

情報量を考慮した関係記述の類似度に基づく 家の初期構造概念の学習

山 口 智 浩[†] 脇 谷 康 一[†] 谷 内 田 正 彦[†]

AI研究の目標のひとつに、コンピュータビジョンと機械学習とを融合した、視覚入力からの概念学習システムの実現がある。しかしながら、このようなシステムの実現には以下の課題があったため、従来、これらは別々の表現や手法によって研究されてきた。(1) 獲得する高次概念の種類、(2) 幾何→記号表現の変換の問題、(3) 概念の分節化の方法。本論文では、画像から得られた3Dモデルを入力として抽象的な概念記述を学習する方法について述べる。第1の問題に対し、本論文では、入力となる形状記述が暗黙的に持つ構造を概念として学習する。そのため対象を部分構造に分類して副概念として学習し、次に副概念間の関係記述を対象の構造概念として学習する方法を提案する。第2の問題は、物体の形状を表す3Dモデルと抽象的な概念記述との表現の変換の問題である。本論文では、特徴属性は用いず、3Dモデルから容易に変換可能な、定性的な幾何関係属性に基づく概念記述言語を定義する。第3の問題は概念記述を獲得する方法である。本論文では、対象記述の部分構造への分割を副概念クラスタリングと呼ぶ。クラスタリング手法として、まず要素間の関係の単純な類似度を定義し、次に学習例における関係属性値の分布を類似度の重み付けに用いてクラスタリングの精度を改善した、関係の珍しさの情報量に基づく類似度を提案し、簡単な家の初期構造概念の学習の実験を行う。

Learning Initial Structural Concept of Houses Based on Similarity of Relations Weighted by Information

TOMOHIRO YAMAGUCHI,[†] KOICHI WAKITANI[†]
and MASAHIKO YACHIDA[†]

One of the ultimate goals for AI research was to make a learning and recognition system integrating Computer Vision and Machine Learning. However, they have been studied independently in each field, and there are still large gaps between them. To integrate learning and recognition system, it is necessary to solve the following problems: (1) What kind of concepts to be obtained; (2) Description transformation between geometric and symbolic; (3) Method for conceptual discrimination. This paper describes a method that learns structural concept of an object from 3D geometric model. To the first problem, we first learn the partial structures of an object as sub-concept and then learn the structural concept from relations of these sub-concepts. To the second problem, we define Concept Description Language that is based on the qualitative geometric relations. To the third problem, this paper proposes a two clustering methods for analyzing partial structures. First we define a simple similarity of relations and then we revise it to a information-based similarity clustering method that uses the distribution of attribute values as rarity information to weight the similarity measure to improve the clustering result. Experimental results are given using simple and complicated house examples.

1. まえがき

AI研究の究極の目標のひとつとして、コンピュータビジョン（以下 CV と略す）と機械学習とを融合した物体の認識、学習システムの実現¹⁾がある。本論文では、対象の実例をコンピュータに見せることにより、

対象の概念を自動的に学習するシステムを目指す。しかしながら、このようなシステムの実現は困難で、多くの解決すべき課題があったため、従来これらは物体認識や概念学習として別々の表現や手法によって研究してきた。

CV での物体認識では、モデルベースのマッチングがよく用いられるが、対象ごとにモデルが必要なため、様々な対象を扱うにはモデルが多くなり、マッチングコストが増大するという欠点があった。多様な形状を

[†] 大阪大学基礎工学部

Faculty of Engineering Science, Osaka University

表現、認識する汎用なモデルを用いる物体認識システム²⁾は少數である。しかも、その汎用なモデルは、人間により与えられたものであり、汎用なモデルを機械学習によって獲得する手法が求められている。

認識と学習とを同時に進行する手法としては、ニューラルネットワークによる信号レベルの学習³⁾があるが、人間にとって理解可能な概念表現や、構造レベルの学習を行うことができない。また、2次元イメージの認識が中心であり、3次元（以下3Dと略す）の立体形状を扱うのは困難であった。

一方、機械学習では、記号表現をベースとして、物体の構造や機能などの抽象的な概念を学習するシステムが研究されてきた。しかしながら、ANALOGYでのアーチの学習⁴⁾やカップの概念学習⁵⁾に見られるように、入力の知識表現として、support, liftable 等の高次な関係記述と、あらかじめ分割された対象からなる概念記述言語¹⁵⁾が人間によって与えられたため、構造⁴⁾や機能⁶⁾などの高次の概念を扱うことが可能となった。

これに対して、CVで得られる3Dモデルでは、頂点、線分、平面、立体という幾何的な階層構造^{7),8)}によって形状を表現する。そのため、このような低次の記述から対象の構造や機能等の高次の概念を解析するのは容易ではない。対象を2次元形状に限定し、“なめらかな局所対称性”によって、形状認識段階で部分形状に分割した後、部分形状間の位置関係等を抽出して意味ネットワーク表現に変換し、ANALOGYと同様な手法で概念の一般化を行う研究⁹⁾もあるが、対象の構造化が“なめらかな局所対称性”に依存しているため、扱える対象が、ハンマーや飛行機等の細長い部品で構成される2次元形状に限定され、複雑な構造や3D形状が扱えないという問題点があった。

このように、機械学習で用いる抽象的な記号表現と、CVで獲得可能な形状主体の3Dモデル記述との間には、大きなギャップがあるため、そのままでは組合せることはできない。両者を統合するには、以下の問題点¹⁰⁾を解決する必要がある。

- (1) 獲得する高次概念の種類
- (2) 幾何 → 記号表現の変換の問題
- (3) 概念の分節化の方法

まず第1の問題は、どのような高次概念を学習するかである。画像解析から得られるのは物体の形状記述であり、一般に形状記述は、対象を反映した何らかの構造を暗黙的に持つと考えられる。そこで本論文では、物体の構造概念¹¹⁾に注目し、より抽象度が高く、形状から一意には決まらない機能概念は扱わないこと

とする。

第2の問題は、物体の形状を表す3Dモデルと抽象的な概念記述との表現の変換の問題^{12),13)}である。これに対して本論文では、物体の形状記述に近く3Dモデルから容易に変換可能である、定性的な幾何関係に基づく概念記述言語を用いることにする。

第3の概念の分節化とは、対象記述を意味のある部分構造に分割して構造化した概念を獲得することである。本論文では、この対象記述の部分構造への分節化を副概念クラスタリング^{11),21)}と呼ぶ。以下2章では、副概念間の関係記述に基づく構造概念の獲得^{11),14)}の概要について述べる。3章では、システム全体の処理の概要と、本論文の初期構造概念学習の位置づけについて述べる。4章では、関係の類似度に基づく副概念クラスタリング手法について述べ、5章では、類似度の定義に関係属性の情報量による重み付けを導入して分類精度を向上させた手法^{11),21)}を提案する。6章では、簡単な家の例での副概念間の関係記述に基づく構造概念の生成結果について報告する。

2. 副概念間の関係記述に基づく構造概念

2.1 獲得する概念の種類

本論文が対象とする構造概念について、ANALOGY⁴⁾を例として説明する。アーチの概念は、柱、天板等の構成要素や特徴値、属性値をノードとし、要素が持つ特徴、属性関係や要素間の関係記述をアーケで表す意味ネットワークを用いて記述される。この概念記述は、要素が持つ特徴、属性等の性質的な記述と、要素間の関係記述の2種類に分類でき、このうち構造概念は、後者の構成要素間の関係記述の集合として表現されている。次節では、意味ネットワークによる構造概念記述を用いた従来手法を、家の概念学習に適用した場合の問題点について議論する。

2.2 従来の構造概念学習の問題点¹⁰⁾

従来の構造概念学習では、概念記述の構造化が不十分である。ANALOGYの場合、アーチの基本要素である積み木は、暗黙的に柱、天板等アーチの部分構造に対応していたため、これら部分構造の認識の問題が生じず、概念記述の構造化を考える必要がなかった。また、アーチの本質的な構造概念を強調するため、少数の単純化された要素と要素間の関係記述を用いていた。よって、概念の探索空間が小さくてすみ、少数のニアミスによる、効率的な概念の洗練が可能となった。

一方、CVで得られた幾何情報、たとえば平面を対象の記述要素を入力として、それらの平面の性質や平面間の制約関係を対象の概念として獲得した場合、多

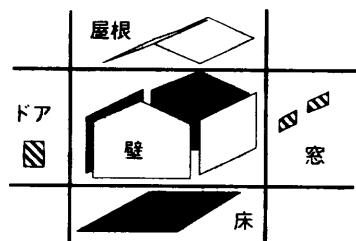


図1 家を構成する平面集合の部分構造への分割
Fig. 1 Segmentation of plane set of house into partial structures.

くの構成要素や関係記述が必要となるため、概念記述が複雑になって意味ネットワークが巨大化し、概念の探索空間が大きくなり、学習に時間がかかるうえ、得られた概念記述は、一般的な構造を表現してはいない。

これに対し人間は、図1のように、家の構成要素を{床、壁、屋根、窓、ドア}といった部分構造を表す下位の概念に構造化、階層化して対象全体を認識していると考えられる。そこで本論文では、対象を構成する下位の概念を副概念と呼び、これらの副概念を用いて概念記述の構造化を行う。

2.3 副概念間の関係記述に基づく構造概念表現

前節で議論した問題点に対する解決のアイデアについて述べる。まず第1に、本論文では、概念記述の構造化を提案する。対象の構造概念を学習するには、まず対象の部分構造の解析が必要である。図1を用いて説明する。家の構成要素を部分構造に分割することができれば、構成要素の数や、構造が部分的に変化しても、これら5つの部分構造間の制約関係を獲得することによって、それらの差異を吸収した、一般的な家の構造概念を学習することが可能になる。つまり、対象の概念記述は、その対象が本来持つ構造を反映した、階層性を持つべきである。ここで、部分構造とは、対象の記述のうち、類似度の高い性質や関係記述を持つ構成要素の部分集合であると定義する。副概念とは、対象記述を何らかの類似度に基づいて分類して得られた対象記述の部分集合を一般化した、対象の部分構造に対応する概念記述であると定義する。この分類のため、関係の類似度を提案し、4.2節で説明する。

第2に関係に基づく概念記述を提案する。概念記述、特に構造概念は絶対的なものではなく、関連する他の要素や概念との関係に基づく相対的な記述となるべきである。特徴や属性だけでは、構造概念を表現できない。たとえば屋根の概念は、表面の色、テクスチャ、形状等の特徴によって表現できるが、それだけでは屋根の構造や機能を表すことはできず、むしろそれらの特徴は、屋根の種類の違いを表現するのに有効である。

そこで、本論文では対象の概念を構成する副概念を、“屋根は傾いて接する2枚の平面からなる”といった平面間の関係記述として獲得し、次に“屋根は壁の上にある”のような副概念間の相対的な関係記述を対象全体の構造概念として学習する方法を6章で説明する。

2.4 副概念クラスタリング¹¹⁾

対象を部分構造に分割する基本的なアイデアについて説明する。対象が、基本要素の集合と要素間の関係とで記述されているとき、同じ部分構造に属する各要素は、他の要素と似た関係を持つはずである。つまり要素間の関係の共通性や類似度を評価することで対象の記述を分節化することが可能となる。

一般に、概念記述言語と概念の類似度とを定義すれば、概念のクラスタリング¹⁸⁾が可能となる。一般にクラスタリングは、要素間の関係の共通性や類似性を利用して行い、類似度に基づく手法が代表的である。しかし、類似度に基づくクラスタリングでは、類似性の尺度がすべての属性を同等に扱うため、生成されたクラスタが本質的に単純な概念に対応せず、またクラスタの外延的記述や数値的な類似度情報は得られるが、概念を説明する内包的記述が生成できないという問題点¹⁸⁾がある。そのため、概念的に異なるものが、本質的でない属性の共通性によって、同じクラスタに分類されてしまう。これを防ぐには、あらかじめ人間によって属性の重み付けを決めておく方法が考えられるが、この重みの定義は一般に困難であり、またそれぞれの属性の独立性が保証されないことも問題¹⁸⁾である。

これらを解決するため、本論文では、例における属性値の分布を類似度の重み付けに用いてクラスタリングの精度を改善した、情報量^{16),17)}に基づく関係の類似度を提案する。情報量は、ID3¹⁶⁾での大量データからの決定木の帰納学習や定量値を持つ属性を多値区間に分割¹⁷⁾する際の評価基準等、分類学習では主に分類の効率化を目的としてよく用いられるが、本論文では、属性値の情報量を、珍しい関係を重視するように類似度の重み付けを行うのに用いる点が特徴である。

3. システムの概要

3.1 前提となる画像解析

本論文では、画像から得られた3Dモデル^{7),8)}を入力として抽象的な概念記述を学習する方法について、多面体近似された家を対象とする。画像から、多面体近似された3Dモデルを獲得する方法は、我々がすでに提案した手法^{7),8)}を用いる。また学習対象として家を選んだのは、部分構造が明確で分かりやすく、また比較的曲線、曲面部分が少なく、多面体近似した場合

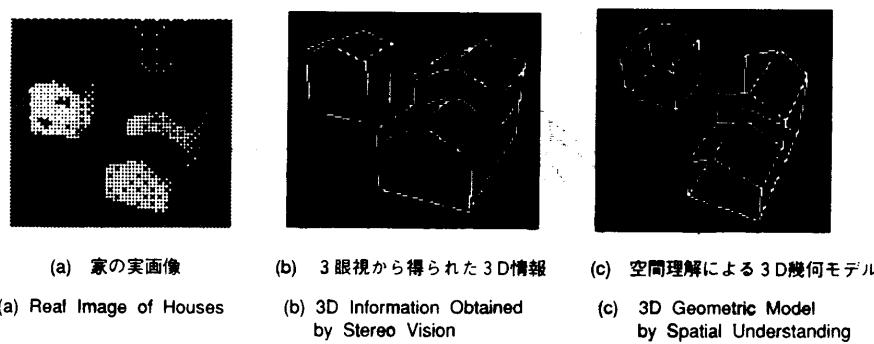


図2 画像解析の処理過程
Fig. 2 The process of the image analysis.

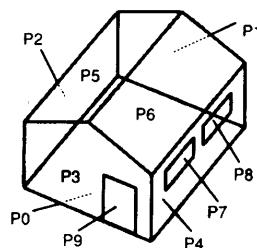


図3 家の入力例1 (house 1)
Fig. 3 An input example of house 1.

平面:	…, P2(L9, L13, L0, L2), …
線分:	L0(C1,C2), … L9(C6,C7), … L12(C2,C7), L13(C1,C6), …
頂点:	…, C1(0.50,100), C2,(0,0,100), … C6(0.50,0), C7(0,0,0), …

図4 3次元モデルの階層情報

Fig. 4 Hierarchical information of the 3D model.

に平面数が少なくてすむという利点があるためである。ここでは、コンピュータビジョンで獲得可能な物体形状を表す3Dモデルを入力とし、物体の構造概念を学習する手順について述べる。図2に、画像解析の流れを示す。まず図2(a)に示す実画像から、ステレオ視などによって図2(b)に示す線分レベルの3D情報を得る。そして推論による補間を用いて隠面情報を補うことにより、図2(c)に示す対象の3Dモデルを獲得する。本論文で説明に用いる家の例 house 1 を図3に示す。house 1 は、P0~P9の10枚の平面から構成された多面体モデルである。この3Dモデルでは、対象を構成する平面、線分、頂点情報が図4に示すように階層的に記述されている。以下、本論文では、この3Dモデルを学習システムの入力とする。

3.2 学習システムの全体の流れ

図5に学習システムの全体の流れを示す。まずこの3Dモデルを、記号表現である概念記述言語に変換する。詳細は後述するが、概念記述言語は平面を基本要

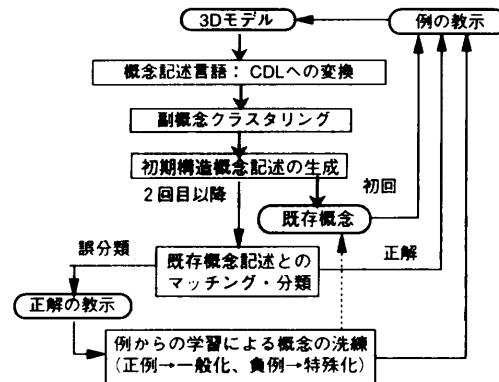


図5 学習システム全体の流れ
Fig. 5 The flow of the learning system.

素とし、2平面間の定性的な幾何関係によって物体の形状を記述する。次に、この概念記述言語で表現された対象記述から、構造概念の初期記述を学習する。まず、副概念のクラスタリングを行い、対象を構成する平面集合を部分構造に分割し、各部分平面集合に分類する。次に各部分構造に分割された関係記述から副概念記述を学習し、副概念間の関係を対象の構造概念として学習する。得られた家の構造概念の初期記述の例を図6に示す。各ノードは得られた副概念を、アーチは副概念間の定性的幾何関係を表す。このようにして、最初の例から構造概念の初期記述を獲得した後、各副概念記述と対象の構造概念記述それぞれに対して、正負の例からの帰納学習^{4),15)}を適用して概念記述を洗練^{12),13)}する。ただし、本論文では、主に副概念クラスタリングによる初期構造概念の学習について述べる。

3.3 概念記述言語 CDL

本論文では、対象の構造を扱うため、3Dモデルから概念記述言語への変換時に、面間の角度や座標位置、大きさといった定量的な情報や、平面の形や色、材質といった属性や特徴等の記述は捨て、{直角、水平、斜め}, {高い、等高、低い}といった定性的な

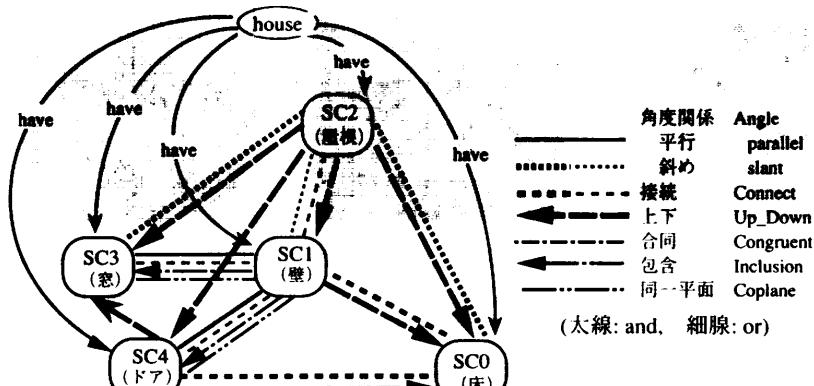


図6 家 (house) の構造概念の初期記述の例

Fig. 6 An initial description of the structural concept of house 1.

表1 概念記述言語 CDL

Table 1 Concept description language CDL.

関係属性	関係属性値
Angle (角度関係)	(Right_Angle, Parallel, Slant) (直角, 平行, 斜め)
Connect (接続関係)	(True, False) (接続, なし)
Up_Down (上下関係)	(Equiv, Below) (等高, 下方)
Congruent (合同関係)	(True, False) (合同, 非合同)
Inclusion (包含関係)	(Include, Nil) (含む, なし)
Coplane (同一平面)	(True, False) (同一面, なし)

表2 CDL の記述例 (P1-P2 間の関係積)

Table 2 Relational descriptions on CDL between P1 and P2.

関係属性	関係属性値
Angle	Right_Angle
Connect	True
Up_Down	Equiv
Congruent	False
Inclusion	Nil
Coplane	False

関係に限定した簡単な概念記述言語 CDL (Concept Description Language) を定義する。CDL は平面を基本要素とし、2 平面間の定性的な関係によって、対象物体の形状を記述する。表 1 に、本論文で用いる CDL を示す。CDL は 6 種の関係記述から構成され、すべての関係は、2 平面間の関係を表している。表 2 に 2 平面間の関係の記述例を示す。これら、Angle, Connect 等の関係記述を関係属性、Parallel, True といった値を関係属性値と呼ぶ。値 True は、その関係が存在することを、値 False, Nil は、その関係が存在

しないことを表す。厳密な定義は省略するが、これらの関係記述は、すべてナイーブな幾何的関係なので、平面の法線ベクトル、重心の位置関係などを用いて、画像解析で得られた対象の 3D モデルから手続き的に計算可能である。

4. 関係の類似度に基づく副概念クラスタリング

4.1 決定木によるクラスタリングとその問題点

対象記述を分類する方法としてまず考えられるのは、先駆的知識によるクラスタリングである。たとえば、領域固有の知識として、環境からの制約が、物体の形状や構造を制約することに着目すると、家などの建物の場合、各平面の水平面に対する定性的な角度 { 垂直、水平、傾いた } によって { 壁、床、屋根 } のように平面を分類する方法が考えられる。すなわち、CDL の関係属性をうまく選ぶことにより、対象記述集合をその属性値の数だけの部分集合に分割できる。この関係属性による分割を必要な分類結果が得られるまで繰り返す。このように、複数の関係属性と分類への適用順序を表す、分類のための木を領域ごとに与える方法を決定木法¹⁹⁾と呼ぶ。この手法は、クラスタリングの精度が良い反面、領域依存の先駆的知識が必要となるため、家以外の対象への応用が困難になるという欠点がある。こういった決定木法の問題点を解決するため、次に、領域に依存しない関係の類似度によるクラスタリング手法を提案する。

4.2 関係の類似度の定義

4.2.1 関係記述の類似性

平面の副概念への分割は、水平面に対する角度のような性質の違いのみでは行えず、他面との関係の共通性や差異も重要となってくる。たとえば、窓は、壁と

表3 平面P3と他面との全関係積集合
Table 3 An entire relational product set of plane P3 with other planes.

No	Angle	Connnect	Up_Down	Congruent	Inclusion	Coplane
P0	Right_Angle	True	Above	False	Nil	False
P1	Parallel	False	Equiv	True	Nil	False
P2	Right_Angle	True	Equiv	False	Nil	False
P4	Right_Angle	True	Equiv	False	Nil	False
P5	Right_Angle	True	Below	False	Nil	False
P6	Right_Angle	True	Below	False	Nil	False
P7	Right_Angle	False	Equiv	False	Nil	False
P8	Right_Angle	False	Equiv	False	Nil	False
P9	Parallel	True	Equiv	False	Include	True

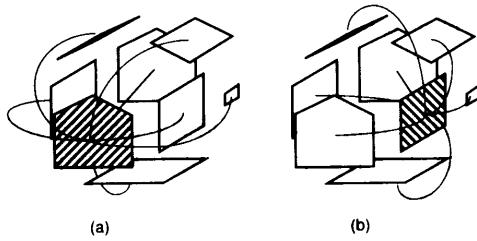


図7 ある面の他面との関係の共通性
Fig. 7 Similar relations of a plane with other planes.

の包含関係によって他面とは区別されるし、水平な屋根は、他面との上下関係によって床と区別可能となる。このような差異の共通性を仮定し、各平面の他面すべてとの関係を比較すれば、同じ副概念に属する平面は、その他面との関係に類似点が多いはずである。たとえば、図7に示すように、壁である2つの平面(a), (b)は、2枚の平面(壁)と直角に接し、上下を2枚の平面(屋根、床)に挟まれる点で、他面との関係記述の類似点がある。そこで、平面間の関係記述の類似性を用いて平面をクラスタリングする手法を本論文では、関係の類似度に基づくクラスタリングと呼ぶ。

4.2.2 関係の類似度の定義

まず、本章で用いる用語定義を行う。概念記述言語において、対象の記述が、 n 個の基本要素で構成され、 r 個の関係属性を持つとする。2面間の関係は複数の関係属性で表される。表2に示す2面間の関係属性記述の集まりを関係積、表3に示すある面の他面すべてとの関係を表した関係積の集合を全関係積集合と呼ぶ。

定義1：関係属性値間の類似度

関係属性 A_i において、 $A_i(p, u)$ が平面 $p, u (p \neq u)$ の関係属性値であるとき、 $A_i(p, u)$ と $A_i(q, v)$ の間の類似度 $s(A_i(p, u), A_i(q, v))$ ：

$$s(A_i(p, u), A_i(q, v)) = \begin{cases} k & A_i(p, u) = A_i(q, v) \\ 0 & A_i(p, u) \neq A_i(q, v) \end{cases} \quad (\text{ただし } k > 0, p \neq u, q \neq v) \quad (1)$$

定義2：関係積間の類似度

関係属性集合 $\{A_1, A_2, \dots, A_r\}$ に対して、次のような2つの関係積 $rp(p, u), rp(q, v)$ があるとき、

$$\begin{aligned} rp(p, u) &= A_1(p, u) \wedge A_2(p, u) \wedge \dots \wedge A_r(p, u) \\ rp(q, v) &= A_1(q, v) \wedge A_2(q, v) \wedge \dots \wedge A_r(q, v) \end{aligned}$$

関係積間の類似度 $s(rp(p, u), rp(q, v))$:

$$s(rp(p, u), rp(q, v)) = \sum_{i=1}^r s(A_i(p, u), A_i(q, v)) \quad (2)$$

定義3：2平面間の類似度

2平面間の類似度は、関係積集合間の類似度によって定義する。

次のような、平面 p, q それぞれの関係積集合 $erps(p), erps(q)$ に対して、

$$erps(p) = \{rp(p, 1), rp(p, 2), \dots, rp(p, n)\} \quad (rp(p, p) \text{ を除く})$$

$$erps(q) = \{rp(q, 1), rp(q, 2), \dots, rp(q, n)\} \quad (rp(q, q) \text{ を除く})$$

2平面間の類似度 $Sp(p, q)$:

$$Sp(p, q) = \max \sum_{k=1}^{n-1} s(rp(p, u(k)), rp(q, v(k))) \quad (3)$$

ただし

$$u(k) \in \{1, 2, \dots, n\} \quad (p \text{ を除く})$$

$$v(k) \in \{1, 2, \dots, n\} \quad (q \text{ を除く})$$

ここで、 \max とは、式(2)の関係積間の類似度のすべての組合せのうち、類似度が最大となる組合せを選ぶ事を表す。例を図8に示す。

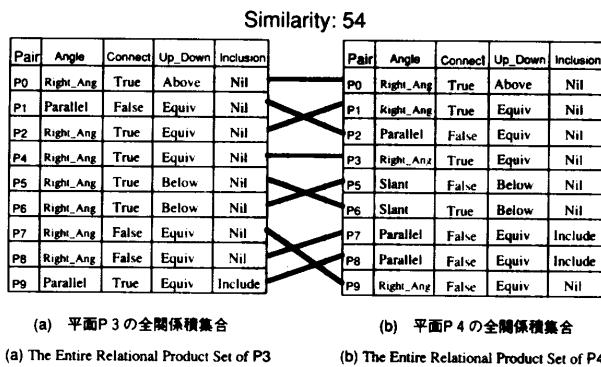


Fig. 8 Calculating relational similarity for a plane pair, P3 and P4.

表 4 各平面間の類似度表 (家1)
Table 4 Simple similarity measures of all plane pairs of house 1.

	P0								
P1	53								
P2	50	59							
P3	50	60	56						
P4	46	53	59	54					
P5	48	47	50	44	46	46	46	46	P5
P6	48	47	50	44	46	63	63	63	P6
P7	44	51	53	51	54	46	46	46	P7
P8	44	51	53	51	54	46	46	63	P8
P9	49	53	51	55	50	45	45	53	53

4.3 関係の類似度に基づくクラスタリング

関係の類似度に基づくクラスタリングの手順を説明する。まず、表3の全関係積集合をすべての平面について求める。次に、図8のように2つの平面の全関係積集合について、定義3を用いて最大となる類似度を計算する。これを表4のようにすべての2平面の組合せに対して計算し、設定したしきい値を超える類似度を持つ面どうしができる限り同じ部分集合に属し、かつしきい値以下の類似度を持つ面どうしが、できる限り互いに疎となるように平面全体を分類する。つまり、同じクラスタ内の各要素間では類似度が高く、異なるクラスタ間では各要素の類似度が低くなるように分類を行う。

4.4 関係の類似度による分類結果

図3のhouse1について、4.2.2項で定義した関係の類似度を用いて計算したすべての2平面間での類似度(以下、単に単純な類似度と呼ぶ)を表4に、その分布を図9に示す。ただし横軸は、表4に示した2平面間のすべての組合せを順に表す。図において、◆は、同一の副概念に分類すべき2平面間の類似度、□は、異なる副概念に分類すべき2平面間の類似度。

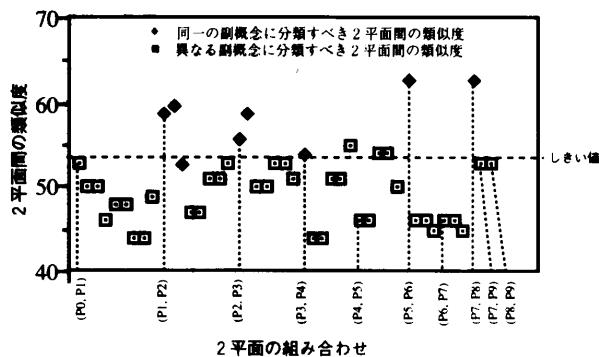


図9 House1 の各2平面間での関係の類似度の分布

Fig. 9 A distribution of the simple similarity measure for plane pairs of house 1.

なる副概念に分類すべき2平面間の類似度を表す。前者がしきい値より大きく、後者がしきい値より小さくなるのが理想的であるが、図9では、類似度55付近で両者の大きさが逆転しているペアがいくつかある。表4をみると、P9(ドア), P7, P8(窓)およびP1～P4(壁)の間で53～55の類似度を持ち、異なるクラスタ間での分離度が悪いという傾向が見られた。

4.5 単純な類似度の問題点

単純な類似度による分類精度が悪い理由として、関係の類似度の定義1での、次のような2つの問題点が考えられる。

問題点1：属性値の平等な扱い

定義1では、関係属性値が一致すれば、関係なし(False)の場合でも類似度が与えられるので、関係あり(True)の一一致度が相対的に低く評価される。しかし、人間は通常、関係なしの一一致は無視して考えるので、関係あり(True)の一一致の類似度を大きくしたほうが合理的である。

問題点2：属性値の差異の扱い

定義1では、関係属性値が一致しなければ、類似度は、一律0である。しかし、表1の関係属性のうち、角度や上下関係のように、属性値集合が順序関係を持つ線形記述子^{10),15)}の場合と、接続、合同、同一平面上、包含関係のように、属性値集合が論理値を持つ場合とでは、値の違いにも類似度が異なるはずである。たとえば、直角、斜めといった角度関係の違いよりも、「含む」か「含まれる」といった排他的な包含関係の違いの方が人間は大きいと考える。

以上の問題点は、すべての関係属性の関係属性値を同じ重みで扱っていた点にある。そこで、それぞれの関係属性値に何らかの重み付けを行う必要がある。

表 5 House1 の属性値の分布による関係の類似度の重み
Table 5 Weight of the similarity of relations by the distribution of attribute values of house 1.

関係属性	各属性値の情報量	平均情報量
Angle (角度)	Right_Angle, Parallel, Slant (直角, 平行, 斜め) 0.85 2.32 2.03	1.43
Connect (接続)	True:接続, False:なし 1.40 0.68	0.96
Up_Down (上下)	Equiv:等高, Below:下方 1.17 1.85	1.55
Congruent (合同)	True:合同, False:非合同 3.49 0.13	0.43
Inclusion (包含)	Include:含む, Nil:なし 4.90 0.10	0.42
Coplane (同一平面)	True:同一平面, False:なし 3.49 0.13	0.43
平均情報量の和		5.22

5. 情報量の重み付けによる関係の類似度の改善

5.1 情報量を用いた類似度の重み付け

4.5 節での検討から、関係の類似度に重み付けが必要であることが分かった。その重み付けの基本的なアイデアは、記述における属性値の分布において「珍しい関係積を重視」する点である。これを実現するためには情報量を用いて類似度の重み付けを行う。

まず、4.5 節の問題点 1 に対しては、値の情報量を用いて一致した属性値の類似度の重み付けを行う。よって、出現頻度 (p) の小さい値が一致した場合に、重み ($-k \log(p)$) が大きくなる。次に問題点 2 に対しては、不一致の場合の類似度を一律 0 とするのではなく、属性値の差異を評価すればよい。線形記述子については、各属性ごとに値の順序性に関する知識を与えれば可能であるが、より一般的な方法として、出現確率の低いものどうしの不一致は、出現確率の高いものの場合よりも違いが大きいとみなす。比較する属性値の情報量の和に -1 をかけた値を類似度として定義する。すなわち、珍しい値どうしの情報量の和は大きくなるので、この符号を逆転して、類似度が小さくなるようにする。

以上の方針に基づき、4.2.2 項の 3 つの定義のうち、定義 1 の関係属性値間の類似度を、情報量を用いた定義 1' に変更する。

定義 1'：情報量による関係属性値間の類似度

関係属性 A_i において、 $A_i(p, u)$ が平面 $p, u (p \neq u)$ の A_i の関係属性値、 $P_i(p, u)$ が関係属性 A_i 中で $A_i(p, u)$ の現われる確率である。このとき、 $A_i(p, u)$ と $A_i(q, v)$ 間の類似度 $s(A_i(p, u), A_i(q, v))$:

$$s(A_i(p, u), A_i(q, v)) = \begin{cases} -k \log(P_i(p, u)) & A_i(p, u) = A_i(q, v) \\ k(\log(P_i(p, u)) + \log(P_i(q, v))) & A_i(p, u) \neq A_i(q, v) \\ \end{cases} \quad (1')$$

(ただし $k > 0, p \neq u, q \neq v$)

5.2 分類のためのしきい値の決定法

前節で定義した情報量による重み付けの改善手法を以下、情報量に基づく類似度と呼ぶ。これによるクラスタリングは、4.3 節と同様の方法で行えるが、単純な類似度の場合と同様、対象ごとに毎回しきい値を調整する必要がある。そこでこの設定を自動化するため、最適なしきい値は 2 平面間の平均類似度の定数倍と仮定し、以下の式から対象ごとに値を算出して実験したところ、良好な結果を得た。

〈情報量に基づく類似度でのしきい値〉

$$k \times I \times (n - 1) \quad (4)$$

ただし、

k : 定数

I : 各関係属性の平均情報量の和

n : 平面の枚数

ここで I は、表 3 の平面の全関係積集合のうちの 1 行分の平均情報量の和を表すので、 $I \times (n - 1)$ はある平面の全関係積集合の持つ平均情報量の和を表す。また、 k は、いくつかの家のデータのクラスタリング結果からパラメータ調整を行い、 $k = 0.37$ とした。

5.3 house 1 での実験結果

まず、定義した情報量に基づく類似度を図 3 の house 1 について計算した結果を示す。表 5 は、house 1 における任意の 2 平面間での各関係属性値の情報量に

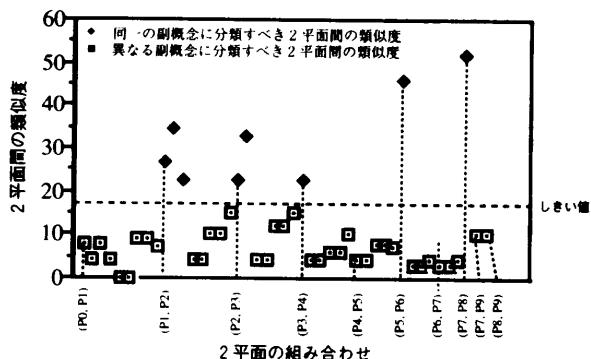


図 10 House1 の各 2 平面間での情報量で重み付けされた類似度の分布

Fig. 10 A distribution of the improved similarity measure for plane pairs of house 1 (weighted by information).

表 6 情報量を用いた house 1 の分類結果

Table 6 The classification result of house 1 by the similarity measure weighted by information.

副概念 No.	平面集合	対応副概念
SC0	P0	床
SC1	P1, P2, P3, P4	壁
SC2	P5, P6	屋根
SC3	P7, P8	窓
SC4	P9	ドア

よる、関係の類似度の重みと平均情報量である。情報量が大きいほど、属性値における分布が小さく、珍しい関係であることを示す。たとえば、包含関係の場合、ほとんどの 2 平面間では包含関係がないため、包含関係のある方がまれであるということが分かる。また、各属性の平均情報量は、属性間の重みの度合を表す。たとえば、表 5 の 6 種の関係属性の中では、上下関係が、最も重みが大きくなっている。前節で述べたしきい値の house 1 での計算式は、表 5 の平均情報量の和から、以下のとおりである。

$$k \times I \times (n - 1) = 0.37 \times 5.22 \times 9 \div 17.3 \quad (5)$$

この情報量に基づく（重み付けされた関係）類似度を計算した、house 1 での任意の 2 平面間での類似度の分布およびクラスタリングに用いたしきい値を図 10 に示す。ただし横軸は、表 4 に示した 2 平面間のすべての組合せを順に表す。単純な関係の類似度を用いた図 9 と比較すると、全体として同じ副概念に分類すべき面間の類似度と、別の副概念に分類すべき面間の類似度との分離度が大きいことが分かる。

たとえば、P7, P8 (窓), P9 (ドア) の 3 ペア (グラフ右端) の類似度の分布を比較すると、(P7, P9), (P8, P9) の類似度が、図 9 ではしきい値付近であるのに対し、図 10 ではしきい値から小さくなり、しかも

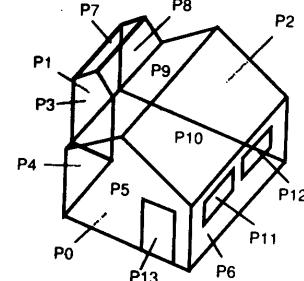


図 11 やや複雑な家の例 (house 2)

Fig. 11 A more complicated example of house 2.

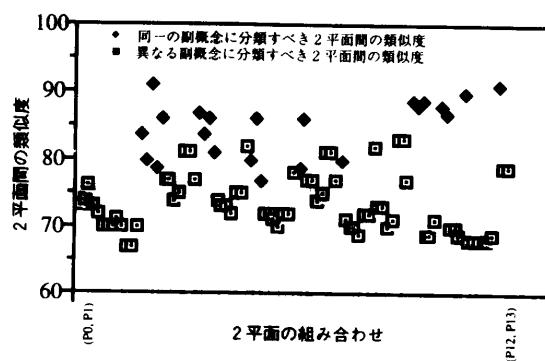


図 12 House2 の各 2 平面間での関係の類似度の分布

Fig. 12 A distribution of the simple similarity measure for plane pairs of house 2.

差が大きくなっている分離度が改善され、ドアと窓が区別されやすくなっていることが分かる。

情報量を類似度の重み付けに用いた手法による副概念の分類結果は、表 6 に示すとおり、常識的な副概念への分類となった。これらのことから、情報量を用いることにより、クラスタリングが改善されたといえる。

5.4 やや複雑な事例での分類結果の比較

提案した 2 種の類似度について、図 11 に示す、やや複雑な事例 (house 2) の副概念クラスタリングの実験を行った。図 12 は、単純な類似度に基づくクラスタリングを行ったときの類似度の分布、図 13 は、情報量を用いた類似度による類似度の分布である。ただし横軸は、2 平面間のすべての組合せを順に表す。これら 2 つを比較すると、類似度の分布では、単純な類似度 (図 12) に対し、情報量を用いた類似度 (図 13) の結果は、◆と□との境界が明確になり、改善されていることが分かる。分類結果も、単純な類似度では、同じ副概念 SC1 に分類されていたドア (P13) と壁が、情報量を用いた類似度 (表 7) では、異なる概念に分類できた。以上より、平面間の関係の類似度を用いることによって平面の副概念への分類が行え、さらに情報量を類似度の重み付けに用いることにより、複

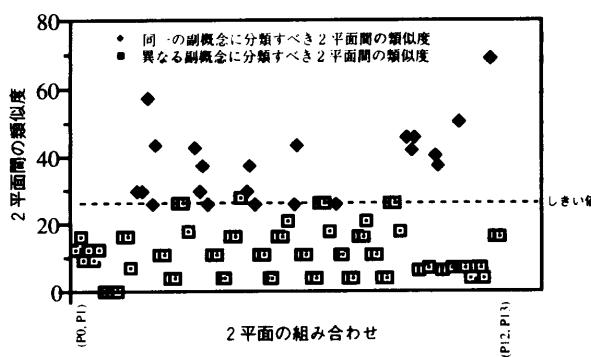


図 13 House2 の各 2 平面間での情報量で重み付けされた類似度の分布

Fig. 13 A distribution of the improved similarity measure for plane pairs of house 2 (weighted by information).

表 7 情報量を用いた house 2 の分類結果
Table 7 The classification result of house 2 by the similarity measure weighted by information.

副概念 No.	平面集合	対応副概念
SC0	P0	床
SC1	P1, P2, P3, P4, P5, P6	壁
SC2	P7, P8, P9, P10	屋根
SC3	P11, P12	窓
SC4	P13	ドア

雑な例でも分類精度を上げられることが分かった。

5.5 議論

本手法の属性値の珍しさを強調する類似度の重み付けは、直観的には似顔絵に例えられる。似顔絵は、顔の輪郭をなぞただけの機械的な絵よりは、その人をよく表す特徴を強調して描いた方が一目で分かりやすい。その反面、本手法において包含関係のような情報量の大きい属性を重視すると、玄関側の壁や、窓の多い壁が窓のない壁と別分類になったり、天窓のある屋根と同分類になったりする問題が予想される。しかしながら、図 10 の類似度の分布では、そうではない。これは、類似度を算出する際に、接続関係のある面どうしだけではなく、すべての面との関係積集合を元にしているからである。このように、本手法は、すべての要素との強調すべき組合せ的な関係の評価と、属性値の重み付けとのバランスによって良いクラスタリング精度を実現している。

類似度に基づくクラスタリングの長所は、領域独立の知識によって類似度を定義しているため、家以外の領域にも適用可能な点であるが、各平面についてすべての平面との関係を計算するため、対象を構成する平面の数が増大すると、それにともなって計算量が組合せ的に増大する欠点がある。これを回避する方法とし

て決定木、類似度両方を組み合わせてクラスタリングする方法が考えられる。まず第 1 に、領域依存の背景知識のうち、一般性の高い知識を用いて大まかに分類し、その後、類似度を用いて詳細な分類を行う手法¹⁹⁾では、領域依存の知識を少なくし、かつ、全体の計算量を抑えることができる。第 2 に、決定木の計算量が少なく、精度が高いという長所を生かすために、類似度を用いたクラスタリングにより典型的な対象例を副概念に分類し、その分類結果から、4.1 節で述べた決定木を ID3¹⁶⁾によって帰納学習する手法も可能である。これにより、決定木による精度の高く計算量の少ない副概念クラスタリングが領域独立な知識で行え、効率のよい構造概念の学習が実現される。

6. 副概念間の関係記述に基づく初期構造概念の生成

副概念クラスタリングで得られた分類結果から、対象の記述を各副概念の記述と副概念間の関係記述とに分けて、それぞれ正負の例からの帰納学習¹⁵⁾を行う。

6.1 副概念記述の生成

分類結果は、決定木の各葉ノードで表されるので、ここから副概念を生成する。副概念記述は、同一副概念に分類された平面どうしに成り立つ関係を正例として or 結合によって一般化し、一方、学習中の副概念に属さない面どうしの記述（負例）が、それに含まれないように、概念記述を特殊化して、これらを積和論理式として生成する。表 8 に、図 3 の house 1 の分類結果（表 6）に対する、SC0～SC4 の副概念記述を示す。横 1 行は、6 つの関係属性値の論理積を表し、行と行とは、論理積の論理和を表す。たとえば、SC1（壁）では、4 つの平面のうち、隣り合った場合と、向かい合った場合との 2 通りの関係が生じるため、その概念記述は、否定の項を省略すると、

(直角 and 接続 and 等高)

or (平行 and 等高 and 合同)

となる。ただしこの方法では、SC0（床）や SC4（ドア）のように 1 つの要素から成る部分構造に対する副概念記述は得られないで、この場合は NIL とする。これは 3.3 節で述べたように、用いた CDL が、2 平面間の関係記述のみで構成され、平面の形や色、材質といった属性や特徴等の記述を用いていないためである。これらの副概念は、次章で述べる他の副概念との関係記述により、相対的に表現される。

6.2 副概念間の関係記述の生成

副概念間の関係は、それぞれに属する平面どうしの関係から、6.1 節と同様の方法によって、共通の関係

表 8 House1 の 5 つの副概念記述
Table 8 The 5 sub-concepts description of house 1.

副概念	Angle	Connect	Up_Down	Congruent	Inclusion	Coplane
SC1 (壁)	Right_Angle	True	Equiv	False	Nil	False
	Parallel	False	Equiv	True	Nil	False
SC2 (屋根)	Slant	True	Equiv	False	Nil	False
SC3 (窓)	Parallel	False	Equiv	True	Nil	True
SC4 (ドア)			NIL			
SC0 (床)			NIL			

表 9 house 1 の SC1 と他の副概念間の関係記述
Table 9 The relational descriptions of house 1 between SC1 and other sub-concepts.

関係記述	Angle	Connect	Up_Down	Congruent	Inclusion	Coplane
SC0-SC1	Right Angle	True	Below	False	Nil	False
	Slant	True	Below	False	Nil	False
	Slant	False	Below	False	Nil	False
SC1-SC2	Right_Angle	True	Equiv	False	Nil	False
	Parallel	False	Equiv	False	Include	True
	Parallel	False	Equiv	False	Nil	False
SC1-SC3	Right_Angle	True	Equiv	False	Nil	False
	Parallel	False	Equiv	False	Include	True
	Parallel	False	Equiv	False	Nil	False
SC1-SC4	Parallel	True	Equiv	False	Include	True
	Parallel	False	Equiv	False	Nil	False
	Right_Angle	True	Equiv	False	Nil	False

を積和論理式として生成することにより獲得される。表 9 に house 1 に対する、SC1 (壁) と他の副概念との関係記述を示す。これらの記述から、対象全体の構造概念を意味ネットワーク表現として生成する。3 章で示した図 6 が、得られた house 1 全体の初期概念記述の意味ネットワークである。各ノードは副概念を表し、アーチは副概念間の関係記述を表す。ただし太線は and 記述を、細線は or 記述を表し、否定関係および直角関係は省略した。

6.3 検討

house 1 (図 3), house 2 (図 11), および結果は割愛するが水平な屋根を持つ house3 の形状の異なる 3 つの家に対し、表 6, 表 7 に示すように、平面集合をそれぞれ 5 つの副概念に分類し、house 2, house3 の副概念記述および副概念間の関係記述として、house 1 (表 8, 表 9) の記述とほぼ同一の初期概念記述が得られた (ただし house3 は、水平な屋根をもつため、屋根に関する副概念記述が、他と異なっている)。以上より、家に共通の 5 つの副概念および、家の構造概念を学習することができ、本手法は、形状の差異を吸収した一般的な家の構造概念を学習したといえる。

7. むすび

本論文では、対象の 3D モデルから、構造概念を獲得する手法について述べた。副概念クラスタリングの方法として、関係の類似度を提案して対象記述を副概

念に分類し、さらに、関係属性値の情報量を用いた類似度の重み付けの導入により、より精度の高い分類を実現した。そして対象記述の分類結果からそれぞれの副概念記述を学習し、全体の構造概念を副概念間の関係記述として学習した。本手法により、異なる形状の家に対して共通の構造概念が得られることを実験によって確認した。

今後の課題としては、定性的な関係記述のみではなく、定量的な属性記述も用いた概念学習¹³⁾や、柔軟な概念記述の実現²⁰⁾等がある。また、今回は 1 階建ての家のみを対象としたが、1 階建てと 2 階建ての家を区別するには、“部屋”という上位の部分構造を分節化した、家の階層的な構造概念の学習法が考えられる。

視覚からの概念学習¹⁰⁾には、この他にも多くの解決すべき問題点が残されているが、本論文で提案した、副概念クラスタリングによる対象記述からの部分構造への分節化は、概念学習研究のみならず、主体と外界とをどう区別するかといったエージェントの主観的認識を取り扱う人工生命的研究やロボットの強化学習研究²²⁾にとっても重要な一步であると思われる。なお、本論文は文部省科学研究費・重点領域 1・知識科学・03245102 の補助を受けた。

謝辞 本論文の作成にあたり、有益なコメントをいただいた、東京工業大の山田誠二助教授、谷内田研究室の大澤幸夫助手、および詳細かつ適切な改善のコメントをいただいた査読者に感謝いたします。

参考文献

- 1) Banu, B. and Poggio, T.A.: Introduction to the Special Section on Learning in Computer Vision, *IEEE Trans. PAMI*, Vol.16, No.9, pp.865-868 (1994).
- 2) Brooks, R.A.: *Model-Based Computer Vision*, UMI Research Press, Ann Arbor, MI (1984).
- 3) Weng, J.J., Ahuja, N. and Huang, T.S.: Learning Recognition and Segmentation of 3-D Objects from 2-D Images, *Proc. 4th Int. Conf. on Computer Vision (ICCV-93)*, pp.121-128 (1993).
- 4) Winston, P.H.: Learning Structural Description from Examples, *The Psychology of Computer Vision*, Winston, P.H. (Ed.), McGraw-Hill (1975). 邦訳: コンピュータービジョンの心理, pp.173-235, 産業図書 (1979).
- 5) Mitchell, T.M., Keller, R.M. and Kedar-Cabelli, S.T.: Explanation-Based Generalization: A Unifying View, *Machine Learning*, Vol. 1, pp.47-80 (1986).
- 6) Winston, P.H., Binford, T.O., Katz, B. and Lowry, M.: Learning Physical Description from Functional Definitions, Examples, and Precedents, *Int. Symposium on Robotics Research*, 1, Brady, M. and Paul, R. (Eds.), MIT Press (1984).
- 7) Utsumi, A., Yagi, Y. and Yachida, M.: Recognizing Surface and Spatial Structure of Environment from Wire-frame Model Obtained by Motion Stereo, *Proc. 8th Scandinavian Conf. on Image Analysis (SCIA-93)*, pp.441-447 (1993).
- 8) 内海, 八木, 谷内田: 視覚センサにより得られた3次元線分情報からの面情報の獲得, 日本ロボット学会誌, Vol.13, No.8, pp.1145-1152 (1995).
- 9) Connell, J.H. and Brady, M.: Generating and Generalizing Models of Visual Objects, *Int. J. of Artificial Intelligence*, Vol.31, No.2, pp.159-183 (1987).
- 10) 谷内田, 山口: 視覚からのモデルと概念の学習, 日本ロボット学会誌, Vol.13, No.1, pp.25-31 (1995).
- 11) 脇谷, 山口, 谷内田: 背景知識に基づく家の構造概念の学習, 人工知能学会人工知能基礎論研究会, SIG-FAI-9303, pp.1-8 (1994).
- 12) 董, 山口, 八木, 谷内田: 実例と教示による物体形状の概念学習—定量3D情報から定性値表現へ—, 情報処理学会CV研究会, 94-CV-87-8, pp.57-64 (1994).
- 13) Dong, G., Yamaguchi, T. and Yachida, M.: Learning Shape Concept from 3-D Spatial Structure of Objects, *Proc. 3rd Pacific Rim. Int. Conf. on Artificial Intelligence (PRICAI-94)*, pp.919-925 (1994).
- 14) Dong, G., Yamaguchi, T. and Yachida, M.: Learning Structural Concept from 3-D Geometric Model of Objects, *7th Australian Joint Conf. on Artificial Intelligence (AI-94)*, pp.21-28 (1994).
- 15) Michalski, R.S.: A Theory and Methodology of Inductive Learning, *Machine Learning, An Artificial Intelligence Approach*, Michalski, et al. (Eds.), pp.83-134, Tioga (1983). 邦訳: 帰納学習の理論と方法論, pp.91-148, 知識獲得と学習シリーズ1, 知識獲得入門, 共立出版 (1987).
- 16) Quinlan, J.R.: Induction of Decision Trees, *Machine Learning*, Vol.1, pp.81-106 (1986).
- 17) Fayyad, U.M. and Irani, K.B.: Multi-Interval Discretization of Continuous-Valued Attributes for Classification Learning, *Proc. IJCAI-93*, pp.1022-1027 (1993).
- 18) Michalski, R.S.: Clustering, *Encyclopedia of Artificial Intelligence*, 2nd Ed., Shapiro, S.C. (Ed.), pp.168-176, Wiley-Interscience (1992). 大須賀節雄(訳): 人工知能大辞典 (1st Ed.), pp.315-322, 丸善書店 (1991).
- 19) 董, 脇谷, 山口, 谷内田: 背景知識に基づく家の構造概念の学習, 人工知能学会第8回全国大会, pp.105-108 (1994).
- 20) Dong, G., Yamaguchi, T. and Yachida, M.: Fuzzy Relational Model with 3-D Structural Information of Objects, *IAPR Workshop on Machine Vision Applications (MVA-94)*, pp.57-60 (1994).
- 21) 山口, 脇谷, 谷内田: 関係の類似度に基づく家の構造概念の学習, 人工知能学会第8回全国大会, pp.93-96 (1994).
- 22) Yamaguchi, T., Masubuchi, M., Tanaka, Y. and Yachida, M.: Reinforcement Learning for a Real Robot in the Real Environment, *Proc. the 12th European Conf. on Artificial Intelligence (ECAI-96)*, pp.694-698 (1996).

(平成7年6月9日受付)

(平成8年9月12日採録)



山口 智浩（正会員）

1961年7月23日生まれ。1985年大阪大学基礎工学部制御工学科卒業。1987年同大学院基礎工学研究科修士課程修了。同年三菱電機（株）情報電子研究所、1988年松下電器産業（株）情報システム研究所研究員を経て1991年大阪大学基礎工学部アーツステーション助手。1993年同学部システム工学科助手、現在に至る。抽象化問題解決、概念学習、機械学習、人工生命等の研究に従事。現在の主たる研究テーマは、ロボット行動の強化学習の高速化手法および多様な挙動の獲得。情報処理学会、人工知能学会、ロボット学会各会員。



脇谷 康一

1970年9月15日生まれ。1992年大阪大学基礎工学部情報工学科中退。1994年同大学院基礎工学研究科制御工学分野修士課程修了。同年松下電器産業（株）入社。生産技術本部機械研究所制御要素開発部に勤務し、FA用画像処理検査装置の開発に従事。電子情報通信学会会員。



谷内田正彦（正会員）

1945年9月4日生まれ。1969年大阪大学工学部電気工学科卒業。1971年同大学院工学研究科修士課程修了。同年、大阪大学基礎工学部制御工学科助手。1982年同助教授を経て同学部情報工学科教授、1993年同学部システム工学科教授、現在に至る。画像処理、人工知能、移動ロボット等の研究に従事。工学博士。著書ロボットビジョン（昭晃堂）、コンピュータビジョン（丸善、編著）等。システム制御情報学会、情報処理学会、人工知能学会、ロボット学会等各会員。