情報処理学会論文誌　コンピューティングシステム　Vol. 3　No. 2　113–125 (June 2010)

センサネットワークにおけるパケットロス耐性のあるコンテキスト検出手法の提案

間　博人[†1]　中澤　仁[†1]　徳田英幸[†1]

実空間オブジェクトに多数のセンサが付与される生活環境において，センサデータから人や環境の状態をコンテキストとして抽出し，その情報を各種機器の制御に活用する方法は重要な課題である．本論文ではサーバでベイズ推論の計算を行い，センサノードへ圧縮した事後確率表を配布することで，センサネットワーク内でベイズ推論の結果を得ることができるハイブリッド型ベイズ推論機構を対象とする．ハイブリッド型ベイズ推論機構は，パケットロスにより，事後確率表がセンサノードに届かなかった場合や，推論に必要なデータが揃わなかった場合，コンテキストの検知ができない．本論文では，パケットロスへの耐性を向上させる事後確率表配送手法を提案し，これらの問題を解決する．提案する事後確率表配送手法は，複数のノードへ事後確率表を配送する手法と複数の事後確率表を選択する手法からなる．複数の事後確率表配送手法を定義し，実空間上で 20 台の MICAz Mote を用いたパケットロスの測定と，その結果を利用した環境シミュレータ上での空調制御シナリオによって評価を行う．パケットロスが発生する環境下での事後確率表の再送率，コンテキスト検出率および推論品質を評価し，各事後確率表配送手法の性能を検証した．結果として，パケットロス率が高い環境下でも事後確率表の再送率を低減し，高いコンテキスト検出率と推論品質を達成した．

Packet Loss Tolerant Context Capturing Schemes for Sensor Networks

Hiroto Aida,[†1] Jin Nakazawa[†1] and Hideyuki Tokuda[†1]

Real life objects are to be embedded with various sensors in our future lives. The sensors are used to extract the contextual information of human and surroundings, and this information is important to control devices around us automatically. In this paper, we target environments where Hybrid Bayesian Inference Mechanism (HBIM) is used for distribution of compressed posterior probabilistic table for analyzing spatial context for air conditioning control. HBIM enables lightweight computation and Bayesian inference among the sensor nodes, it is vulnerable to loss of data used for inference and dynamic change of node quantity among the network. To challenge this issue, we propose a Reliable Hybrid Bayesian Inference Mechanism (RHBIM). RHBIM predicts the fluctuation of node numbers within the network, and sends the posterior probabilistic table required for Bayesian inference to the required nodes. Among this process, RHBIM selects the posterior probabilistic table, and the essential sensor node to send the table. As a preliminary experiment, we have deployed 21 sensor nodes in a real life office environment and observed the location of heat accumulation, and the packet loss in the network. We have then run an environmental simulator configured by the data acquired from our experiment, and have deployed RHBIM on an air conditioning system. We have evaluated the retransmission of posterior probabilistic table among lossy environments, the context detection ratio and the quality of inference, and have shown that RHBIM is effective among traditional methods.

1. はじめに

身の回りの実空間オブジェクトに小型無線センサノードより得られる環境情報データから，統計的手法を用いて人や環境の状態を解析する手法に関する研究がさかんである．照度，温度，加速度などのセンサデータより人や環境の状態をコンテキストとして抽出し，アクチュエーションのトリガとして利用することで，異常検知，日常動作の自動化などの様々なアプリケーションが実現可能になる[3),7)]．

このようなセンサデータの解析モデルとして，近年ベイジアンネットワーク[8),10)]が大きな注目を集めている．ベイジアンネットワークは，グラフ構造によって結合確率分布を効率的に表現できるだけでなく，視覚的にセンサデータ間の依存関係をモデル化できるという利点がある．また，確率を用いることで不確実な要因下でも妥当な推論を実行できる利点がある．筆者らは，サーバでベイズ推論の計算を行い，圧縮した事後確率表（Posterior Probability table: PPT）をセンサノードへ配布することで，複数のセンサノード間でベイズ推論の結果を得ることができるハイブリッド型ベイズ推論機構（Hybrid Bayesian Inference Mechanism: HBIM）を提案した[2)]．

HBIM では，1 度サーバから PPT をセンサノードに配送してしまえば，センサノード内

†1 慶應義塾大学大学院政策・メディア研究科
Graduate School of Media and Governance, Keio University

© 2010 Information Processing Society of Japan

で自律的にベイズ推論が実行できる．また，ベイズ推論の計算処理を基幹サーバ側で行うため，センサノード上での処理が軽い．しかしながら HBIM は，パケットロスにより PPT がセンサノードに届かなかったり，必要な測定データが揃わなかったりした場合，コンテキストを検出できないという問題がある．この問題を解決するために，本論文はリライアブルハイブリッド型ベイズ推論機構（Reliable Hybrid Bayesian Inference Mechanism: RHBIM）を提案する．RHBIM は，複数の PPT を複数のノードに送信することで，ハイブリッド型ベイズ推論機構がかかえるパケットロス時の推論品質の劣化という問題を解決する．RHBIM は，冗長性を用いてデータの信頼性を確保するため，パケットロスが発生しても再送せずに高い推論品質とコンテキストの検出率を維持できるという特徴を持つ．この RHBIM を空調制御システムに適用し，パケットロスの発生する環境下で各配送方式の評価を行う．

本論文の構成は，次章でベイズ推論機構について説明する．3 章では，本論文で提案する RHBIM について説明する．4 章では，RHIBM を空調制御シナリオへ適用する際の課題を整理する．5 章で空間モデルを作成し，提案手法の実験評価を行う．6 章で関連研究について述べ，最後に 7 章で本論文をまとめる．

2. ベイジアンネットワークによるセンサデータの解析

本章では，ベイジアンネットワークによるセンサデータの解析方法の概要を説明する．次に，ベイズ推論機構の分類について説明し，ハイブリッド型ベイズ推論機構とその問題点について述べる．

2.1 概　　要

ベイジアンネットワークは，複数の確率変数間の依存関係をグラフ構造によって表し，変数間の関係を条件付確率で表す確率モデルである．**図 1** に，「空間 A の快適さ」というコンテキストを抽出するためのベイジアンネットワークを示す．各楕円がコンテキスト，センサデータを表す確率変数にそれぞれ対応する．Comfort がコンテキストに対応し，Temperature(1), Humidity(1) は 1 つのセンサノードから取得できる温度および湿度に対応する．同様に (2), (3) も異なるセンサノードから取得できるセンサデータ群を表す．これらのセンサデータに対応する確率変数は，Comfort と直接的な依存関係を持ち，依存関係は 2 つの確率変数間を結ぶ有向リンクとして表現される．これらの依存関係は確率変数ごとに定義された条件付き確率分布表によって重み付けられる．それぞれの条件付き確率は，Comfort が真または偽であったときの各センサデータの割合であるため，蓄積したセンサデータに対してあらかじめコンテキストに関するメタ情報を付加しておくことで求められる．図 1 において，そ

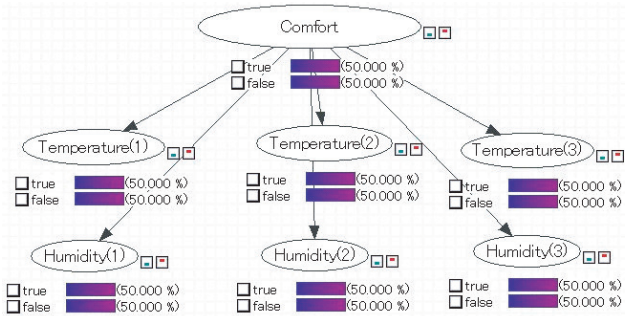

図 1　Comofrt コンテキストを表すベイジアンネットワーク
Fig. 1　Bayesian network for Comfort context.

れぞれの確率変数は 2 値で離散化されているため，この推論モデルの Comfort に対する確率変数の組合せは 64 (2^6) 通りである．

事象 A という条件が与えられたときの事象 B の確率をベイズ推論により求めたものを，事後確率 $P(B|A)$ と定義する．コンテキストの事後確率 P は，時刻 t で取得したセンサデータを条件とし，ベイズ推論アルゴリズムを用いることで求められる．ある組合せにおける Comfort コンテキストの事後確率は次のように記述する．

$$\mathrm{P(Comfort|warm,\ humid,\ warm,\ humid,\ warm,\ humid)} = 0.05$$

これは，時刻 t においてセンサデータ群に対応する確率変数が，それぞれ warm，humid，warm，humid，warm，humid であるときに Comfort である確率が 0.05 であることを示す．

2.2 ベイズ推論機構の分類

センサデータをベイジアンネットワークを用いて解析し，その結果に基づいて機器を制御するシステムをベイズ推論機構と呼ぶ．ベイズ推論機構は，以下の 3 つに分類できる．

- Centralized Bayesian Inference Mechanism（CBIM）：センサネットワークのすべてのデータをセンサネットワーク外の基幹サーバに集約し，解析する．CBIM ではつねに基幹サーバが必要となる．基幹サーバがボトルネックとなり，それが停止すると全機能が停止する．
- Distributed Bayesian Inference Mechanism（DBIM）：各センサノードにベイズ推論エンジンを載せ，センサノード自体がベイズ推論の計算を分散，並列に行う．学習データやコンテキストの推論モデルをセンサノードに配送してしまえば，サーバに依存せずにセンサノード間でベイズ推論が可能である．しかしながら DBIM は，センサノード

© 2010 Information Processing Society of Japan

で膨大な計算処理が必要となり，処理時間と電力消費の観点から問題がある．

- Hybrid Bayesian Inference Mechanism（HBIM）：サーバでベイズ推論の計算を行い，PPT をセンサノードへ配布し，センサノード上で PPT と測定データをマッチングさせることでベイズ推論の結果を得る．HBIM では，1 度サーバから PPT をセンサノードに配送してしまえば，サーバとの接続が切れてもセンサノード間でベイズ推論が可能である．したがって，CBIM と異なり，サーバの常時稼働を前提としない．また，ベイズ推論の計算処理を基幹サーバ側で行うため，センサノード上での処理が軽いという特徴がある．

本論文では，HBIM を中心に議論する．次に議論の前提となる HBIM の概要とその問題点を説明する．

2.3　ハイブリッド型ベイズ推論機構とその問題

図 2 に HBIM の処理の流れを示す．基幹サーバ側では，ベイジアンネットワークを用いたコンテキストの推論モデルを構築する．次に確率推論アルゴリズムを用い PPT を算出する．**表 1** に Comfort コンテキストの PPT の一部を示す．PPT は，推論モデルが複雑になるに従いデータ量が増大する．したがって，センサノードに送る際には効率的に削減する必要がある．文献 2) では，PPT の圧縮手法の提案と評価を行った．

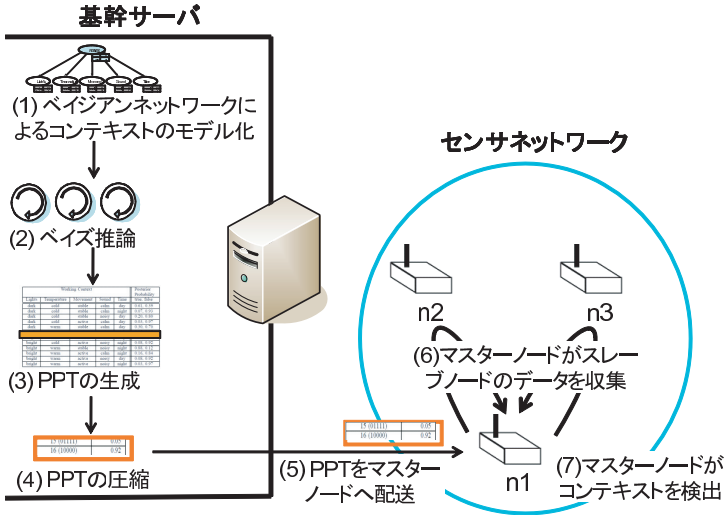

図 2　HBIM の処理の流れ
Fig. 2　Flow of processing.

センサノードは，推論モデルを基にセンサネットワーク内でグループ G を構成する．**図 3** (a) に示す n_1，n_2，n_3 から構成されたノードグループ G は，$G = \{n_1, n_2, n_3\}$ となる．ノード n_1 をマスタノードと呼ぶ．マスタノードは，スレーブノードのセンサデータを収集し，サーバから送信された PPT を基にコンテキストを検出する．ノード n_2，n_3 をスレーブノードと呼ぶ．スレーブノードは，マスタノードからの要求に応じて測定データを送信する．

HBIM の第 1 の問題は，サーバがマスタノードへ送信する PPT がロスした場合，マスタノードはコンテキストを検出できないという点である．第 2 の問題は，ノード間のパケットロスにより推論モデルに必要なデータが揃わない場合，コンテキストの検出ができないという点である．たとえば，表 1 の PPT(n_1, n_2, n_3) をノードグループ $G = \{n_1, n_2, n_3\}$

表 1　Comfort コンテキストの事後確率表の抜粋
Table 1　A part of the posterior probability table associated with Comfort context.

Comfort context						p.p.
Temp(n1)	Hum(n1)	Temp(n2)	Hum(n2)	Temp(n3)	Hum(n3)	true
warm	humid	warm	humid	warm	humid	0.05
warm	humid	cold	humid	cold	humid	0.54
warm	dry	warm	dry	warm	humid	0.02
warm	dry	cold	dry	cold	humid	0.85
cold	humid	cold	humid	warm	humid	0.54
cold	dry	warm	humid	cold	humid	0.74

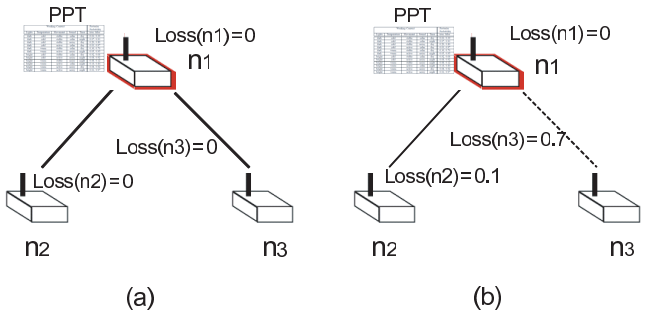

図 3　センサノードグループ
Fig. 3　Sensor node groups.

© 2010 Information Processing Society of Japan

のマスタノード n_1 に送信するとする．PPT(n_1, n_2, n_3) は，n_1，n_2，n_3 の 3 台のセンサノードで推論モデルを構築した PPT を示す．この PPT が，パケットロスによりマスタノードに届かなかった場合，マスタノードはコンテキストを検出できない．また，マスタノード n_1 は，スレーブノード n_2，n_3 の温度データと湿度データを収集し，表 1 の PPT と照らし合わせ comfort コンテキストを検出する．n_2 からのデータがパケットロスにより収集できない場合，マスタノード n_1 は，Temp (n_2) と Hum (n_2) が分からないため，表 1 の PPT(n_1, n_2, n_3) ではコンテキストを検出できない．次章で，これらの問題の解決方法を示し，リライアブルハイブリッド型ベイズ推論機構（RHBIM）を提案する．

3. パケットロスに耐性のあるコンテキスト検出手法

まず HBIM の問題点に対するアプローチを述べ，パケットロスに耐性のあるコンテキスト検出手法として，PPT 配送先ノードの選択手法と送信する PPT の選択手法からなる RHBIM の概要について述べる．

3.1 アプローチ

サーバが PPT をマスタノードへ送信する際にロスした場合，マスタノードはコンテキストを検出できないという問題に対する解決方法の 1 つに PPT を再送するという方法がある．しかしながら，パケットロス率が高い環境下では再送コストが増大してしまう．マスタノード以外のノードにも PPT を配送し，ノードグループ内で PPT を持つノードがマスタノードになることで，再送コストを低減させることができる．たとえばノードグループ $G = \{n_1, n_2, n_3\}$ のすべてのノードに PPT(n_1, n_2, n_3) を送信すると，n_1 への PPT がロスにより届かなかった場合でも n_2 がマスタノードになることでコンテキストの検出を継続できる．この解決手法を，PPT 配送先ノードの選択手法とし，3.2 節で説明する．

ノード間のパケットロスにより推論モデルに必要なデータが揃わない場合，コンテキストの検出ができないという問題に対しては，あらかじめ複数の PPT を送っておく方法をとる．たとえば，マスタノード n_1 に PPT(n_1, n_2, n_3) と PPT(n_1, n_3) をあらかじめ送っておくことで，n_2 のデータがパケットロスにより収集できない場合でも，n_1 はコンテキストを検出可能となる．PPT のサイズはセンサノードにとって大きいため，できるだけ無駄が少ないように，ノード間のロスを考慮して必要となりうる PPT を選択すべきである．この解決手法を，送信する PPT の選択手法とし，3.3 節で説明する．

3.2 PPT 配送先ノードの選択

PPT の配送先センサノードに応じて次の手法を定義する．

- Single node delivery（SND）：ベイズ推論モデルごとにノードグループの 1 台のセンサノードを選択し PPT を配送する．
- Multiple node delivery（MND）：ベイズ推論モデルごとにノードグループから一定割合のセンサノードを選択し PPT を配送する．
- All node delivery（AND）：ベイズ推論モデルごとにノードグループのすべてのセンサノードに対して PPT を配送する．

SND，MND，AND をパケットロスへの耐性，メモリ占有率，再送コストの 3 つの軸から比較したものを**表 2** に示す．パケットロスへの耐性は，すべてのノードで PPT を管理する AND が最も高い．SND は 1 台のノードで管理するためパケットロス耐性は低く，再送コストが高くなる．MND のパケットロスは，SND より高く AND より低くなる．一方，メモリ占有率は SND が最も低くなり，AND が最も高くなる．MND は SND より高く AND より低くなる．この SND，MND，AND からなる PPT 配送先ノードの選択手法は，5.4 節で評価する．

表 2　SND，MND，AND の比較
Table 2　Comparison among SND, MND and AND.

	SND	MND	AND
パケットロス耐性	×	△	○
メモリ占有率	○	△	×
再送コスト	×	△	○

3.3 送信する PPT の選択

まず前提となる Complete PPT（CPPT）および PPT set（PPTS）を定義する．$PPT(n_1, \ldots, n_N)$ のとき，$N = |G|$ の PPT を CPPT と呼ぶ．$|G|$ は，ノードグループ G の要素数を示す．また，1 台のセンサノードに配送する PPT の集合を PPTS と呼ぶ．たとえば，図 3 (a) において n_1 に配送するすべての PPT の集合は，PPTS = { PPT(n_1, n_2, n_3), PPT(n_1, n_2), PPT(n_1, n_3), PPT(n_1) } と表すことができる．次に，それぞれの PPT_j の評価指標として Quality of Inference（QoI）を導入する．PPT_j の QoI を以下のように定義する．

$$QoI(PPT_j) = |PPT_j|/|CPPT| \tag{1}$$

ここで，$|PPT_j|$ および $|CPPT|$ は，それぞれの PPT_j の推論モデルを構成するノード数を示す．推論が成功した場合，PPT の構成ノード数が CPPT に近づくほど QoI は高くなり，CPPT と等しい PPT_j の QoI は 1 となる．しかしながら，センサノード間で受け

© 2010 Information Processing Society of Japan

渡す測定データが欠損して推論に必要なデータが得られなかった場合は，推論ができないため QoI は 0 になる．たとえば，図 3 (a) において，CPPT は $PPT(n_1, n_2, n_3)$ となり，$|CPPT| = 3$ となる．したがって，$PPT(n_1, n_2)$ の QoI は 0.67 となるが，n_2 のデータを n_1 が受信できなかった場合，推論はできないため QoI は 0 となる．

推論モデルによって，各ノードの推論への寄与率が異なる場合がある．図 3 (a) において，n_1 と n_2 が天井付近に配置され，n_3 は机の上に配置していることを想定する．机周辺の Comfort コンテキストを得たい場合，$PPT(n_1, n_2)$ と $PPT(n_1, n_3)$ の QoI は等しいが，$PPT(n_1, n_3)$ を優先して選択すべきである．このように，各ノードの推論への寄与率が大きく異なることが明確な場合，QoI だけでは，妥当な PPT を選択できない．この場合，表 1 の p.p. の列に相当する事後確率の分布を比較することで，各 PPT の推論への寄与率が分かる．寄与率の低いノードで構成された PPT の事後確率は 0.5 周辺になることが多く，コンテキストを明確に検出できない．これに対し，寄与率の高いノードを含む PPT の事後確率は，1 に近い組合せが生じる．したがって，閾値 $ppth$ を 0.5 よりも十分に大きな数値に設定し，事後確率が $ppth$ 以上になる組合せ数を調べることで，各ノードの推論への寄与率を考慮した，PPT の選択が可能である．Algorithm 1 に，各ノードの推論への寄与率を考慮した PPT の選択方法を示す．

Algorithm 1 各ノードの推論への寄与率を考慮した PPT の選択

if $QoI(PPT_j) = QoI(PPT_k)$ **then**
　if $Contrib(ppth, PPT_j)) > Contrib(ppth, PPT_k))$ **then**
　　PPT_j を優先
　else
　　PPT_k を優先
　end if
end if

$Contrib(ppth, PPT_j))$ は，閾値 $ppth$ 以上の PPT_j の行数を表す．表 1 の場合，$ppth$ を 0.7 とすると $Contrib(0.7, PPT(n1, n2, n3)) = 2$ となる．以後の議論において，各ノードの推論への寄与率は等しいものとし，式 (1) の QoI を基に評価を行う．

次に，ロスを考慮した QoI を得るために，Expected QoI（EQoI）を導入する．EQoI を以下のように定義する．

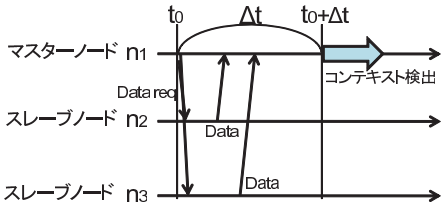

図 4　マスタ–スレーブ間の通信
Fig. 4　Master-slave protocol.

$$EQoI(PPT_j) = |PPT_j|/|CPPT| \cdot \prod_{k=2}^{n_{|PPT_j|}} (1 - Loss(n_k)) \tag{2}$$

EQoI は，QoI と PPT を構成するノード間のロス率である $Loss(n_k)$ を考慮した指標である．**図 4** にマスタノード，スレーブノード間の通信を時系列にみた様子を示す．マスタノードはコンテキストが必要な時点 t_0 で，Data Request パケットをブロードキャストする．Data Request を受信したスレーブノードは，測定したセンサデータをマスタノードに対しユニキャストで送信する．マスタノードは，Δt の間スレーブノードからの応答を待ち，コンテキスト検知処理を実行する．マスタノードは $t_0 + \Delta t$ の時点で応答のないスレーブノードをロスしたものと認識する．マスタノードは，過去 p 回分の試行から算出される $Loss(n_k)$ を保持し，$Loss(n_k)$ が一定値 lth 以上変動すると基幹サーバに $Loss(n_k)$ を通知する．基幹サーバ側は，通知された $Loss(n_i)$ を基に PPTS を選択し，以前送った PPTS と異なる構成になった場合は再送する．

図 3 (a) は，各ノード間の $Loss(n_k)$ が 0 でロスが発生していない状況を示す．この場合推論は失敗しないため，$PPT(n_1, n_2, n_3)$，$PPT(n_1, n_2)$，$PPT(n_1, n_3)$，$PPT(n_1)$ の EQoI は，それぞれ 1，0.67，0.67，0.33 となる．図 3 (b) は，各ノード間にロスが発生し，$Loss(n_2)$ が 0.1，$Loss(n_3)$ が 0.7 の状況を示す．$PPT(n_1, n_2, n_3)$，$PPT(n_1, n_2)$，$PPT(n_1, n_3)$，$PPT(n_1)$ の EQoI は，それぞれ 0.27，0.6，0.2，0.33 となる．結果として 3 台の推論モデルから計算された $PPT(n_1, n_2, n_3)$ よりも，1 台の推論モデルである $PPT(n_1)$ の EQoI の方が高くなる．これらの議論を基に，送信する PPT の選択手法として以下の 4 手法を定義する．

- Single PPT set（SPPT）：1 台のセンサノードに対して CPPT のみを送信する．
- Random PPT set 1（RPPT1）：1 台のセンサノードに対して PPTS の候補からラン

© 2010 Information Processing Society of Japan

ダムに m 個の PPT を選択する．

- Random PPT set 2（RPPT2）：CPPT を必ずいれて，残りを PPTS の候補からランダムに m − 1 個の PPT を選択する．
- Weighted PPT set based on QoI（WPPT）：1 台のセンサノードに対して PPTS の候補から Expected QoI が高い PPT を m 個選択する．

m は以下の実装上の制約に基づいて決定される．

$$\sum_{j=1}^{m} sizeof(PPT_j) \leq \text{センサノードにおける利用可能メモリ容量}$$

各手法の擬似コードを Algorithm 2 に示す．複数の PPT を送信する必要がある RPPT と WPPT の通信コストは，単一の PPT のみを送信する SPPT に比べ高くなる．SPPT は，パケットロスが発生しない環境では最も効率良く最大の QoI を達成できるが，パケットロスが発生する環境では QoI は低下する．2 つの RPPT は，CPPT の有無が性能にあたえる影響を評価するために用意した．RPPT1 と RPPT2 の 2 つの手法を用意することで，CPPT をつねに選択する SPPT との比較が明確になる．WPPT は，$Loss(n_k)$ から PPT の EQoI を計算し，EQoI の高い PPT を優先して選択する．送信する PPT の選択手法の評価は，5.5 節で行う．

4. 空調制御シナリオへの適用

本章では，RHBIM の空調制御シナリオに適用する際に必要となる空間の分割方法について論じ，RHBIM を用いた空調制御の制御シナリオを示す．

空調制御システムでは一般的に，制御対象空間の室温を送風機の空気吸入口のみで計測し，送風の温度や方向を決定する．このため，窓際に直射日光が射していたり，サーバラックなどの熱源が存在したりする空間では，室内温度に偏りが生じる．この問題は，室内に温度センサを搭載した無線センサノードを多数設置し，それらから得られる温度情報を解析して，空調制御システムにフィードバックすることで解決できる．このとき，本論文で提案する RHBIM は，以下の特徴を持つ．まず，HBIM に準拠した方式であるため，温度情報を解析するためのサーバを設置する必要がない．オフィス内でサーバの監視者を要さないため，低コストでの運用が可能となる．次に，システム運用中に温度監視点を増減できる．温度にムラを感じる任意の箇所にセンサノードを設置し，システムの動作を改善できる．さらに，無線センサノードどうしの通信が阻害されても，温度情報の解析を継続できる．人体の移動

Algorithm 2 送信する PPT の選択手法の擬似コード

$l \leftarrow CPPT.sizeof()$
$m \leftarrow PPTS.sizeof()$

SPPT()
PPTS[1] ← CPPT

RPPT1()
for $i = 1$ **to** m **do**
　PPTS[i] ← PPT[ ] からランダムで選択
end for

RPPT2()
PPTS[1] ← CPPT
for $i = 2$ **to** m **do**
　PPTS[i] ← PPT[ ] からランダムで選択
end for

WPPT()
for $i = 1$ **to** $2^{|CPPT|-1}$ **do**
　$m \leftarrow PPT[i].sizeof()$
　$PPT[i].eqoi \leftarrow QoI(PPT[i]) \cdot (1 - Loss[2])) \cdots (1 - Loss[m])$
end for
for i = 1 **to** m **do**
　PPTS[i] ← $eqoi$ が最も大きい PPT[ ] から順に選択
end for

や電子レンジの使用などといった電波干渉源の存在する室内でも，システムの運用が可能となる．

次に，RHBIM を用いた空調制御の空間の分割と制御シナリオについて説明する．

4.1 空間の分割と制御

空調制御システムの適用エリアは，制御したい空間ごとに「リージョン」に分割する．リー

© 2010 Information Processing Society of Japan

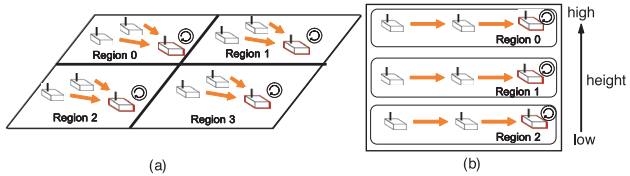

図 5　リージョンによる空間の分割とノードグループの対応
Fig. 5　Division of space by region and node group.

ジョンは，部屋単位や空調の制御できる範囲など目的に合わせて決定する．制御する空調機器とリージョンは静的に対応付けられていると仮定する．リージョンには，複数台のセンサノードを設置し，リージョンごとにベイズ推論モデルを構築する．リージョンはそれぞれ HBIM のノードグループに対応する．

リージョンの構成の方法はいくつか考えられる．**図 5** (a) は，空間を平面で 4 つのリージョンに区切った例である．それぞれのリージョンにセンサノードを配置し，ノードグループを構築する．リージョンごとに Comfort コンテキストを抽出し空調制御を実現する．図 5 (b) は，空間を高さで 3 つのリージョンに区切った例である．このリージョンの分割方法により，オフィスで椅子に座っているときの高さでの快適性を重視し空調を制御することなどが可能になる．このほかに，オフィスデスクごとにリージョンを区切るといった方法も考えられる．このリージョンの分割方法を用いることで，個別のオフィスワーカを対象とした快適性のコンテキストを得ることができる．

リージョンの配置と実際の空調機器の配置によっては，制御できる範囲に齟齬が生じる場合がある．リージョンをオフィスデスクごとに設定した場合，室内に風向を変えることができない吹出口が 1 カ所しかなければ，リージョンごとの要求を満たすことは難しい．しかしながら，同じリージョンの分割方法であっても，各デスクに吹出口が付いていれば制御は容易である．もしリージョンの要求に実際の空調制御が対応できない場合にも，新たな空調機器の設置の必要性や現状の空調でどの程度快適なオフィス環境が実現できているかといった知見を得ることができる．

4.2　制御シナリオ

RHBIM を用いた空調制御の制御シナリオを示す．

(1)　リージョンとセンサノードの設置：空調制御システムの適用エリアを，制御したい空間ごとにリージョンに分割する．分割したリージョンごとに複数のセンサノードを配置する．センサノード間でマスタノードを選出し，ノードグループを構築する．

(2)　ベイズ推論モデルの作成：センサノードから推論モデルに必要なセンサデータおよびノード間の QoC を一定期間取得する．センサノードから取得したデータを基に，リージョンごとのベイズ推論モデルを作成する．

(3)　PPT の計算と配布：まず，SND，RND，AND いずれかの手法を選択し，どのノードに PPT を送るかを決定する．いずれの手法においても，各リージョンのマスタノードへは必ず送信する．PPT を送るノードが決定したら，SPPTset，RPPTset，WPPTset のいずれかを選択し，各ノードへ送る PPT セットを決定する．PPT セットに含まれる各 PPT をベイズ推論に基づいて計算し，組合せインデックスとインデックス選択を用い圧縮する．圧縮した PPT セットをはじめに決定したセンサノードへ送信する．

(4)　推論および空調制御の実現：マスタノードは，PPT セットを受信すると一定間隔おきにノードグループに所属するスレーブノードから必要な測定データを収集する．収集した測定データと適切な PPT でマッチングを行いリージョンが快適である否かといったコンテキストを検知する．検知したコンテキストに基づいて必要な場合は空調コントローラへ制御メッセージを送信する．空調コントローラは，各リージョンから送信される要求を基に空調室内機を制御する．

5.　評　　価

本章では，RHBIM を用いた空調制御シナリオにおいて 3 章で提案した送信する PPT の選択手法と PPT 配送先ノードの選択手法の有効性を評価する．

5.1　実空間におけるパケットロスの計測

予備実験として，筆者らの研究室（20.9 m × 7.3 m × 3.1 m）に 21 台の無線センサノード（CrossBow MICAz MOTE[4]）を設置し，パケットロスを計測した．**図 6** に実験環境を示す．実験環境は，PC やサーバ，無線 LAN 基地局など，無線通信のノイズ源となりうる機器が多数設置されている．またパーティションや机，棚といった障害物も多いため，無線通信にとって厳しい環境であるといえる．図 6 に，センサノードの設置箇所を点で示す．センサノードは約 1 m 間隔で 20 m までの同心円上に 21 台配置した．同心円の中心にあるノードを基準ノードと呼び n0 とする．他のノードを，基準ノードからの距離に応じ，それぞれ n1, n2 . . . n20 と表す．

今回の実験において，基準ノードと各ノード間はシングルホップで接続するものとする．これは，ノード間の距離が 20 m であるためマルチホップの実験を行うには狭いことと，シン

© 2010 Information Processing Society of Japan

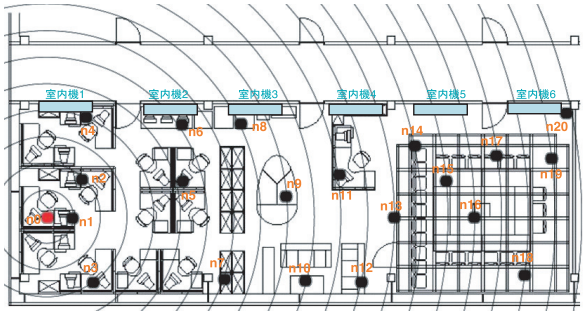

図 6　実験環境におけるノードの配置
Fig. 6　Location of sensor nodes in the experimental environment.

グルホップでロスが発生する環境下における提案手法の有効性を評価したいためである．パケットロスの測定は，片方向ではなく双方向で行う．まず基準ノードがシーケンス番号を含んだパケットを 1 秒おきに 1 時間（3600 パケット）ブロードキャストで送信する．n1–n20 は，基準ノードからのパケットを受信すると確認応答パケットをユニキャストで基準ノードへ送信する．送信パケット数に対して，確認応答が得られなかった数の比率を，パケットロス率とする．

本実験全体を通じて，各送信パケットに対して確認応答パケットが得られたノードの数は，平均 13.8（分散 1.8）であった．最大が 20 ノード，最小が 9 ノードと大きなばらつきがあり，多くのパケットロスが発生している．**図 7** に，ノードごとのパケットロス率を示す．基準ノードからの距離が離れるほどロス率が高くなる傾向にあるものの，n8（距離 8 m）がロス率 20%以上であるのに対し，n16（距離 16 m）は 10%程度と，距離だけではパケットロス率を予測できないことが分かる．

5.2　空間モデルの作成

空間モデルを作成し，夏期の冷房を想定した空調制御のシミュレーションを行う．空間モデルの作成および環境シミュレータは，汎用流体解析パッケージである Flow Designer [1] を用いた．空間モデルは，オフィス家具やパーティション，室内機を実空間と同じように配置している．空間モデルは，オフィス環境における標準的な熱負荷をパラメータとして与えて動作させる．**表 3** に熱負荷条件，**表 4** に計算条件をそれぞれ示す．空間モデルの熱負荷として，床面に人体と OA 機器，天井に照明をそれぞ設定した．左辺と下辺は，一面ガラス張りであるため，日射と熱貫流の熱負荷を設定した．空間モデルの空調システムとして

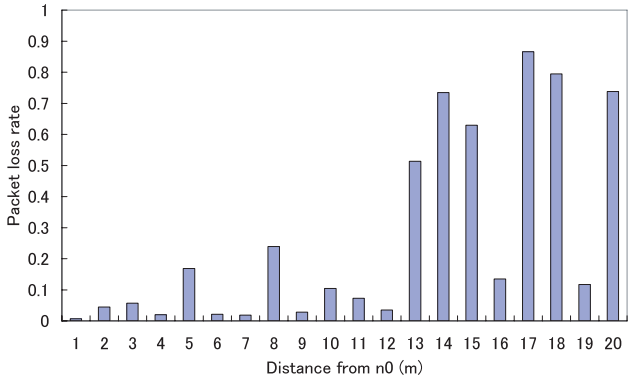

図 7　パケットロスと距離の関係
Fig. 7　Relationship between distance and packet loss rate.

表 3　単位面積あたりの熱負荷条件（W/m^2）
Table 3　Heat load per unit area (W/m^2).

Human body	Office equipment	Lighting	Insolation	Heat transmission
13	39	20	34	8

表 4　計算条件
Table 4　Calculation condition.

Number of analytical meshes	48(x) × 25(y) × 12(z) = 14,400
Turbulent flow model	Standard $k-\varepsilon$ Model
Algorithm	Unsteady Analysis

上辺の天井に接する形で 6 機の室内機を設置した．それぞれの室内機は，稼働時に 1 m/s, 16°C の風を送風し，非稼働時には送風を停止するものとする．初期温度，相対湿度はそれぞれ 30°C，70%とし，1 時間の非定常解析を行う．作成した空間モデルと環境シミュレーションの様子を**図 8** に示す．

5.3　空間モデル上での RHBIM の動作

実空間で MICAz MOTE を設置した場所と同じ場所にモニタリングポイントを設定することで，n0 から n20 のそれぞれのセンサノードがシミュレータ上で得ることのできる環境データが分かる．センサノードへの PPT の配信時および，マスタノードがスレーブノード

© 2010 Information Processing Society of Japan

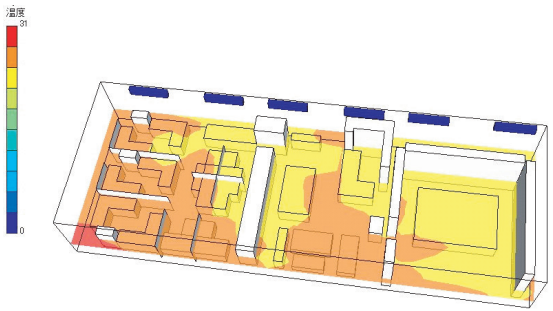

図 8　実験空間における環境シミュレーション
Fig. 8　Environmental simulation in experiment space.

から環境データを収集するときには，5.1 節で計測したロスパターンを基にデータ受信が成功するか否かを決定する．温度分布に関しては，5.2 節で定義したオフィスにおける標準的な熱負荷条件に基づいて動作している．

推論モデルは，図 1 に示した Comfort コンテキストを求めるベイジアンネットワークを使用する．したがって，本実験におけるノードグループは 3 台で構成される．マスタノードによるコンテキストの検出は 10 秒おきとし，Comfort コンテキストが false であった場合に空調を作動し，Comfort コンテキストが true である場合には空調を停止する．

実験環境で用いるリージョンを**図 9** に示す．評価にあたり，R1，R2，R3，R4，R5 の 5 種類のリージョンを用いる．

R1：良いリンク．n0 から n6 までの 7 台．
R2：中程度のリンク．n7 から n13 までの 7 台．
R3：悪いリンク．n14 から n20 までの 7 台．
R4：良いリンクと中程度のリンク．n0 から n13 までの 14 台．
R5：良いリンクから悪いリンク．n0 から n20 までの 21 台．
これら 5 種類のリージョンを用いて，実験の対象とする空調制御空間を規定する．

5.4　PPT 配送先ノードの選択手法の評価

RHBIM は，PPT 送信時にノードグループ内のすべてのノードに PPT が配送されなかった場合，PPT を再送する．PPT 配送先ノードの選択手法のパケットロスに対する有効性を調べるために，SND，MND，AND の各手法ごとに PPT の送信時の再送率を評価した．

まず，R1，R2，R3，R4，R5 の各リージョンごとにノードグループのメンバをランダム

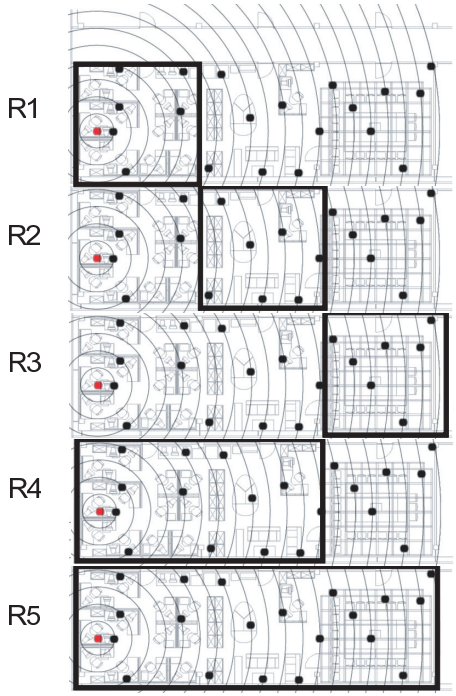

図 9　実験環境におけるリージョン
Fig. 9　Region in experimental environment.

に 10 通り決定する．この際，基準ノードから PPT を送信するため，ノードグループメンバに n0 は含めない．SND，MND，AND の各手法に基づいて PPT を送信するノードを決定し PPT を配送する．本実験で MND は，ノードグループから 2 台のノードをランダムに選択するものとする．ノードグループ内のすべてのノードに PPT が配送されず，PPT を再送することになる確率を算出する．

図 10 に PPT 配送先ノードの選択手法ごとの PPT 再送率の結果を示す．縦軸の PPT 再送率は，10 通りのノードグループにおける平均値である．SND は，ロスの少ない R1 では 5%程度の再送率であるが，R3，R5 では 40%を超える．これに対し AND は，すべてのリージョンにおいて最も再送率が低くなった．R3 において 5%，R5 において 1.5%程度の再送率であった．

© 2010 Information Processing Society of Japan

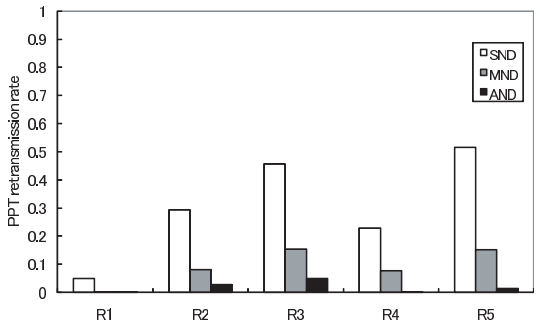

図 10　PPT 配送先ノードの選択手法と PPT 再送率
Fig. 10　Essential node selection scheme for delivering PPT and PPT retransmission rate.

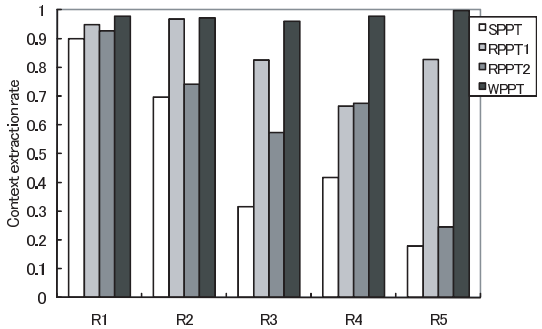

図 11　送信する PPT の選択手法とコンテキスト検出率
Fig. 11　Selection scheme of PPT and context extraction rate.

次に各手法のオーバヘッドについて考える．今回の実験において PPT の送信は，基準ノードからのブロードキャストで行われるため，配送先ノード数の増加により PPT の送信回数は変わらない．したがって，各手法とも PPT 送信コストは変わらない．しかしながら，SND に対して MND，AND は複数ノードで PPT を管理することになるため，ノードグループ全体で見た際のメモリ占有率は高くなる．今回の実験では，SND に対して MND，AND はそれぞれ 2 倍，3 倍のメモリ空間をノードグループ内で確保する必要がある．

この結果から，再送率という観点から見ると PPT 配送先ノードの選択手法として AND を選択することが望ましいといえる．また，メモリ空間に余裕がなくロス率の低い環境下で運用する場合には，SND や MND を選択しても RHBIM の性能に大きく影響はしないといえる．

このほかに PPT 配送先ノードの選択手法は，マスタノード再選択時の性能にも影響する．これは，マスタノードの再選出時にノードグループに PPT がない場合は PPT を再送する必要があるためである．今回の実空間におけるパケットロスの測定では，基準ノードである n0 を中心にロスを計測しており，他のノード間のロス率に関しては対象外である．したがって，スレーブ間のロス率が必要となるマスタノード再選択時の性能評価は行わない．しかしながら，MND，AND を用い複数センサノードに PPT を配送することで，マスタノード再選択時にも PPT 配送時と同様に低い再送率が実現できると考えられる．

5.5　送信する PPT の選択手法の評価

送信する PPT の選択手法のパケットロスに対する有効性を調べるために，SPPT，RPPT，WPPT の各手法ごとにコンテキスト検出率と QoI を評価した．

まず，R1，R2，R3，R4，R5 の各リージョンごとにノードグループのメンバをランダムに 10 通り決定する．この際，基準ノードをマスタノードとし，他の 2 台を対象リージョンからランダムに選択する．n0 に配送する PPT セットを SPPT，RPPT，WPPT の各手法に応じて決定する．RPPT1，RPPT2，WPPT は，各手法に基づいて 2 つの PPT を選択する．

環境シミュレータによる空調制御のシミュレーションを開始し，n0 は Comfort コンテキストの検出タイミングごとに，スレーブノードから環境データを収集する．環境データ収集時の通信は，あらかじめ計測したパケットロスパターンを用いる．n0 は，Comfort コンテキストを検出できたか否かと，推論品質の指標として QoI を記録する．

図 11，**図 12** に送信する PPT の選択手法ごとのコンテキスト検出率および QoI を示す．図 11 の縦軸である検出率は，10 通りのノードグループにおける検出率の平均値である．また，図 12 の縦軸である QoI は，10 通りのノードグループで記録した QoI の平均値である．まず，SPPT のコンテキスト検出率を見ると，R1 では 90%あるのに対し，ロス率が高い環境へ推移するにつれて大幅に低下し，R3 では 31% R5 では 17%程度の検出率となってしまう．他の手法はすべての環境下で SPPT よりも高い検出率を達成しているが，特に WPPT はロス率が高い環境下である R3，R5 においても検出率は 95%以上を維持している．R5 では逆にわずかに上昇しているが，これは高いロス率により WPPT が CPPT ではなく，構成ノードが少ない PPT を選択することで収集データの比較時に PPT と適合する可能性が高くなったためと考えられる．

QoI においても SPPT は，コンテキスト検出率と同様にロス率が高い環境へ移行するほ

© 2010 Information Processing Society of Japan

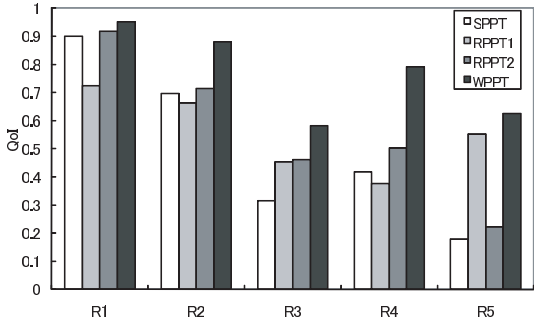

図 12　送信する PPT の選択手法と QoI
Fig. 12　Selection scheme of PPT and QoI.

ど大幅に低下する．これに対し，WPPT はコンテキスト検出率とは違い，ロス率が高い環境へ移行するに従い QoI が低下する．これは，WPPT が CPPT ではなく，構成ノードが少ない PPT を選択したことを示している．しかしながら，WPPT はどのリージョンにおいてもすべての手法の中で最も高い QoI を示しており，コンテキストの検出率と QoI の双方で高い性能を達成しているといえる．一方 RPPT2 は，すべてのリージョンにおいて，SPPT よりもわずかに QoI が改善している．これは RPPT2 が，SPPT の持つ CPPT を必ず選択し，それ以外にランダムで別の PPT が選択されているためと考えられる．これに対し RPPT1 は，RPPT2 と違い QoI の変動が大きい．これは RPPT1 は完全にランダムに PPT を選択するため，適切な PPT を選択した際には QoI は高くなるが，不適切な PPT を選択した場合は QoI が低くなるためだと考えられる．特に，ロス率のそれほど高くない R1，R2，R4 といったリージョンでは，他の手法違い CPPT を選択しない場合が生じてしまうため QoI が低くなる傾向がある．

最後に各手法のオーバヘッドについて論ずる．CPPT のみを選択し送信する SPPT に対し，RPPT および WPPT は複数の PPT を選択し送信する．今回の実験において PPT 選択数は 2 であるため，単純に考えれば送信サイズは 2 倍になる．しかしながら，CPPT 以外に選択することとなる PPT は CPPT より構成ノードが少なくなるため，それに従いデータサイズも CPPT より小さくなる．具体的な PPT のサイズは，インデックスの選択送信時にいくつのインデックスを選択するかに依存する．すべての PPT において 10 のインデックスを選択したものとすると，CPPT のデータサイズは 60 bit，2 台で構成する PPT は 40 bit，1 台で構成する PPT は 20 bit となる．したがって，本実験では SPPT の送信サイズが 60 bit であるのに対し，RPPT および WPPT の送信サイズは 100 bit から 60 bit となる．

6. 関 連 研 究

ベイジアンネットワークを利用して，センサデータから特定のコンテキストを取得する研究として，Sparacino[12] による手法や Patterson ら[6] による手法があげられる．これらの手法は，データを基幹サーバに集めコンテキストを解析する中央集中型のアプローチをとっている．これに対し筆者らは，PPT をセンサノードへ配送することで，センサネットワーク内でのコンテキストの検出を実現するハイブリッドベイズ推論機構を対象としている．本研究の主眼は，ベイジアンネットワークを用いた特定コンテキストのための推論モデル作成ではなく，これらのベイズ推論モデルが駆動するための基盤となるハイブリッドベイズ推論機構の耐障害性の向上にある．

センサネットワークにおけるパケットロスを低減し，信頼性を向上させるための研究は多方面からなされている．パケットロスの測定で使用した MICAz MOTE の MAC 層は，TinyOS の標準の MAC プロトコルである B-MAC[9] を用いた．B-MAC は CSMA 方式であるのに対し，センサネットワークアプリケーションに最適化された TDMA 方式の例として S-MAC[15] や T-MAC[5] があげられる．これらの MAC プロトコルを用いることでパケットロスは低減させることができるだろう．また，Wan ら[13] は，センサネットワーク上でのトランスポート層を用いた信頼性の向上手法を提案している．再送による信頼性の向上手法は，高いロス率の環境下ではオーバヘッドが増大し，著しくパフォーマンスが低下する．また，即応性が要求されるコンテキストでは，再送による遅延は好ましくない．

これに対し筆者らの提案は，たとえパケットロスが生じても，推論品質とコンテキストの検出率を高める手法として RHBIM を提案した．したがって，これらのセンサネットワークの信頼性を高める技術と相反せず，ともに用いることでより RHBIM の性能を高めることができる．

7. 結論と今後の課題

本論文では，ハイブリッド型ベイズ推論機構において問題となるデータロスが生じた場合の性能低下に対応するために，PPT 配送先ノードの選択手法と送信する PPT の選択手法からなるリライアブルハイブリッド型ベイズ推論機構 RHBIM を提案した．

実空間上で 20 台の MICAz Mote を配置しパケットロスの測定を行い，その結果を利用

© 2010 Information Processing Society of Japan

した環境シミュレータ上での空調制御シナリオによって評価を行った．PPT 配送先ノードの選択手法に関しては，パケットロスが発生する環境下での PPT の再送率を評価し，そのオーバヘッドに関する考察を行った．また，送信する PPT の選択手法に関しては，ロスが発生する環境下でのコンテキスト検出率および推論品質を評価し提案手法の有効性を示した．

今後の課題として，より複雑な環境下での空調制御を考える必要がある．本論文の空調制御シナリオでは，非常にシンプルな推論モデルを用いたが，実際の快適な空調環境を実現するために必要となる推論モデルはより複雑になると考えられる．複雑な推論モデルであっても RHBIM は適用可能であるが，実空間に適用するためにはより実状に即した推論モデルを用意する必要がある．また，現状では単一のリージョンで実験を行っており，複数のリージョン間の相互作用は考えていない．複数のリージョン間をまたいだ空調制御を行う場合，リージョンが完全に密閉されていない限り隣接リージョンへの影響も生じるため，室内機間の連携が必要になるだろう．このほかに，空調機とリージョンの動的な対応付けに関しても考える必要がある．昼夜や季節といった時間経過により変動する熱負荷分布に対応するには，各空調機を動的にリージョンに対応付ける機構が必要となるだろう．

また RHBIM は，複数のノードに複数の PPT を配送することで冗長性を高めているため，ロングタームのパケットロスにも対応可能である．しかしながら，今回提案した手法および実験は，ショートタームのパケットロスを対象としている．したがって，ノードの故障やバッテリ切れなどで生じるロングタームのパケットロスに対応できる枠組みの提案と評価が必要となるだろう．

謝辞　本研究は，総務省「ユビキタスサービスプラットフォーム技術の研究開発」および，NICT 委託研究「ダイナミックネットワーク技術の研究開発」の研究成果の一部である．

参　考　文　献

1) Advanced Knowledge Laboratory: Flow Designer 7. available at http://www.akl.co.jp/products/flowdesigner/
2) 間　博人，門田昌哉，中澤　仁，徳田英幸：センサ/アクチュエータネットワークにおけるネットワーク切断を考慮した確率推論機構，情報処理学会論文誌，Vol.48, No.2 (2007).
3) Chen, G. and Kotz, D.: A survey of context-aware mobile computing research, Technical Report TR2000-381, Dept. of Computer Science, Dartmouth College (Nov. 2000).
4) Crossbow: MICAz ZigBee Series. available at http://www.xbow.com/Products/Product_pdf_files/Wireless_pdf/MICAz_Datasheet.pdf
5) van Dam, T. and Langendoen, K.: An adaptive energy-efficient MAC protocol for wireless sensor networks, *Proc. 1st International Conference on Embedded Networked Sensor Systems*, Los Angeles, California, USA (Nov. 2003).
6) Patterson, D.J., Liao, L., Fox, D. and Kautz, H.: Inferring high-level behavior from low-level sensors, *Proc. Ubicomp 2003* (Oct. 2003).
7) 森川博之：ユビキタスネットワーク社会の構築，電学論 C，Vol.124, No.1, pp.12–17 (2004).
8) Neapolitan, R.E.: *Learning Bayesian Networks*, Prentice Hall (2003).
9) Polastre, J., Hill, J. and Culler, D.: Versatile low power media access for wireless sensor networks, *Proc. 2nd International Conference on Embedded Networked Sensor Systems* (*SenSys 2004*), pp.95–107 (Nov. 2004).
10) Russel, S. and Norvig, P.: *Artificiall Intelligence Modern Approach, 2nd Edition*, Prentice Hall (2002).
11) Seppanen, O., Fisk, W. and Lei, Q.H.: Effect of temperature on task performance in offfice environment, *Proc. Cold Climate HVAC conference*, Moscow (2006).
12) Sparacino, F.: Sto(ry)chastic: A bayesian network architecture for user modeling and computational storytelling for interactive space, *Proc. Ubicomp 2003* (Oct. 2003).
13) Wan, C.-Y., Campbell, A.T. and Krishnamurthy, L.: PSFQ: A reliable transport protocol for wireless sensor networks, *Proc. 1st ACM International Workshop on Wireless Sensor Networks and Applications*, Atlanta, Georgia, USA (Sep. 2002).
14) Wyon, D.P. and Wargochi, P.: Room temperature effects on office work, Creating the Productive Environment, Croome, D. (Ed.), pp.193–205.
15) Ye, W., Heidemann, J. and Estrin, D.: An energy-efficient mac protocol for wireless sensor networks, *Proc. 21st International Annual Joint Conference IEEE Computer and Communications Societies* (*INFOCOM 2002*), New York, NY, USA (June 2002).

(平成 21 年 10 月 2 日受付)
(平成 22 年 2 月 25 日採録)

間　博人（正会員）
博士（政策・メディア）．慶應義塾大学大学院政策・メディア研究科特別研究助教．センサネットワーク，無線通信，通信プロトコル等の研究に従事．電気学会，計測自動制御学会，IEEE 各会員．

© 2010 Information Processing Society of Japan

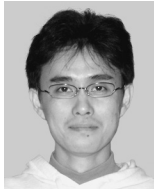

中澤　　仁（正会員）

博士（政策・メディア）．慶應義塾大学大学院政策・メディア研究科講師．日本ソフトウェア科学会，ACM 各会員．ミドルウェア，システムソフトウェア，ユビキタスコンピューティング等の研究に従事．

徳田　英幸（正会員）

慶應義塾大学より工学修士．カナダ，ウォータールー大学より Ph.D.（Computer Science）．現在，慶應義塾大学大学院政策メディア・研究科委員長，同大学環境情報学部教授．分散リアルタイムシステム，マルチメディアシステム，通信プロトコル，超並列・超分散システム，モバイルシステム等の研究に従事．IEEE，ACM，日本ソフトウェア科学会各会員．

© 2010 Information Processing Society of Japan