

I-5 コンテキストを用いた環境センシングからの知識発見手法の提案

Proposal of a Methodology for Knowledge Discovery from Environmental Sensing Data Using Contextual Data

吉田善博¹・矢吹信喜²

Yoshihiro YOSHIDA, Nobuyoshi YABUKI

抄録: 環境センシングによって得られた膨大な量のデータから有意な知識を発見するためには、データマイニングが有効だと考えられる。しかしながら、センサデータは、単なる数値データであるため、センシングによって得られたデータのみを用いてデータマイニングを行っただけでは、一般的に期待されるような知識を発見できる可能性は低いものと考えられる。そこで本研究では、センサとコンテキストのデータを用いたデータマイニングの方法論を考案した。さらに、建物内の環境に関するデータマイニングを行い、本研究で考案した方法論の検証を行った。その結果、本方法論により、妥当な知識を導き出せることが確認された。

Abstract: In order to find meaningful information and knowledge from a large amount of sensor data, data mining has attracted considerable attention. However, simple application of the data mining technique to sensor data may not be so successful as expected. Therefore, a methodology for data mining using contextual data was proposed in this research. The proposed methodology was verified executing data mining for environment in a building. As a result, meaningful and effective knowledge was discovered applying the proposed methodology.

キーワード: データベース, センサ, データマイニング, コンテキスト, 環境センシング, クラスタリング, 相関ルール分析

Keywords : Database, sensor, data mining, context, environmental sensing, clustering, association-rule mining

1. はじめに

MEMS 技術の発達により、センサの費用は急速に低下しており、将来、社会は、ありとあらゆる場所にセンサが設置されたユビキタスな社会になるものと予想される¹⁾。センシングによって得られた膨大な量のデータから有意な知識を発見するためには、データマイニングが有効だと考えられる。しかしながら、センサデータは、単なる数値データであるため、センシングによって得られたデータのみを用いてデータマイニングを行っただけでは、一般的に期待されるような知識を発見できる可能性は低いものと考えられる。センサデータの背後には、その値をもたらしたコンテキスト(文脈)が存在すると考えられる。コンテキストには、センサの周辺に配置されている機械類の動作状態、空調設備のダクトから出てくる冷気の量、窓の開閉状態、天気、周辺の人間の数や活動状況など様々な情報が含まれる。こうしたコンテキストは、通常は、データベースには含まれておらず、センサの配置状況を示す平面図や断面図などの図の中に、人間が見てその意味がわかるように記される。しかし、こうした図は、人間にとっては理解できても、コンピュータにとっては単

なる線や点などの集合であり、そこから人間が理解するのと同じように、コンピュータに理解させることは困難である。従って、膨大なセンサデータから、データマイニングによって有意な知識を発見するためには、センサデータのみならず、センサを取り巻く環境に関する情報や、センサ周囲に存在するオブジェクトとの関係に関する情報等のコンテキストに関する情報を加味した、知識発見に関する新しい方法論を確立する必要があると考えられる。環境センシングによって得られたデータを用いてデータマイニングを行った事例として Wu²⁾らの研究があるが、コンテキストのデータは加味されていない。

そこで本研究では、膨大なセンサデータから、効率的に有意な知識を発見するために、コンテキストの情報を加味したデータマイニングの方法論を考案した。さらに、建物内の環境に関するデータマイニングを、本研究で考案した方法論を用いて行うことで、妥当性の検証を行った。

2. データマイニング

データマイニングとは、膨大な量のデータから、有

1 : 学生会員 工修 大阪大学大学院工学研究科 環境・エネルギー工学専攻 博士後期課程 環境設計情報学領域
2 : 正会員 Ph.D. 大阪大学大学院工学研究科 環境・エネルギー工学専攻 教授
(〒565-0871 大阪府吹田市山田丘 2-1, Tel :06-6879-7660, E-mail : yabuki@see.eng.osaka-u.ac.jp)

意な知識を導き出すための一連の手続きのことであり、データベース理論、統計学、機械学習等の様々な分野の方法論が融合した方法論である。データマイニングを行うための基本的な処理の流れは、大きく分けて以下の4つのプロセスから構成される^{3),4)}。

(1) データウェアハウス構築

データウェアハウスは、データマイニングに必要なデータを収集し、一箇所に集めて管理することによって構築される。収集対象となるデータは、地理的に異なる場所のデータベース内に貯蔵されていることや、異なるデータ形式で保存されていることがある。従って、データウェアハウスを構築するためには、データを収集するだけでなく、データ形式の統一も必要になる場合がある。

(2) 前処理

このプロセスでは、データマイニングのアルゴリズムの適用のために必要な処理として、データクレンジング（外れ値・ノイズの除去、欠損値の補間等）が行われる。また、連続値の離散化やカテゴリー化等のデータタイプの変換処理も行われる。

(3) パターン発見

前処理を行ったデータセットに対して、データマイニング手法を適用することによって、パターンの発見を行う。データマイニング手法には、「教師あり学習」と「教師なし学習」がある。「教師あり学習」とは、クラス情報を必要とする手法で、代表的な手法として、決定木分析やニューラルネットワーク等がある。一方、「教師なし学習」は、クラス情報を必要としない手法で、代表的な手法として、クラスター分析や自己組織化マップ等がある。

(4) 知識獲得

このプロセスでは、「パターン発見」のプロセスで得られたパターンを、解釈・評価することによって知識を獲得する。データマイニングの一連のプロセスを一度行っただけでは、所望の知識が得られない場合もある。そのような場合には、「パターン発見」のプロセスに戻ってアルゴリズムを適用し直すことや、新しいデータを追加するために、「データウェアハウス構築」のプロセスに戻ることがある。

(5) データマイニングの点検への応用事例

水野⁵⁾は鋼鉄道橋の検査記録から亀裂の発生傾向の決定木を構築する研究を行い、可能性を示唆している。また、鋼橋の塗膜状況の調査結果からデータマイニングを用いて要因分析を実施し、要因をいくつか抽出している。

3. 提案する方法論

(1) コンテキストデータ

センサデータは、単なる数値情報であるため、膨大なセンサデータから、データマイニングによって有意な知識を発見するためには、センサデータのみならず、センサを取り巻く環境に関する情報や、センサ周囲に存在するオブジェクトとの関係に関する情報等のコンテキストに関する情報を加味してデータマイニングを行う必要がある。コンテキストデータは、様々な対象に関するデータから構成されるため、データの種類によってセンサとの関係性が異なる。そこで本研究では、コンテキストデータを、センサを取り巻く環境に関するデータである「環境データ」と、センサ周囲に存在するオブジェクトとの関係に関するデータである「オブジェクトデータ」に分類することとした。

(2) 方法論の概要

本研究で提案する方法論のフローチャートを図-1に示す。

本方法論では、まず、環境データを用いてクラスターリングを行い、類似したコンテキスト同士のグループ化を行う。本論では、この処理を「セグメント化」、

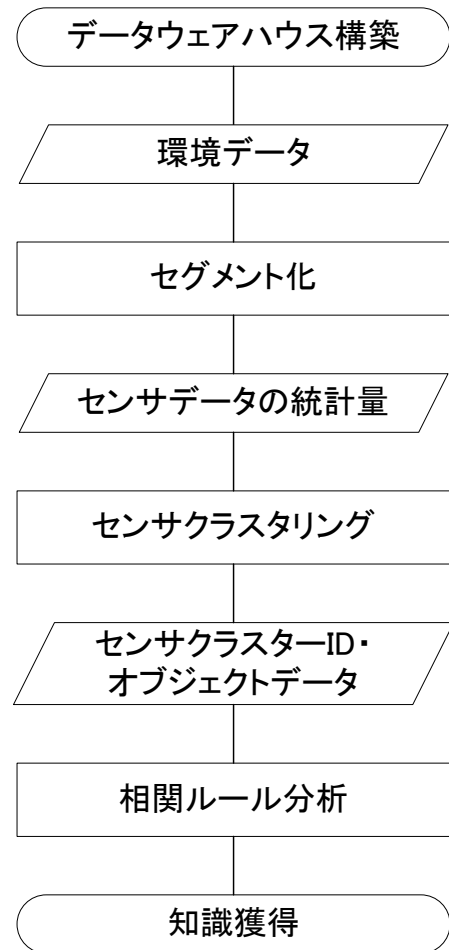


図-1 方法論のフローチャート

生成されたクラスターを「セグメント」、クラスター情報を「セグメント ID」と呼ぶこととする。

次に、セグメント ID とセンサデータを結合し、セグメント毎にセンサデータの統計量を算出して、センサデータを要約する。その後、算出した統計量を用いて、クラスタリングを行い、センサのグループ化を行う。本論では、センサデータを用いたクラスタリングを「センサクラスタリング」、生成されたクラスターを「センサクラスター」、クラスター情報を「センサクラスターID」と呼ぶこととする。

センサクラスタリング終了後は、センサクラスターの生成結果を、センサ周囲のオブジェクトとの関係性の観点から分析するために、センサクラスターID とオブジェクトデータを用いて相関ルール分析を行う。

最後に、セグメント毎に、センサクラスターの結果を解釈・評価することにより知識を獲得する。

(3) データマイニング手法

本研究で提案する方法論では、データマイニング手法として、クラスター分析、決定木分析、相関ルール分析を用いることとした。それぞれの手法について以下に述べる。

a) クラスター分析

クラスター分析は、対象データ集合中の類似したデータ同士をまとめて、データ集合をいくつかのグループに分割する手法である。クラスタリングの手法は、階層的手法と非階層的手法に大別される。階層的手法は、全てのデータを一つのクラスターとみなし、類似したデータ同士を逐次的に併合していき、全てのデータが一つのクラスターに併合されるまで処理を繰り返す手法である。一方、非階層的手法は、クラスターの数をあらかじめ設定し、全てのデータを何れかのクラスターに割り当てていく手法である。階層的手法では、クラスタリングの結果をデンドログラム（樹状図）として表現するが、コンテキストデータに階層的クラスタリング手法を適用した場合、複雑で理解し難いデンドログラムが生成される可能性が高い。そこで本方法論のクラスター分析には、非階層的手法を用いることとした。

b) 決定木分析

決定木とは、クラス情報が与えられたデータセットにおける、クラスを分類するためのルールを、木構造で表現したものである。決定木を作成することによって、クラスの分類と属性との関係を木構造で分かり易く表現することが可能である。本方法論では、セグメントの生成結果の理解を容易にするために、セグメント ID をクラス情報に設定し、環境データを属性に設定した決定木を作成した。

c) 相関ルール分析

相関ルール分析とは、ある事象が起こった際に、別

の事象が起こりやすいというような、異なる事象間の共起規則を導き出す手法である。導き出されるルールは、If-then の形式で記述され、X という事象が起こったら Y が起こるというルールであれば、If X then Y (または X->Y) と表される。また、前述のルールの X の部分を条件部と呼び、Y の部分を結論部と呼ぶ。導き出されたルールの評価指標として、支持度と確信度がある。支持度とは、全トランザクションの中で、導き出されたルールが出現する割合のことである。一方、確信度とは、条件部が起こった際に、結論部が起こる割合のことである。本方法論では、同じセンサクラスターID を持つセンサと、その周囲のオブジェクトとの関係について、相関ルール分析を用いて共起規則を導き出すこととした。

4. シミュレーションデータを用いた方法論の検証

(1) シミュレーション方法

本研究で考案した方法論の検証は、環境シミュレーションソフトによって生成したデータを用いて行った。シミュレーションソフトには、英国 DesignBuilder 社の DesignBuilder⁶⁾を使用した。シミュレーションは、**図-2**に示す建物モデルをソフトウェア上に作成し、2002年7月1日から7月5日までの東京の気象データを用




図-2 建物モデルの外観（上：南西側，下：北東側）

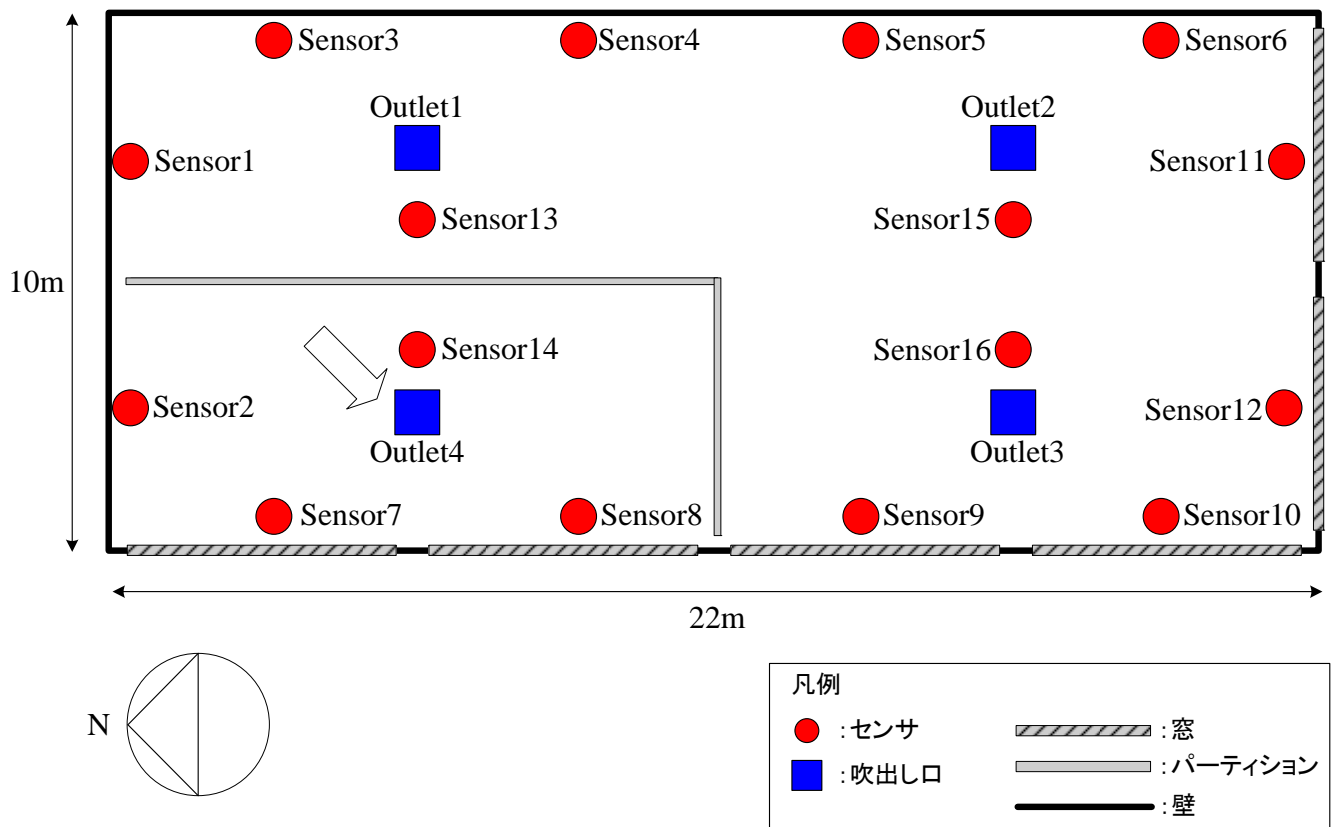


図-3 センサと吹出し口の配置図




図-4 パラメータの設定内容

いて行った。建物内には、パーティションで区切られた領域を設け（図-3）、空調の吹出し口を4箇所配置し（図-3）、空調方式は可変風量方式、設定温度は24℃とした。また、建物内の16箇所にセンサを配置し（図-3）、温度計測が行われているものと仮定した。サンプリングレートは、気象データに合わせて1時間とした。

シミュレーションの各種パラメータの設定内容を図-4に示す。空調設備の運転、在室人数、照明の点灯・

消灯のスケジュールには、ステップ関数を用いた（図-5）。空調のスケジュールに関しては、7月5日にダンパが故障したと仮定して、図-3の矢印の位置の「吹出し口4」の空調を、7月5日のみ意図的にOFFにした。これにより、「吹出し口4」からは冷気が出なくなる。この現象を、本研究で開発した手法により発見できるか検証した。

(2) コンテキストデータ

環境データには、気象データの一部、空調の消費電





図-5 ステップ関数の一部（上：在室人数，下：照明の点灯・消灯）

表-1 変数の説明

| 変数名 | 説明 |
|-----------|---|
| HVAC | 空調の消費電力. |
| Occ | 在室人数. |
| Ltg | 照明の消費電力. |
| Temp | 外気の乾球温度. |
| Rad | 直達日射と散乱日射の合計値. |
| Cld | 空に占める雲の割合を0から10までの整数値で表す. 0が最も晴れた状態を表す. |
| Day | 日付の日にち部分のみの数字. |
| TimeIndex | AMまたはPMの2値. |

表-2 環境データの一部

| HVAC | Occ | Ltg | Temp | Rad | Cld | Day | TimeIndex |
|-------|-----|-----|------|------|-----|-----|-----------|
| 0 | 0 | 0 | 23 | 0 | 9 | 2 | AM |
| 0 | 0 | 0 | 23 | 0 | 9 | 2 | AM |
| 0 | 0 | 0 | 24 | 0.05 | 9 | 2 | AM |
| 7.03 | 6 | 20 | 25 | 0.18 | 9 | 2 | AM |
| 6.95 | 12 | 20 | 25 | 0.3 | 9 | 2 | AM |
| 7.15 | 24 | 20 | 26 | 0.4 | 9 | 2 | AM |
| 7.38 | 24 | 20 | 26 | 0.48 | 9 | 2 | AM |
| 7.53 | 24 | 20 | 29 | 0.91 | 5 | 2 | AM |
| 7.88 | 18 | 20 | 30 | 0.94 | 5 | 2 | AM |
| 8.31 | 18 | 20 | 29 | 0.56 | 9 | 2 | PM |
| 9.18 | 24 | 20 | 30 | 0.89 | 5 | 2 | PM |
| 10.69 | 24 | 20 | 31 | 0.9 | 2 | 2 | PM |

表-3 オブジェクトデータの作成に用いた条件

| オブジェクトの種類 | 条件 |
|-----------|-----------------------------|
| 壁・窓 | 部材表面から3m以内. |
| 吹出し口 | 吹出し口とセンサを結んだ直線上にパーティションがない. |

表-4 トランザクション型のデータセットの例

| ID | データセット |
|----|----------------------------------|
| 1 | {Wall1, Wall2} |
| 2 | {Wall3, Wall4, Window1, Window2} |

力, 在室人数, 照明の消費電力, 時刻情報を用いた (表-1, 2).

一方, オブジェクトデータは, 表-3の条件に該当するオブジェクトの情報を, トランザクション型のデータセットとして用いた (表-4).

(3) データマイニング

データマイニングツールには, SPSS 社の Clementine9.0⁷⁾と, オープンソースのデータマイニングツールである Weka⁸⁾を用いた.

クラスタリングのアルゴリズムには, 非階層的クラスタリングアルゴリズムの一つで, k-means 法を拡張したアルゴリズムである x-means 法⁹⁾を用いた. k-means 法は, クラスターの分割数を予め設定する必要があるが, x-means 法では, ベイズ情報量基準を用いることによって, 最適なクラスター数を自動的に定めることができる. 相関ルール分析には, 効率的な相関ルールの抽出が可能な Apriori アルゴリズム¹⁰⁾を用いることとした. 決定木分析には, 高速な処理が可能な C5.0¹¹⁾を用いた.

以下に, 方法論のプロセス毎の結果を示す.

a) セグメント化

まず, 環境データを用いてセグメント化を行った. セグメント化は, 表-2のデータから, 時刻情報を除いたデータを用いて行った. その結果, 4つのセグメントが生成された. セグメント生成後は, 環境データとセグメント ID の関係を表す決定木を作成した (図-6).

b) センサクラスタリング

次に, セグメント ID とセンサデータを結合し, セグメント毎に, それぞれのセンサの統計量を算出した. 統計量は, 最大値, 中央値, 最小値, 標準偏差を算出した (表-5). 算出した統計量を用いてセンサクラスタリングを実施した結果, セグメント ID が 1 の場合, 2つのセンサクラスターが生成された. 一方, セグメント ID が 2, 3, 4 の場合は, センサクラスター

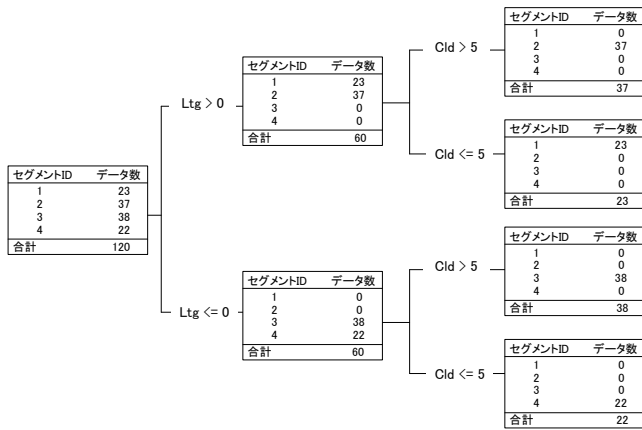


図-6 環境データとセグメント ID の関係を表す決定木

表-5 セグメント内のセンサデータの統計量の一部 (上:セグメント ID=1, 下:セグメント ID=2)

| センサ名 | 最大値 | 中央値 | 最小値 | 標準偏差 |
|----------|-------|-------|-------|------|
| Sensor1 | 27.43 | 26.74 | 25.23 | 0.61 |
| Sensor2 | 30.05 | 25.64 | 23.87 | 1.82 |
| Sensor3 | 27.32 | 26.81 | 25.23 | 0.58 |
| Sensor4 | 27.47 | 26.93 | 25.15 | 0.64 |
| Sensor5 | 27.86 | 27.13 | 25.06 | 0.83 |
| Sensor6 | 27.96 | 27.36 | 25.23 | 0.86 |
| Sensor7 | 31.04 | 25.93 | 24.06 | 2.10 |
| Sensor8 | 30.99 | 25.96 | 24.08 | 2.08 |
| Sensor9 | 29.21 | 27.61 | 25.08 | 1.26 |
| Sensor10 | 28.84 | 27.51 | 25.12 | 1.19 |
| Sensor11 | 28.23 | 27.75 | 25.31 | 0.92 |
| Sensor12 | 28.40 | 27.69 | 25.20 | 1.00 |
| Sensor13 | 26.68 | 26.27 | 24.74 | 0.52 |
| Sensor14 | 29.67 | 25.02 | 23.28 | 1.88 |
| Sensor15 | 27.13 | 26.59 | 24.59 | 0.77 |
| Sensor16 | 27.53 | 26.62 | 24.40 | 0.99 |

| センサ名 | 最大値 | 中央値 | 最小値 | 標準偏差 |
|----------|-------|-------|-------|------|
| Sensor1 | 27.21 | 26.03 | 22.36 | 1.22 |
| Sensor2 | 27.81 | 24.66 | 21.72 | 1.54 |
| Sensor3 | 27.22 | 26.12 | 22.36 | 1.21 |
| Sensor4 | 27.37 | 26.20 | 22.28 | 1.28 |
| Sensor5 | 27.66 | 26.21 | 22.14 | 1.42 |
| Sensor6 | 27.74 | 26.29 | 22.22 | 1.47 |
| Sensor7 | 28.60 | 24.80 | 21.78 | 1.64 |
| Sensor8 | 28.60 | 24.81 | 21.76 | 1.67 |
| Sensor9 | 28.73 | 26.53 | 22.08 | 1.66 |
| Sensor10 | 28.42 | 26.33 | 22.15 | 1.60 |
| Sensor11 | 27.93 | 26.58 | 22.24 | 1.54 |
| Sensor12 | 28.07 | 26.46 | 22.20 | 1.56 |
| Sensor13 | 26.58 | 25.73 | 21.98 | 1.17 |
| Sensor14 | 27.19 | 23.99 | 21.16 | 1.53 |
| Sensor15 | 26.92 | 25.76 | 21.74 | 1.39 |
| Sensor16 | 27.24 | 25.58 | 21.59 | 1.51 |

表-6 相関ルール分析に使用したデータの一部

| センサ名 | データセット |
|---------|---|
| Sensor1 | {Wall1, Wall4, Outlet1, Outlet4, s1} |
| Sensor2 | {Wall1, Wall3, Outlet4, s2} |
| Sensor3 | {Wall1, Wall4, Outlet1, Outlet2, Outlet3, s1} |
| Sensor4 | {Wall1, Outlet1, Outlet2, Outlet3, s1} |

表-7 相関ルール分析に使用したデータの一部

| 統計量 | センサクラスターID=1 | センサクラスターID=2 | センサクラスターの中心距離 |
|------|--------------|--------------|---------------|
| 最大値 | 30.44 | 27.84 | 2.60 |
| 中央値 | 25.64 | 27.08 | 1.21 |
| 最小値 | 23.82 | 25.03 | 1.45 |
| 標準偏差 | 1.97 | 0.85 | 1.12 |

は生成されなかった。

c) 相関ルール分析

センサクラスターリングの結果を受け、セグメント ID が 1 の時の、センサクラスター ID とオブジェクトデータを結合することによって、トランザクション型のデータセット (表-6) を作成し、相関ルール分析を行った。尚、Apriori アルゴリズムは、シンボル値しか使用できないため、データセット内のセンサクラスター ID には、プレフィックスとして s をつけた。Apriori アルゴリズムの設定値は、最小サポート値を 20%、最小確信度を 50% とした。その結果、合計 149 件のルールが生成された。生成されたルールの中から、同じセンサクラスター ID を持つセンサ間で成立する、周囲のオブジェクトとの関係に関する共起規則を導き出すために、結論部がセンサクラスター ID で、かつ、確信度が 100% のデータを抽出した。その結果、

If Outlet4 then s2

というルールが抽出された。この意味は、『「吹出し口 4」と関係があるセンサは、センサクラスター ID が 2 である。』である。

d) 知識獲得

セグメント ID が 2, 3, 4 の場合は、センサクラスターが生成されなかったことから、全ての位置で温度の傾向がほぼ等しいことが分かる。

一方、セグメント ID が 1 の場合は、2 つのセンサクラスターが生成された。そこで、温度データの最大値、中央値、最小値、標準偏差に関する、センサクラスターの中心距離を比較した (表-7)。ここで、センサクラスターの中心距離とは、それぞれのセンサクラスター中心値の間の距離のことである (図-7)。また、センサクラスター中心値とは、それぞれのセンサクラスター内の、センサデータの統計量 (最大値、中央値、最小値、標準偏差) の平均値である (図-7)。センサクラスターの中心距離を比較した結果、温度データの最大値に最も大きな差があることが分かった。

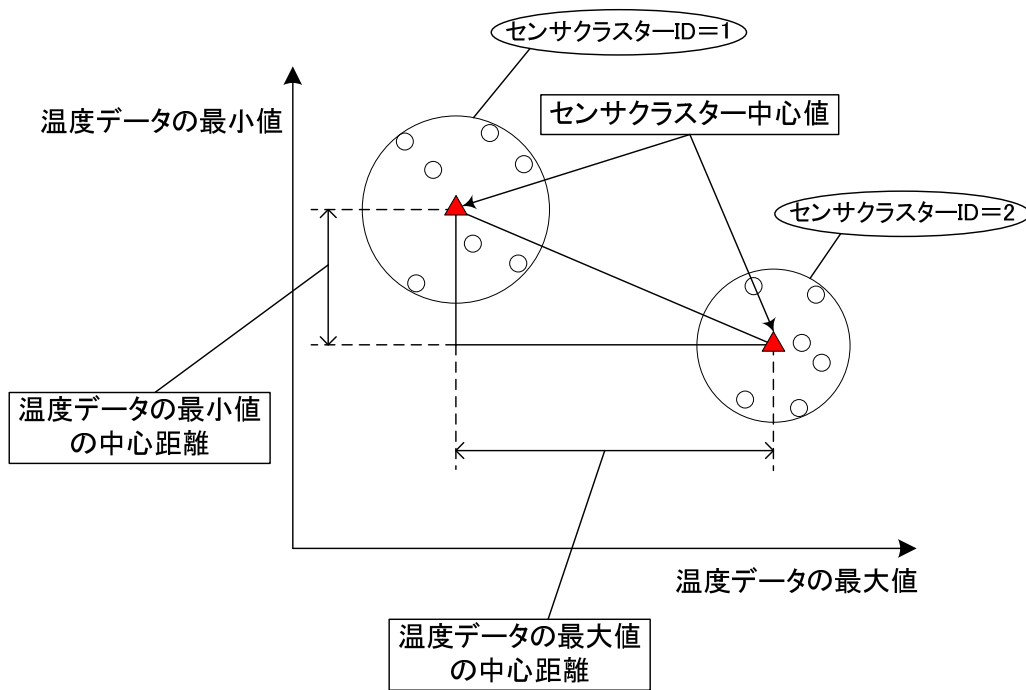


図-7 センサクラスターの中心距離の説明

表-8 センサクラスター中心値の比較結果

| Day | TimeIndex | UpperID | Central Value |
|-----|-----------|---------|---------------|
| 2 | AM | 1 | 26.14 |
| 2 | AM | 1 | 26.62 |
| 2 | PM | 1 | 27.59 |
| 2 | PM | 1 | 28.33 |
| 2 | PM | 1 | 28.80 |
| 4 | AM | 1 | 25.33 |
| 4 | AM | 1 | 25.46 |
| 4 | AM | 1 | 26.03 |
| 4 | AM | 1 | 26.53 |
| 4 | AM | 1 | 27.24 |
| 4 | AM | 1 | 27.64 |
| 4 | PM | 1 | 27.78 |
| 4 | PM | 1 | 28.18 |
| 4 | PM | 1 | 28.76 |
| 4 | PM | 1 | 28.92 |
| 5 | AM | 1 | 27.54 |
| 5 | PM | 1 | 27.72 |
| 5 | PM | 1 | 28.06 |
| 5 | PM | 1 | 28.71 |
| 5 | PM | 2 | 30.29 |
| 5 | PM | 2 | 31.04 |
| 5 | PM | 2 | 30.53 |

そこで、クラスター間の温度データの最大値の差について、より詳細なデータマイニングを行うために、温度データの最大値のセンサクラスター中心値を時刻別に比較し、値が大きい方のセンサクラスターID (UpperID) とセンサクラスター中心値 (Central Value) を表にまとめた (表-8)。その結果、以下のことが明らかとなった。

- ・ 7月2日, 4日では、時間帯に関係なく、UpperID は1である。一方、7月5日では、UpperID が2の時間帯がある。
- ・ UpperID が2の時は、センサクラスターID が1の時よりも中心値が大きい。

以上の2点に加えて、相関ルール分析より、「吹出し口4」と関係があるセンサは、センサクラスターID が2であるという結果が得られている。これらの結果から、『7月5日の午後の時間帯だけ、「吹出し口4」周辺のセンサが、室内で最も高い温度を示している。』という知識を獲得し、吹出し口4の異常を推論することが可能だと考えられる。

5. まとめ

本研究では、センサデータとコンテキストのデータを用いて知識発見を行うための方法論を考案した。また、建物内に複数のセンサが設置された事例を用いて方法論の検証を行った。その結果、本研究で提案する方法論によって、妥当な知識を導き出せることが確認

された。

今後の課題は、本研究で提案した方法論の有用性を検証するために、実データを用いてデータマイニングを行うことである。

参考文献

- 1) 日本建築学会：ユビキタスは建築をどう変えるか，彰国社，2007.
- 2) Wu, S., Clements-Croome, D.: Understanding the indoor environment through mining sensory data—A case study, *Energy and Buildings*, 39(11), pp.1183-1191, 2007.
- 3) T. J. ティオリー（原田勝訳）：データベースの設計，勁草書房，2000.
- 4) 元田浩，津本周作，山口高平，沼尾正行：データマイニングの基礎，オーム社，2006.
- 5) 水野裕介：データウェアハウス，データマイニング技術による社会基盤構造物の維持管理データの管理手法の提案，東京大学大学院工学系研究科博士論文，2004.9.
- 6) DesignBuilder: <http://www.designbuilder.co.uk/>
- 7) SPSS: <http://www.spss.co.jp/>
- 8) Weka: <http://www.cs.waikato.ac.nz/ml/weka/>
- 9) Pelleg, D. and Moore, A. : X-means: Extending Kmeans with Efficient Estimation of the Number of Clusters, ICML-2000, pp.727-734, 2000.
- 10) R. Agrawal and R. Srikant: Fast Algorithms for Mining Association Rules, 20th International Conference on Very Large Data Bases, Santiago, Chile, Sept. 1994.
- 11) R. Quinlan, “C5.0: An Informal Tutorial”, <http://www.rulequest.com/see5-unix.html>.

(2010. 5. 28 受付)