

結合エントロピーに基づくデータ集約モデルの導出と省電力センサネットワークへの適用

高 博昭^{†a)} 上原 秀幸^{††} 大平 孝^{††}

Data Aggregation Model Based on Joint Entropy and Its Application to Energy Efficient Wireless Sensor Networks

Hiroaki TAKA^{†a)}, Hideyuki UEAHARA^{††}, and Takashi OHIRA^{††}

あらまし 無線センサネットワークにおいて、センサノードの消費電力を削減することは非常に重要な研究課題である。省電力化を実現するアプローチ手法の一つとして、データ集約が挙げられる。データ集約とは、センサノードで得られたデータに対して演算や符号化等を行うことでデータ量を削減し、省電力化を図る方式である。本論文では、データ集約効果の定式化を目的とし、ノード数と観測値の結合エントロピー増加量の関係性を示す集約モデルを定義、導出する。集約モデルは実環境モデルから導出し、決定係数による検証からモデルの妥当性を示した。また、この集約モデルの利用の一例としてクラスタリングにおける間欠送信手法について述べる。この方式は、クラスタごとに集約モデルを導出し、集約モデルに応じて各クラスタ内のノードの送信確率を設定することで送信データ量を削減し、消費電力の削減を図る方式である。シミュレーションにより、間欠送信手法により送信回数削減が可能であることを確認した。

キーワード センサネットワーク、集約モデル、省電力、クラスタリング

1. まえがき

センサネットワークは、センサノードにより様々な情報を取得することを目的としたネットワークであり、防犯・セキュリティ、災害予測、環境モニタリングなどの分野に利用されており、今後も様々な分野への応用が期待されるネットワークである [1]。センサノードは、ノード配置の自由度の観点から無線センサノードが使用される。無線センサノードは、情報を収集するためのセンサ、計算処理を行う MPU、通信をつかさどる無線通信装置と、これらのデバイスを駆動させるための電力を供給するバッテリーで構成される。センサノードのバッテリーが枯渇したとき、バッテリーの交換等

が必要になる。しかし、多数のセンサノードが配置されるセンサネットワークでは、人件費等のコスト面からバッテリー交換は困難である。そのため、アプリケーションが要求するネットワーク稼動期間を満足するためにも、センサノードの省電力化が必要不可欠となる。

これまで様々な省電力化手法が提案されているが、我々はその中でもデータ集約手法 [2] に着目する。データ集約とは、得られたデータに対して演算、符号化等を行うことによりデータサイズを削減する手法で、データ送信時の消費電力を削減することが可能である。例えば、複数ノードの観測値の平均値や最大・最小値などの統計量を求めることもデータ集約である。Directed Diffusion [3], TAG [4], TiNA [5] などのデータセントリックなプロトコルでは、ネットワーク全体にクエリを送信し、該当するノードがデータを送信、若しくは中継ノードにおいてクエリに対応するための処理を行う方式である。Distributed Source Coding [6] では、複数の送信ノードは互いに通信することなく符号化を行い (distributed coding), 受信側でそれらの符号化データから元のデータを復号する方

[†] 豊橋技術科学大学大学院電子・情報工学専攻, 豊橋市
Graduate School of Electronic and Information Engineering,
Toyohashi University of Technology, Toyohashi-shi, 441-
8580 Japan

^{††} 豊橋技術科学大学電気・電子情報工学系, 豊橋市
Department of Electrical and Electronic Information Engineering,
Toyohashi University of Technology, Toyohashi-shi,
441-8580 Japan

a) E-mail: taka@comm.ee.tut.ac.jp

法 (joint decoding) であり, この原理に基づく方式として DOC [7] などが挙げられる. しかし, この方式は実機への実装については述べられておらず, 計算能力の乏しいセンサノードでは実現が難しいと考えられる.

本論文では, 実環境のデータに対して情報理論的解析を行い, 集約モデルの導出を行う. 集約モデルは, 観測値の結合エントロピー増加量とノード数の関係を定式化したものであり, 集約モデルを用いることでデータ集約時における集約後のデータサイズを求める. これにより, データ集約を考慮した既存プロトコルの評価を簡単に行うことが可能となる. また, センサノードはモデルの係数を知ることで結合エントロピー増加量を把握することができ, 計算能力に制約のあるセンサノードでは大きなメリットとなる. 本論文では, 集約モデルを利用した方式の一例として, クラスタリングにおけるセンサノードのデータ間欠送信手法についても提案する. 本論文で間欠送信とは, 与えられた送信機会全てで送信を行わずに確率的に送信を行うことと定義しており, この送信確率は集約モデルに基づいて決定する.

2. 集約モデル

集約モデルは情報理論 [8] に基づき定義される. 本論文では様々な実環境データに情報理論的解析を行うことで集約モデルを導出し, 決定係数によるモデル評価を行った.

2.1 情報源符号化後のデータサイズの定式化

確率変数を V_1, \dots, V_N , 確率変数 V_N がとり得る値を v_{N1}, v_{N2}, \dots とし, とり得る値の集合を $\mathbf{v}_N = \{v_n | v_{N1}, v_{N2}, \dots\}$ とする. このとき V_1, \dots, V_N の結合エントロピー $\mathcal{H}(V_1, \dots, V_N)$ は次式で与えられる.

$$\begin{aligned} \mathcal{H}(V_1, \dots, V_N) &= - \sum_{\mathbf{v}_1 \in \mathbf{v}_1, \dots, \mathbf{v}_N \in \mathbf{v}_N} p(v_1, \dots, v_N) \log_2 p(v_1, \dots, v_N) \quad (1) \end{aligned}$$

ここで $p(v_1, \dots, v_N)$ は確率変数 V_1, \dots, V_N の結合確率密度関数である.

また, 確率変数の個数が $i-1$ 個から i 個に増えたときのエントロピーの増加量 $\Delta H(i)$ を次式で定義する.

$$\Delta H(i) = \begin{cases} \frac{\mathcal{H}(V_1, \dots, V_i) - \mathcal{H}(V_1, \dots, V_{i-1})}{\mathcal{H}(V_1, \dots, V_{i-1})} & i > 1 \\ 1 & i = 1 \end{cases} \quad (2)$$

センサネットワークにおいて, V_i はセンサノード i で観測する物理量, \mathbf{v}_i がセンサノード i の観測値の集

合に相当する. $\mathcal{H}(V_1, \dots, V_i)$ は冗長なくセンサノード $1, \dots, i$ の全ての観測値を表現するために必要なビット数を表している. これは, 情報源符号化を行った際の最小のビット数を示している.

一般的に結合エントロピー $\mathcal{H}(V_1, \dots, V_i)$ は以下の劣加法性を満たす.

$$\mathcal{H}(V_1, \dots, V_i) \leq \mathcal{H}(V_1) + \dots + \mathcal{H}(V_i) \quad (3)$$

ここで, $\mathcal{H}(V_i)$ はセンサノード i で観測する物理量のエントロピーである. この式は, i 個のセンサノードで観測する物理量の結合エントロピーが, i 個のセンサノード個々のエントロピーの総和以下となることを意味している. なお, ここで等式が成り立つのは V_1, \dots, V_i が互いに独立のときのみに限られる.

ノード数 m のときの結合エントロピー $\mathcal{H}(V_1, \dots, V_m)$ を $H_{agg}(m)$ とし, $H_{agg}(m)$ を式 (2) を用いて表すと次式となる.

$$H_{agg}(m) = H_1 + H_1 \sum_{i=2}^m \Delta H(i) = \mathcal{H}(V_1, \dots, V_m) \quad (4)$$

ここで, H_1 は各ノードで得られる観測値のエントロピーの平均値である.

2.2 実環境データを用いたエントロピー増加量のモデル化

実際の観測値をもとにエントロピー増加量の導出を行った. エントロピー導出に際して, 屋内にセンサネットワークを構成して温度, 及び照度データを収集した. 図 1 にノード配置, 表 1 にデータ収集条件を

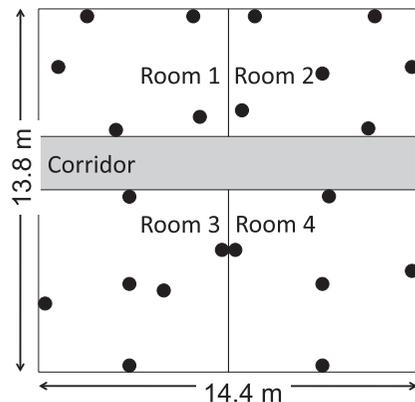


図 1 ノード配置図
Fig. 1 Node deployment.

表 1 使用したデータの詳細
Table 1 Details of used data.

Sensor node	mote mica2 [9]
Number of nodes	22
Sensor board	MDA100 [10]
Sensing period	Oct. 22, 2010 ~ Nov. 18, 2010
Sensing object	temperature light
Sensing interval	10 min.

示す。

エントロピーの増加量は以下の手順に従った。

(1) 全てのセンサノードから $i (1 \leq i \leq N)$ 個のセンサノードを選択し、それらのセンサノードで観測された物理量の集合 \mathbf{S} を作成する。集合 $\mathbf{S} (\mathbf{S} = \{V_j | j = 1, \dots, i\})$ に含まれるセンサノードで観測された物理量に対して、結合エントロピーを計算する。結合エントロピーの計算は式 (1) に基づく。ここで V_j はセンサノード j で観測された物理量である。なお N 個のセンサノードから i 個を選ぶときの組み合わせは、 ${}_N C_i$ 通り存在する。

(2) 上記 (1) の処理をそれぞれの i の値に対して行う。センサノードの組合せによって結合エントロピーの値は異なるため、それぞれの i に対して結合エントロピーの平均を取ったものをセンサノード数が i のときの結合エントロピーの値とする。

(3) 平均した結合エントロピーを、 $i = 1$ のときの結合エントロピー H_1 の値で正規化し、それぞれの i に対する正規化結合エントロピーを計算する。これを $\mathcal{H}(V_1, \dots, V_i)$ とする。

(4) 式 (2) を用いてセンサノード数 i のときのエントロピー増加量 $\Delta H(i)$ を計算する。

図 2 及び図 3 に正規化結合エントロピー、図 4 及び図 5 にエントロピー増加量を示す。ここではデータ期間の違いによる影響を示すため、1 週間単位でグラフ化した結果を示す。データの期間によって正規化結合エントロピー及びエントロピー増加量は異なるものの、センサノード数の増加に伴い、正規化結合エントロピーはある一定の値に、エントロピー増加量は 0 に漸近することが分かる。このエントロピー増加量を以下の指数関数で近似する [11]。

$$\Delta H(i) = a \cdot \exp(-b \cdot i) \quad (i > 1) \quad (5)$$

ここで、 a 及び b は観測条件や観測対象等に依存する定数である。特異な場合として $a = 0$ のとき、エントロピーの増加量が常にゼロとなることから、式 (4) よ

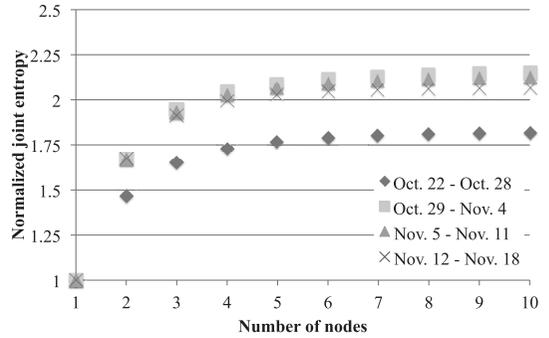


図 2 気温データから求めた正規化結合エントロピー
Fig. 2 Normalized joint entropy of temperature.

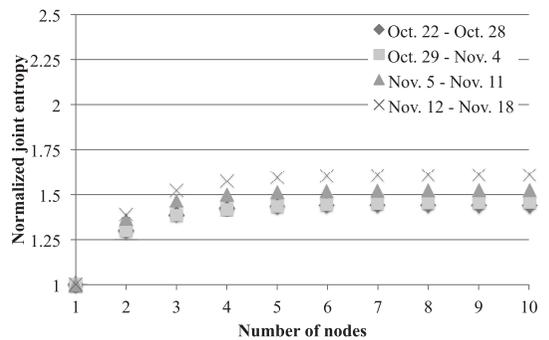


図 3 照度データから求めた正規化結合エントロピー
Fig. 3 Normalized joint entropy of light.

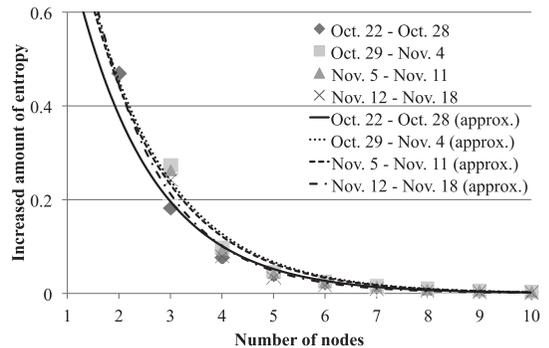


図 4 気温データから求めたエントロピー増加量
Fig. 4 Aggregation model of temperature.

り結合エントロピーはノード数によらず H_1 で一定となる。また $b = 0$ のとき、センサノード数によらずエントロピー増加量は一定となり、結合エントロピーも傾き a の直線となる。本論文では、式 (5) を集約モデルとして定義する。

また、集約モデルの妥当性を検証するための指標として決定係数 R^2 を用いる。 R^2 は次式で表される。

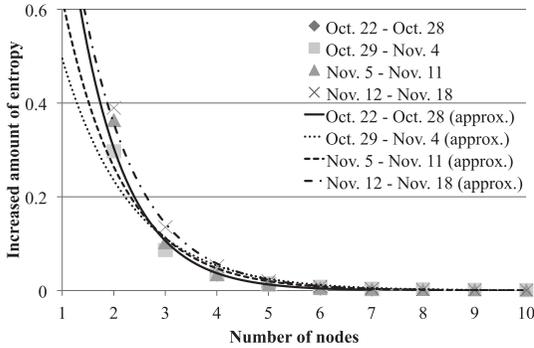


図5 照度データから求めたエントロピー増加量
Fig. 5 Aggregation model of temperature.

表2 屋内センサネットワークのデータから導出した集約モデルの係数と決定係数

Table 2 Aggregation model coefficients and determination coefficient derived from intra sensor network data.

data	period	a	b	R^2
temperature	Oct. 22 ~ Oct. 28	1.431	0.663	0.988
	Oct. 29 ~ Nov. 4	1.626	0.637	0.978
	Nov. 5 ~ Nov. 11	1.614	0.646	0.976
	Nov. 12 ~ Nov. 18	1.963	0.741	0.987
illuminance	Oct. 22 ~ Oct. 28	2.492	1.051	0.998
	Oct. 29 ~ Nov. 4	1.041	0.743	0.970
	Nov. 5 ~ Nov. 11	1.471	0.859	0.982
	Nov. 12 ~ Nov. 18	2.209	0.912	0.999

$$R^2 = 1 - \frac{\sum_i (y_i - f_i)}{\sum_i (y_i - \bar{y})} \quad (6)$$

ここで、 y_i は実測値、 \bar{y} は実測値の平均値、 f_i は回帰式による推定値を表す。 R^2 は 0 から 1 の範囲を取り、1 に近いほど回帰式の当てはまりが良いことを意味する。本論文では、 y を実際の結合エントロピーから求めたエントロピー増加量、 f を集約モデルにより求めたエントロピー増加量として決定係数を計算する。決定係数は、集約モデルの妥当性を検討するための指標として用いる。

表 2 に屋内で収集した温度及び照度データより求めた集約モデル係数 a , b 及び決定係数 R^2 の値を示す。この結果から、集約モデルとして指数関数を用いたことは妥当であったといえる。同様に SensorScope [12] で提供されているデータから集約モデル及び決定係数を計算した結果を表 3 に示す。SensorScope のデータは 2007 年 1 月の 10 分ごとの各ノードの大気気温、地表温度、湿度のデータを使用し、データの刻み幅

表3 SensorScope のデータから導出した集約モデルの係数と決定係数 [12]

Table 3 Aggregation model coefficients and determination coefficient derived from SensorScope [12].

Type	Step size	Period	a	b	R^2
Air temp.	0.1°C	Monthly	1.446	0.886	0.964
		Weekly	1.725	0.943	0.977
		Daily	1.539	0.922	0.990
	1°C	Monthly	0.836	0.389	0.945
		Weekly	0.872	0.374	0.940
		Daily	0.669	0.352	0.899
Surface temp.	0.1°C	Monthly	1.466	1.017	0.938
		Weekly	2.811	1.208	0.991
		Daily	2.226	1.075	0.993
	1°C	Monthly	1.072	0.458	0.965
		Weekly	1.021	0.431	0.957
		Daily	0.804	0.364	0.930
Humidity	1%/div	Monthly	1.689	0.660	0.985
		Weekly	1.800	0.701	0.990
		Daily	1.202	0.624	0.979
	5%	Monthly	0.957	0.354	0.943
		Weekly	0.918	0.343	0.928
		Daily	0.781	0.352	0.929

(Step size) 及びデータ期間 (Period) を変化させてモデル導出を行った。例えばデータ期間が Weekly の場合は、一週間分のデータを使用して集約モデル及び決定係数を導出し、その平均値が表に記載されている。SensorScope のデータを使用した場合でも、データの刻み幅及びデータ期間によって、 a , b の値は大きく異なるものの、決定係数の値はいずれも高い値を示している。以上のことからデータの時間間隔、観測範囲、観測対象等により集約モデルの係数は異なるが、いずれも決定係数の値が高いため、指数関数で近似することは妥当である。

集約モデルを導出したことにより、集約モデルから結合エントロピーが漸近する値を推定することも可能となる。以下にその手順を示す。まず式 (4) を変形すると、

$$\begin{aligned} H_{agg}(m) &= H_1 + H_1 \sum_{i=2}^m \Delta H(i) \\ &= H_1 + H_1 \sum_{i=2}^m a \exp(-bi) \\ &= H_1 + aH_1 \sum_{i=2}^m \exp(-bi) \\ &= H_1 + aH_1 \{ \exp(-2b) + \dots + \exp(-mb) \} \end{aligned} \quad (7)$$

ここで、初項 a 、公比 r の等差数列の m 項部分 S_m は次式で与えられる。

$$S_m = \frac{a(1-r^m)}{1-r} \quad (8)$$

式 (8) を用い、式 (7) を変形すると

$$H_{agg}(M) = H_1 \left\{ 1 + a \exp(-2b) \frac{1 - \exp\{-b(m+1)\}}{1 - \exp(-b)} \right\} \quad (9)$$

となる。 $H_{agg}(M)$ の極限をとると

$$\lim_{m \rightarrow \infty} H_{agg}(m) = H_1 + \frac{aH_1 \cdot \exp(-2 \cdot b)}{1 - \exp(-b)} \quad (10)$$

となる。これは集約モデルの係数 a 、 b が求まれば、全センサノードのデータの結合エントロピーが簡単に推定できることを意味している。

3. 集約モデルに基づく間欠送信手法

本章では集約モデルを利用した省電力手法として、クラスタリングスキームにおけるデータ送信回数削減手法について述べる。クラスタリングとは、ネットワーク中に存在するセンサノードを複数のクラスタに分割する方式である。各クラスタ内にはクラスタヘッドと呼ばれるノードが存在し、クラスタ内の他のノードはクラスタヘッドを中継ノードとしたマルチホップ通信を行う。これによりシンクノードまでの長距離通信を抑制し、消費電力を削減する。また、クラスタヘッドにおいてデータ集約を行うことで送信データサイズを削減し、省電力化を図る。クラスタリング手法として、LEACH [13]、HEED [14]、DWEHC [15]、相関指標クラスタリング [16] などがある。LEACH では、クラスタヘッドを確率的に選択して距離指標でクラスタリングを行う。HEED では、センサノードの残存電力を考慮した上でクラスタヘッドを選択した上でクラスタリングを行う。DWEHC では、構成するクラスタのサイズも考慮してクラスタリングを行う。相関指標クラスタリングでは、観測値の相関が高いノード同士でクラスタを構成する。

図 6 に提案手法のコンセプトを示す。ハフマン符号化等の情報源符号化によりクラスタヘッドでクラスタ内のデータを集約する場合、クラスタヘッドが送信するデータ量を削減することで省電力化を図る。提案方式では、シンクノードが計算した集約モデルの係数

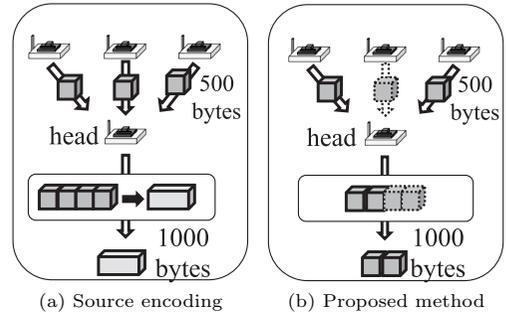


図 6 間欠送信手法のコンセプト

Fig. 6 Concept of intermittent transmission method.

とエントロピー増加の有無を判断するしきい値から、各センサノードのデータ送信確率を計算する。センサノードはこのデータ送信確率をもとに間欠送信を行い、クラスタヘッドでは情報源符号化を行わずにデータを送信する。これにより、クラスタメンバの送信による消費電力とクラスタヘッドでのデータ集約処理による消費電力を削減することが可能となる。このとき、情報源符号化を行った際のデータサイズと、提案方式でクラスタヘッドが送信するデータサイズがほぼ等しくなるようにセンサノードのデータ送信確率を集約モデルに基づき決定する。

本手法の利点は、様々なクラスタリング手法に組み込むことが可能な点である。本論文では、クラスタリングスキームはラウンドと呼ばれる時間単位で動作し、ラウンドはクラスタリングフェーズとデータ送信フェーズの二つのフェーズから構成され、データ送信フェーズは N_F 個のフレームから構成されているものとする。また、各ノードは衝突なくデータを送信できるものと仮定する。

以下に間欠送信手法のアルゴリズムを示す。

(1) クラスタリングフェーズにおいて、シンクノードは既存のクラスタリング手法に基づきクラスタリングを行う。

(2) シンクノードは各クラスタの集約モデル $\Delta H_k(m_k)$ の係数をこれまで受信したデータから計算する。ここで添字の k はクラスタ番号を表す。前節と同様に結合エントロピー増加量から指数関数による近似を行うことで求める。

(3) シンクノードは各クラスタに対して、以下の条件を満たす最小のノード数 m_k を求める。

$$\Delta H_k(m_k) \leq H_{TH} \quad (1 \leq m_k \leq M_k) \quad (11)$$

ここで M_k はクラスタ k 内のノード数, H_{TH} は結合エントロピーの増加の有無を判別するしきい値である. $\Delta H_k(m_k)$ が H_{TH} 以下である場合, ノード数 $m_k + 1$ 以上については結合エントロピーの増分はないものとして扱う. m_k はデータ送信フェーズにおいて, 1 フレーム当りの送信ノード数の期待値を表す.

(4) 式 (11) の条件を満たした最小の m_k から, 各クラスタ内のセンサノードの送信確率 p_k を求める.

$$p_k = \frac{m_k}{M_k} \quad (12)$$

式 (12) において, 分子は 1 フレーム当りのクラスタ k の送信ノード数の期待値, 分母はクラスタ k のクラスタメンバ数を表しており, 各フレームにおいて m_k 個のクラスタメンバがデータ送信を行うように, クラスタメンバのデータ送信確率を決定している.

(5) 計算した送信確率 p_k を, クラスタ k のノードに通知する. クラスタ内のクラスタメンバは, p_k に従いデータ送信フェーズにおいて確率的にデータ送信を行う. なお, 送信確率はただか数バイト程度であるため, 送信確率を配信するための通信コストは少なく, 電力消費に与える影響は軽微である.

4. シミュレーション実験

間欠送信手法を既存のクラスタリング手法である LEACH [13] と相関指標クラスタリング CLARA [16] に適用し, 送信回数削減効果とデータ精度に関するシミュレーション評価を行った (表 4). シミュレータには C 言語により作成したシミュレータを使用し, データとして SensorScope で提供されている 2007 年 1 月の 10 分ごとの地表温度データを用いた. ラウンド構成については, 1 日を 1 ラウンド, 1 フレームを 10 分に対応させている. シミュレーションの初期設定として, 最初の 1 ラウンドは間欠送信は行わずに, それぞれのクラスタリングアルゴリズムに基づき, 集約モデル導出のためのデータを収集する. 表 3 より地表気温の一日分のデータで集約モデルを導出した場合も決定係数が 0.9 以上と高いため, 集約モデルの導出には前日分のデータを用いる. 一般的にモデルの導出に用いるデータは期間が長いほど, より長期のデータの特徴を表すことができるが, 今回 SensorScope を用いてモデル導出を行った結果モデル係数に有為な差は見られないため, どちらも同等の送信回数削減効果が得られると考えられる. 間欠送信により欠落したデータは, 線形補間により補間するものとする.

表 4 シミュレーション諸元
Table 4 Simulation parameters.

Clustering strategy	LEACH (distance-base) [13] CLARA (average-base) [16]
Number of nodes	88
Number of rounds	31
Sensing data	surface temperature for Jan 2007 (SensorScope)
Number of frames N_F	144
Threshold value H_{TH}	0.01, 0.05, 0.1, 0.2
Simulator	C language

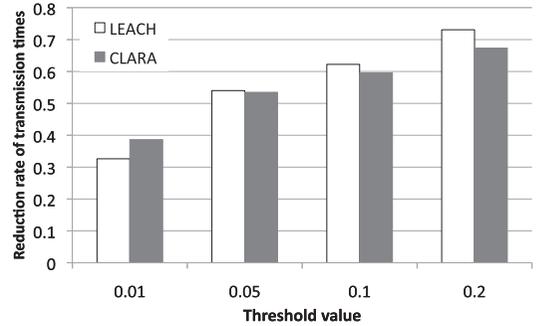


図 7 送信回数削減率

Fig. 7 Reduction rate of data transmission times.

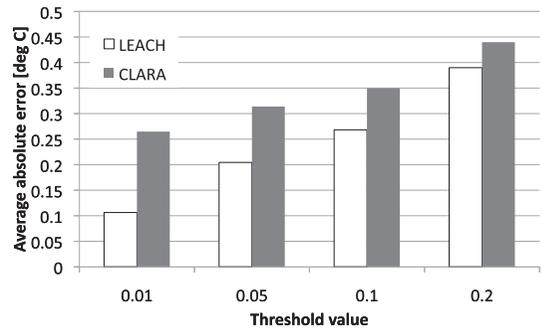


図 8 各ノードの絶対誤差の平均値

Fig. 8 Average absolute error.

図 7 に送信回数削減率, 図 8 に各ノードの絶対誤差の平均値を示す. 送信回数削減率とは, 従来のクラスタリング方式における送信回数から, 間欠送信を行うことでどれだけ送信回数が削減できたかを示す指標である. 絶対誤差の平均値とは, 各フレームごとに観測値の真値とシンクでの補間値の絶対誤差を計算し, その平均を求めたものである. しきい値が大きいくほど送信回数削減率が増加していることが分かる. しきい値が 0.2 のとき, LEACH で 73%, CLARA で 67% の送信回数の削減を実現している. したがってシンクノードでのデータ受信量も同等の結果である. これは, し

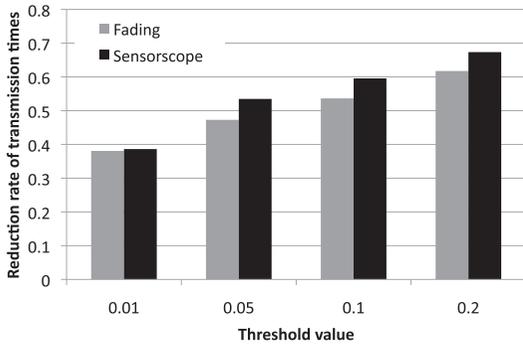


図9 データセットの違いによる送信回数削減率
Fig.9 Reduction rate of data transmission times.

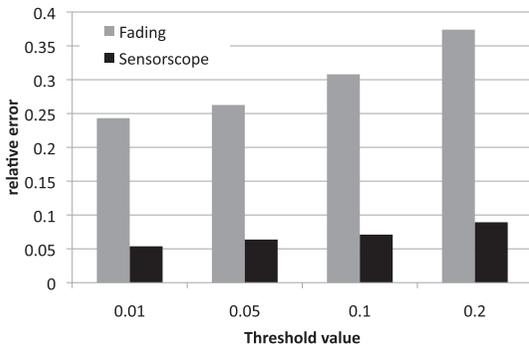


図10 データセットの違いによる相対誤差
Fig.10 Average absolute error.

きい値が大きいかほど式(11)の条件を満たす m_k の値が小さくなるためであり、その結果、式(12)で与えられる送信確率も低くなるからである。また、絶対誤差の平均値についてもきい値が大きいかほど増加することが分かる。

クラスタリングスキームに CLARA を用い、SensorScope のデータ、仮想的なデータとして相関が低く時間的変動の大きいレイリーフェージングの包絡線振幅データを使用したときの送信回数削減率を図9、相対誤差を図10に示す。送信回数削減率についてはそれほど大きな差はない。しかし SensorScope のデータの場合は相対誤差は10%未満であるのに対して、フェージングのデータを使用した場合は相対誤差は25%~35%と非常に大きい。これはデータの時間的変動が大きく、データ補間の際の誤差が大きくなったためである。

5. む す び

本論文では、ノード数と観測値の結合エントロピー

増加量の関係性を指数関数によって近似し、データ集約効果を示す集約モデルを定義した。屋内センサネットワーク及び SensorScope で提供されている屋外データから集約モデルを導出した結果、ほとんどの場合において0.9以上と高い決定係数が得られていることから、集約モデルに指数関数を用いることは妥当であるといえる。

また、集約モデルの活用例として、クラスタリングスキームにおいてクラスタ内ノードのデータ送信確率を集約モデルによって設定する間欠送信手法の提案を行った。シミュレーションにより間欠送信手法の評価を行った結果、送信回数の削減を実現可能であることを確認した。この間欠送信手法は、圃場ごとの土壌センシングや、各部屋の平均温度の収集等のアプリケーションにおいて、面的な情報収集を行いつつ、長寿命化が実現可能となると考えられる。

謝辞 本研究の一部は、国立大学法人豊橋技術科学大学グローバル COE プログラム“インテリジェントセンシングのフロンティア,”日本学術振興会科学研究費補助金、基盤研究(C)21560397の援助により行われた。関係者各位に深謝する。

文 献

- [1] I.F. Akyildiz, W. Su, Y. Sankarasubramaniam, and E. Cayirci, “A survey on sensor networks,” *IEEE Commun. Mag.*, vol.40, no.8, pp.102–114, Aug. 2002.
- [2] E. Fasolo, M. Rossi, J. Widmer, and M. Zorzi, “In-network aggregation techniques for wireless sensor networks: A survey,” *IEEE Wireless Commun. Mag.*, vol.14, no.2, pp.70–87, May 2007.
- [3] C. Intanagonwivat, R. Govindan, D. Estrin, J. Heidemann, and F. Silva, “Directed diffusion for wireless sensor networking,” *IEEE/ACM Trans. Netw.*, vol.11, no.1, pp.2–16, Feb. 2002.
- [4] S. Madden, M.J. Franklin, J.M. Hellerstein, and W. Hong, “TAG: A tiny aggregation service for ad-hoc sensor networks,” *OSDI 2002*, Boston, MA, US, Dec. 2002.
- [5] A. Sharaf, J. Beaver, A. Labrinidis, and K. Chrysanthos, “Balancing energy efficiency and quality of aggregate data in sensor networks,” *The VLDB Journal*, vol.13, no.4, pp.384–403, Dec. 2004.
- [6] Z. Xiong, A.D. Liveris, and S. Cheng, “Distributed source coding for sensor networks,” *IEEE Signal Process. Mag.*, vol.21, no.5, pp.80–94, Sept. 2004.
- [7] J. Zheng, P. Wang, S. Member, and C. Li, “Distributed data aggregation using slepian-wolf coding in cluster-based wireless sensor networks,” *IEEE Trans. Veh. Technol.*, vol.59, no.5, pp.2564–2574, June 2010.

- [8] 中川聖一, 情報理論の基礎と応用, 近代科学社, 東京, 1992.
- [9] クロスボー株式会社, XM2110J/MPR2600J/420/520-MIB User Manual, <http://www.xbow.jp/mprmib.pdf>
- [10] クロスボー株式会社, MTS/MDA Sensor Board User's Manual, <http://www.xbow.jp/mtsmmaj.pdf>
- [11] H. Taka, H. Uehara, and T. Ohira, "Node scheduling method based on aggregation model for clustering scheme in wireless sensor networks," WPMC'09, Sendai, Japan, Sept. 2009.
- [12] SensorScope, http://sensorscope.epfl.ch/index.php/Main_Page
- [13] W.B. Heinzelman, A.P. Chandrakasan, and H. Balakrishnan, "An application-specific protocol architecture for wireless microsensor networks," IEEE Trans. Wireless Commun., vol.1, no.4, pp.660-670, Oct. 2002.
- [14] O. Younis and S. Fahmy, "HEED: A hybrid, energy-efficient, distributed clustering approach for ad hoc sensor networks," IEEE Trans. Mobile Comput., vol.3, no.4, pp.366-379, Oct. 2004.
- [15] P. Ding, J. Holliday, and A. Celik, "Distributed energy-efficient hierarchical clustering for wireless sensor networks," IEEE International Conference on Distributed Computing in Sensor Systems, Marina Del Rey, CA, June 2005.
- [16] D. Maeda, H. Uehara, and M. Yokoyama, "Efficient clustering scheme considering non-uniform correlation distribution for ubiquitous sensor networks," IEICE Trans. Fundamentals, vol.E90-A, no.7, pp.1344-1352, July 2007.

(平成 23 年 5 月 27 日受付, 9 月 20 日再受付)



高 博昭 (学生員)

平 19 豊橋技科大・工・情報卒, 平 21 同大学院修士課程了. 現在同大学院博士後期課程・電子情報工学専攻在学中. 主としてセンサネットワークに関する研究に従事.



上原 秀幸 (正員:シニア会員)

平 4 慶大・理工・電気卒. 平 9 同大学院博士課程了. 同年豊橋技科大・情報・助手. 平 14 同講師. 平 16 同助教授. 平 18 同大・未来ビークルリサーチセンター・助教授, 平 19 同准教授, 現在, 同大学院電気・電子情報工学系准教授. 平 14~15 ATR 適応コミュニケーション研究所客員研究員. 主として無線アクセス方式, マルチホップ通信の研究に従事. 情報処理学会, IEEE, ACM 各会員. 平 14, 平 18, 平 23 本会通信ソサエティ活動功労賞.



大平 孝 (正員:シニア会員)

昭 53 阪大・工・通信卒. 昭 58 同大学院博士課程了. NTT にて衛星搭載 GaAs-MMIC の設計を担当. ATR にてエスパーテナの研究に従事. 平 17 ATR 波動工学研究所長. 現在, 豊橋技術科学大学教授. 昭 61 本会篠原賞. 平 10 APMC Japan Microwave Prize. 平 16 本会エレクトロニクス賞. 電気学会ミリ波調査専門委員長. URSI Communication C Chair. IEEE MTT-S Kansai Chapter Founder. IEEE MTT-S Nagoya Chapter Founder. 工博. IEEE Fellow.