に示す。この場合、相関係数を考慮しない場合に比べて、計測値と予測値の間の相関係数は9.92%大きく、絶対誤差の平均値と標準偏差はそれぞれ23.3%と28.3%小さく、また、相対誤差の平均値と標準偏差はそれぞれ27.9%と25.9%小さくなっている。

表3に、最適のパラメータ値を用いた場合のMWDL法の予測結果を示す。図1(b)に予測値の時間的変化を示す。図1の(a)と(b)を比較すると、1月から3月の上旬までの期間、CSDS法を用いたSDSLの方がより計測値に近い予測値を与えていることが分かる。MWDL法と比較すると、CSDS法でユークリッド距離を用いて $m=2$ とした場合に、相関係数は4.0%大きく、絶対誤差の平均値と標準偏差はそれぞれ15.4%と8.5%小さく、相対誤差の平均値は18.0%小さくなっている。これらの結果から、CSDS法により適切な次数で相関係数を考慮したSDSL法はMWDL法に比べて、予測精度がかなりよいといえよう。


なお、この建物の空調は運転管理者が制御する装置と居住者が自由に制御する装置とから成っている。図1に示すように、SDSL法とMWDL法の両者とも、3月中下旬には予測値は計測値とかなり異なっている。




(a) 自己相関係数
(a) Autocorrelation coefficients.



(b) 午前8時の室温
(b) Room temperature at 8 a.m.



(c) 午前8時の室内湿度
(c) Room relative humidity at 8 a.m.



(d) 前日午前12時の室温
(d) Room temperature at 12 a.m. on previous day.

図2 予熱時間データの自己相関係数および説明変数データとの相関係数

Fig. 2 Correlation coefficients for warming-up time data between itself and its explanatory variable data.

これは、気候の寒暖の変化が激しくなり、前日に居住者がセットした装置の状態が当日の気候に合わないために生じたものであると推測される。

3.3 予冷時間の予測

1993年8月、9月および1994年7月から9月までの82日分のデータを用いた。空調装置は、常に午前7時45分に起動された。冷房の場合には、温度だけでなく湿度も快適さに影響があるため、扱う変数を不

表1 予熱時間予測時の最適パラメータ値

Table 1 Optimum parameter values for the prediction of warming-up time.

方法	d	ネットワークの構成	n
SDSL	2	7-11-1	20
MWDL	2	7-8-1	22

表2 最適パラメータ値を用いたSDSL法による予熱時間の予測結果

Table 2 Prediction results for warming-up time with SDSL method using optimum parameter values.

DST	COR	m	CRC	ABE	ABE	RLE	RLE	
			mean	σ	mean	σ		
1	0	—	0.823	8.12	7.74	24.0	16.9	
			1	0.888	6.92	5.85	20.5	16.5
			2	0.907	6.31	5.13	18.8	15.2
			3	0.887	6.97	5.64	20.5	15.4
2	0	—	0.827	7.95	7.38	24.7	21.6	
			1	0.873	7.68	6.16	22.5	16.3
			2	0.909	6.10	5.29	17.8	16.0
			3	0.910	6.26	4.95	19.4	16.0

表3 最適パラメータ値を用いたMWDL法による予熱時間の予測結果

Table 3 Prediction results for warming-up time with MWDL method using optimum parameter values.

CRC	ABE	ABE	RLE	RLE
mean	σ	mean	σ	
0.874	7.21	5.78	21.7	16.0

快指数とした。不快指数 DI は、次式で表される。

$$DI = 0.72(t_a + t_w) + 40.6 \quad (11)$$

ここで、 t_a は乾球温度 ($^{\circ}C$)、 t_w は湿球温度 ($^{\circ}C$) である。目標不快指数を75 (この値以上ではやや暑いと感じる境界の値) として、前述のようにして予冷時間の計測値を求めた。図3に、各予測日 (横軸) の予冷時間の計測値を折れ線グラフで示す。説明変数として、当日の午前7時の室内の不快指数、当日の午前7時の外気の不快指数、および前日 (空調装置の運転のいかんにかかわらず) の午前12時の室内の不快指数を用いた。通常、休日の翌日には建物の温度が高くなっているため、予冷時間が長くなる。前日12時の室内の不快指数は、前日の室内の温度・湿度とともに空調装置が運転されていたかどうかを考慮するために用いた。

図4に、時差 (τ) と相関係数 (ρ) の関係を示す。自己相関係数は τ が小さい範囲でかなり大きな値であり、 τ が大きくなるにつれて次第に小さくなっていく (図4の(a))。ことから、この時系列データは滑らかに変化する性質を持っており、かなり広い範囲の近傍の値が影響することが分かる。説明変数について




図3 予冷時間の計測値の時系列データとその予測値の比較
Fig. 3 Time series data for pulling-down time vs. its predicted values.

表4 予冷時間予測時の最適パラメータ値

Table 4 Optimum parameter values for the prediction of pulling-down time.

方法	<i>d</i>	ネットワークの構成	<i>n</i>
SDSL	6	23-3-1	22
MWDL	6	23-1-1	19

表5 最適パラメータ値を用いたSDSL法による予冷時間の予測結果

Table 5 Prediction results for pulling-down time with SDSL method using optimum parameter values.

DST	COR	<i>m</i>	CRC	ABE	ABE	RLE	RLE
			mean	σ	mean	σ	
1	1	0	0.886	6.02	5.16	11.5	8.93
		5	0.899	5.67	4.76	11.3	9.07
		6	0.908	5.50	4.48	10.8	8.18
2	1	7	0.898	5.54	5.00	11.1	10.0
		0	0.893	5.88	4.96	11.6	9.12
		2	0.885	5.89	5.29	11.6	10.1
		3	0.890	5.76	5.14	11.4	9.96
		4	0.886	6.01	5.05	12.0	9.88

の相関係数は自己相関係数と同様な傾向を示しており(図4の(b), (c), (d)), 用いた説明変数は, 予冷時間とかなり強い相関関係を持っていることが分かる。

予測開始日をデータの先頭から28番目の日として, 予測計算を行った。表4に, 最もよい予測精度が得られた場合のパラメータの値を示す。表5に, このようなパラメータ値を用いた場合の, SDSL法による予測結果を示す。距離の計算において相関係数による重み

表6 最適パラメータ値を用いたMWDL法による予冷時間の予測結果

Table 6 Prediction results for pulling-down time with MWDL method using optimum parameter values.

CRC	ABE	ABE	RLE	RLE
	mean	σ	mean	σ
0.915	5.46	4.48	10.5	7.60

づけをしない場合に比べて, CSDS法を用いた場合, マンハッタン距離ではやや予測精度がよいが, ユークリッド距離では同程度かやや悪い結果になっている。マンハッタン距離で $m = 6$ とした場合の予測精度が最もよい。この場合の予測値の時間的変化を, 図3(a)に示す。

表6に, 最適のパラメータ値を用いた場合のMWDL法の予測結果を示す。図3(b)に予測値の時間的変化を示す。CSDS法を用いたSDSL法で予測精度が最もよい場合(マンハッタン距離を用いて $m = 6$ とした場合)とMWDL法と比較すると, 後者の方がやや予測精度がよい。

なお, この建物の空調装置は冷房負荷が大きく全室で連続運転すると契約電力量をオーバーする恐れがあるときは, 冷房負荷に応じてある時間ごとに間欠運転されるようになっている。8月上旬における計測値の変化は, このような運転条件の差異によるものであり, 予測には運転条件についての説明変数を用いていないため, 予測精度が悪くなっているものと推測される。

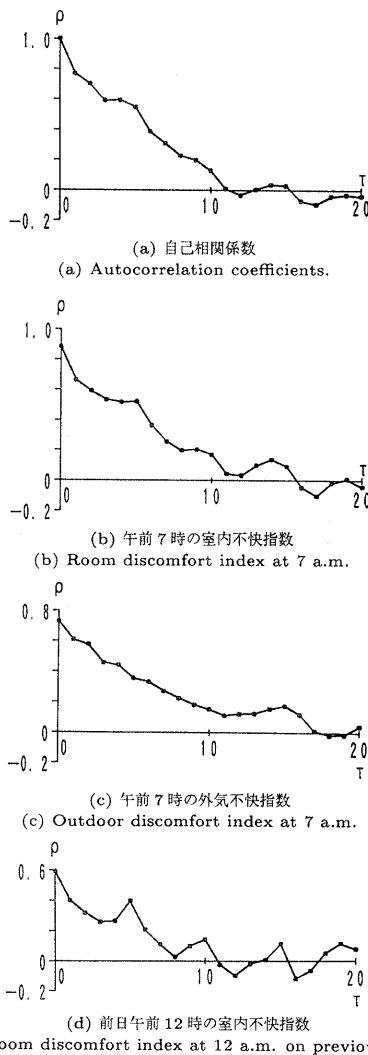


図4 予冷時間データの自己相関係数および説明変数データとの相関係数

Fig. 4 Correlation coefficients for pulling-down time data between itself and its explanatory variable data.

3.4 結果の考察

以上の数値実験の結果により、次のことが分かる。SDSL法とMWDL法による予測精度は、対象とする時系列データの性質に依存する。変わりやすい性質の予熱時間のデータの場合には、SDSL法においてCSDS法を用いることは、予測精度の向上にかなり有効である。最も適切な次数で相関係数を考慮した場合、MWDL法よりもかなり精度のよい予測値が得られている。滑らかな性質の予冷時間のデータの場合には、CSDS法を用いたSDSL法の予測精度は、最もよい場合でもMWDL法よりもやや劣っている。

変わりやすい性質のデータの場合にCSDS法を用

いたSDSL法の予測精度がMWDL法よりよいのは、データの性質や構造をとらえるためには、予測時点近傍のデータのみでは十分ではなく、過去の広い範囲における値と変化の状況が類似したデータを必要とすることを意味している。滑らかな性質のデータの場合にSDSL法の予測精度がMWDL法より劣るのは、予測日近傍のデータの影響の方が強いいため、過去の類似データよりも予測日近傍のデータを学習する方がよいことを意味している。

4. 関連する研究

Pengら³⁾は、ニューラルネットワークを用いた電力の需要予測において、類似データ選定法を用いている。距離の計算において、入力変数による出力変数の偏微分値を重みとして考慮している。重みづけを考慮した場合の予測精度を、重みづけを考慮しない場合と比べると、通常のフィードフォワード型のニューラルネットワークではむしろ悪くなっているが、線形計算を行うネットワークを付加した型のニューラルネットワークでは、相対誤差の平均値と標準偏差がそれぞれ5.4%と17.1%小さくなっている。しかしながら、入力変数による出力変数の微分値は、変数の変動量を関係づける値であり、一般的には、ある時点の入力値そのものが予測時点の出力値に及ぼす影響を直接的に表すものではない。

筆者が提案したCSDS法⁴⁾の新規性は、類似データを選定する距離の計算において、2時点間のデータの依存関係を表す量として、理論的に明確な相関係数を用いて重みづけを行う点にある。さらに、相関係数のべき乗の関数で考慮することにより、係数値の大小による重みづけの度を調整できるように工夫している。本論文では、説明変数をもつ時系列データの場合についてCSDS法を拡張し、性質の異なったデータを用いて数値実験を行い、CSDS法を用いたSDSL法とMWDL法の予測精度について新しい知見を提供している。

5. むすび

数値実験の結果により、次のことが分かった。変わりやすい性質の予熱時間のデータの場合には、SDSL法においてCSDS法を用いることは、予測精度の向上にかなり有効である。最も適切な次数で相関係数を考慮した場合、MWDL法よりもかなり精度のよい予測値が得られている。滑らかな性質の予冷時間のデータの場合には、CSDS法を用いたSDSL法の予測精度は、最もよい場合でもMWDL法よりもやや劣って

いる。

上記のデータの性質と CSDS 法による予測精度向上の効果の関係は、1 変数の時系列データの場合の結果⁴⁾とはほぼ同じである。これらの結果により、筆者が提案した CSDS 法を用いた SDSL 法は、変わりやすい時系列データの予測のための有力な学習データ選定方法になり得るものと考えられる。今後も、様々な観測データについて提案方法を適用し、その有効性を広く検証したいと考えている。

参 考 文 献

- 1) Lambert, J. et al.: Application of Feedforward and Recurrent Neural Networks to Chemical Plant Predictive Modeling, *Proc. IJCNN*, Vol.I, pp.373-378 (1991).
- 2) Peng, T.M. et al.: Conceptual Approach to the Application of Neural Network for Short-term Load Forecasting, *Proc. of the 1990 IEEE International Symposium on Circuits and Systems*, pp.2942-2945 (1990).
- 3) Peng, T.M. et al.: Advancement in the Application of Neural Networks for Short-term Load Forecasting, *IEEE Transactions on Power Systems*, Vol.7, No.1, pp.250-257 (1992).
- 4) 下平丕作士:ニューラルネットワークによる時系列予測における相関係数を用いた学習用類似データ選定方法, 情報処理学会論文誌, Vol.36, No.2, pp.266-274 (1995).
- 5) Rumelhart D.E. et al.: *Parallel Distributed Processing*, Vol.1, Chapter 8, MIT Press (1986).
- 6) Kaufman, L. et al.: *Finding Groups in Data*, p.13, John Wiley & Sons, Inc. (1990).
- 7) Shumway, R.H.: *Applied Statistical Time Series Analysis*, p.17, Prentice Hall (1988).

(平成 7 年 3 月 2 日受付)

(平成 7 年 7 月 7 日採録)



下平丕作士 (正会員)

昭和 44 年東京都立大学工学部建築工学科卒業。昭和 46 年同大学修士課程修了。同年日本電信電話公社(現株式会社)入社。武蔵野電気通信研究所および建築部建築技術開発室において、構造工学、数値解析、CAD、データベース、AI 等の研究とシステム開発に従事。平成 4 年から日本メックス(株)において、建物・設備管理へのコンピュータの応用に関する研究・開発に従事。データ工学、データベース、知識工学、エキスパートシステム、ニューラルネットワーク、GA、図形処理、CG 等に興味を持っている。工学博士。電子情報通信学会、人工知能学会、日本建築学会各会員。