

属性ごとのクラスタリングと関連ある属性の統合に基づくデータの関連付け

松本 唯志[†] 吉高 淳夫[†]

概要 複数の属性を持つデータを参照する際に、個々の属性に注目して類似するデータを探す場合がある。このとき、データの全ての属性について個々に類似するデータを参照することは少なく、属性の代表的な値や稀にしか見られない特殊な値という特徴的な値をとる属性のみに注目して、類似するデータを探すことが多い。そこで本研究では、属性ごとにクラスタリングした結果からデータごとに特徴的な属性を検出し、その属性について類似するデータを関連付ける。また、それらの属性の中で関連が強い属性については統合を行い、統合した属性についてデータの関連付けを行う。このデータの関連付けにより、データの特徴的な属性について類似するデータの参照を容易にする。

Extracting Relation between Data based on Clustering and Integration of Correlated Attributes

Tadashi Matsumoto[†] and Atsuo Yoshitaka[†]

Abstract When a user refers to data which have many attributes, he/she may search similar data of a individual attribute. Then, in many cases, he/she pays attention to the characteristic attributes that take a typical or rare value, and searches data which are similar to referred data. We detect characteristic attributes of individual data from the result of clustering, and extract relation between data of a individual attribute. Furthermore, we integrate correlated attributes, and extract relation between data of the set of integrated attributes. By extracting relation, a user easily refers to similar data of characteristic attributes.

1. はじめに

データベースの中で必要とするデータを参照したとき、その参照したデータに類似するデータを探す場合がある。例えば、特定の属性をキーとして検索を行い、必要とするデータを参

照したとき、キーとした属性以外に、そのデータの中で特徴的な値をとる属性があり、その属性に注目して類似するデータを探すというような場合が考えられる。このような場合に容易に類似するデータを参照できるようにするためには、データの中で特徴的な値をとる属性を検出し、その属性について類似するデータへの関連付けを行うことが必要となる。

[†]: 広島大学大学院工学研究科
Graduate School of Engineering, Hiroshima University

ここで、属性値の中での特徴的な値とは、属性の代表的な値と特殊な値を指す。前者は類似するデータが多い値であり、後者は類似するデータが少ない値である。以後、前者をメジャーな値、後者をマイナーな値と呼ぶ。メジャーな値を参照することでそのデータベースでの基本的な情報を得ることができ、マイナーな値を参照することで新しい情報を発見することができる。よって、データが持つ複数の属性の中で、これらのメジャーな値をとる属性とマイナーな値をとる属性(以後、メジャーな属性とマイナーな属性)が重要な属性であるので、これらについてデータの関連付けを行う。

また、参照したデータの中で特徴的な値をとる属性が複数ある場合には、それらの個々の属性について関連するデータを探すという作業を何度か行うことになる。このとき、それらの属性の中で関連が強い属性がある場合、参照したデータに関連するデータとして提示される結果が類似する。類似する結果を度々参照することは冗長であるので、関連が強い属性を1つの集合として統合する必要がある。

本研究では、属性ごとにクラスタリングを行った結果から、データごとにメジャーとマイナーな属性を判断し、その属性について類似するデータに関連付ける。そして、メジャーとマイナーそれぞれについて属性間の関連が強い属性の統合を行う。本研究で行う統合とは、関連が強い属性のみを構成要素とする集合を作ることである。この属性の集合に対して類似するデータの関連付けを行う。これにより、データの中で重要な属性について関連するデータへのリンクを張り、参照を容易にする。

2. 関連研究

[1]では、関連ある属性を統合し、統合した属性の重要さを考慮して類似するデータを探すため、主成分分析を用いている。しかし、主成分分析による属性の統合は、全ての属性に対して重みを付けその和をとることで行うため、

関連が弱い属性も小さな重みを付けられて統合される。よって、特定の属性に焦点を絞って関連する情報を参照することはできない。本研究では、属性ごとにクラスタリングを行い、関連が強い属性のみを集合としてまとめることで統合し、データの関連付けを行う。

[2], [3]では、複数ある属性の中から重要な属性を選択する手法を提案している。[2]ではクラスタリングを行うアルゴリズムである k 平均法の反復処理の中に、クラスタ内の分散が最小になるような特徴を選択するという処理を加えている。[3]では、ICD アルゴリズム[4]を用いて属性間の関連とデータ間の距離を求め、属性間の直接的な関連と間接的な関連を全ての属性について計算し、他の多くの属性との関連が弱い属性は除き、関連が強い属性のみを選択している。しかしこれらの手法は、データ全体に対して重要な属性を判断しており、個々のデータについてどの属性が重要であるかということ判断していない。よって、データ全体に対して重要であると判断した属性と、参照しているデータの重要な属性が異なる場合があり、このような場合にはデータの重要な属性に注目して関連するデータを参照するということができない。本研究では、データごとにメジャーとマイナーな属性を検出することで、参照したデータに対応した重要な属性の選択を行い、全てのデータについて、データ固有の重要な属性に注目して関連するデータを参照することを可能にする。

3. データの関連付け

データの関連付けを行う処理の流れを図 1 に示す。

まず、属性ごとに値の範囲が異なるため、関連付けの前処理としてそれぞれの属性について平均が 0、分散が 1 となるようにデータを標準化する。データベース中の m 個のデータを d_1, \dots, d_m 、 n 個の属性を f_1, \dots, f_n とする。そして、データ $d_i (i = 1, 2, \dots, m)$ の属性 $f_j (j = 1, 2,$

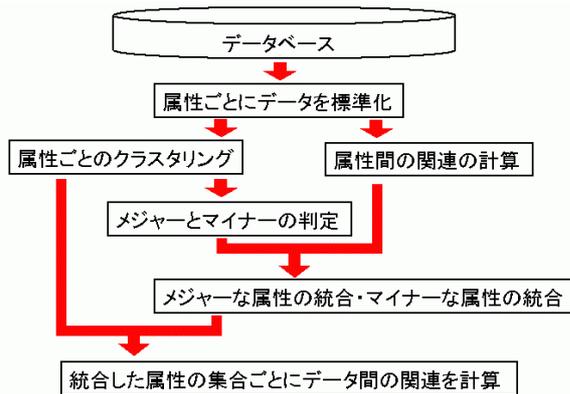


図1 関連付けの処理の流れ

..., n)に対する値を $value(d_i, f_j)$ とする。そして、データ d_i の属性 f_j について標準化した値 $value'(d_i, f_j)$ を属性 f_j の値の平均 μ_{f_j} と標準偏差 δ_{f_j} を用いて、式(1)で計算する。

$$value'(d_i, f_j) = \frac{value(d_i, f_j) - \mu_{f_j}}{\delta_{f_j}} \quad (1)$$

この標準化したデータに対して以下の3.1～3.5の処理を行い、関連付けを行う。

3.1 属性ごとのクラスタリング

一般に用いられるクラスタリングの手法の1つに k 平均法がある。この手法ではクラスタ数を事前に指定しなければならないので、本研究では適切なクラスタ数を自動的に決定してクラスタリングするため、以下の～の処理を行う。この処理を全ての属性に対して行う。

初期値としてクラスタ数 k を2とし、クラスタの重心を平均 \pm 標準偏差とする。

クラスタ数 k として k 平均法によりクラスタリングを行う。

各クラスタの分散を計算し、その値が閾値 (0.05) より大きいクラスタを検出する。

で検出されたクラスタ数を l としたとき、 l が0なら処理を終了する。

で検出された l 個のクラスタをそれぞれ2つのクラスタに分割し、分割前のクラスタの平均 \pm 標準偏差をクラスタの重心と

する。これにより分割後のクラスタの重心の数 k' は $k+l$ となる。

クラスタ数 k を k' とした後、へ戻る。

3.2 属性間の関連の計算

属性間の関連を計算する。属性 f_s と f_t の関連を表す $r(f_s, f_t)$ は式(2)によって求める。 $r(f_s, f_t)$ は属性 f_s と f_t の共分散であり、 δ_{f_s} と δ_{f_t} はそれぞれ属性 f_s, f_t の値の標準偏差である。前処理でデータの標準化を行っているので、 δ_{f_s} と δ_{f_t} はともに1となっている。 $r(f_s, f_t)$ は、 f_s と f_t の関係が、傾きが正である比例関係に近いときに1に近い値をとり、傾きが負である比例関係であるとき-1に近い値をとる。 f_s と f_t にこのような関係が見られないときには $r(f_s, f_t)$ は0に近い値をとる。つまり、 f_s と f_t が比例関係に近いとき $|r(f_s, f_t)|$ が1に近い値をとり、そのような関係が無いときには $|r(f_s, f_t)|$ が0に近い値をとる。よって、この $|r(f_s, f_t)|$ を属性間の関連の強さとする。

$$r(f_s, f_t) = \frac{\delta_{f_s f_t}}{\delta_{f_s} \times \delta_{f_t}} \quad (2)$$

3.3 メジャーとマイナーな属性の判定

個々のデータに注目し、個々の属性値についてのメジャーさを計算する。式(3)によってデータ d_x の属性 f_j の値のメジャー性 $major(d_x, f_j)$ を計算する。ここで、属性 f_j に対するクラスタリングを行った結果生成されたクラスタの中で、所属データ数が最少のクラスタの所属データ数を $num_{min}(f_j)$ 、最大のクラスタの所属データ数を $num_{max}(f_j)$ とする。 $num(d_x, f_j)$ は属性 f_j において d_x が所属するクラスタの所属データ数とする。

$$major(d_x, f_j) = 2 \times \frac{num(d_x, f_j) - num_{min}(f_j)}{num_{max}(f_j) - num_{min}(f_j)} - 1 \quad (3)$$

この $major(d_x, f_j)$ は、所属データ数が最も多いクラスタにデータ d_x が所属するときに最大

値 1、最も少ないクラスに所属するとき最小値 1 をとる。

全てのデータの個々の属性値についてメジャー性を計算した後、メジャーと判定する閾値の初期値を 1 とし、この閾値を徐々に小さくしていく。そして、メジャー性が閾値以上となる値の数が、値の総数 ($m \times n$) の 40% を越えた時点での閾値を Th_{major} とする。マイナーも同様にして、マイナーとなる値の数が、値の総数の 15% を越えた時点での閾値 Th_{minor} とする。

3.4 属性の統合

メジャー性と属性間の関連の強さを用いて d_x に対するメジャーな属性の統合、マイナーな属性の統合を行う。個々の属性 f_j に対して以下の () ~ () の処理を行い、メジャーな属性を統合する。ここで、属性間の関連が強いかどうかを判定するための閾値 Th_r は 0.7 とする。この値は、式(2)の値の 2 乗が一方の変数の分散を他方の変数の分散で推定できる割合を表し [5]、またその割合が約半分となるのが 0.7 であるという理由から決定した。

- () データ d_x の属性 f_j の値に対するメジャー性が閾値 Th_{major} 以上のときメジャーな値とし、以下の処理でメジャーな属性の統合を行う。メジャーな値ではない場合は処理を終了する。
- () 属性 f_j について関連が強い属性の集合を Set_{major} と表し、 Set_{major} の要素を f_j のみとする。
- () 属性の中で Set_{major} に含まれない属性の集合を F とする。
- () F に含まれる属性 f_u と Set_{major} に含まれる属性 f_v について式(4)を計算する。そして、 Set_{major} に含まれる全ての属性について、式(4)が閾値 $Th_{major} \times Th_r$ 以上となる属性 f_u を全て見つける。
- () () で見つけた属性の中で、式(4)の値が最も高くなる属性を Set_{major} に加えて () に戻

る。() の条件に該当する属性が存在しない場合は属性 f_j についての集合を Set_{major} と決定して処理を終了する。

$$mr(d_x, f_u, f_v) = major'(d_x, f_u) \times r'(f_u, f_v) \quad (4)$$

$$major'(d_x, f_u) = \begin{cases} major(d_x, f_u) & \text{if (a)} \\ Th_{major} + (major(d_x, f_u) - Th_{major}) \times |Th_{major}| & \text{otherwise} \end{cases} \quad (5)$$

$$r'(f_u, f_v) = \begin{cases} |r(f_u, f_v)| & \text{if (b)} \\ Th_r + (|r(f_u, f_v)| - Th_r) \times Th_r & \text{otherwise} \end{cases} \quad (6)$$

$$(a) : |r(f_u, f_v)| \geq Th_r \quad (b) : major(d_x, f_u) \geq Th_{major}$$

$major'(d_x, f_u)$ は属性 f_u と f_v の関連の強さが Th_r 未満の際に、 Th_{major} との差が小さくなるように補正したメジャー性である。 $r'(f_u, f_v)$ は属性 f_u のメジャー性が閾値 Th_{major} 未満の際に、 Th_r と属性間の関連の強さの差が小さくなるよう補正した値である。

閾値 Th_{major} 以上かつ Th_r 以上という条件を満たす属性のみを統合した場合には、以下の () もしくは () の条件を満たす属性 f_u が統合されないため、式(4) ~ (6)により属性の統合の判定を行う。

f_u と Set_{major} に含まれる属性との関連の強さは Th_r より非常に大きい、 f_u の値のメジャー性が Th_{major} より僅かに小さい、 f_u の値のメジャー性が Th_{major} より非常に大きい、 f_u と Set_{major} に含まれる属性の関連の強さが Th_r より僅かに小さい

マイナーな属性の統合は、閾値の違いとメジャー性の符号の違いがあるため、() ~ () の処理において以下のように変更することで行う。

- 閾値を Th_{major} の代わりに Th_{minor} とする
- 関連が強い属性の集合「 Set_{major} 」を「 Set_{minor} 」

とする

- ・ ()で「閾値 Th_{major} 以上」ではなく「閾値 Th_{minor} 以下」とする
- ・ ()で「閾値 $Th_{major} \times Th_r$ 以上」ではなく「閾値 $Th_{minor} \times Th_r$ 以下」とする
- ・ 式(6)において条件(b)を条件(b')とする

$$(b') : major(d_x, f_u) \leq Th_{minor}$$

3.5 データ間の関連の強さ

統合した属性の集合に対して、注目したデータと他のデータの関連の強さを計算し、関連付けを行う。本節では、メジャーな属性の集合に対してデータ間の関連の強さを計算する場合のみを説明する。マイナーな属性の集合については、メジャーな属性の集合に対する処理における「 Set_{major} 」を「 Set_{minor} 」に変更することで行う。

注目するデータ d_x と他のデータ d_y の属性の集合 Set_{major} に対する関連の強さとして式(7)の $dr(d_x, d_y, Set_{major})$ を計算する。式(8)の $sim(d_x, d_y, f_j)$ は f_j についての d_x と d_y の類似度であり、式(9)は属性 f_j についての d_x と d_y の距離 $dis(d_x, d_y, f_j)$ である。距離 $dis(d_x, d_y, f_j)$ は、属性 f_j についてのクラスタリングの結果、 d_x と d_y が所属しているクラスタ間の距離を計算している。ここで、 d_x と d_y が所属するクラスタに所属する全てのデータの集合をそれぞれ S_{d_x} と S_{d_y} としている。そして、それらの重心を $g(S_{d_x}, f_j)$ 、 $g(S_{d_y}, f_j)$ とする。クラスタ間の距離は、重心間の距離とそれぞれのクラスタに所属するデータ間の最短距離の積をとることにより計算している。 $dis(d_x, d_y, f_j)$ は必ず 0 以上となるので、 $sim(d_x, d_y, f_j)$ の最大値は 1、最小値は 0 となる。

$$dr(d_x, d_y, Set_{major}) = \frac{1}{|Set_{major}|} \times \sum_{f_j \in Set_{major}} \left(sim(d_x, d_y, f_j) \sum_{f_j \in Set_{major}} \frac{|mr(d_x, f_j, f_j)|}{|Set_{major}|} \right) \quad (7)$$

$$sim(d_x, d_y, f_j) = \frac{1}{1 + dis(d_x, d_y, f_j)} \quad (8)$$

$$dis(d_x, d_y, f_j) = \left| g(S_{d_x}, f_j) - g(S_{d_y}, f_j) \right| \times \left(\min_{d_x' \in S_{d_x}, d_y' \in S_{d_y}} |d_x' - d_y'| \right) \quad (9)$$

この $dr(d_x, d_y, Set_{major})$ の値が閾値 Th_{dr} 以上であるとき、属性の集合 Set_{major} においてデータ d_x とデータ d_y に関連があると判断する。閾値 Th_{dr} については、メジャーな属性の集合のときは $Th_{major} \times Th_r$ とし、マイナーな属性の集合のときは $|Th_{minor} \times Th_r|$ とする。これらは属性の統合を判定するための式(4)に対する閾値であり、これらの閾値以上の属性のみが統合されているため、式(7)に用いた $|mr(d_x, f_j, f_j)|$ の平均が必ずこれらの閾値以上となる。よって、統合した属性の中の多くで d_x と d_y が同一のクラスタにあれば、式(7)の値もこの閾値以上になるという理由から、これらの閾値を用いる。

4. 関連の情報の保存

既存のデータベースに対してデータの関連付けを行った後、関連の情報(以後、関連情報)を保存する際に、そのデータベースのデータ構造を変更してしまうと、そのデータベースに関するシステム全てを変更しなければならない。そこで、既存のデータベースを変更せずに関連情報を保存するため、既存のデータベースとは別に関連情報データベースを作成する。

関連情報を関連情報データベースに保存するため 4.1~4.4 のクラスを用いる。これらの4つのクラスにより、関連情報をデータごとに、そして属性の集合ごとにまとめる。なお、これ以降ではデータベース中のデータを「データ」と表し、関連情報データベース中のデータを「関連情報データ」と表す。

4.1 データポイントクラス

このクラスのインスタンスはデータベース中の1つのデータへのリンクを持ち、さらに関連情報クラスのインスタンスへのリンクを属

性の集合が作られた数だけ持つことで、データごとに関連の情報を分類する役割を果たしている。

4.2 関連情報クラス

このクラスは、データポインタクラスのインスタンスが指すデータに対して複数作られた属性の集合のうち 1 つについて関連するデータをまとめる役割を持っている。

4.3 属性集合クラス

このクラスのインスタンスは属性の集合とその集合がメジャーかマイナーかという情報を保存する。異なるデータであっても属性の統合を行う際に同じ属性の集合ができることがあるため、関連情報クラスのインスタンスに属性の集合の情報を保存するのではなく、この属性集合クラスに属性の集合の情報を保存する形をとっている。

4.4 関連データクラス

このクラスのインスタンスは 2 つのデータの関連の強さを保存するためのものである。このクラスのインスタンスは、データポインタクラスと関連情報クラスのインスタンスを通じて辿られる。辿ったインスタンスが指すデータを d_x とし属性の集合を set_y とすると、 set_y に対して d_x に関連するデータの中の 1 つへのリンクとそのデータ間の関連の強さを保存する。

4.5 関連情報データの保存例

これらのクラスを用いて関連の情報を保存した例を図 2 に示す。図 2 ではメジャーな属性の集合 set_1 についてデータ d_1 に関連するデータとして d_3 と d_4 があり、マイナーな属性の集合 set_2 についてデータ d_1 に関連するデータとして d_2 と d_4 がある例を示している。

dp_1 は d_1 を指しているので、 d_1 についての関連情報をまとめるインスタンスである。 dp_1 は set_1 や set_2 を指す関連情報クラスのインスタン

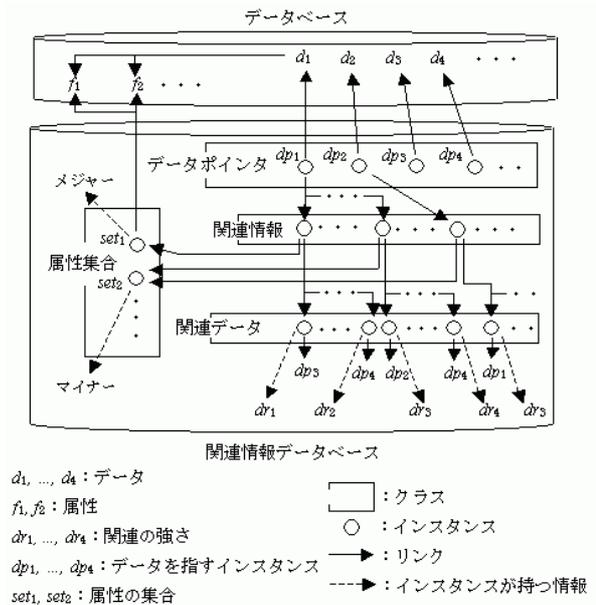


図 2 関連情報データベース

スへのリンクを持っている。 set_1 を指す関連情報クラスのインスタンスは、 set_1 について d_1 と関連するデータを保存する関連データクラスのインスタンスへのリンクを持っている。これらのリンクの先には、関連の強さ dr_1 で dp_3 が指す d_3 が関連することを示すインスタンスや、関連の強さ dr_2 で dp_4 が指す d_4 が関連することを示すインスタンスがある。

5. 実験

データの個々の属性に注目したときに、関連する情報を参照できるかどうかを確認するための実験を行った。実験では、本手法によるデータの関連付けと、重要な属性を選択する一般的な手法である主成分分析による関連付けを行い、両者の比較を行った。

実験に用いたデータは、東京都の各区、市についての構造別着工建築物のデータである。データの属性として、木造の棟数・床面積の合計・工事費予定額や、鉄骨鉄筋コンクリート造の棟数・床面積の合計・工事費予定額などがある。データの例を表 1 に示す。表 1 に示されていない属性としては鉄筋コンクリート造などがあり、属性数は 15 である。また、データ数は 54 である。

表 1 構造別着工建築物のデータの例

	総 数			木 造			鉄骨鉄筋コンクリート造		
	棟 数	床 面 積	工事費予定額	棟 数	床 面 積	工事費予定額	棟 数	床 面 積	工事費予定額
新 宿 区	834	611 747	15 635 818	376	42 597	812 001	50	269 914	8 169 321
千 代 田 区	201	600 093	15 953 271	6	520	9 560	31	270 954	7 473 990
中 央 区	286	494 002	10 606 085	13	712	13 300	56	255 267	5 694 486
港 区	658	2 763 931	72 204 909	168	24 776	460 491	91	1 818 983	48 876 529
文 京 区	623	284 521	5 604 355	309	39 000	748 267	33	88 128	1 746 560
台 東 区	484	287 261	5 894 485	93	9 722	185 443	40	139 297	2 587 370
墨 田 区	713	273 561	5 128 703	259	25 641	485 064	27	87 423	1 736 000
江 東 区	970	1 094 901	18 992 562	332	37 124	648 096	46	366 021	8 553 353
品 川 区	1 143	461 423	9 198 877	673	75 574	1 472 409	38	105 983	2 010 203
目 黒 区	1 302	400 390	8 302 018	855	104 801	2 036 238	23	54 719	1 377 950
大 田 区	2 753	1 045 333	20 868 729	1 431	162 650	3 054 686	34	168 268	2 937 361
世 田 谷 区	3 763	977 488	19 881 030	2 717	343 244	6 577 300	24	49 429	1 003 832
渋 谷 区	899	481 884	10 559 963	421	56 002	1 081 586	35	132 000	2 705 729
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮

5.1 実験結果

本手法による関連付けの例と、主成分分析を行った関連付けの結果を示す。本実験では、新宿区のデータに注目して関連付けを行った。

本手法により新宿区のデータの中でメジャーな属性を検出したところ、木造の棟数がメジャーな属性であったため、この木造の棟数について関連するデータの例を示す。本手法では、木造の棟数・床面積の合計・工事費予定額はメジャーな属性として統合されており、この統合された属性の集合について、新宿区と関連があると判定されたデータの結果を表 2 に示す。表 2 より、木造の棟数について新宿区と類似したデータが関連付けられていることがわかる。また、関連付けられたデータは、統合された属性である木造の床面積の合計や工事費予定額についても新宿区と類似した値をとるデータが関連付けられていることがわかる。

次に、主成分分析によって属性の統合を行った際の関連付けの結果を示す。主成分分析を行った結果、属性に重みが付けられて統合されるので、本実験では木造の棟数の重みが最も大きい主成分 1 つを用いてクラスタリングを行い、新宿区と同一のクラスタに所属するデータを関連付けた。その結果を表 3 に示す。この主成分は、木造の棟数の重みが正の向きに大きく、また総数の棟数の重みが負の向きに大きくな

っていた。これより、木造の棟数と総数の棟数が新宿区に類似している江東区や渋谷区が関連付けられている。さらに、木造の棟数と総数の棟数という 2 つの属性値の違いが相殺されてしまうことにより、千代田区や中央区のように木造の棟数と総数の棟数がともに新宿区より小さいというデータも関連付けられている。

5.2 結果の比較

主成分分析による属性の統合により特定の属性に注目してデータの関連付けを行った場合では、注目した属性について類似していないデータであっても他の属性の重み付けの影響により、関連付けられた。しかし、本手法では注目した属性について類似したデータのみが関連付けられている。この結果から、個々の属性に注目した関連付けにおいて本手法が有効であると言える。

また、本手法で行った属性の統合により統合された属性についても注目したデータと関連付けられているデータが類似しているため、属性の統合も適切であると考えられる。

6. まとめ

本研究では、データごとに重要な属性であるメジャーとマイナーな属性を検出し、その中でも関連が強い属性は統合を行い、その統合した属性の集合に対してデータの関連付ける手法

表2 本手法により新宿区と関連付けられたデータ

	総 数			木 造			鉄骨鉄筋コンクリート造		
	棟 数	床 面 積	工事費予定額	棟 数	床 面 積	工事費予定額	棟 数	床 面 積	工事費予定額
新 宿 区	834	611 747	15 635 818	376	42 597	812 001	50	269 914	8 169 321
澁 谷 区	899	481 884	10 559 963	421	56 002	1 081 586	35	132 000	2 705 729
豊 島 区	894	328 988	6 718 372	513	57 923	1 089 947	27	80 218	1 676 246
江 東 区	970	1 094 901	18 992 562	332	37 124	648 096	46	366 021	8 553 353
昭 島 市	581	237 035	3 589 190	412	42 289	750 166	5	81 097	1 250 800
国 分 寺 市	723	127 564	2 424 647	568	57 332	1 065 218	2	18 564	320 000
田 無 市	482	102 446	1 856 060	391	40 352	755 026	2	952	21 000
保 谷 市	555	115 262	2 002 322	456	48 837	855 165	1	45	800
狛 江 市	424	90 262	1 451 793	342	36 215	684 864	2	180	4 220
東 大 和 市	594	141 086	2 191 356	479	48 648	875 986	4	35 250	454 000
清 瀬 市	540	104 304	1 471 320	392	40 700	704 324	2	3 158	55 200
東 久 留 米 市	685	136 320	2 224 467	572	56 248	1 012 103	5	32 822	512 500
多 摩 市	502	155 397	2 972 832	353	40 956	772 279	7	28 314	574 049
武 蔵 野 市	621	170 408	3 353 741	451	53 421	1 004 152	5	31 465	718 748

 : メジャーな属性

表3 主成分分析により新宿区と関連付けられたデータ

	総 数			木 造			鉄骨鉄筋コンクリート造		
	棟 数	床 面 積	工事費予定額	棟 数	床 面 積	工事費予定額	棟 数	床 面 積	工事費予定額
新 宿 区	834	611 747	15 635 818	376	42 597	812 001	50	269 914	8 169 321
千 代 田 区	201	600 093	15 953 271	6	520	9 560	31	270 954	7 473 990
中 央 区	286	494 002	10 606 085	13	712	13 300	56	255 267	5 694 486
江 東 区	970	1 094 901	18 992 562	332	37 124	648 096	46	366 021	8 553 353
品 川 区	1 143	461 423	9 198 877	673	75 574	1 472 409	38	105 983	2 010 203
目 黒 区	1 302	400 390	8 302 018	855	104 801	2 036 238	23	54 719	1 377 950
澁 谷 区	899	481 884	10 559 963	421	56 002	1 081 586	35	132 000	2 705 729
府 中 市	1 431	316 707	5 751 718	1 027	113 906	2 132 767	8	25 371	388 400

 : 重み大きい属性

を提案した。

今後の課題は、メジャーとマイナーの判定を行う前に、データ自体にメジャーとマイナーな値が存在するかどうかを判定することである。データが一樣に分布している場合には、クラスタリングを行った結果、全てのクラスタの所属データ数がほぼ等しくなるため、メジャーやマイナーな値が存在しない。属性がこの状態になっているかどうかの判定と、この状態での関連付けの方法について今後考える必要がある。

参考文献

[1] 三治 信一郎, 橋本 周司, “多次元データを把握するための視覚化ツール”, 情報処理学会, コンピュータビジョンとイメージメディア研究報告, No. 127, pp. 167-170,

2001.

[2] 井上 光平, 浦浜 喜一, “特徴選択を伴うクラスタリングの反復解法”, 電子情報通信学会論文誌, D-, Vol. 83 - D-, No. 4, 2000.

[3] Tomoya Ogawa, et al., “FEATURE SELECTION FOR EFFECTIVE CALCULATION OF A SIMILARITY MEASURE”, International Conference on Artificial and Computational Intelligence, 2002.

[4] G. Das and H. Mannila. “Context-Based Similarity Measures for Categorical Database”, Proc. of PKDD2000, pp. 200-210, 2000.

[5] 肥田 野直, “統計入門”, 培風館, 1995.