

P2P ネットワーク内処理による センサ時系列予測

田中 博和[†], 寺西 裕一[†], 加藤 精一^{††}, 下條真司[‡], 西尾章治郎[†]

[†] 大阪大学大学院 情報科学研究科 ^{††} 兵庫医療大学 [‡] 情報通信研究機構

我々は、様々なセンサノードを地理的オーバレイネットワークで結びつけた P2P 型広域センサネットワークについて研究を進めている。本稿では、そのモニタリングアプリケーションとして、センサデータの時系列予測に着目し、同ネットワークのセンサデータに対する予測手法を提案する。予測モデルとしては、時系列モデルの一種である多変量自己回帰モデルを使用しセンサからのデータより予測を行う。しかし、一般にこれらに基づく予測プロセスは手元の静的な時系列データに対する処理を前提としているため、P2P 型広域センサネットワーク上にそのまま適用することは、データの分散とストリーム性から現実的ではない。そこで本稿では、まず予測プロセスを階層化し、次いでこれらの課題が顕在化した相関層及び予測層でのビア選択における解決策として、算出法の使い分け及び偏相間にに基づく Greedy などビア選択手順をそれぞれに提案する。

P2P-Sensing Network and Short-Term Forecast by using Timeseries Corelation

Hirokazu Tanaka[†] Yuichi Teranishi[†] Seiichi X. Kato^{††} Shinji Shimojo[‡] Shojiro Nishio[†]

[†] Graduate School of Infomation Science and Technology, Osaka University

^{††} Hyogo University of Health Sciences

[‡] National Institute of Infomation and Communications Technology

We are advancing the research on the wide area P2P sensor network that consists of various sensor node. In this paper, we pay attention to the time series forecasting as a monitoring application on this network. we selected the vector auto-regressive model as a forecast model, and by using this model we can forecast the sensor value. However, these forecast processes based on VAR model requires the local static data as the precondition in general. It is difficult to cope with this forecast model to the P2P sensor network as it is. So, in this paper, we first propose the hierarchization of the forecast process, and next we propose both "Greedy peer selection procedure based on partial correlation coefficient" and "Procedure of using correlation calculation properly" as the solution of correlation layer and forecast layer.

1 はじめに

近年、新たなセンサ機器の登場により実空間の環境上モニタリングに関する研究開発が盛んである。特に無線マルチホップ系センサネットワークなどにより高密度な環境データの取得が可能となり、数多くのセンサネットワークが各地で構築・運用され、防犯・防災・気象など様々な分野への応用が期待されている。一方、これらセンサネットワークや単一センサを利用し、気象現象などのより広域にわたる現象を把握するには、インターネットなどの広域網によりこれらをネットワーク化することが必要となる。既存のシステムとしては、AMeDAS に代表される広域観測網が挙げられ、管理・運用

の面から、サーバ・クライアント型の構成をとり、データの保存や処理を一極に集中させている場合が多い。しかし多数のセンサ及びセンサネットワークが参加する場合、システムのスケーラビリティや提供するサービスの可用性・信頼性、管理コストの観点から分散型のアーキテクチャが有用と考えられ、オーバレイネットワークに基づく研究が幾つか提案されている²⁾。現在、我々のグループでは同様に LL-Net⁴⁾などの地理的オーバレイを基にした P2P 型の観測網（以下、P2P 型広域センサネットワーク）について研究を行っており、位置情報に基づくエリアクエリ等、センサの位置が重要な要素となるこれらネットワークにおいて有用と考えられる。本稿では、同ネットワーク環境

下におけるモニタリングアプリケーションとしてセンサデータの時系列予測に着目し、各ピアのセンサより出力される、分散ストリームデータに適した時系列予測プロセスを提案する。以下、本稿では2章で時系列予測について説明し、3章ではそのP2P型広域センサネットワークへの適用について各プロセスでの問題点を述べ、その解決手法を提案する。そして4章でまとめと今後の展望を述べる。

2 時系列予測

モニタリングアプリケーションとしては、単純なデータ提示からなるものから類似検索や異常検出より複雑な処理を含むものまで様々なものが挙げられる。本稿ではアプリケーションとして予測値の有用性から短期の時系列予測に着目し、その予測手法として統計学的な背景を持つ時系列解析を選択、処理プロセスのP2P型広域センサネットワーク上への適用について、具体的な提案を行う。まず既存の予測プロセスについて、以下に解説を行う。

2.1 予測プロセス

長さ n 、変量数 l の l 次多変量時系列データ Y の多変量自己回帰モデルによる予測手順を説明する。

$$\begin{aligned} Y &= (y_1, y_2, \dots, y_l)^t \\ y_i &= (y_i(t), y_i(t-1), \dots, y_i(t-n+1)) \end{aligned}$$

予測プロセスは大きく分けて、前処理・モデル構築・後処理の三段階に分けられる。それぞれの段階での主な処理項目は以下となる。

前処理 平均・分散、正規化、相関計算

モデル推定 データ選択、予測モデル推定

後処理 逆正規化、予測処理

2.1.1 前処理

前処理では時系列データの平均・分散を求め、時系列の正規化(平均0、分散1の時系列への変換)を行なう。その後、時系列間の相互共分散関数(正規化後は相互相関関数と等しい)を求める。なお相互共分散関数は偶関数のため、ラグ値 τ は正の場合のみ求めれば良い。

$$y'_i = \frac{y_i - \mu_i}{\sigma_i} \quad (\text{正規化})$$

$$\begin{aligned} \mu_i &= \frac{1}{n} \sum_{k=0}^{n-1} y_i(t-k), & \sigma_i &= \sqrt{\frac{1}{n} \sum_{k=0}^{n-1} (y_i(t-k) - \mu_i)^2} \\ Cov_\tau(i, j) &= \frac{1}{n} \sum_{k=\tau}^{n-1} (y'_i(t-k) - \mu_i)(y'_j(t-k-\tau) - \mu_j) \\ &\quad (i \neq j) \end{aligned}$$

2.1.2 モデル推定

l 個の時系列全てを使用して y_i の予測を行なう場合、偽相関などの見せ掛けの相関を持つものが悪影響を及ぼす。よってそれらを排除しつつ、有効な時系列のみを利用して予測するため、時系列の選択を行なうことが必要となる。データ選択アルゴリズムには諸手法存在するが、本稿では提案を含め3.4にて解説を行う。次に選択された時系列間の相互共分散より予測モデルの構築を行なう。本稿では予測モデルとして状態空間モデルの中でも比較的シンプルな多変量自己回帰モデルを使用する。

$$y(t+1) = \sum_{k=0}^{m-1} A_k^m y(t-k) + v_n$$

m はモデル次数、 A は係数行列、 v_n は残差である。また、時系列が定常であるならば、モデル係数と相互共分散関数の間には Yule-Walker 方程式が成り立ち、モデル推定手順は以下となる。

```

 $\hat{V}_0 \leftarrow C_0$ 
 $\hat{U}_0 \leftarrow C_0$ 
for all  $i = 1$  to  $M$  do
   $W_i \leftarrow C_i - \sum_{j=1}^{i-1} A_j^{i-1} C_{i-j}$ 
   $A_i^i \leftarrow W_i U_{i-1}^{-1}$ 
   $B_i^i \leftarrow W_i^t V_{i-1}^{-1}$ 
  for all  $j = 0$  to  $i-1$  do
     $A_j^{i-1} \leftarrow A_j^{i-1} - A_j^i B_{i-j}^{i-1}$ 
     $B_j^i \leftarrow B_j^{i-1} - B_j^i A_{i-j}^{i-1}$ 
  end for
   $V_i \leftarrow \sum_{j=1}^i A_j^i C_j^t$ 
   $U_i \leftarrow C_0 - \sum_{j=1}^i B_j^i C_j$ 
end for

```

C は分散共分散行列、 V は残差 v の分散共分散行列、 M は最大モデル次数、 W 、 U 、 B は処理用行列である。これにより、1~ M 次までの多変量自己回帰モデルの係数行列 A を漸化的に求めることができる。

2.1.3 後処理

推定したモデルに以下の手順で、時系列データを代入することで p ステップ先 ($p > 1$) の予測値が出せる。

```

 $\hat{y}'(t+1) \leftarrow \sum_{k=1}^m A_k^m y'(t-k+1)$ 
for all  $i = 2$  to  $p$  do
   $\hat{y}'(t+i) \leftarrow \sum_{k=1}^{i-1} A_k^m \hat{y}'(t+i-k) + \sum_{k=0}^{m-i} A_{i+k}^m y'(t-k)$ 
end for

```

最後に逆正規化 $\hat{y}_i = \sigma_i \hat{y}'_i + \mu_i$ を行い、予測値とする。

3 P2P型広域センサネットワーク上への適用

本稿では、各々センサを持つピアから成る地理的オーバレイネットワーク上に、2.1の予測プロセスを適用し各ピアが自立分散的に各々最適のモデルを構築し予測値を出力する予測アプリケーションについて検討する。具体的には、2.1の予測プロセスは一般にローカルに存在する静的な時系列データに対してバッチ処理という形で利用されることが多い。しかし、本稿が想定している環境はデータが分散蓄積され、半永久的に更新される、分散ストリーム環境下であり、幾つかの問題点が生じる。一つはデータのストリーム性に対するもので、ある時点で構築されたモデルや統計値は時間が経過する程に真のモデル・統計値との誤差が大きくなる。もう一つはデータの分散性に対するもので、相関処理やデータ選択アルゴリズムでは複数ピアの時系列を使用するために、ピア間の通信が発生し、ローカル環境では比較的容易であった全ピアとの相関算出や組み合わせ比較は、通信・ピア数の観点から困難になると予想される。そこで、これらを改善するため予測プロセスの各ステップについて、データのストリーム性や分散を考慮しつつ、計算コスト・通信コスト・レスポンス時間・予測誤差などを抑えたアルゴリズムを提案する。

3.1 予測アプリケーションの階層化

予測アプリケーションは、大きくデータ取得・共有基盤、予測前処理、モデル構築及び予測の3部に分けることができる。本稿では、同様にオーバレイネットワーク層、相関層、予測層の三層にアプリケーションを階層化する。図1はその概要である。これより各層の機能の説明及び相関層と予測層については、問題点と提案手法を解説する。

3.2 オーバレイネットワーク層

オーバレイネットワーク層は上位層にセンサデータの共有基盤を提供する。この層の主な機能は、定期的にセンサからのデータをローカルDBに蓄えるストレージ機能、及びピア間でオーバレイネットワークを構築しセンサデータを共有する機能である。具体的には任意の位置に存在するピアのセンサ値提供、地理的近傍ピアの探索、上位層間メッセージの伝達などの機能を備えるものとする。本稿ではオーバレイネットワークのトポロジとして、

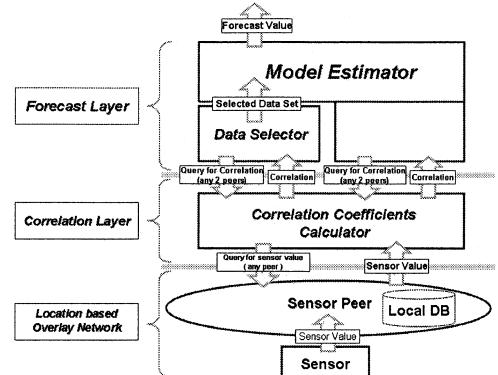


図1 階層構造

LL-Net⁴⁾等のピアの位置情報に基づくものを想定する。

3.3 相関層

相関層は予測プロセスでの前処理に対応し、オーバレイネットワーク層が提供するセンサデータの共有基盤を利用して、任意2ピア間の相関係数・共分散などを上位層に提供する。この相関層の主な機能はピア間の相関係数及び共分散の計算処理である。ただし、P2P型広域センサネットワーク環境下では、データが散逸しているため、相関値の計算処理にはピア間通信を伴う。特にピア間の通信はオーバレイネットワーク層において複数ピアを経由するため、全体の処理時間に占める割合は大きい。また、各ピアのセンサは次々に新たなセンサ値を出し、2ピア間の相関関係も徐々に変化する。従って、一度算出した相関値と真の相関値間の誤差は時間経過と共に大きくなり、正確な値が必要な場合には、再計算が必要となる。このため、例えば各ピアの予測モジュールが相関層に対して、複数の最新相関値を要求する場合、相関層の計算負荷やオーバレイ層以下の通信負荷が問題となりえる。そこで本章では、まず4種の相関算出法を示し、次いで、場合に応じた算出法の使い分け手法について解説する。

3.3.1 相関係数の算出式

相関係数の算出式としては一般に、ピアソンの積率相関の定義式(1)及びフーリエ変換を利用したもの(2)の2種がある。 $X_t = (x_t, x_{t-1}, \dots, x_{t-n+1})$, $Y_t = (y_t, y_{t-1}, \dots, y_{t-n+1})$ のとき、 X_t, Y_t 間の相関係数は

$$Cor(X_t, Y_t, \tau) = \frac{\sum_{i=0}^{n-1} (x_{t-i} - \bar{x}_t)(y_{t-i-\tau} - \bar{y}_{t-\tau})}{\sqrt{\sum_{i=0}^{n-1} (x_{t-i} - \bar{x}_t)^2 \sum_{i=0}^{n-1} (y_{t-i-\tau} - \bar{y}_{t-\tau})^2}} \quad (1)$$

$$Cor(X_t, Y_t) = \Im^{-1}[\Im[X_t] \Im[Y_t]] \quad (2)$$

となる。このとき、 $\tau = 0, \dots, k$ はラグ値、 \bar{x} 、 \bar{y} は平均値である。次に(1)及び(2)のラグを含めた相関計算オーダはそれぞれ nk 、 $n \log n$ となるが、時刻 $t-1$ での相関係数やフーリエ係数を既に得ている場合、これを用い、以下の(3)や(4)等の漸化式を用いることができる。

$$Cor(X_t, Y_t) = \frac{R_t^{XY}}{\sqrt{R_t^{XX} R_t^{YY}}} \quad (3)$$

$$\left\{ \begin{array}{l} R_t^{XY} = R_{t-1}^{XY} + x_t y_t - x_{t-n} y_{t-n} + (n-1) \Delta(\bar{x}\bar{y}) \\ - (n\bar{x}_t - x_t) \Delta\bar{y} - (n\bar{y}_t - y_t) \Delta\bar{x} \\ R_t^{XX} = R_{t-1}^{XX} + x_t^2 - x_{t-n}^2 + (n-1) \Delta\bar{x}^2 - 2(n\bar{x}_t - x_t) \Delta\bar{x} \\ R_t^{YY} = R_{t-1}^{YY} + y_t^2 - y_{t-n}^2 + (n-1) \Delta\bar{y}^2 - 2(n\bar{y}_t - y_t) \Delta\bar{y} \end{array} \right.$$

$$\left\{ \begin{array}{l} f_i[X_t] = E^i f_i[X_{t-1}] + x_t E^0 + x_{t-n} E^{n-i} \\ f_i[X_t] = \sum_{k=0}^{n-1} x_{t-k} \exp\left(\frac{-2\pi i}{n} jk\right) \quad (i = 0, \dots, n-1) \\ E = \exp\left(\frac{-2\pi i}{n} j\right) \end{array} \right. \quad (4)$$

なお、このとき R_t^{XY} 、 R_t^{XX} 、 R_t^{YY} はそれぞれ時刻 t での XY 間の共分散、X の分散、Y の分散、 $\Delta(\bar{x}\bar{y}) = \bar{x}_t \bar{y}_t - \bar{x}_{t-1} \bar{y}_{t-1}$ 、 $\Delta(\bar{x}) = \bar{x}_t - \bar{x}_{t-1}$ 、 $\Delta(\bar{y}) = \bar{y}_t - \bar{y}_{t-1}$ 、 f はフーリエ係数である。

3.3.2 オーバレイネットワーク上での相関係数

前節の式を用いて下位のオーバレイネットワーク層を利用し、具体的に相関係数を求める手順について説明する。まず、基づく算出式が(1)、(2)、(1)(3)、(2)(4) であるものをそれぞれ手法 1~4 とすると、P1 の相関モジュールに対して、P2-P3 間の相関値が要求された場合の手法 1~4 のピア間の処理の流れは図 2 のようになる。これから分かるように、手法 1・2 がクエリ後処理が始まるのに対し、漸化式を用いる手法 3・4 では新たなセンサデータが出力される度に更新処理が必要となる。また更新処理において手法 3 ではピア間通信が発生するが、手法 4 ではフーリエ係数の更新のみで済む。次に各手法を比較・検討すると、手法 1 と手法 2 では、計算量に関して手法 2 が優れ、手法 2 と手法 4 では、更新処理が発生する分、手法 4 が不利だが、フーリエ係数を予め持つことにより、手法 2 と比較し FFT が総計 2 回削減可能である。また自ピアと他のピアとの相関値を手法 3 にて予め更新している場合、表 1 とは異なり、ピア間通信なしに、相関値を返答可能である。

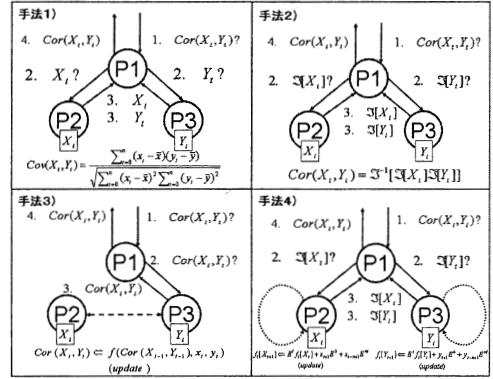


図 2 ピア間の処理の流れ

3.3.3 手法の使い分け

これらに基づき、各場面に応じて有利な手法を用いるため、本稿では各手法を相関参照の局所性と累積更新コストと一括処理コストの分岐回数に基づく切り替えにより使い分ける手順(図 3)を提案する。相関参照の局所性とは、ある時点で参照された相関値は近い将来に再び参照される可能性が高いという性質であり、累積更新コストと一括処理コストの分岐回数に基づく切り替えとは、例えばある手法 A の更新処理の累積計算コストが他の手法 B のクエリ処理の計算コストを超えた時点をもって手法を A から B へと切り替えることを表し、分岐回数は手法 2・4 間で $[2n \log n/k]$ 回、手法 3・4 間で $[n \log n/k]$ 回である。これらに基づき各ピアの相関モジュールは、図 3 での S1:「更新処理を行っていない状態」、S2:「自ピアの時系列のフーリエ係数について式(4)で更新を行う状態」、S3:「フーリエ係数に加えて、一部の相関値を式(3)で更新を行う状態」の間を遷移する。初期状態は S1 であり、もし手法 2 の処理過程で自ピアのセンサデータのフーリエ係数を副産物として得た場合、状態を S2 に遷移し、フーリエ係数の更新を開始する。この際、タイマ 1 に $[2n \log n/k]$ をセット、更新処理ごとに減算し、0 となれば状態を S1 に遷移する。また状態 S1、S2 において自ピアと他ピアとの相関値を得た場合、状態を S3 に遷移し、その相関値に関しては、フーリエ係数の更新に加え、手法 3 での式(3)による相関値の更新を開始する。この場合も相関値ごとにタイマ 2 を $[n \log n/k]$ にセットし、同じく更新処理ごとに減算、0 をもってその相関値に関する更新処理を停止

止する。なお全ての相関値の更新処理が停止した場合は状態 S2 に遷移する。これら使い分け手順を用いた場合、S1-S1, S2-S2, S3-S3 のピア間では手法 2, 手法 4, 一部を手法 3 (他は手法 4) で相関処理を、また S1-S2, S2-S3, S1-S3 のピア間では手法 2, 手法 4, 手法 2 で相関処理を行うことになる。

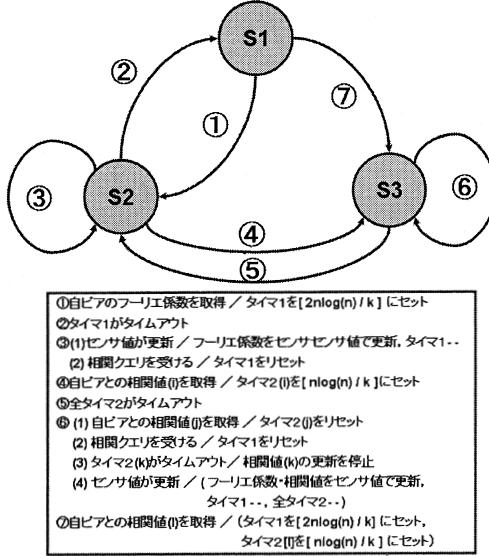


図 3 相関モジュールの状態遷移

	通信回数	通信量	計算量
手法 1	4	$O(n)$	$O(nk)$
手法 2	4	$O(k)$	$O(n \log n)$
手法 3	2	$O(k)$	$O(1)$
手法 4	4	$O(k)$	$O(n \log n)$

	通信回数 (更新)	通信量 (更新)	計算量 (更新)
手法 1	-	-	-
手法 2	-	-	-
手法 3	2	$O(1)$	$O(k)$
手法 4	-	-	$O(k)$

表 1 手法 1 ~ 4 の処理コストの比較

3.4 予測層

予測層は、予測プロセスでのモデル推定及び後処理に相当し、相関層によって提供される相関値に基づき、自ピアの予測に有効なデータを有するピアの選択、及びそれらデータからの多変量時系列モデル構築を行う。また、予測処理を行いモデルから推測される予測値を出力する。このうちモデル構築及び予測に関しては 2.12 のモデル推定手順により $O(n^2k)$ 程度で処理可能だが、データ選

択に関しては、選択に複数ピアのデータが必要なためピア間通信を伴い、且つピアの組み合わせが最大 $O(n!)$ (n はピア数) となるため、探索に要する処理コストは大きく、適したピアも時間と共に変化する。そこで本稿ではピア選択に関し、コストを抑制するため偏相関に基づく Greedy な選択手順を提案する。

3.4.1 理想条件と偏相関係数

まずピアを選択する上で、最適なデータセットとはどのような性質を持ち、どのような基準を用いて選択すればよいだろうか。ここでは、まず使用するモデルから見た予測誤差が最小となる理想的なデータセットが持つ条件（理想条件）を示す。

$X_t^1, X_t^2, \dots, X_t^n$ を用いて、 Y_t を予測する場合、 Y_t の予測誤差が最小となる X_t^i の条件は

$$\text{Correlation}(Y_t, X_t^i) = 1 \quad (i = 1, \dots, n) \quad (5)$$

$$\text{Correlation}(X_t^i, X_t^j) = 0 \quad (i \neq j) \quad (6)$$

即ち、 $X_t^1, X_t^2, \dots, X_t^n$ が一次独立かつ、 $Y, X_t^1, X_t^2, \dots, X_t^n$ が一次従属であることと同値である。さて、現実にはこの理想条件に合致するデータセットが存在することは、非常に稀である。従って、理想条件にできる限り近いデータセットを選択することになるが、あるデータがどの程度理想条件に近いかの評価基準が必要となる。以下に示す偏相関係数はその基準として利用可能な指標である。

$Y_t, G = \{X_t^1, \dots, X_t^n\}$ が Y_t に関して理想条件に従う時、 Z_t, Y_t, G がどれだけ理想条件に近いかを G の影響を除いた Y_t-Z_t 間の n 次偏相関係数 $R_{YZ/G}$ で評価 ($1 \Rightarrow Z$ は独立、 $0 \Rightarrow Z$ は従属) できる。

$$R_{YZ/G} = \text{Cor}(Y_t, Z_t) \\ \text{for } i = 1 \text{ to } n \text{ do} \\ R_{YZ/G} \leftarrow \frac{R_{YZ/G} - \text{Cor}(Y_t, X_t^i)\text{Cor}(Z_t, X_t^i)}{\sqrt{1 - \text{Cor}(Y_t, X_t^i)^2}\sqrt{1 - \text{Cor}(Z_t, X_t^i)^2}} \\ \text{end for}$$

3.4.2 偏相関に基づくピア選択機構

以上に基づき本稿では、ピア選択評価基準として、偏相関を用い、また他のセマンティクスとしてピア間の距離、即ち“近いピアは予測に有用である”という経験則を用いた、偏相関に基づく Greedy なピア選択手順（下記）を提案する。これにより、自ピアと物理的に近いピアでかつ、偏相関が高いピアを順次選択・定期更新することで、近傍領域のピアで組み合わせ最適化を図り、試行すべき組

み合わせ数の大幅な削減と、時間変化する適したデータ組み合わせへの追隨を可能とする。

```

近隣ピア群 ← 主ピアの近傍 k ピア
予測ピア群 ← { 主ピア }
loop
    候補ピア群 ← {}
    for (ピア P : 予測ピア群) do
        候補ピア群に P の近傍ピア群を追加
    end for
    候補ピア群より予測ピア群を除去
    候補ピア ← 候補ピア群より 1 ピア
    if 予測ピア群の数 > 最大予測ピア数 then
        予測ピア群に候補ピアを追加
    else if 候補ピア群の数 = 最大予測ピア数 then
        X ← 主ピアと候補ピア間の偏相関
        Y[] ← 主ピアと予測ピア群間の偏相関
        if X > min(Y) then
            予測ピア群より偏相関が最小のピアを除去
            予測ピア群に候補ピアを追加
        end if
    end if
end loop

```

3.4.3 評価

次に AMeDAS の近畿圏一ヶ月分（15 分間隔）の気温データを用いてピア選択手順の評価を最大予測ピア数が 2 ~ 7 ピアの場合で行った（図 4）。主ピアの観測地は神戸であり、神戸の予測に有用と思われる予測ピア群を上記手順に従い選択し，“ピア選択”，“選択ピア群からの主ピアの予測”を繰り返した。縦軸は予測値（10 日間:960 ステップ）と実際の観測値の予測誤差の二乗平均値 (RMSE) 及び横軸は選択回数である。図から分かるように、徐々に予測誤差が減少・収束していくことが見て取れ、また、最大予測ピア数が多いほど、予測に有効な傾向があることも分かる。この 7 ピアでの収束値 1.04 ℃は気象庁の予測精度と比較しても遜色がない値である。なお、ここでは静止データを使用したため予測ピア群の組み合わせが収束したが、実際にはセンサからの動的な時系列データを基に選択を行うため、収束せず、常に変動する。

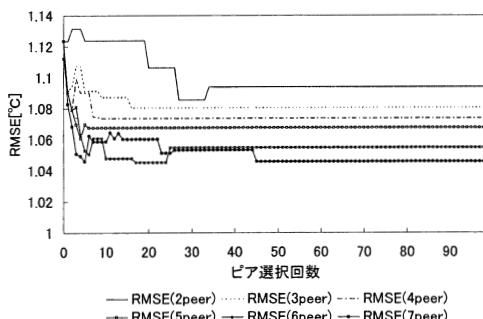


図 4 ピア選択評価

4 まとめ

本稿では、P2P 型広域センサネットワーク上に VAR モデルによる予測プロセスを展開し、自律分散的な P2P 予測アプリケーションの提案を行った。またその際に問題となった、ピア間通信を伴う、相関計算・ピア選択プロセスについて相関値の算出手法の使い分け及び偏相関に基づく Greedy なピア選択手順の提案を行い、後者については予測誤差に対する評価を示し、予測への有効性を確認した。今後の展望としては、評価及び他手法との比較、異なる予測プロセス・時系列アプリケーションの P2P 型広域センサネットワーク上への適用などが挙げられる。

謝辞

本研究の一部は、平成 20 年度総務省委託研究「ユビキタスサービスプラットフォーム技術の研究開発」による成果である。また、本研究の一部は、文部科学省グローバル COE プログラム（研究拠点形成費）および科学研究費補助金・特定領域研究の研究助成によるものである。ここに記して謝意を表す。

参考文献

- Y. Hatanaka, M. Arisugi, "Calculating Correlations of Stream Data with Data Tendencies," DBSJ Letters, Vol.2, No.3, December 2003, pp.21-24.
- M. Isomura, C. Decker, M. Beigl, "Generic Communication Structure to Integrate Widely Distributed Wireless Sensor Nodes by P2P Technology," in Proceedings of the seventh International conference on Ubiquitous Computing (Ubicomp 2005), September, 2005, Tokyo, Japan.
- Y. Zhu, D. Shasha, "Statstream: Statistical monitoring of thousands of data streams in real time," VLDB'02, pp.358-369(2002).
- 金子雄、春本要、福村真哉、下條真司、西尾章治郎、"ユビキタス環境における端末の位置情報に基づく P2P ネットワーク," 情報処理学会論文誌: データベース, vol.46, pp.1-15 (2005.12).