語彙獲得過程における
カテゴリ化空間の幾何学的モデル

日高　昇平

語彙獲得過程におけるカテゴリ化空間の幾何学的モデル

日高　昇平

内容梗概

我々の日常的な知識は，名詞に象徴される何らかの概念から織り成されている．論理的には，無数の可能性がある名詞の意味を，我々は造作もなく特定し，共有する事で相互の意思疎通を可能にする．基本的な概念に関する我々の「直感」は，どのように発生し，なぜ共通に一定の方向性を持つのだろうか．カテゴリ学習，名詞の獲得，画像の命名，特徴の評定など，様々な心理学的研究から，人は基本カテゴリと呼ばれる一群の名詞 (e.g., 花，鳥，魚など) を効率的に操作できる事が知られている．また，2，3 歳児は新奇名詞の付与された新奇事例を，たった一事例からでも正しく他の事例に汎用する事ができ，これを即時マッピングと呼ぶ．このような効率的なカテゴリ化の背後には，名詞カテゴリの意味的な構造化があると考えられ，この構造をカテゴリの凝集性と呼ぶ．

本研究の目的は，自然名詞および新奇名詞のカテゴリ化の効率性と，その効率化によって生じる意味 (特徴空間) の幾何学的構造を解明する事である．具体的には，まず心理実験による基本カテゴリの特徴評定を行い，この結果に基づき，カテゴリの凝集性を幾何学的性質によって定量化する尺度を提案した．この尺度は特徴空間の曲率分布を捉えるため，カテゴリの滑らかさと呼ぶ．名詞カテゴリを分析した結果，効率性の高いと考えられる基本カテゴリは，他よりも滑らかである事が示された．次に，滑らかなカテゴリの発生を説明する計算論的モデルを提案した．このモデルでは，カテゴリ集団の識別性と汎用性を効率とみなし，この効率化が高い表現自由度と予測性を併せ持つ滑らかなカテゴリを導く．その結果，既知のカテゴリの滑らかさを利用する事によって，未知のカテゴリ分布に対する素早い推定 (i.e., 即時マッピング) が可能となる．従って，最も効率のよい基本カテゴリは滑らかな (凝集的な) 幾何学的構造を持ち，またその性質は新奇名詞の獲得を促進する事が示唆された．

続く三つの研究では，提案した計算理論におけるカテゴリ表現の詳細な検討を行い，特徴処理の階層性や，カテゴリの文脈依存性という側面への拡張を議論した．最後に，特徴空間の公理系の選択という観点から，それに必要な認知発達と，想定される幾何学的なモデルについて考察し，特徴空間の幾何学的性質の発達的変化に関する仮説を提案する．

A geometric model of categorization space for lexical acquisition

Shohei Hidaka

Abstract

Our knowledge in daily life consists of concepts symbolized by nouns. Even though a given noun could logically have infinitely many possible meanings, we easily specify noun meanings common to others. Where does this intuition on foundational concepts come from? And why it is coherent between people? Various psychological studies, such as category learning, noun acquisition, picture naming, and feature evaluation have shown that people can efficiently manipulate a set of nouns called "basic categories" (e.g., "flower", "bird", "fish", etc.). Likewise, many developmental studies have shown that two- and three-year-old children use to correctly generalize novel nouns given to novel instances, a behavior called "fast mapping". The semantic structure in the background of efficient categorization is generally called "category coherence".

The goal of the present study is to specify the categorization efficiency for natural and novel noun categories, and its relationship to the geometric structure of meaning (feature space) of noun categories. First, feature ratings of basic categories were obtained from a psychological experiment, and based on the result, I proposed a quantitative and geometric measure for category coherence. I call the measure "smoothness" of categories, because it summarizes curvature distribution on feature space. The analysis with smoothness showed that basic categories, which were supposed efficient, were smoother than the other. Next I proposed a computational theory which accounts for the emergence of smooth categories. In the theory, the efficiency is defined as discriminability and generality, and optimization with the efficiency leads smooth categories with high flexibility and predictability. As a result, the best use of known smooth categories enables the rapid estimation of an unknown category (i.e., fast mapping). Therefore, I claim that efficient basic categories have smooth (coherent) geometric structure which enhances learning of novel nouns.

The subsequent three parts in this paper consist of a detailed investigation of theoretical assumptions, and exploratory studies for the theory extending

the theory to hierarchical feature and context dependent categories. Finally, in terms of selection of axioms of feature space, I discussed necessary cognitive developments, and proposed geometric models and a hypothesis on the developmental change of the geometric nature of the feature space.

語彙獲得過程におけるカテゴリ化空間の幾何学的モデル

目次

第 1 章　序論：意味の不確定性，その制約としてのバイアス　1

1.1　本論文の主題 2
1.2　カテゴリの形成要因とカテゴリ化バイアス 3
1.2.1　情報処理の水準 4
1.2.2　本論文のアプローチ 5
1.3　カテゴリ化の理論的研究の背景 6
1.3.1　カテゴリの表現形式 7
1.3.2　カテゴリの集団的性質 8
1.4　カテゴリ凝集性 11
1.4.1　統計的モデルによるカテゴリ凝集性の説明 12
1.4.2　素朴理論によるカテゴリ凝集性の説明 12
1.5　新奇語の汎用 14
1.5.1　即時マッピング 14
1.5.2　新奇語の汎用とカテゴリ凝集性 16
1.6　カテゴリ化理論および新奇語汎用のまとめ 17
1.7　本論文の構成 18

第 2 章　名詞カテゴリの特徴評定実験　21

2.1　実験目的 21
2.2　方法 22
2.2.1　協力者 23
2.2.2　評定対象 23
2.2.3　実験手続き 24
2.2.4　分析方法 25
2.3　結果と考察 26
2.3.1　形容語対の選択 26
2.3.2　日本語・英語話者の評定データの比較 26
2.3.3　主成分の構造 27

第 3 章　自然カテゴリの凝集性の計算理論　29

3.1 心理実験による滑らかさの検討 33
3.1.1 方法 34
3.1.2 結果・考察 36
3.2 カテゴリの詰め込みモデル 38
3.3 カテゴリ詰め込みの理論的定式化 45
3.4 シミュレーション 47
3.5 シミュレーション１：カテゴリの詰め込み 48
3.5.1 手続き 48
3.5.2 結果・考察 49
3.6 シミュレーション２：カテゴリの効率性の検討 50
3.6.1 方法 51
3.6.2 結果・考察 53
3.7 シミュレーション３：未知カテゴリの即時マッピング 54
3.7.1 方法 56
3.7.2 結果・考察 57
3.8 シミュレーション４：ランダム分布点のカテゴリ化 58
3.8.1 方法 59
3.8.2 結果・考察 59
3.9 結論 59
3.9.1 多様体仮説：曲面上に埋め込まれたカテゴリ 62
3.9.2 理論的な仮定の妥当性およびその補強 63
3.9.3 研究の展望：基底の安定性，階層性，文脈に対する柔軟性 65

第 4 章 カテゴリの表現基底 67

4.1 シミュレーション 1：CHN モデル 70
4.1.1 シミュレーション手続き 71
4.1.2 結果 74
4.2 シミュレーション 2：3 次元-CHN モデル 75
4.2.1 方法 75
4.2.2 結果と考察 76
4.3 シミュレーション 3：3 次元-PSAL モデル 79
4.3.1 方法 79

4.3.2 結果・考察 80
4.4 シミュレーション 4：PSAL モデルの名詞カテゴリへの適用 . . . 82
4.4.1 方法 82
4.4.2 結果・考察 83
4.5 結論 85
4.5.1 プロトタイプによる学習 85
4.5.2 統語的カテゴリの影響 86

第 5 章 カテゴリ化効率性と特徴の階層性 87

5.1 発達心理学的な知見 87
5.2 物体の階層表現の選択による形バイアスの形成 90
5.2.1 階層的な情報処理における循環性 90
5.3 シミュレーション 91
5.3.1 方法 94
5.3.2 結果と考察 98

第 6 章 文脈依存的なカテゴリの構造化 106

6.1 情報圧縮による境界移動仮説の説明 110
6.2 名詞・特徴データの再分析：名詞カテゴリの言語固有の構造 . . 111
6.2.1 分析方法 111
6.2.2 結果と考察 112
6.3 シミュレーション 1：存在論的カテゴリの境界移動 115
6.3.1 方法 117
6.3.2 結果・考察 119
6.4 シミュレーション 2：新奇語汎用の言語差 123
6.4.1 日本語・英語話者による新奇語汎用の比較言語実験 . . . 124
6.4.2 文脈手がかりを利用した新奇語汎用のモデル 126
6.4.3 方法 126
6.4.4 結果と考察 130
6.5 結論 131

第 7 章 総合考察：意味認知の幾何学的変化 136

7.1 各章のまとめ 136
7.2 効率と幾何学的構造 139

7.2.1 幾何学的性質の選択の必要性 140
7.3 カテゴリ表現の発達的変化 142
7.4 幾何学的性質の選択：理論研究の展望 145
7.4.1 コネクショニストモデルによる意味認知の説明 145
7.4.2 複雑なネットワークとしての自然カテゴリの表現 146
7.5 おわりに 148

参考文献 **149**

付録 **A-1**

A.1 評定実験に用いた語彙および結果 A-1
A.1.1 言語尺度 A-1
A.1.2 語彙調査の評定結果 A-1
A.2 Contrastive Hebbian Learning A-4
A.3 PSAL の数学的定式化 A-5
A.4 詰め込みモデルの数学的定式化 A-6
A.4.1 詰め込み効率性関数の導出 A-6
A.4.2 詰め込み効率の解析的な最適解 A-8
A.4.3 滑らかな構造の発生 A-11
A.4.4 最適解の安定性 A-12
A.4.5 他のメトリックモデルとの関係 A-13
A.4.6 詰め込み効率関数の階層的な性質 A-16
A.4.7 混合正規分布モデルによるクラスタリングモデルへの拡張 A-18

図一覧

1.1 カテゴリ化の決定要因 4
1.2 典型的な新奇語汎用課題 15
2.1 第一・第二主成分における名詞カテゴリ平均値のプロット 28
3.1 滑らかな仮想的な名詞カテゴリ 33
3.2 2 カテゴリの平均ベクトルのノルム (x 軸)，および共分散行列のノルム (y 軸) の散布図において，正の相関または単調増加が滑らかさの指標となる． 34
3.3 日本語の名詞カテゴリの滑らかさ ($S = 0.5221$) 39
3.4 英語の名詞カテゴリの滑らかさ ($S = 0.3491$) 39
3.5 日本語の上位カテゴリの滑らかさ ($S = 0.2598$) 40
3.6 英語の上位カテゴリの滑らかさ ($S = 0.1746$) 40
3.7 仮想カテゴリ A,B の尤度 43
3.8 カテゴリの詰め込み 45
3.9 詰め込み効率性を最適化する 20 カテゴリの分布構造の例 49
3.10 詰め込み効率性を最適にするカテゴリ群の滑らかさ 50
3.11 滑らかさと詰め込み誤り率の散布図． 55
3.12 滑らかさとカテゴリ間・カテゴリ内分散比の平均の散布図． 55
3.13 滑らかさと残差分散の平均の散布図． 56
3.14 評定実験のカテゴリ分散と詰め込みモデルによって予測されたカテゴリ分散 58
3.15 詰め込み効率の最適化によるクラスタリング 60
3.16 分散比の最適化によるクラスタリング 60
4.1 Samuelson(2002) のモデル 71
4.2 名詞カテゴリの知覚特徴空間．白領域から学習刺激，黒領域から標準刺激が提示される． 73
4.3 形類似刺激選択率．チャンスレベル 50%に対し有意に平均が大きい条件を*で示す． 74
4.4 CHN モデルの固形平面上の汎化パタン． 77
4.5 固形/非固形刺激の汎化パタンと形/材質次元との相関． 77
4.6 PSAL モデルのネットワークアーキテクチャ 80

4.7 固形平面上の PSAL モデルの汎化パタン 81
4.8 PSAL モデルの相関パタン．全ての条件で形・材質バイアスが見られた． 81
4.9 新奇語汎用課題の形類似刺激選択率 84
5.1 階層的な特徴の循環的な情報処理 92
5.2 形，色，肌理によって定義された視覚的物体 94
5.3 物体特徴のシンボル化モデルの情報処理過程 95
5.4 各シミュレーション条件での平均正答率 103
5.5 Jones (2003) の新奇語汎用課題の結果：(左) 非典型発達群 (右) 統制群 103
5.6 学習エポックに対する基準条件の平均正答率の推移 104
5.7 モデル個体内の平均正答率順に並べ替えて平滑化した正答率 104
5.8 中間層-出力層間の相互情報量と平均正答率のモデル個体散布図 105
6.1 存在論的カテゴリと言語固有の統語カテゴリ 108
6.2 主成分と言語固有の統語カテゴリの F 値 116
6.3 存在論的カテゴリの移動を表す模式図．図中に最大の重みを持つ 5 つの形容語対 (その一つのみを示す) を示す．詳細は本文を参照． . . 118
6.4 統語属性の効果 (横軸) に対する各項目の相関 121
6.5 日本語・統語あり条件の階層クラスタリング． 123
6.6 英語・統語あり条件の階層クラスタリング 124
6.7 新奇語汎用パタン． 133
7.1 幾何学的構造の変化 142

表一覧

1.1 仮想的なカテゴリ・特徴の対応 (Rogers & McClelland[1] の表の一部を改変). 10
1.2 カテゴリの計算理論，表現形式，それに対応する心理学的な現象 . . . 17
3.1 名詞カテゴリとその上位カテゴリ．表中の記号 A は “Animals (Real or Toy)”，B は “Body Parts”，C は “Clothing”, FD は “Food and Drink”, FR は “Furniture and Rooms”, O は “Outside Things”,S は “Small Household Items”, T は “Toys”, V は “Vehicles (Real or Toy)” を表す. 37
3.2 滑らかさ指標 38
4.1 Samuelson (1999) の調査による初期獲得語彙の固形性カテゴリ，統語的カテゴリ，カテゴリ化の比率．括弧の隣の数値はモデルでの値で括弧内は評定実験の結果である． 72
4.2 シミュレーション２，３で用いた語彙モデル 76
5.1 各条件の多層パーセプトロンの入力，中間，出力層のユニット数および学習に成功した（100 シミュレーション中の）回数 97
6.1 日本語と英語の名詞カテゴリおよび統語カテゴリ．i は “いる”，a は “ある” が用いられる日本語名詞，c は英語の可算名詞,m は非可算名詞を表す．また，“足” の項目はカテゴリに含まれる事例が足を持つ (1)/持たない (0) ことを表す. 113
6.2 名詞カテゴリの統語属性に関する識別性．*は $p < 0.05$，**は $p < 0.001$ を表す. 117
6.3 統語あり・なし条件での統語属性に関する識別性．*は $p < 0.05$，**は $p < 0.001$ を表す. 120
6.4 新奇語汎用の行動データ (Yoshida & Smith, 2003) に対する MDA モデル，最適モデルの適合性. 132
7.1 表 7.1 カテゴリ表現の幾何学的構造とそれに対応する必要な発達的変化 142
A.1 評定に用いた形容語対および物体の属性を表す語 A-1
A.2 各メトリックの Pearson 積率相関係数 (上三角) と Kendall 順位相関係数 (下三角) A-16

第 1 章　序論：意味の不確定性，その制約としてのバイアス

今目の前にある対象が，その隣にある別の対象や，過去に経験した複数の対象と「同じ」であるか「異なる」のか，我々はどの瞬間にも意識的・無意識的に判断を行っている。このような判断をカテゴリ化 (categorization) と呼び，その結果，同一視される集合をカテゴリ (category) と呼ぶ．カテゴリは一義的ではなく，一般に多義的であり，文脈に応じて我々は全く同一の対象を，別なカテゴリとして捉える事ができる．例えば，目の前にいる四足で小型の対象を「ポチ」「ヨークシャテリア」「イヌ」「哺乳類」「動物」「生物」などのように，様々な抽象化のレベルでカテゴリ化できる[1)]．また,「四足のモノ」,「そこにある茶色い毛の生えたモノ」,「爪の生えた動物」などのように，ある特定の属性を基にカテゴリ化することもできる．このように同一の対象であっても可能なカテゴリ化は実質無限にある．また同様に，ある新奇な名詞 (e.g.,「ガヴァガーイ」) の意味する事象の集合にも，論理的には無限の可能性がある [2]．しかし，このようなカテゴリと指示対象の冗長性・不定性にも関わらず，我々は特定の対象に対してはある特定のカテゴリ化を好む傾向がある．

具体的には，様々な抽象化の水準の中から特定水準の名詞を選択する事が多い．例えば，日常の場面で「ヨークシャテリア」を見た場合に，それは「動物」でもあるが，多くの場合「イヌ」という抽象化のレベルで会話をすることが多い [3].「イヌ」「イス」「リンゴ」のような中位の抽象化のレベルの自然カテゴリは「基本カテゴリ」と呼ばれる．基本カテゴリは「哺乳類」「家具」「果物」などのような上位カテゴリや,「ドーベルマン」「ロッキングチェアー」「青リンゴ」などのような下位カテゴリに比べて，様々な心理学的な課題において優位性を持つ事が示されている [4]．このような特定のカテゴリを好む傾向と同様に，新奇な物体に与えられた新奇語の汎用でも，特定の属性に対する選好がみられる．例えば，幼児は木製のブロックなどの新奇な (馴染みのない) 固形な物体 (solid object) に与えられた新奇語を，材質，色，肌理や大きさなどの属性よりも，形状の類似性に基づいて他の物体に汎用する傾向がある [5].

以上のように，自然カテゴリおよび人工的に作成した新奇物体に対するカテ

[1)] 以下では特に断りが限りカテゴリ名を「イヌ」のように括弧で示す.

ゴリ化では系統的な選好がみられる．このようなカテゴリ化にみられる系統的な選好は，既存の知識を利用し，新しいカテゴリの参照する「意味」の範囲を限定する戦略を反映すると考えられている [6]．人は既に学習した対象から，未知の対象へと一般化可能な特性を抽出することで，新奇なカテゴリの素早い学習を可能にすると考えられる．このように形成された事例に対する「事前知識」が，特定の特徴やカテゴリの選好として表れると考えられる．従って，カテゴリ化における偏り・選好は「何を特徴とみなすべきか」，または「何を同一とみなすべきか」などの，我々の直感的なカテゴリ処理の一端，つまり，概念の骨格を形成する構成要素であると考えられる．

1.1 本論文の主題

本研究の目的は，自然カテゴリの構造や新奇語獲得のモデル化を通じて，概念発達の計算論的なメカニズムを解明することである．カテゴリ化，そのエラー，もしくは未知の対象への汎化において，人が系統的に示す偏り・選好を本論文ではカテゴリ化バイアスと呼ぶ．カテゴリ学習，自然カテゴリの評定実験，言語発達などの関連研究で，様々なカテゴリ化バイアスが報告され，これを分析・理論化する事で，カテゴリの表現形式やカテゴリの集団的な性質などの一端が明らかにされてきた．

本論文の全ての研究に共通する理論的な骨格は，自然カテゴリや新奇カテゴリの汎用行動を，カテゴリの効率化の観点から説明できるという主張である．ここで，カテゴリの効率性とは，カテゴリの識別性，一般性，また認知的な経済性などの要素からなる均衡状態を意味している．生物は経験する全ての事象を記憶し処理する事はできないために，生存に何らかの点でより重要な情報を取捨選択する必要がある．従って，カテゴリ化の最も重要な性質の一つは，過去の経験の蓄積を将来出会う未知の対象に一般化する事である．一般的な知識は，少ない認知資源でより多くの対象に適用できる．しかし，一般的すぎるカテゴリ (e.g.,「事象」「存在」など) によっては，全ての対象が同一視され，適用対象の識別性が失われる．つまり，この相反する一般性と識別性が均衡を保つ事で，生物としての，もしくは情報処理系として適切なカテゴリの表現が取捨選択されると考えられる [4]．逆に言えば，もし認知的資源に制限などなく，あらゆる意味で効率化する必要がないならば，全ての事例，特徴を偏りなく均質に記憶・利用する事も可能である．しかし，実際には何らかの意味で最適化・効

率化されているために，それに付随したカテゴリ化バイアスが発生すると考えられる．

従って，本論文では全ての研究を通じて，カテゴリの効率性とは何か，またそれによって形成される表現形式 (幾何学的モデル) とは何かを議論するために，人のカテゴリ化バイアスは重要な手がかりになると考えられる．次節では，カテゴリ化メカニズムとバイアスの関係について述べ，本研究ではそれをどのように捉えるのか説明する．

1.2 カテゴリの形成要因とカテゴリ化バイアス

本論文では，カテゴリ化を基本的な以下の４つの要因に分けて議論を展開する．あるシステムでカテゴリが決定されるための相互に独立ではない要因として

(1) 分類対象となる事例群の構造（入力として与えられる情報の形式）

(2) 分類するべきカテゴリラベルの付与（出力構造・教師信号）

(3) カテゴリ化システム内部のカテゴリの表現形式とアルゴリズム

(4) (1), (2), (3) の関係により定義される効率性

まず,(1) 入力構造とは，分類の前段階で対象に関して得られる情報の形式のことである．例えば，視覚呈示された図形を何らかのカテゴリに分類する場合であれば，対象となる図形の種類・頻度や，また分類者がどの特徴によってそれを知覚するのか，などが入力の構造として含まれる．

次に，(2) 出力構造とは，分類対象の一部に対して，分類されるべきカテゴリを明示的に表す信号 (カテゴリラベル) である．前の例では，三角形の幾つかがカテゴリ A で，四角形の幾つかがカテゴリ B である，などと与えられる情報はカテゴリラベルである．このカテゴリラベルは三角形と四角形を異なるものとみなす事を暗示しているので，他の三角形と四角形のカテゴリ化に影響すると考えられる．また，当然のことながら明示的なカテゴリラベルが学習時に全く与えられない場合もある．

(3) カテゴリ化システム内部の表現形式とアルゴリズムとは，対象の特徴を表現する単位 (i.e., 特徴空間の幾何学的性質) と，カテゴリの判断をするための類似性の計算手順のことである．個々のカテゴリの表現とアルゴリズムを以下ではカテゴリ基底と呼ぶ．

(4) カテゴリの効率性は，他の要因と関連して定義される．この構造を図 1.1 に示した．図 1.1 では，事例・カテゴリラベルの分布構造は，カテゴリ学習者

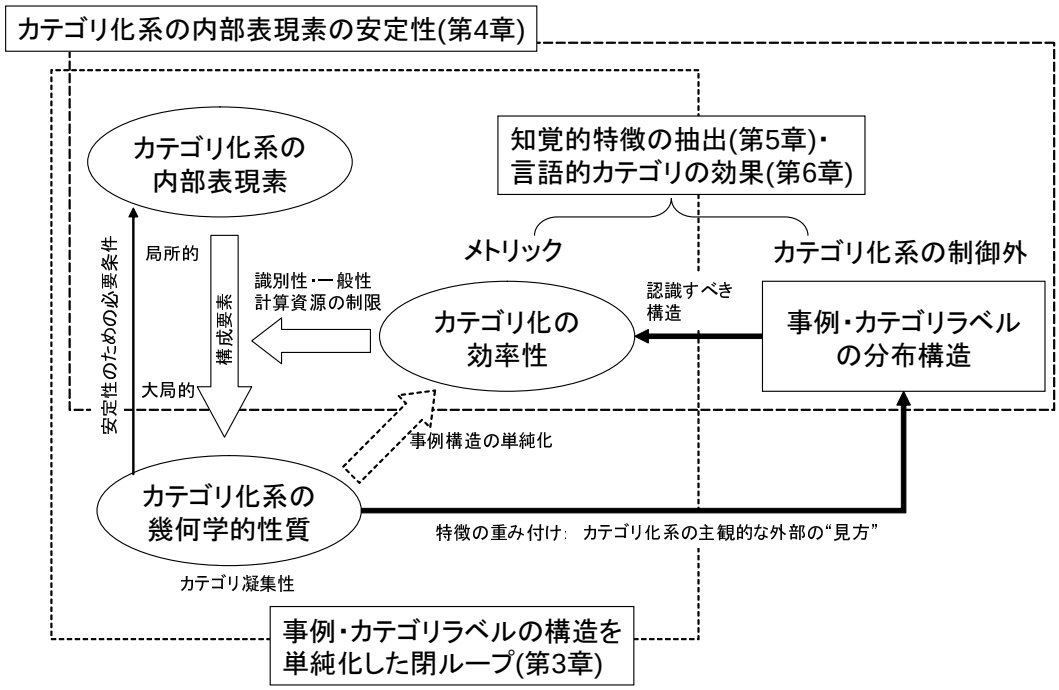

図 1.1: カテゴリ化の決定要因

に与えられるが，直接制御できないとする．カテゴリ化の目的は，システム内部のカテゴリ基底に基づいて，事例とカテゴリラベルを適切に関連付ける事である．従って，事例・カテゴリ分布の構造に起因する識別性・一般性や，カテゴリ基底に起因する認知的な経済性がカテゴリ化の効率性を構成する．ただし，識別性・一般性・経済性のうち，いずれかを重視する，またはバランスをとる，といった効率化の戦略に依存して，形成されるカテゴリの集団的な性質は異なると考えられる．

1.2.1 情報処理の水準

Marr [7] は，情報処理の過程を，計算理論 (Computational theory)，表現とアルゴリズム (Representation and Algorithm)，ハードウェアによる実現 (Hardware implementation)，の 3 つの水準で捉える考え方を示した．この観点からは，(1)，(2)，(3) は，いずれも表現とアルゴリズムの水準，(4) は計算理論の水準の問題として捉えられる．計算理論の水準では情報処理の目的，その計算に必要な条件など,「なに」をまた「なぜ」処理するのかを問う水準である．また表現とアルゴリズムでは，情報の表現形式や，その表現を変換するアルゴリズムなど,「どのように」情報処理をするかを問う水準である．ハードウェアでの実装では，ア

ルゴリズムの実行を行う実体について問う水準である．本論文ではハードウェアの水準，つまり脳・神経回路網での実現の妥当性は一部を除きあまり議論しない．表現とアルゴリズムの水準では，各種の統計的なモデルの形成する特徴空間の幾何学的な構造について議論する．また，計算理論の水準では，なぜ特定の幾何学的構造が発生するのか，それを制約する条件について議論する．

この中で表現とアルゴリズムの水準は，心理実験による行動パタンの観察への適合性，および計算理論の要請などから，本論文では最も具体的に議論する対象である．表現形式とアルゴリズムが一つ定まれば，必ず何らかのバイアスが発生する．従って，逆に行動様式にみられるカテゴリ化バイアスが発生するための表現・アルゴリズムを構成的に特定できると考えられる．例えば，殆どの人は 10 進法 (表現) で整数 (計算理論) を表すが，その心的な表現形式は人の数字の計算および判断の偏りに表れる [7]．10 進数で表現し計算する人にとって，ある数字を 10 で割った余りを計算するのは容易いが，ある数字を 7 で割った余りを計算するのは容易ではない．この例が端的に示すことは，同じ計算理論 (ここでは整数) でも，何らかの表現形式を取ることで，それに対応した偏りが発生する事である．つまり，ある特定のカテゴリ化バイアス (e.g., 基本カテゴリの優位性，形類似性の優位性) は，カテゴリを形成する要因 (i.e., 対象事例の構造，カテゴリラベルの付与，システム内の表現) の何れかに，これを発生するメカニズムがあるからであると考えられる．

1.2.2 本論文のアプローチ

本論文では，従来別々の文脈で議論されることの多かった (主に成人を対象とする) カテゴリ学習の理論と幼児の新奇語の汎用を統一的な視点から議論していく．カテゴリ学習の研究では，主に人工的に設定されたカテゴリの学習過程の分析や，(主に完成した知識を持つ成人を対象とする) 自然カテゴリの評定などを行う事で，人がどのようにカテゴリを表現し，利用するか調べられてきた．一方，言語獲得の研究では，実験的な少数の人工カテゴリの学習ではなく，幼児が実際に名詞カテゴリ学習の過程が調べられてきた．研究対象の違いから，両者は異なる実験的手法を用いる場合が多い．しかし，両者の知見は共通のメカニズムから発生したカテゴリ化バイアスを，異なる側面から見たものであると本論文では考える．このような立場から，両者に共通する一般的な自然カテゴリの描像として，本論文で重要視するのが “カテゴリの凝集性” (Category Coherence) [8] である．様々な研究から，自然カテゴリの全体像は多数の領域固有の知識

(domain-specific knowledge) [1)]の集合として描写できる事が示唆されており，それぞれの領域では特定のカテゴリが集団的な類似性を持つと考えられている．このようなカテゴリのクラスタ構造を凝集性と呼ぶ．より具体的な説明は，関連する研究を踏まえて後に述べるが，ここで重要な事は次の二点である．第一に，自然カテゴリの全体的な描像は，多数の固有領域に分かれているように見えるが，個々のカテゴリの心理的な表象は，カテゴリ学習の理論によってモデル化できる点である．つまり，カテゴリ学習の理論は，カテゴリの凝集性をモデル化するための基礎である．第二に，自然カテゴリの固有領域に関する知識は，幼児の新奇語の獲得を促進する事が示唆されている点である．従って，カテゴリ学習の理論を拡張し，カテゴリの集団的な構造から得られる領域固有の知識を新奇なカテゴリに汎用するメカニズムを解明するためには，カテゴリの凝集性への理解が不可欠である．

本論文では，カテゴリ凝集性の発生および新奇語の汎用メカニズムの理論的な解明を目的として研究を展開した．各章の研究では，カテゴリ化の効率性に加えて，幾つかの部分的なカテゴリ化の要因 (図 1.1) に焦点を当てて (その他の要因を単純化して) 議論する．次節では，これまでに行われてきたカテゴリの理論的な研究を紹介し，カテゴリの凝集性についてより詳しい説明を行う．次に，本論文の各章で主にモデル化の対象とする幼児の新奇語汎用について述べ，最後に本論文の構成について述べる．

1.3 カテゴリ化の理論的研究の背景

ここで取り上げる研究は大きく分けて，個別のカテゴリの表現形式 (カテゴリ基底) と，多数のカテゴリの集団的な構造に関連するものがある．自然カテゴリの集団的な構造は，還元論的に個々のカテゴリの表現だけで説明する事はできない．しかし，新奇な人工カテゴリの学習過程や，特定の自然カテゴリに対する心理的属性に関する知見は，特定のカテゴリだけではなく，自然カテゴリの集団的構造の理解へと繋がる足がかりになると考えられる．以下では，古典

[1)] 幾つか発達心理研究の分野では，心理的に類似の傾向を共有すると見られる対象を「領域」“domain” または「種類」(“kind”) と呼ぶ．例えば，言語などの領域固有の知識が,「領域固有」(Domain-specific) なメカニズム (e.g., 生成文法 [9]) により獲得されるか,「領域一般」(Domain-general) なメカニズム (e.g., 学習や記憶など一般の認知能力) によって獲得されるか，などのように用いられる．しかし，何が「領域」であるか厳密に定義するのは難しく，統一的な見解は得られていない [10].

的なカテゴリモデル，確率的なカテゴリモデルを取り上げ，確率的なカテゴリモデルによる自然カテゴリの理論的な説明を紹介する．しかし，確率的なカテゴリモデルによる説明だけでは，自然カテゴリの構造化を十分に説明する事はできない事が次第に明らかになりつつある．なぜなら，自然カテゴリの構造化を説明するには，類似性とは何か，カテゴリとは何か，特徴とは何か，といったカテゴリ化理論の前提となる「常識」そのものを問い直す必要があるからである．このような研究では，まだ十分に議論は尽くされていないが，現段階で挙げられる代表的な仮説について述べる．

1.3.1 カテゴリの表現形式

1960 年代から 1970 年代にかけては，述語論理的なカテゴリの表現形式が主に研究されていた．現在ではこれは古典的カテゴリ観と呼ばれる [11]．この理論では，カテゴリがそれに含まれる事例の集合によって定義され，カテゴリの有する特徴は，その下位の集合全てに共有される．例えば,「人」のカテゴリに「ソクラテス」が含まれ (i.e., 述語「ソクラテスは人である」に対応),「人」が「死ぬ」という特徴を持つ場合 (i.e., 「人はみな死ぬ」),「ソクラテスは死ぬ」という三段論法による推論が可能となる．このような述語論理的なカテゴリ表現の利点は，三段論法のような強力な推論によって未知の対象に対する高い一般化が可能な点である．いまカテゴリが述語論理的な心的な表現をとるとしよう．このとき,「動物」⊇「人」⊇「ソクラテス」であるから,「ソクラテスは動物である」と「ソクラテスは人である」の述語判断では，二段階の推論を要する前者より，後者の判断が速いと考えられる．Collins & Quillian[12] は，この予測を心理実験によって確かめ，述語論理的なカテゴリ表象を支持した．しかし，Collins & Quillian [12] の実験は，事例や特徴の頻度や親近性などが統制されていない事が指摘されている．後の複数の統制された実験では，Collins & Quillian の主張は支持されない事が示唆されている [13].

このような反証に加えて，多くのカテゴリには “勾配” がある事が示唆されている．もし，カテゴリが述語論理的に処理されているのであれば，あるカテゴリに属する全ての事例は等しく認知されるはずである．しかし，多くの実験から，ほとんどあらゆるカテゴリ (たとえ,「偶数」のような論理的カテゴリであっても [14]) で，“典型的な” 事例や “非典型的な” 事例の認知処理が異なる事が示唆されている [15, 4]．従って，述語論理的なカテゴリ表現に代わって，現在では確率的な勾配によるカテゴリの表現が支持されている．確率的なカテゴリ表象

では，カテゴリ内の事例の全てが等しいわけではなく，より典型的な事例や非典型的な事例が含まれる．例えば,「トリ」のカテゴリの事例として「スズメ」,「ツバメ」などは典型的だが,「ペンギン」,「ダチョウ」などは非典型的な事例である．心理実験で協力者にカテゴリの典型性を聞くと，複数の協力者で一貫した典型性の評定が得られ，また事例の特徴の列挙や，事例がカテゴリに属するか判断するまでの反応時間などで，典型性と一貫したなだらかな勾配が見られる事が示された [15]．このような一連の研究を通じて，カテゴリの心的表現がプロトタイプと呼ばれる代表点を頂点として，なだらかな確率的勾配を持つ構造を持つことが示唆された．以降の研究では，より詳細にカテゴリの心的表現が議論され，代表点に確率的勾配の中心を持つプロトタイプモデル [16, 17] や，事例ごとに確率的勾配の中心を持つ事例モデル [18, 19, 20] などが研究されている．これらのモデルの検討は，人工カテゴリの学習過程を予測する事で行われてきた．プロトタイプモデルや事例モデルは，カテゴリや事例の類似性を異なる表現・アルゴリズムによって計算する．しかし，共にある特徴を持った事例の頻度や，事例間の類似性を基にカテゴリ判断を行うとする点では，共通の計算理論を持つと考えられる．

1.3.2 カテゴリの集団的性質

ここまで紹介した個々のカテゴリ境界の決定に関する理論を基礎として，多数の自然カテゴリの集団的な構造に関する研究も並行的に行われてきた．例えば，基本レベルと呼ばれる特別なクラスのカテゴリ群が他のレベルのカテゴリよりも様々な認知的課題で優位な成績を示す事などが，カテゴリの集団的な性質を示す知見として挙げられる．基本カテゴリとは，カテゴリの階層性の中位のレベルであり，実際に “見える”事例として最も一般的なレベルであると言われる．例えば,「動物」を上位カテゴリとして,「鳥」は基本カテゴリであり,「鳥」の一種の「コマドリ」や固有名の「スズメ」は下位カテゴリとされる (表 1.1)．Rosch et al. [4] は様々な認知処理に関して，上位カテゴリや下位カテゴリに比べて，基本カテゴリは最も効率的なレベルである事を，一連の実験によって示した．例えば，人は基本カテゴリに関して，写真で提示された対象の名前を速く呼ぶことができ，与えられたカテゴリに対して最も多くの特徴を列挙できる．また，幼児が最も早く獲得し頻繁に発話する名詞であり，最も早期に正しく分類できるカテゴリである．

それでは，なぜ基本カテゴリは他のレベルに比べて，このように様々な優位

性を持つのだろうか．Rosch et al. [4] は，基本カテゴリは観察者の運動，知覚システムなどを含む自然環境の多くの相関構造を反映した”切り口”であると考えた．そのため，基本カテゴリは最も一般性を持ち，同時に識別性を持つ効率的な中位のレベルであると主張した．Rosch 以降，基本レベルのカテゴリを特徴づける多くの理論的研究がなされ，カテゴリの統計的な性質の関数としてカテゴリの効率性を特徴付ける様々なモデルが提案された [21, 22, 23, 24, 25]．その一例を挙げると，Corter & Gluck [24] は “カテゴリ有用性” (Category Utility) を定義し，特徴とカテゴリの確率的従属性[1)]をカテゴリの効率性とするモデルを提案した．

仮想的なカテゴリと特徴の対応を示した表 1.1 を用いて，統計的なモデルによる説明を具体的に説明する．表の最上段には上位カテゴリ，二段目には基本カテゴリ，三段目には下位カテゴリが表記され，それらがある特徴を持つ場合は 1, 持たない場合は 0 で表記されている．この表で注目すべき点は,「葉」,「根」,「皮膚」,「足」(を持つ) という特徴は「植物」と「動物」の違いをよく説明し (つまりカテゴリと特徴に強い確率的な従属性がある)，一方,「樹皮」,「花弁」,「翼」,「うろこ」(を持つ) という特徴は基本カテゴリ (「木」,「花」など) の違いをよく説明する事である[2)]．もし，この表のようなカテゴリ・特徴の構造があれば，統計的なモデルの観点からは，基本カテゴリが優先的に学習される事が予測される．なぜなら，基本カテゴリの持つ (1 カテゴリあたりの) 情報量が上位・下位カテゴリのそれより多いからである．つまり,「動物」・「植物」のような上位カテゴリを学習する事によって，4 次元の特徴を説明できる (i.e.,「動物」・「植物」の違いは「葉をもつ」,「皮膚をもつ」の違いを代表する)．一方，基本カテゴリを学習する事では，11 次元全ての特徴を説明できるからである．また，下位カテゴリも基本カテゴリと同様に 11 次元全てをよく説明できるが，より多くのカテゴリを学習する必要があるので，1 カテゴリあたりの情報量は基本カテゴリが最も高い．従って，統計的な構造の学習や情報圧縮の観点から，基本カテゴリの優位性といった集団的な構造化を説明できると考えられる．

[1)] ある特徴 X からカテゴリ Y を予測する条件付確率と，その逆の条件付確率の積 $P(Y|X)P(X|Y)$ と，結合確率 $P(Y,X)$ の対比 $P(Y,X) - P(Y|X)P(X|Y)$ が特徴とカテゴリの確率的独立性 (従属性) の度合いを表す．この統計量は相互情報量とほぼ一致する [24].

[2)] Rogers & McClelland[1] の表には下位カテゴリをよく説明する特徴 (e.g.,「カナリア」のみが「歌う」) もあるが，少数であるため表記を省略した．

		植物							動物							
		木				花			鳥				魚			
		マツ	オーク	カエデ	カバノキ	バラ	チューリップ	ヒマワリ	コマドリ	カナリア	スズメ	ペンギン	マンボウ	サケ	ヒラメ	タラ
特徴（～をもつ）	葉	0	**1**	**1**	**1**	**1**	**1**	**1**	0	0	0	0	0	0	0	0
	根	**1**	**1**	**1**	**1**	**1**	**1**	**1**	0	0	0	0	0	0	0	0
	皮膚	0	0	0	0	0	0	0	**1**	**1**	**1**	**1**	**1**	**1**	**1**	**1**
	足	0	0	0	0	0	0	0	**1**	**1**	**1**	**1**	**1**	**1**	**1**	**1**
	樹皮	**1**	**1**	**1**	**1**	0	0	0	0	0	0	0	0	0	0	0
	枝	**1**	**1**	**1**	**1**	0	0	0	0	0	0	0	0	0	0	0
	花弁	0	0	0	0	**1**	**1**	**1**	0	0	0	0	0	0	0	0
	翼	0	0	0	0	0	0	0	**1**	**1**	**1**	**1**	0	0	0	0
	羽	0	0	0	0	0	0	0	**1**	**1**	**1**	**1**	0	0	0	0
	うろこ	0	0	0	0	0	0	0	0	0	0	0	**1**	**1**	**1**	**1**
	グリル	0	0	0	0	0	0	0	0	0	0	0	**1**	**1**	**1**	**1**

表 1.1: 仮想的なカテゴリ・特徴の対応 (Rogers & McClelland[1] の表の一部を改変).

1.4 カテゴリ凝集性

基本カテゴリの優位性を説明するためには，自然カテゴリは**どのような構造であるべき**なのだろうか？もし表 1.1 の構造であれば，統計的モデルにより基本カテゴリの優位性を説明できるが，別な特徴次元を与えれば，別な結果になりうる．

表 1.1 に表したように，多くの自然カテゴリでは，特定のカテゴリ群 (e.g.,「木」,「花」) と特定の特徴群 (e.g.,「樹皮をもつ」,「枝をもつ」) が固有の関連性を持つ多数のクラスタからなる [8]．このような特異的なクラスタは基本カテゴリだけではなく，上位，下位レベルのカテゴリでも見られる一般的な傾向である．また，後に詳しく述べるように，幼児が新奇語を獲得する際には，新奇な対象に対しても物体の種類に特異的なカテゴリ化の傾向が見られる．このように，自然カテゴリの集団的な構造が，カテゴリ群・特徴群の特異的なクラスタから構成される事を「カテゴリの凝集性」(Category Coherence) と呼ぶ [8]．カテゴリの凝集性は，カテゴリの最も “自然な” 構造であると考えられるため，なぜ名詞カテゴリ・特徴がこのような構造をとるか解明する事が，意味認知研究の最も根本的な目的であると考えられる．

カテゴリ凝集性の理論的な説明に関しては，現在でも論争中であり，統一的な見解は得られていない．ここでは,「理論に基づく理論」(Theory-theory[1)]) と呼ばれる仮説と，統計的な学習による二つの仮説を挙げて，概要を述べるに留める．統計的な学習による仮説の立場では，幾つか具体的な計算論的モデルが幾つか提案されている．この仮説に基づくカテゴリ凝集性に関連するモデルには，コネクショニストモデル (ニューラルネットワークモデル) [26, 1, 27] や，ベイズ理論によるモデル [28]，大規模コーパスのデータマイニング的なモデル [29, 30] などが挙げられる．

[1)] ここで「理論」(または素朴理論, folk theory) とは，素朴物理学 (e.g., モノは突然消えたり，貫通したりしない)，素朴生物学 (生き物は食べる，成長する，寝る)，素朴心理学 (e.g., お母さんは心をもつ)，などの幼児が発達の初期に形成すると考えられる素朴な体系を指す．またこのような体系を「領域」(domain) と呼び，ある領域に関する理論を領域特異的知識 (domain-specific knowledge) とも呼ぶ．

1.4.1 統計的モデルによるカテゴリ凝集性の説明

ここでは，前述の基本カテゴリの説明と同様に，統計的モデルにより，カテゴリの凝集性を説明可能か考えてみる[1)]．統計的モデルによれば，基本カテゴリが他のレベルのカテゴリより認知的な効率がよい理由は，基本カテゴリがより多くのクラスタ (表 1.1 の枠で囲まれた対応関係) を少ないカテゴリによって代表するからである．しかし，この説明が成り立つには，カテゴリと特徴が表 1.1 で表されるようなデータ構造を持つ場合に限られる事に注意したい．例えば，もし上位カテゴリによって代表できる特徴がより多い場合 (e.g., 表 1.1 に「動く」,「血をもつ」, … などを表に加えた場合)，前述の基本カテゴリの優位性は消え，代わりに上位カテゴリが優先的に学習される事になる．従って，統計的なモデル (データ駆動型のモデル) は，仮定されるデータの構造 (＝カテゴリの凝集性) による．ところが，モデルが学習するデータの構造とは，人 (e.g., モデルの設計者や，特徴評定を行った実験協力者) が何らかの直感的な基準に従って作成したものである．これは，なぜ人の直感的なカテゴリの構造が凝集性を持つのかという議論の開始地点に戻っている．もし，表中のカテゴリおよび特徴が十分に自明な物理量であれば (e.g., 手書き文字認識における画像など)，統計的なモデルを適用する事に全く問題は生じない．しかし，表中の特徴はカテゴリと同じくらい抽象的な概念で，少なくとも，自明な物理的な量で表せないので，データ駆動型のモデルだけでは凝集的なカテゴリ構造を説明するのに不十分である．

1.4.2 素朴理論によるカテゴリ凝集性の説明

Murphy & Medin [8] は前述のように，特徴やカテゴリ自体の決定には原理的な循環性があるために，統計的な性質だけでは概念構造を説明するのに不十分であると考えた．彼らは，自然カテゴリの凝集性を説明するために，類似性や頻度とは異なる要因として，因果律などの対象に対する素朴な信念を挙げている (素朴理論説)．つまり，何らかの先見的な知識が人に備わっており，これが概念領域の凝集化を促進する事になる．そのため，カテゴリ循環性を論拠として，類似性ベースのモデルの欠点を補うために，多くの研究で領域特異的な知識の研究が行われた素朴理論仮説の主張では,「イヌ」,「カップ」などの自然

[1)] 言い換えれば，カテゴリの凝集性におけるクラスタを，相互情報量の高いカテゴリと特徴の集合と同一視できるだろうか．相互情報量はカテゴリと特徴の対応表を与えないと規定できない事に注意．

カテゴリが凝集性を持つ理由は，それぞれの領域特異的な知識に基づく推論による．例えば,「イヌ」は「四本足があるから歩ける」という本質的な知識からの推論によって「四本足を持つ」という特徴と「歩ける」という特徴が「イヌ」カテゴリに対して凝集されると考える．また「カップ」は「何かを入れるための道具である」という本質的な知識からの推論により「容器型の形」と「形が崩れない (固形性)」という特徴が「カップ」カテゴリに対して凝集されると考える．実際に，新奇なカテゴリに対して実験協力者に因果的な知識を与えた後では，関連する特徴の学習は促進される [31]．しかし，あるカテゴリに関する事象は無限にあるので，何が本質的な「素朴理論」であるのかを選り分ける必要がある．例えば,「イヌは歯 (口) があるのでドッグフードを食べられる」ので「歯 (口) がある」と「ドッグフードを食べる」は凝集されるべきだろうか．もし「四本足があるから歩ける」を発見するためだけの「ad hoc な理論」の存在を主張するならば，恒等命題的であり，問題は実質的に未解決のままである．そのため「素朴理論の選択理論」(メタ理論) が必要となるが，その選択理論もまた何らかの選択理論 (メタメタ理論) が必要である．従って，メタ理論の無限後退を避けるために何らかの公理的な素朴理論が必要となり，これは生得的な素朴理論であると考えられている．しかし，そのような原初の素朴理論が何であるか，またその公理から「イヌ」に対して「四本足があるから歩ける」事を演繹的に導けるのか，未だに具体的な計算論的モデルは発表されていない [1].

カテゴリの凝集性の具体的な切り口　以上で述べたように，これまでの理論的な研究では，カテゴリの凝集性を説明するのに不十分であると考えられる．この問題は，自然カテゴリは自明な物理量ではなく，それ自体が説明を要するような心理量を特徴として記述されるために生じると考えられる．従って，本論文では二つのアプローチをとる．一つは，カテゴリ学習者に与えられるべき入力構造 (データ構造) を特定せずに (データとの適合性を無視して)，最終的に得られるカテゴリが満たすべき効率性 (カテゴリの識別性，汎用性) を議論する方法である．これについては，本論文の構成 (1.7 節) で詳しく述べる．もう一つは，一般のカテゴリ・特徴ではなく，初期に幼児が獲得する名詞カテゴリに焦点を絞る事である．一般の自然カテゴリは様々な抽象化のレベルの概念的な特徴を取りうるため，何を持って特徴構造の基礎とすべきか明確ではない．しかし，ごく発達初期の自然カテゴリ形成は，その殆どが知覚的特徴に基づき行われるため，具体的に扱いやすく問題を限定できる．また次節で述べるように，新奇

語の汎用は単に扱いやすいだけではなく，既存の知識を利用して新奇対象の学習を促進する現象が見られる．従って，本研究では自然カテゴリの構造化を調べるために，幼児の新奇語の獲得を具体的な切り口として議論を展開する．以下では，幼児の新奇語の汎用に関して，これまでに得られている一般的な知見を簡潔に紹介し，カテゴリ凝集性との関係について述べる．

1.5 新奇語の汎用

言語・概念発達の研究では，様々な場面での幼児の新奇語に対する汎用が，新奇語汎用課題 (Novel word generalization tasks) によって調べられている．典型的な新奇語汎用課題では，実験者が幼児に馴染みの無い刺激を呈示し，同時に新奇な名詞を付与する (e.g., ”This is the wug”)．その後，特徴の異なる別な刺激が選択肢を呈示し，どれに新奇語を汎用するか幼児に尋ねる (図 1.2)．この課題に関しては，幼児の発達段階の違いや，教示言語の違い，母国語の違い，物体に付加した手がかりの違いなど多くの系統的な発達心理学的な知見が約 20 年に渡り蓄積されている [32, 33, 5, 34, 35, 36]．

1.5.1 即時マッピング

このような新奇語の汎用で最も重要な特性は，刺激が新奇でたった一事例であっても (つまり，複数の事例と名詞の関係を経験する事なしに)，新奇名詞を系統的に汎用する事である．これを即時マッピング (fast mapping) と呼ぶ．例えば，ある新奇な事例が未知の名詞”wug” である事を知っても，その事例と形が類似した他のモノ A と，材質が類似した他のモノ B のうち，どちらが “wug” らしいか答える事はできないと思われる．しかし，幼児の新奇名詞の汎用はランダムではなく，与えられた状況に応じて系統的に特定の選択肢に偏る．以下では，これまでに知られている代表的な即時マッピングのパタンを紹介する．

1.5.1.1 発達に応じた汎用パタンの変化 即時マッピングは語彙発達のごく初期の段階 (1 才前後) から見られるのではなく，月齢や語彙数などに伴う発達に従ってあらわれる．特に，語彙爆発と呼ばれる語彙の獲得速度が高まる 18ヶ月前後，または約 50 語の語彙を獲得する時期を境にして系統的なカテゴリ化バイアスが出現する事が示唆されている [34]．一方，初期の語彙獲得は非常に遅く，幼児は名詞カテゴリを過剰 (e.g., 「イヌ」を四足の動物) または過小 (e.g., 「イヌ」を自宅のペットのみ) に適用する [37, 38]．しかし 2 歳を過ぎるころには名詞の獲得速度は高まり，ほとんど誤りなしにたった**一事例の呈示**からでも新し

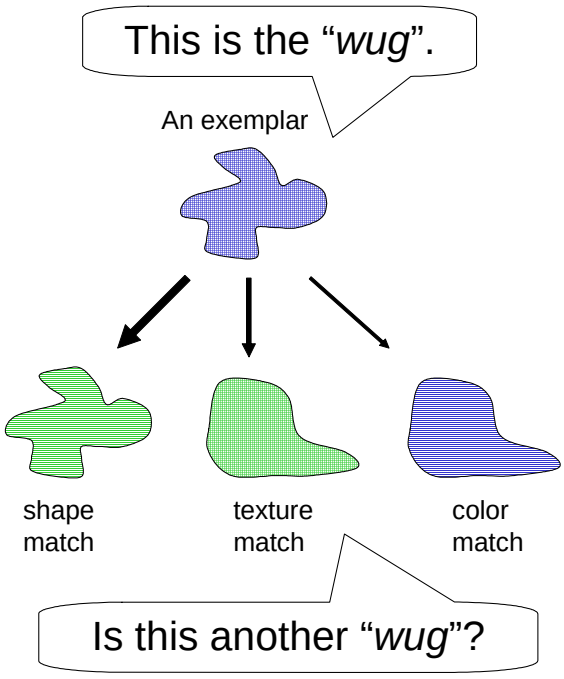

図 1.2: 典型的な新奇語汎用課題

い名詞を正しい対象に適用する事ができるようになる

1.5.1.2　汎用パタンの種類特異性　新奇語の汎用パタンは，命名される事例の “種類” または “領域” の違いによっても系統的な違いが見られる．本論文で後述する研究では，固形な物体 (solid object)，非固形な物質 (nonsolid substance)，動物的な物体 (animates) という 3 種類の存在論的なカテゴリ (ontological category) と呼ばれる事例の種類に関する研究を主に扱う．一般に，固形な物体 (e.g., 木製，プラスチック製のブロックなどの，角張ったモノ，人工的なモノ) は，形の類似性を基に一般化される事が多い．一方，非固形な物質 (e.g., クリームやジェルなどでできたモノや丸みを帯びた形の単純なモノ) は材質の類似性を基に一般化される事が多い [32, 5, 33]．また，動物的な物体 (e.g., 固形の物体に目や手足などの動物を想起させる手がかりを付属したモノ) は，形と肌理，両方の類似性を基に，狭い範囲で一般化される事が多い [39, 40, 36]．このように固形の物体に対して，形類似性に基づき新奇語を汎用する事を「形バイアス」と呼ぶ．同様に，非固形の物質に対する材質類似性に基づく新奇語の汎用を「材質バイ

アス」と呼ぶ．存在論的に異なる事例に対して，異なる知覚属性に基づき新奇語を汎用する事は，最も基礎的で一般的なモノの性質に対する知識を反映すると考えられ，概念発達の研究分野では重要視されている．

1.5.1.3　汎用パタンの文脈依存性　また，新奇名詞の汎用パタンは「カテゴリ化を暗示する文脈」に固有にみられる．例えば，ある事例 A と別な事例 B が “同じもの” であるか問われる場合 (“Can you find the same thing as this?”)，カテゴリラベルを事例 A に与え，別な事例 B に汎用する場合 (“This is a dax. Can you find another dax?”) では，幼児の反応は異なる．Markman & Hutchinson [6] は，連想的な類似性 (e.g., パトカーに対して警察官) と分類学的な類似性 (e.g., パトカーと別な種類の自動車) を，カテゴリラベルの有無の点から比較した．その結果，3 歳児は “同じもの” の文脈では，両方を半々に選んだが，新奇名詞の文脈では，分類学的類似性を選好する傾向が見られた．同様に，固形の物体に対する形類似性による汎用は，新奇名詞の文脈で見られる [5].

1.5.1.4　汎用パタンの言語的な影響　新奇語汎用パタンにおける事例の種類特異性と文脈特異性は，複合的に効果を及ぼす事も知られている．教示に含まれる統語的な手がかりは特定の種類の概念を暗示する傾向がある．例えば，英語では，可算名詞の文脈では (e.g., “This is a dax.”)，事例を固形の物体とみなし，形類似性を重視しやすく，非可算名詞の文脈では (e.g., “This is dax.”)，事例を非固形の物質とみなし，材質類似性を重視しやすい [32]．一方，日本語では，動物性を暗示する文脈では (e.g., “ダックスがいる.”)，事例を動物的な物体とみなし，複数の特徴を重視しやすく，非動物を暗示する文脈では (e.g., “ダックスがある”)，事例を人工的な物体とみなし，形類似性を重視しやすい [36].

1.5.2　新奇語の汎用とカテゴリ凝集性

幼児の新奇語の汎用についての知見をまとめる．新奇語の汎用の代表的な特性として，即時性，領域 (種類) 特異性，文脈依存性，発達的変化，言語固有性が挙げられる．新奇事例に付与された新奇語にも関わらず，幼児は系統的なバイアスを示し (即時性)，特に，ある特定の種類の事例に対して，それぞれ固有のバイアスを示す (領域特異性)．新奇語の汎用のこの性質は，自然カテゴリの凝集性を反映する一つの典型であると考えられる．幼児の新奇語の汎用行動では，特定の「種類」のモノに対して特定の特徴の類似性を重視し，このように凝集的なカテゴリのクラスタが複数存在しているように見える．つまり，固形なモノ，角張ったモノ，人工的なモノは，それぞれ形の類似性を基にそのカテ

ゴリを形成し，非固形なモノ，丸みを帯びた単純なモノは材質の類似性を基にそのカテゴリを形成する．これは,「トリ」のカテゴリ群 (e.g., 「スズメ」,「ハト」) が「飛ぶ」,「羽がある」などの特徴群で特徴づけられ,「イヌ」のカテゴリ群 (e.g., 「テリア」,「ダックスフント」) が「歩く」,「四足を持つ」などの特徴群で特徴付けられるカテゴリ凝集的な構造と類似している．

一般的な名詞のカテゴリ化と異なる点は,「トリ」や「イヌ」が自然言語の名詞の与えられた既知のカテゴリであるのに対して，幼児のカテゴリ化は通常「Dax」,「Rif」などの新奇な名詞が (見慣れない物体に対して) 与えられる新奇なカテゴリであるという点である．また，新奇な事例を対象とするため,「飛ぶ」,「歩く」などの複雑で固有の概念的特徴ではなく,「形」,「肌理」,「色」などの一般的な知覚的特徴などが実験的に統制される事が多い．このような幾つかの相違点は，幼児の新奇語のカテゴリ化を研究する利点となっている．つまり，新奇な対象を扱うため事前の知識が統制され，また一般的な知覚的特徴に関するカテゴリ化を調べるため，複数の研究から統一的な知見を得やすいと考えられる．そこで本論文の各章の研究では，新奇語の汎用を，自然カテゴリの形成を具体的に調べる切り口として用いた．

1.6 カテゴリ化理論および新奇語汎用のまとめ

対象の範囲	個別カテゴリの境界		自然カテゴリの集団的性質		
計算理論	集合論	類似性・頻度	統計的効率性	連想学習	素朴理論
表現形式	述語論理	プロトタイプ・事例	プロトタイプ・事例	コネクショニスト	演繹的推論
心理学的現象	述語判断	典型性・カテゴリ学習	基本カテゴリ	即時マッピング カテゴリ凝集性	事前知識の影響

表 1.2: カテゴリの計算理論，表現形式，それに対応する心理学的な現象

以上これまでのカテゴリ化理論および新奇語の汎用に関する研究をまとめる (表 1.2)．初期の集合論的なカテゴリ観に代わって，現在ではカテゴリ学習のモデルとして確率的なカテゴリ表現が提案されている．これらの研究が基礎となり，自然カテゴリの集団的な性質を記述する目的で，基本カテゴリの優位性を説明する統計的効率性のモデルが提案されてきた．これらの統計的なモデル (データ駆動型のモデル) はカテゴリ・特徴の構造が与えられた場合には有効であるが，なぜ自然カテゴリが凝集的な構造をとるか説明する事は難しい．なぜなら，

自然カテゴリは自明な物理量ではなく，それ自体が説明を要する心理量を特徴として記述されるためである．

従って，自然カテゴリの全体像をモデル化するには二つのアプローチがあると考えられる．一つは，心理量として得た (e.g., 評定実験など) カテゴリおよび特徴空間に基づいて，特徴選択やカテゴリ化の特定の傾向を説明する方法である．もう一つは，より根本的に，なぜ人が直感的に凝集的なカテゴリの構造を産出するのかを問う方法である．言い換えれば，カテゴリ・特徴の対応表 (e.g., 1.1) から何らかの特徴を選択するレベルと，対応表自体がなぜ選ばれるのかというレベルである．本論文第 3 章の研究では後者のアプローチを，第 4 章から第 6 章の研究では前者のアプローチをとった (図 1.1)．つまり，第 3 章の研究では，本質的に「学習するべきデータ」の構造を特定せず，カテゴリ学習者にとって都合のよい (識別・汎用の効率のより) カテゴリの集団的構造を議論した．

1.7 本論文の構成

本論文では，まず名詞カテゴリの基礎的な構造を記述するために，評定実験を行った．第 2 章では，名詞カテゴリの特徴評定実験について述べる．この実験で得られた特徴の構造は，以降の第 3 章，第 4 章, 第 6 章の理論的な研究の土台として利用した．第 3 章では，カテゴリ凝集性の発生する計算論的なメカニズムを，一般的な定式化の下で議論する．第 4 章以降の研究では，第 3 章で提案するモデルの補強および理論的な拡張を目的として議論を行った．

第 2 章　第 2 章では，本研究が対象とする名詞カテゴリの特徴空間を明確にするために，言語的な尺度を用いた評定実験を行う．この実験では，ある特定の仮説検証のためというより，むしろ評定そのものから名詞カテゴリの全体像を抽出することである．第 3 章以降の理論的な研究では，多次元特徴によって評定された名詞カテゴリのデータの特定の側面に焦点を当てて議論を展開する．

第 3 章　特定の自然カテゴリは特定の特徴で記述できるが，また別のカテゴリは別な特徴で記述される．自然カテゴリのこの凝集的な性質のために，これまでの研究では，自然カテゴリらしさの「統一的な尺度」を定義できていない (e.g., カテゴリ効率性による基本カテゴリ記述)．これに対し，本研究はその自然カテゴリの性質を逆手にとり，“統一的な尺度化のしにくさ” をカテゴリの凝集性の尺度として導入する．概念だけを端的に言えば，従来の研究が直線または平面的に特徴空間を捉えようとするのに対し，本研究では特徴空間を滑らかな曲面

として捉える．このとき，特徴空間の曲がり具合 (i.e., 曲率) に相当する統計量が，“統一的な尺度化のしにくさ” に相当する．「grue」(2010 年まで緑であるモノ) は，直線的特徴空間 (曲率ゼロ) で捉えられるが人工的で，自然カテゴリは無数の異なる局所的直線が形成する曲がった構造体であり，それゆえに，“自然らしい” と考える．第 3 章では，心理実験によってカテゴリが滑らかな曲面的性質を持つ事を示す．さらに，理論の定式化およびシミュレーションでは，カテゴリ凝集性が発生するために，曲面的な特徴空間におけるカテゴリ表現の効率化 (これを詰め込み効率化と呼ぶ) が必要である事を示す．

第 4 章　第 4 章では，計算理論の骨格であるカテゴリ基底の妥当性を，新奇語汎用パタンの予測の観点から検討した．前述のように，幼児の新奇語汎用パタンは，種類特異的である．しかし，単に特異的であるだけではなく，第 3 章で示すように，両者は滑らかに繋がった構造であると考えられる[1)]．従って，形類似性に基づく固形の物体カテゴリ群と，材質類似性に基づく非固形のカテゴリ群の 2 種類が安定して”共存”するための条件を探った．先行研究では，Samuelson [27]，Colunga & Smith [26] が形・材質バイアスの発生を統計的学習によるモデルで説明している．本論文の第 4 章では，先行研究で提案されたこれらのモデルと比較することで，本研究の提案モデルの妥当性を検討した．

第 5 章　本論文の第 5 章では，階層的な特徴構造の発生とカテゴリ効率化の関係を探る．第 3 章で提案する詰め込みモデルでは，階層的構造の存在を無視して議論を進めた．つまり，特徴やカテゴリが独立であると仮定し，ある特徴・カテゴリ (e.g., 球形, ボール) が，上位特徴の部分 (e.g., 形, 固形の物体) として含まれる事を排除している．しかし，実際には，脳は階層的に情報処理を行っていると考えられる [41]．特徴抽出・カテゴリ化を効率的に行うためには，必然的に階層的な処理が要求されると考えられる．また，階層的な処理によって，特定水準の特徴の選好というカテゴリ化バイアスが生じると考えられる．第 5 章では，形，肌理，色の複数の異なる階層に位置する特徴を利用して視覚的物体をカテゴリ化するシミュレーションを行った．シミュレーションの目的は，物体の分節化・個別化，またその後の物体のカテゴリ化に関して，特徴の階層化とカテゴリ効率性の関係を調べる事である．提案するモデルでは，物体の分節化・個別化における特徴利用の発達順序を説明し，非典型的な語彙発達を示す

[1)] 逆に，不連続で，独立なシステムが特徴空間を張る可能性も考えられるが，第 3 章で考察するように，この場合は循環性が生じる．

幼児の新奇語汎用で見られる，非典型的なカテゴリ化バイアスの説明も同時に行った．

第 6 章　第 3 章では，自然カテゴリを文脈に非依存的・中立的な構造体として単純化した上で理論の定式化を行った．しかし，多くの研究から知られているように，自然カテゴリは本質的な文脈依存性を持つ．そこで，第 6 章では，文脈依存的な性質への拡張を議論する．本論文では，文脈によって変動する成分と，文脈に中立的な成分を明確に区別し，さらに両者を一つの特徴空間の系で表現するモデルを模索する．具体的には，新奇語汎用においてみられる，文脈手がかり依存性や，日本語・英語を母語とする幼児の言語差を説明するモデルを提案する．第 6 章では，言語固有の統語手がかりのカテゴリ化に最適な特徴空間によって，新奇語汎用に見られる言語差の理論的説明を提案する．ここで，重要な点は，文脈手がかりに対する最適化と，自然カテゴリの形成する最適化は，特徴空間の異なる幾何学的な水準においてなされる点である．第 3 章で議論する「詰め込み効率化」は，特徴空間をあたかも「粘土」のように滑らかに歪めて構造化するのに対し，第 6 章で議論する「文脈に対する最適化」は，既に形の固定された特徴空間を回転させ，特徴空間を眺める「視点の方向」を特定する事を意味している[1)]．従って，本研究の定式化では，カテゴリ化に対する文脈的な影響は，特徴空間の本質的な構造を変化させず，それを覗く “窓” の位置が異なるだけであるが，この限定されたモデルは新奇語汎用の言語差を説明するために十分である事を示す．

第 7 章　最後に，総合考察では，以上の全ての研究で共通して議論されてきた「カテゴリ化の効率性」と「特徴空間の幾何学的性質」についてまとめ，特定の幾何学的性質を持つ特徴空間を持つために必要な発達的条件と関連付ける．

[1)] より正確に言えば，本論文では，自然カテゴリの本質的な構造化 (凝集性の発生) は，特徴空間を Rieman 多様体として最適化する事 (第 3 章) に対応し，文脈的な影響は，その本質的な構造を変化させず，線形射影により部分空間をとる操作 (第 6 章) とみなす．

第2章　名詞カテゴリの特徴評定実験

2.1　実験目的

本章では，具体的なカテゴリに関する特徴評定実験を行い，その特徴空間の構造を調べる．本実験の目的は，特定の仮説の検証ではなく，第3章以降の理論的な研究で議論する対象として，名詞カテゴリの描像を明らかにする事である．具体的には，形容語対によって初期獲得の名詞カテゴリの特徴を定量化する事で，名詞の特徴空間を調べる．実験では，成人協力者に対して，例えば,「ネコ」が「動的」か「静的」などの形容語対を用いて，名詞を評定する事を求めた．一般に，幼児の概念を定量的な方法で推定する事は困難であると考えられる．そのため，本研究では大人のカテゴリを幼児のカテゴリの特徴空間の代わりに用いる．これは必ずしも厳密に幼児のカテゴリ構造を反映しない．しかし，幼児は大人との会話によって名詞の指示対象を学習するので，大人の意図する名詞カテゴリの特徴は，幼児が最終的に学習するべき目標，あるいは一定の学習を経た最終状態であると考えられる．つまり，本研究では大人の特徴評定を，幼児にとっての名詞カテゴリの基準とみなす．また，実験で得られる名詞カテゴリの特徴空間に関して，複数の言語・文化に対する共通性・一貫性があるか調べるために，日本語名詞と，それに対応する英語名詞に関する二つの実験を行った．

この評定実験には二つの懸念すべき点がある．第一に，言語的な違いと概念的な違いを区別しなければない点である．つまり，評定実験を終えて日本語話者，英語話者の特徴空間に違いがあった場合に，これが概念構造の違いを反映するのか，それとも実験に用いた対応する語の翻訳のずれによるものか区別しなければならない．従って，我々は評定に用いる形容語がそれぞれどの知覚的属性を表す語か定量化することでこの問題を解消する．第二の最も決定的な問題は，調査前の意図的な特徴次元の限定である．本実験の目的は，なるべく「ありのまま」の名詞カテゴリの構造を持つミニチュアを作成する事である．実験設計者の意図的に実験に用いる特徴を限定すれば，後の理論的研究において人工的な要因が介入する恐れがある．これは目的に対して不適切な方法である．この問題を緩和するために，本研究では比較的多くの特徴次元の中から，ある基準によって特徴を選抜する．形容語による特徴は，少なくとも，名詞カテゴリを描写するために，個々の名詞に対して識別性を持つ必要がある．具体的に言

えば，対象とする名詞カテゴリすべてに曖昧で一貫性のない評定値を持つ形容語 (e.g., 「きれい」,「好きだ」,「よい」など) や，すべてが一貫して当てはまる一般的過ぎる形容語 (e.g., 「存在する」,「見える」,「触れる」) などはこの基準 (識別性) に適さない．

具体的な方法として，まず幼児が獲得する名詞カテゴリを用意し，次にその名詞カテゴリに対して分散の大きい特徴次元を主成分分析によって選抜する．この方法によって，初期に集めた十分な数の特徴次元の中から選択すれば，恣意的な特徴次元の限定の問題は緩和されると考えられる．

2.2 方法

日本語，英語両方の言語で，発達の初期に獲得される名詞を形容語で表現された属性を用いたSD法[42]による評定実験を行った．用いた名詞リストは，3歳までに幼児の50%が獲得する名詞のリスト「English MacArthur Communicative Developmental Inventory」(MCDI)[43]に記載された人名，代名詞などを除く312名詞から48語を無作為に抽出し作成した．また，SD法により物体の形，色，材質，肌理などの知覚属性の構造を調べた複数の評定実験[44]から網羅的に41の形容語対を選択した．また，形容語対の表す属性として10の属性を設定した．実験は全部で三つの評定実験からなる．それぞれ形容語選択実験，形容語・属性実験，名詞・形容語実験と呼ぶ．形容語選択実験は日本語話者のみで行われ，他の二つの実験では日本語・英語話者の両方がそれぞれの母国語で評定を行った．形容詞選択実験では41形容語対 (計82語) を用いて48の名詞カテゴリの評定を行った．しかし，曖昧で，意味が通じないなどの理由で，幾つかの形容語は名詞カテゴリの識別性が低かった．例えば,「きれい・きたない」,「良い・悪い」などによる名詞カテゴリの評定値は分散が小さく，ほとんどの協力者が多くのカテゴリに同じ値で評定した．従って，我々は初期に集めた41の形容語対のうち16の形容語対を，形容語選択実験のデータに対する主成分分析の結果に基づいて選択した．形容語・属性実験の目的は，形容語の意味を定量化し言語間の形容語の用法の違いを算出することであった．もし日本語・英語話者の評定値が高い正の相関を示せば，これは日本語と英語で形容語対の属性に対する意味の一致を意味する．従って，両言語話者の形容語・属性実験の評定の相関を形容語対の一致性とみなす．形容語・属性実験では，協力者は形容語がどの

属性を表現するのに適切か尋ねられた[1)]．この実験では形，肌理，色などの上位の属性カテゴリと形容語によるより具体的な属性カテゴリの関係を調べる事になる．例えば，協力者は「丸い・四角い」が「形」,「明るい・暗い」が「色」や「荒い・滑らか」が「肌理」の表現として用いられるか，などの質問に答えた．最後に，名詞・形容語実験では，形容語選択実験で選択した 16 の形容語対を用いて，名詞カテゴリの特徴の評定を行った．この実験結果は名詞カテゴリの特徴空間をモデル化するのに用いた．事前の基準や文脈を与えないために，全ての実験で協力者は統語的な手がかり (e.g.,「ある」,「いる」,「a」,「some」など) を与えられなかった．

2.2.1 協力者

- 日本語の評定実験の協力者

形容語選択実験は日本語でのみ行われ，11 人の京都大学大学院の学生 (23 歳から 25 歳) が協力者として集められた．形容語・属性実験では，12 人の京都大学大学院の学生 (23 歳から 25 歳) が協力者として集められた．名詞・属性実験では，京都光華女子大学の学生 104 人 (18 歳から 22 歳) が授業の単位を報酬として協力者として集められた．

- 英語の評定実験の協力者

形容語・属性実験では，20 名のインディアナ大学大学院の学生 (23 歳から 27 歳) が協力者として集められた．名詞・属性実験では，20 名のインディアナ大学大学院の学生 (23 歳から 27 歳) が協力者として集められた．

2.2.2 評定対象

実験では以下に示す 10 の知覚属性，41 の形容語対，48 の名詞カテゴリを用いた．形容語選択実験では 41 語の形容語対 (i.e., (2) と (3) のすべて) と 48 名詞カテゴリが用いられた．形容語属性実験では 41 語の形容語対と 10 の知覚属性が用いられた．名詞・形容語実験では (2) に示した 16 形容語対と 48 名詞カテゴリが用いられた．(対応する英語の語彙については A.1.1 を参照．)

10 の知覚属性 形，材質，色，肌理，音，温度，味，動き，匂い，機能

選択された 16 次元の形容語対 動的 (静的), 丸い (四角い), 騒がしい (静かな), 軽い (重い), 精巧な (雑な), なめらかな (いびつな), 大きい (小さい), 真っ直ぐな (曲がった), 安定な (不安定な), 硬い (軟い), 強い (弱い), 自然な (人工

[1)] 第 6 章のシミュレーション 3 では，形容語・属性実験の評定データを比較言語の新奇語汎用課題の属性に対する重みの計算のために用いた．

的な), 温かい (冷たい), 潤った (乾いた), 素早い (遅い), 複雑な (単純な)

選択されなかった 25 次元の形容語対　太い (細い), 高い (低い), 突起した (平らな), 長い (短い), 陽気な (陰気な), 緊張した (緩んだ), 派手な (地味な), 明るい (暗い), 鋭い (鈍い), 規則的な (不規則な), 面白い (退屈な), かわいい (不細工な), 粗末な (優雅な), 古風な (今風な), 質素な (豪華な), 新鮮な (古い), 甘い (辛い), 濃い (薄い), よい (悪い), 好き (嫌い), 特殊な (平凡な), 美しい (汚い), 均一な (不均一な)

48 の名詞カテゴリ　英語 MCDI の 9 つのカテゴリ ('animals', 'body parts', 'clothing', 'food and drink', 'furniture and rooms', 'outside things', 'small household items', 'toys', and 'vehicles'.) の 312 語から無作為に 48 語を選択した (詳細は表 3.1 を参照).

2.2.3　実験手続き

- 形容語選択実験

この実験は，日本語話者のみで行われ，用いた形容語の数以外は後述の名詞・形容語実験とほぼ同じ手続きで行った．またこの実験では協力は Excel ファイルに記載された 48 の名詞カテゴリを 5 段階の 41 の形容語対によって作成された質問表を渡され，それに対して回答する事で評定を行った．調査時間に制限は無かったが、およそ一人 2 時間で評定を行った。教示は次のように行われた。

「(1) 日常の物体に関して、表現語に当てはまるかを 5 段階で評価してください。
(例) 物体：蝶　表現語：美しい (汚い)
[1: 非常に美しい 2:美しい　3:どちらでもない　4:汚い　5:非常に汚い]
※ A(B):A⇔B で非常に A であるとき 1, 非常に B であるときに 5, どちらでもないときは 3 で判断してください。
(2) 表中の空欄を全て 1〜5 の数字で評定してください。
(3) 全部で 1 時間 30 分〜2 時間ほどで終わると思いますが、途中で適宜休憩をとってもらってかまいません。」

- 形容語・属性実験

この実験では形、色などの心理属性を 41 の形容語対に対して、日常的な物体の 10 種の知覚的属性 (2.2.2 節を参照) を表現するのに各言語尺度対が妥当であるかどうかを 5 点尺度により評定した。調査紙は Microsoft Excel ファイルで配布された．調査時間は協力者あたり約 30 分間であった。教示は以下のように行わ

れた。

「日常の物体に関して、属性 (形、色、肌理、材質、動き、匂い、味、音、温度、機能性) を表現するのに適切であるか、不適切であるかを以下の尺度で判断してください。

(例) 形容語対:大きい ⇔ 小さい　表現対象：形

[1:非常に不適切　2:不適切　3:どちらともいえない　4:適切　5:非常に適切]」

英語話者が協力者の場合，英語に訳された質問表は紙に印字され，同様の手続きで実験が行われた．調査時間は協力者あたり約 30 分間であった．

- 名詞・形容語実験

協力者は一度に 1 つの名詞を呈示され，5 点尺度をもつ 16 の形容語対によって，名詞の意味する典型的な事例の特徴を評定した．具体的な教示は形容語・選択実験と同様であった．日本人の協力者は，無作為に並び替えられた 5 つの異なる順序のうち一つの質問紙について回答した．アメリカ人の協力者の場合は，各名詞がコンピュータのディスプレイ上に無作為な順序で呈示され，それに従って回答した．

2.2.4　分析方法

実験データの分析では，主成分分析 (PCA) を共変動する特徴の抽出に用いた．PCA は特徴空間の分散を直交変換によって分解する方法である．この方法で，元の特徴 $1, 2, \ldots, n$ を持つ事例 $i(\mathbf{x}_i = (x_{i1}, x_{i2}, \ldots, x_{in})$ によって表現される) は，分散を最大化する合成特徴 v_i に変換される．v_i は元の特徴と各特徴次元に対する重み $w_1, w_2, \ldots, w_n$ の線形和によって構成され，これを主成分と呼ぶ．n 次元の特徴に対して n 個の主成分があり，合成特徴上の分散が大きい順に第一，第二，第 n 主成分と呼ぶ．第一主成分は，最も多くの特徴次元で共通して変動する成分であると考えられる事から，本研究では主に第一主成分などの高い分散を持つ主成分に注目して分析する．

$$X = \begin{pmatrix} x_{11} & x_{12} & \ldots & x_{1n} \\ x_{21} & x_{22} & \ldots & x_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ x_{m1} & x_{m2} & \ldots & x_{mn} \end{pmatrix} \tag{2.1}$$

$$S = X^T X \tag{2.2}$$

$$v_i = w_1 x_{i1} + w_2 x_{i2} + \ldots + w_n x_{in} \tag{2.3}$$

2.3 結果と考察

評定実験によって得られたデータを次の 2 点に関して分析した．最初に，形容語対の選択結果について述べ，次に名詞カテゴリの持つ特徴について日本語と英語の類似点・相違点の分析結果について述べる．また，名詞・形容語実験の結果 (日本語話者の平均値) は，A.1 に示した．

2.3.1 形容語対の選択

形容語選択実験で得た名詞カテゴリの評定データに PCA を適用する事で，41 次元の形容語対からより分散の大きい形容語対を選択した．具体的には，得られた主成分 41 次元のうち寄与率の高い第一次元から第三次元への因子負荷量の和が高い順に 16 次元の形容詞対を選択した．48 の名詞カテゴリに対する選択された全ての形容詞対の値は有意に大きいカテゴリ間・カテゴリ内分散比を示した ($F(47, 480) > 1.66, p < 0.005$)．ただし，14 番目に大きな因子負荷量を持っていた形容詞対「bold/conservative」は有意に大きな F 値を示さなかったので除外した．選択された 16 次元の形容詞特徴の 41 次元特徴全体の分散に占める寄与率は 68.25%であった．

2.3.2 日本語・英語話者の評定データの比較

形容詞属性実験では，10 の属性に関する 41 の形容語対の表現適性を評定した．これを日本語・英語話者の評定の正の相関を形容語対の二言語の一致性とみなす．選択された 16 次元の平均の相関は 0.78，選択されなかった残りの 25 次元は 0.56 であった．また，名詞・形容語実験での日本語話者と英語話者の 48 名詞カテゴリの協力者平均評定の相関は 0.87 であった．この結果から，日本語話者と英語話者の形容語対の表す属性は二言語で一致し，また，名詞カテゴリの特徴評定は類似する事が示された．さらに，名詞・形容語実験の評定に対して言語 (日本語・英語)，形容語対 (16)，名詞カテゴリ (48) を要因とする 3 要因分散分析を行った．その結果，形容語 ($F(15, 95936) = 253.8, p < 0.001$) と名詞カテゴリ ($F(47, 95936) = 38.0, p < 0.001$) の主効果がみられたが，言語の主効果は見られなかった ($F(1, 95936) = 0.26, p > 0.06$)．この分析結果も名詞・形容語実験の評定における言語差は小さかったことを意味する．同様に，形容語・属性実験の評定に対して言語 (日本語・英語)，形容語対 (16)，属性 (10) を要因とする 3 要因分散分析を行った．その結果，形容語と属性と言語の主効果が示さ

れた ($F(15, 6535) = 30.53, p < .001; F(8, 6535) = 84.47, p < .001; F(1, 6535) = 6.31, p < 0.05$)．しかし，10 の属性のうち “音”の属性を除外した場合，同様の分散分析によって言語の主効果は見られなかった ($F(15, 5880) = 32.29, p < 0.01; F(8, 5880) = 89.56, p < 0.01; F(1, 5880) = 1.81, p > 0.15$)．これらの結果は “音” を除く他の属性では日本語話者と英語話者の評定における言語差は小さいことが示された．まとめると，日本語・英語話者の名詞および属性の形容語を用いた評定には全体として言語差が小さく，両者は基本的に類似した構造を持つことが示された．

2.3.3 主成分の構造

主成分空間の構造を見るために，日本語話者の平均評定の第一，第二主成分軸を図 2.1 に示す．これに対応する英語話者の二次元特徴空間も類似した構造を持っている．図 2.1 では乗り物や家具などの大きく硬いモノが左側，液体，食べ物や動物などの小さく軟らかいモノが右側に配置されている．この事から第一主成分は「固形性」もしくは「大きさ」と解釈できる．また図 2.1 では動物や乗り物などの動的なモノが上部に配置され，家具や液体などの静的なモノが下部に配置されているので，第二の主成分は「動き」を表すと考えられる．

以上の結果をまとめると，類似した名詞カテゴリに対して特徴構造は日本語・英語話者で共通し，この名詞カテゴリの共変動する特徴の情報圧縮によって,「固形性」や「動物性」に対応する合成的な特徴が得られる事が示唆された．この結果は，幼児は個形性に注目して物体と物質に対して異なる新奇語汎用をする事 [33] や，動物性の違いに注目して動物と非動物に対して異なる新奇語汎用をする [45] 事などに一致する．

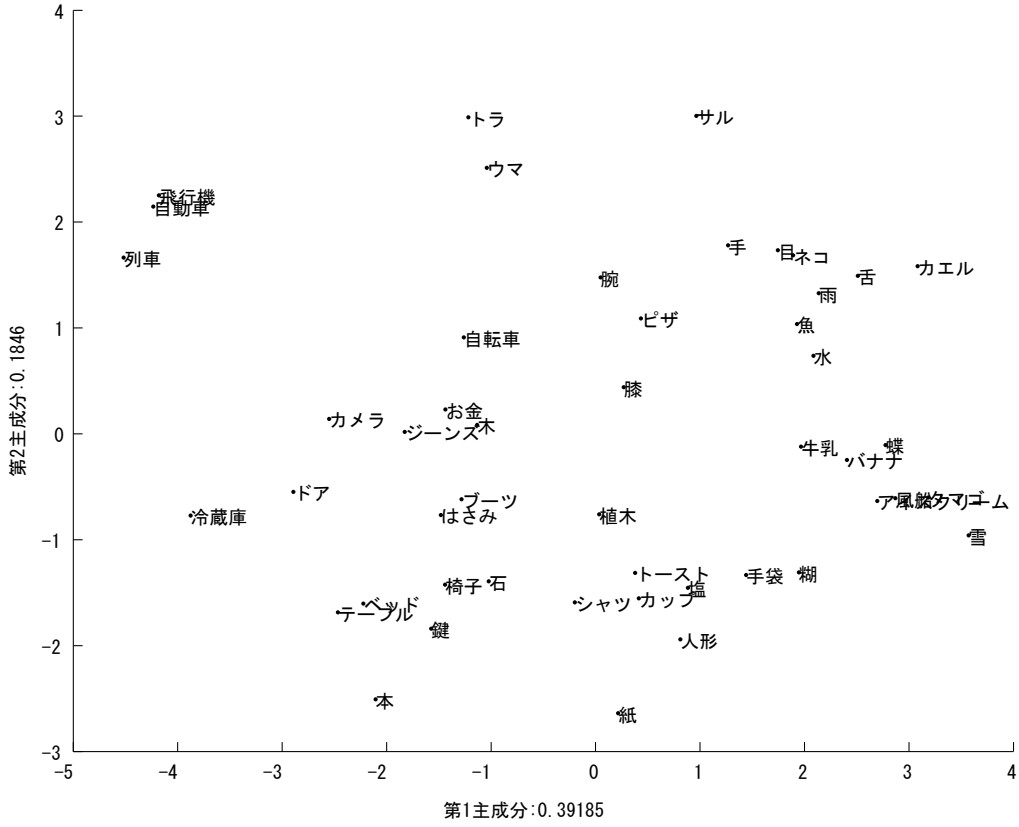

図 2.1: 第一・第二主成分における名詞カテゴリ平均値のプロット

第3章　自然カテゴリの凝集性の計算理論

なぜ自然カテゴリは我々にとって”自然”なのだろうか．我々が最も頻繁に効率よく利用する概念はどのように構造化されているのだろうか．特定の自然カテゴリ群は特定の特徴群と強く関連し，別の自然カテゴリ群は別な特徴群と関連する．例えば,「羽がある」,「巣を作る」,「飛ぶ」などの特徴は,「トリ」と分類される一群のカテゴリ,「スズメ」,「ハト」,「タカ」などに当てはまる．またこれらの特徴群が厳密に特定のカテゴリを定義するのではなく，典型的なトリ (e.g.,「ハト」,「スズメ」) ほど多くの特徴を共有し，非典型的なトリ (e.g.,「ペンギン」,「ダチョウ」) はより少ない特徴を共有する [15]．このカテゴリ群と特徴群間の集団による類似構造を家族的類似性 (Family resemblance) と呼び，この性質は多くの自然カテゴリで観察される．一方,「2010 年まで青色で，それ以降は緑であるモノ」(これを Goodman [46] は “grue” と呼んだ) は厳密に定義されたカテゴリである．しかし，このような人工カテゴリは不自然で，役に立たないように見える．Medin & Muphy [8] は，自然カテゴリは単一の特徴やカテゴリによって定義できず，一群の特徴とカテゴリ間の重層的な構造を持つと主張し，この構造特性をカテゴリ凝集性と呼んだ．つまり，カテゴリ群と特徴群の間の家族的類似性によって凝集し，異なる家族的類似性による多数のクラスタが，自然カテゴリ全体の構造を形成すると考えられる．本研究では，カテゴリ凝集性の発生メカニズムを説明する計算論的モデルを提案する．

本研究のアプローチ　序論で述べたように，カテゴリの骨格を成す 4 つの要因は，カテゴリの表現素，カテゴリ化の効率性，経験する事例・カテゴリラベルの分布構造である．本章の研究では，これらの要因のうち環境から与えられる事例・カテゴリラベルの分布構造を単純化し，弱い仮定を置くことで (図 1.1)，カテゴリ決定の循環性の問題を避けてカテゴリ凝集性の発生を説明する計算理論を提案する．

本研究は以下の手順に従って議論を展開する．

1. カテゴリ凝集性の定量的な尺度を定義し，またそれを実験的に確認する
2. カテゴリ凝集性の発生メカニズムの計算論的な条件 (モデル) を提案する
3. シミュレーションにより提案モデルと他のモデルを比較し，そのカテゴリ化パタンを検討する

カテゴリ凝集性の存在については多くの研究で認められているものの，そのカ

テゴリ構造の定量的な測定方法に関しては合意が得られていない．これは自然カテゴリが多様な事象を参照し，カテゴリの特徴構造が固有の概念によって異なるためであると考えられる[1)]．しかし，本研究ではこのような表面上の違いに依存しない，統計的な定義によってカテゴリ凝集性を捉える方法を提案する．また，この方法によって実際の自然カテゴリ群の特徴空間の幾何学的性質を記述し，その有効性を確かめた．提案する統計量は，特徴空間上におけるカテゴリの中心間距離とカテゴリのばらつきパタンの単調増加の関係を記述したもので，これを「カテゴリの滑らかさ」と呼ぶ．

さらに，本研究では滑らかなカテゴリの発生をモデル化する．提案モデルの骨格となる仮定は，カテゴリの (a)「基底」(内部表現素) と (b)「効率性」にある．具体的に，(a) 局所的に個々のカテゴリがプロトタイプ (カテゴリの中心的表象) を中心として固有のばらつきを持つこと，その上で，(b) 識別性，一般性，認知的資源の均衡から定義されるカテゴリ効率性の最適化を仮定する．この仮定 (a), (b) から，カテゴリの滑らかさが発生する事を示すのが本研究の主な目的である．カテゴリの表現基底に関する仮定 (a) の根拠は，自然カテゴリの典型性が，ある事例を中心とするなだらかな勾配を持ち，主観的な頻度 (頻度に対する期待) と相関する [47, 48] からである．また，カテゴリの効率性に関する仮定 (b) は，ベイズ理論 (Bayesian theory) などに代表される確率論的な合理主義 (rationalism) や，事例モデル，プロトタイプモデルなどに代表されるカテゴリ学習モデルの成功などに動機付けられている [49, 50, 20, 51, 16]．本研究で提案する理論では，具体的な形式で事例の頻度分布など構造は与えずに，カテゴリの内部表現素と効率性のみに焦点を絞って定式化する．しかし，これは事例の構造がどんな場合でも成り立つわけではなく，そこには暗示的な仮定が含まれている．この仮定に関する詳細は考察で述べ，また第 4 章の研究で具体的な事例構造について考えることにする．

以下では，まず凝集性の定量的尺度である「カテゴリの滑らかさ」を示唆する心理学的な知見について紹介する．次に，これらの知見から類推されるカテゴリの構造が，実際の名詞カテゴリで見られるか第 2 章の評定実験の結果を分析する事により検討する．その後，カテゴリの凝集性の発生条件に関する計算

[1)] 自然カテゴリの凝集的な性質は，特定の特徴次元だけでは捉えられないため，定量的な指標として捉えにくいように思える．しかし，単一特徴次元による「捉えにくさ」(=メタ特徴・特徴空間の曲率) として測る事は可能であると考えられる

論的なモデルの提案を行う．

名詞カテゴリの凝集性〜特異性と連続性　第 1 章で述べたように，多くの発達研究で，幼児が新奇名詞を汎用する際に重視する特徴を調べる事 (新奇語汎用課題) で，名詞カテゴリの形成メカニズムが調べられてきた．新奇語の汎用に関する多くの研究から，自然カテゴリの特徴選択がカテゴリ群に特異的であるだけではなく，連続的・漸次的である事が示唆されている．多くの研究で，対象に与えられた新奇名詞を汎用する際に，2，3 歳児は固形な物体 (e.g., 木製のブロック) に対してその形類似性を重視し，また固形でなく液状である物質 (e.g., クリーム) に対してその材質類似性を重視する事が知られている [39, 33]．このような知見は，カテゴリ凝集性の一面を表す典型的な例と言える．しかし，それだけではなく，複数の研究が，固形な物体と固形ではない物質の「中間」にあると想定される事例がその形と材質の両方による中間的なカテゴリ構造を持つ事を示唆している [32, 26]．Colunga & Smith [26] は新奇事例が典型的な人工的なモノ (複雑で，角ばった輪郭を持つ) から，物質的なモノ (単純な形を持つ) へと変わるに従って，形と材質類似性に基づく幼児の新奇名詞の汎用が連続的に変化する事を示した．また，Imai & Gentner [32] や Yoshida & Smith [36] の比較言語的な研究も，同様の連続的な汎用パタンの変化を示唆している．

加えて，初期に獲得される典型的なカテゴリ群の統計的構造を調べた研究でも，自然カテゴリの特異性・連続性が示唆されている．Samuelson & Smith [52] は初期に獲得される 312 名詞について，形，色，材質，曖昧 (どれにも当てはまらない場合) のうち，どの特徴次元の類似性によって名詞カテゴリが形成されるか，成人を実験協力者とする評定実験を行った．実験の結果，協力者は個々の個形物のカテゴリに対しては形特徴の類似性を他の特徴より重視し，一方で，非個形物のカテゴリに対しては材質特徴の類似を重視する事が示された．また，固形でも非固形でもない曖昧なカテゴリには，形，材質，曖昧な特徴次元を重視される事が示された．この事から，固形の物体・非固形の物質の中間的なカテゴリがある事も示唆される．つまり，成人の自然カテゴリの特徴に対する直感的な分布構造と，幼児の新奇語汎用のパタンは定性的な整合性がある．この事は，自然カテゴリの特徴重要性が特異性・連続性を持つ事を示唆する．

以上の研究を踏まえて，幼児が初期に獲得する名詞カテゴリの大域的な分布パタンを表す模式図を図 3.1 に示す．図は形と肌理による 2 次元の特徴空間を表し，楕円はあるカテゴリに属する事例の出現頻度 (カテゴリ尤度: 3 次元図の z

軸) の一定レベルを意味する等高線である．新奇語の汎用や自然カテゴリでは，カテゴリに含まれる事例に共通する特徴はより重視され，事例間でばらつきのある特徴は軽視される事が示唆されている [48, 52]．従って本研究では，あるカテゴリに属する事例の特徴空間上の出現頻度の分布 (以下では，これをカテゴリ尤度と呼ぶ) を特徴の重要性と同一視する．つまり，楕円の形は，カテゴリごとの事例のばらつきを表し，またそのカテゴリの判断に重要な特徴を示す[1)]．図の最も左側にある縦長の楕円は，そのカテゴリに属する事例は肌理特徴ではばらつきがあるが，形特徴ではばらつきが小さく事例の類似性が高い事を示す．従って，最左側にある縦長の楕円は人工物が形類似性に基づき汎用されるパタンを表す．一方，図の最も右側にある横長の楕円は，カテゴリに属する事例が材質次元で類似し，形次元にばらつきがある事を示す．従って，この楕円は物質が材質や肌理類似性に基づき汎用されるパタンを表す．そして，形次元で類似した左側のカテゴリ群と，材質次元で類似した右側のカテゴリ群の間には，形と材質がほどほどに類似した中間的なカテゴリ群が漸次的に横たわっている．

カテゴリ凝集性の一般化・定量化　以上の知見をまとめると，特徴空間上で近接したカテゴリは，類似した方向・形の尤度パタンを持ち，距離の離れたカテゴリは，異なる方向・形の尤度パタンを持つ．言い換えれば，類似したカテゴリほど類似の特徴重要性を持ち，非類似のカテゴリほど非類似の特徴重要性を持つ．本研究では，このような大域的なカテゴリ分布を持つ特徴空間を「滑らかな」特徴空間と呼ぶ．もし，滑らかな性質がある特定の特徴 (e.g., 形や材質) だけではなく，広く一般の特徴次元に関して成り立つとすれば，ある 2 カテゴリの類似性とその 2 カテゴリの事例のばらつきパタン (カテゴリ尤度) の類似性には相関 (もしくは非線形な単調性) があるはずである (図 3.2)．従って，本研究の一つの予測は，自然カテゴリの凝集性を滑らかさとして定量化できるという事である [53, 54]．次節の実験 1 では，この予測を，名詞カテゴリの特徴評定データを分析する事で検討する．

[1)] カテゴリ尤度の分布が (多次元) 正規分布であるときに，尤度の等高線が (超) 楕円になる．本研究ではカテゴリ尤度の第一近似として正規分布を仮定するが，一般にこの条件が成立するとは言い難い．この問題に関して，複数の正規分布の組み合わせからなる混合正規分布への拡張可能性について後に考察する．

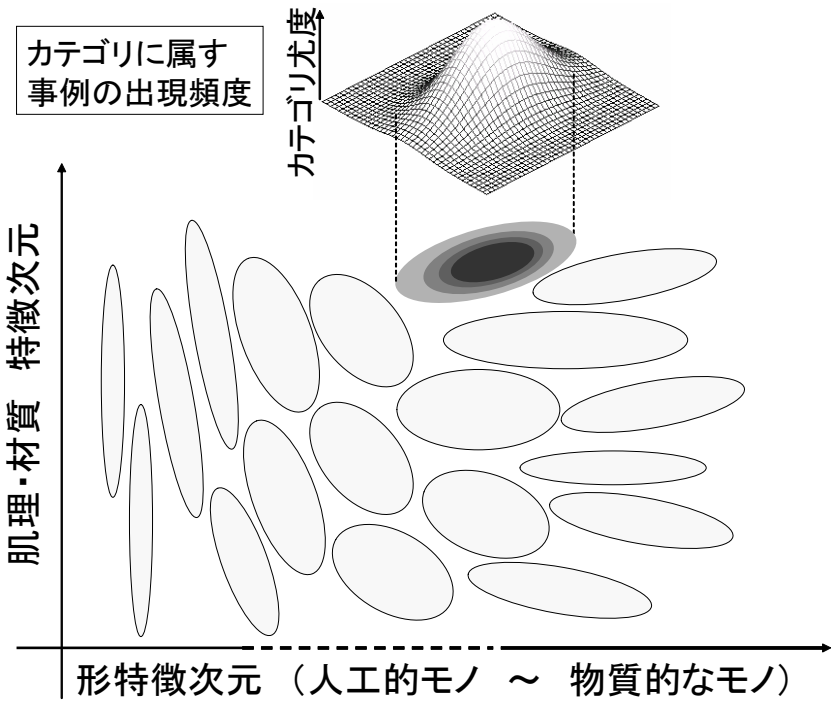

図 3.1: 滑らかな仮想的な名詞カテゴリ

3.1 心理実験による滑らかさの検討

ここでは，名詞カテゴリの特徴データを分析する事で，滑らかさの経験的な証拠を示す．第 2 章では，日本語と英語の名詞カテゴリの特徴を評定する実験を行った (詳しくは 21 ページを参照)．この評定実験の結果を再分析することで，実際の自然カテゴリの特徴空間の滑らかさを検討する．この名詞カテゴリのリストは幼児の 50 %以上が 3 歳までに学習する名詞リスト MCDI[43] の 312 語の中の 48 語からなり，そのほとんどは基本カテゴリであると考えられる．また，滑らかさはカテゴリの階層性とどのような関係をもつのだろうか．これは，基本カテゴリを下位に含む上位分類 (上位カテゴリ) の滑らかさを調べる事で検討できる．従って，本実験では，(1) 基本カテゴリが滑らかな構造を持つか，そして (2) 基本カテゴリに比べて上位カテゴリは滑らかな構造を持つか，という二点を検討する．

名詞カテゴリの評定は 16 の形容詞対[1)]を用いて行われた．104 人の日本話者

[1)] この 16 の形容詞対は，41 の形容詞対の中から予備的な評定実験における分散の大きさを基準として選ばれた．つまり，名詞カテゴリをよく識別する (分散の大きい) 形容詞が選択された．

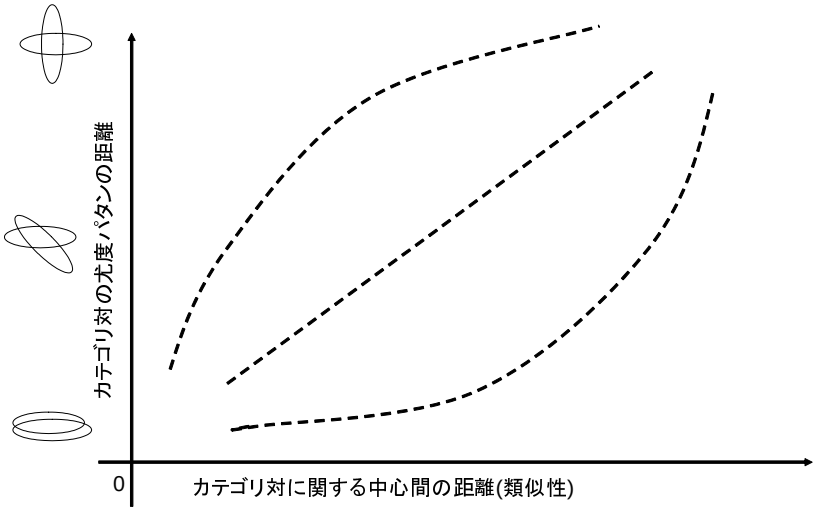

図 3.2: 2 カテゴリの平均ベクトルのノルム (x 軸)，および共分散行列のノルム (y 軸) の散布図において，正の相関または単調増加が滑らかさの指標となる．

(英語名詞に関しては 20 人の英語話者) がそれぞれ独立に評定したカテゴリの特徴値をカテゴリの「事例」の特徴値とみなした．従って，ある名詞カテゴリの特徴空間上のプロトタイプベクトルはその名詞カテゴリの特徴値の協力者平均で，また一般化パタンは特徴値の共分散行列で定義した．滑らかさ指標は，以下の式 (3.1) のように，カテゴリペアの平均ベクトル，共分散行列のノルムの相関で定義する．

3.1.1 方法

3.1.1.1 滑らかさ指標 滑らかさの指標 (式 3.6 の一形式) として，2 カテゴリの平均ベクトル間ノルムと 2 カテゴリの共分散行列間のノルムの相関 S(式 3.1) を定義する．

$$S = \frac{\sum_{i,j<i}\{(|\Delta\mu_{ij}| - |\bar{\Delta}\mu|)(|\Delta\sigma_{i,j}| - |\bar{\Delta}\sigma|)\}}{\sqrt{\sum_{i,j<i}(|\Delta\mu_{ij}| - |\bar{\Delta}\mu_{ij|})^2 \sum_{i,j<i}(|\Delta\sigma_{ij}| - |\bar{\Delta}\sigma|)^2}} \tag{3.1}$$

ただし，$|\Delta\mu_{ij}| = \sqrt{(\mu_i - \mu_j)^t(\mu_i - \mu_j)}$, $|\Delta\sigma_{ij}| = \sqrt{tr((\sigma_i - \sigma_j)^t(\sigma_i - \sigma_j))}$ はそれぞれカテゴリ i, j の平均ベクトルのユークリッド距離 (L_2 ノルム) と共分散行列のユークリッド距離 (L_2 ノルム)，$|\bar{\Delta}\mu| = \frac{2}{n(n-1)}\sum_{i,j<i}|\Delta\mu_{ij}|$，$|\bar{\Delta}\sigma| = \frac{2}{n(n-1)}\sum_{i,j<i}|\Delta\sigma_{ij}|$ は平均ベクトル距離の平均，共分散行列距離の平均である．

3.1.1.2　データ形式に適した補正　すでに述べたように，滑らかさ指標の計算は平均と共分散によって行われる．従って，ある種のデータ形式において，評定結果の構造と無関係に平均と分散には論理的な関係が成り立つ事に注意しなければならない．本実験で用いた評定データの形式は，評定の上限・下限値があり，離散的であるため，平均と分散の取り扱いに注意が必要である．具体的に，実験で用いた評定は 1，2，3，4，5 の 5 段階の順序尺度で行われた．例えば，ある項目の協力者平均が 1 または 5 である場合，全ての協力者がそれぞれ 1 または 5 の評定をした事になり，分散は 0 になる．一方，ある項目の協力者平均が 3 である場合には，様々な組み合わせの評定値の分布があり得るため，平均値 3 に対する分散は 1 や 5 に近い平均に対する分散よりも大きい傾向にある．このような平均と分散の傾向はデータ形式だけに依存する関係であり，評定値の構造に潜む心理学的性質と無関係であるので，滑らかさを推定するためには除去すべきである．

評定値データを補正する方法には 2 通りある．一つの方法は，平均値に依存する分散の大きさを，適切な関数を用いて正規化し，等分散化することである．上限・下限のある変数と連続値変数を関連付ける代表的な関数は，ロジスティック関数 (シグモイド関数) やプロビット関数である．これらの関数は一般化線形モデルの変数間の関係式 (リンク関数) としても頻繁に用いられる [55]．ただし，$\mu_i (1 \leq \mu_i \leq 5)$ は i 番目の評定項目の平均値で，p_i は平均値を $0 \leq \mu_i \leq 1$ に正規化した値である．$p_i = (1 + \exp(\alpha\hat{\mu}_i))^{-1}$ として，μ_i の 1 次微分は $p_i(1 - p_i)$ に比例する．ただし，α は特定の定数である．この関係を用いて，平均によらない分散に規格化された，補正平均 $\hat{\mu}_i$ と補正共分散 $\hat{\sigma_{ij}}$ に変換する．

$$\hat{\sigma_{ij}} = \frac{\sigma_{ij}}{\sqrt{(p_i(1-p_i)p_j(1-p_j)}} \tag{3.2}$$

$$\hat{\mu}_i = \log \frac{p_i}{1-p_i} \tag{3.3}$$

$$p_i = (\mu_i - 1)/4 \tag{3.4}$$

この補正平均・共分散を滑らかさ指標の計算 (式 3.1) に用いた．

もう一つの方法は，分散の大きさを全て定数に正規化し，相関係数だけを共分散の代用とすることである．この方法では第一の補正方法と同様に，平均と分散の大きさの見た目の効果を消すことが出来る．しかし，分散 (共分散行列の対角成分) の大きさを情報として失ってしまうという欠点がある．分析では，

元データの共分散行列，補正した共分散行列，相関行列を用いた滑らかさ指標をそれぞれ併記した．

3.1.1.3　上位カテゴリの分析　48 名詞による基本カテゴリに対して，表 3.1 に示した上位カテゴリを割り当てる事で，上位カテゴリに関する滑らかさ指標を分析する．表 3.5 の上位カテゴリには，48 名詞を取材した MCDI(語彙リスト) [43] が持つ 9 つの名詞の大分類を用いた．滑らかさ指標の計算は，同じ上位カテゴリに含まれる全てのデータの平均・共分散を用いて，基本カテゴリと同様の手順で行った．

3.1.2　結果・考察

表 3.2 に各データ，条件における滑らかさ指標を示す．相関 0 を帰無仮説とする検定に対し，*は $p < 0.001$ を示し，*のない値は全て $p > 0.05$ であった．

日本語・基本カテゴリの結果　元データにおける協力者の平均，共分散行列を用いて計算した滑らかさ指標は 0.2798 (S.D.=0.0286, $p < 0.001$) であった．滑らかさ指標の標準偏差および p 値は，ノンパラメトリックブートストラップ法 [56] によって求めた．同様に，協力者の平均，相関行列を用いて計算された滑らかさ指標は 0.4340 (S.D.= 0.0240, $p < 0.001$)，補正した共分散行列を用いて計算した滑らかさ指標は 0.5221 (S.D.=0.0214, $p < 0.001$) であった．図 3.3 に補正平均の距離と補正共分散の距離との散布図を示す．

英語・基本カテゴリの結果　元データにおける協力者の平均，共分散行列を用いて計算された滑らかさ指標は 0.2321 (S.D.= 0.0283, $p < 0.001$) であった．同様に，協力者の平均，相関行列を用いて計算された滑らかさ指標は 0.2503 (S.D.= 0.0267, $p < 0.001$)，補正した共分散行列を用いて計算された滑らかさ指標は 0.3491 (S.D.= 0.0248, $p < 0.001$) であった．図 3.4 に補正平均の距離と補正共分散の距離との散布図を示す．

上位カテゴリの結果　次に，複数の名詞カテゴリをまとめて形成した上位カテゴリ (表 3.1) の分析結果を示す (表 3.2)．日本語データの相関と補正共分散による滑らかさの分析では，36 点のデータのうち 1 点を外れ値 (いずれも最大の相関または補正共分散を持つ) として除外して滑らかさを計算した．図 3.5, 3.6 に補正平均の距離と補正共分散の距離との散布図を示す (図 3.5 は外れ値を含む)．日本語・英語データの全ての計算方法で，基本カテゴリより上位カテゴリの滑らかさ指標が低い傾向が見られた．

基本カテゴリ	上位	基本カテゴリ	上位
蝶 (butterfly)	A	椅子 (chair)	FR
ネコ (cat)	A	ドア (door)	FR
魚 (fish)	A	冷蔵庫 (refrigerator)	FR
カエル (frog)	A	テーブル (table)	FR
ウマ (horse)	A	雨 (rain)	O
サル (monkey)	A	雪 (snow)	O
トラ (tiger)	A	石 (stone)	O
腕 (arm)	B	木 (tree)	O
目 (eye)	B	水 (water)	O
手 (hand)	B	カメラ (camera)	S
膝 (knee)	B	カップ (cup)	S
舌 (tongue)	B	鍵 (keys)	S
ブーツ (boots)	C	お金 (money)	S
手袋 (gloves)	C	紙 (paper)	S
ジーンズ (jeans)	C	はさみ (scissors)	S
シャツ (shirt)	C	植木 (plant)	S
バナナ (banana)	FD	風船 (balloon)	T
タマゴ (egg)	FD	本 (book)	T
アイスクリーム (ice cream)	FD	人形 (doll)	T
牛乳 (milk)	FD	糊 (glue)	T
ピザ (pizza)	FD	飛行機 (airplane)	V
塩 (salt)	FD	列車 (train)	V
トースト (toast)	FD	自動車 (car)	V
ベッド (bed)	FR	自転車 (bicycle)	V

表 3.1: 名詞カテゴリとその上位カテゴリ．表中の記号 A は “Animals (Real or Toy)”，B は “Body Parts”，C は “Clothing”, FD は “Food and Drink”, FR は “Furniture and Rooms”, O は “Outside Things”,S は “Small Household Items”, T は “Toys”, V は “Vehicles (Real or Toy)” を表す.

結果のまとめ　まとめると，日本語と英語の基本カテゴリの滑らかさ指標は共に，全てのデータ形式 (共分散行列，相関行列，補正共分散行列) の全てで有意な正の値を示した．これに加えて，日本語名詞カテゴリのほうが，英語名詞カテゴリよりも全ての形式で高い滑らかさを示した．この理由は定かではないが，データの標本数の違いに起因する可能性は考えられる．日本語名詞の評定 (N=104) に比べて英語名詞の評定 (N=20) は標本数が小さいために，共分散行列 ($56 = \frac{16\times15}{2}$) を計算するためのデータ自由度 ($304 = (20-1)\times16$) が十分に大きくない．今後の課題として，本実験で見られた滑らかさの違いが言語的な差によるか，標本数やその他の条件を揃えて追実験する事が挙げられる．

また，上位カテゴリの滑らかさ指標は，全ての条件で基本カテゴリより低い傾向が見られた．この事から，認知的な効率が良いとされる基本カテゴリ [4] のほうが上位カテゴリより滑らかな構造を持つ事が示唆された．今回の上位カテゴリは MCDI リストの定義に従っており，心理学実験による操作的な定義と必ずしも一致するとは限らない．また今回の分析では下位カテゴリが検討に含まれていない．従って，今後の検討課題として，上位・下位カテゴリを含めて，心理実験的に定義されるカテゴリの効率性と滑らかさの関係を調べる事が挙げられる．

3.2　カテゴリの詰め込みモデル

論理的には，与えられた事例をカテゴリ化する方法は無数にあり,「滑らかな」カテゴリ化はその一つの候補に過ぎない．滑らかではないカテゴリ群と滑らかなカテゴリ群の違いが生じるのはなぜだろうか．ここでは，滑らかなカテゴリが発生するための計算論的な条件について本研究の仮説を提案する．

		滑らかさ指標 S		
		共分散	相関	補正共分散
基本	日本語話者	0.2798*	0.4340*	0.5221*
カテゴリ	英語話者	0.2321*	0.2503*	0.3491*
上位	日本語話者	0.1086	0.3220	0.2598
カテゴリ	英語話者	-0.0880	-0.0404	0.1746

表 3.2: 滑らかさ指標

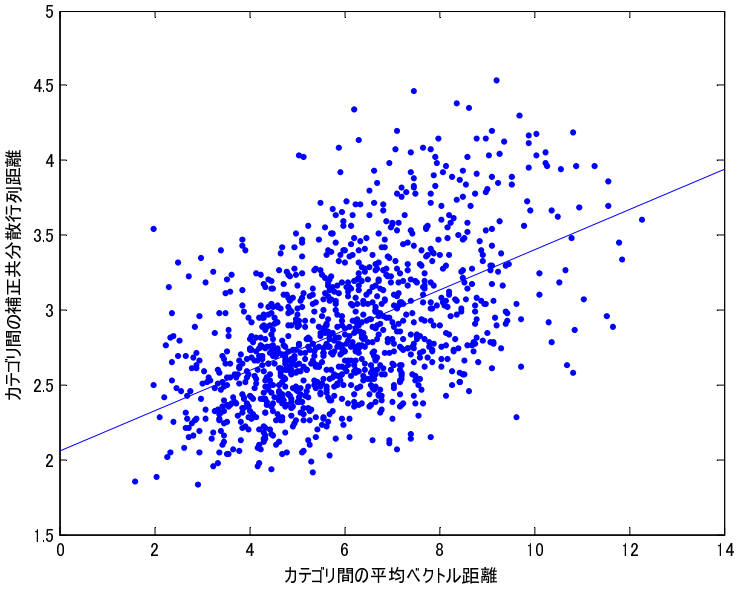

図 3.3: 日本語の名詞カテゴリの滑らかさ ($S = 0.5221$)

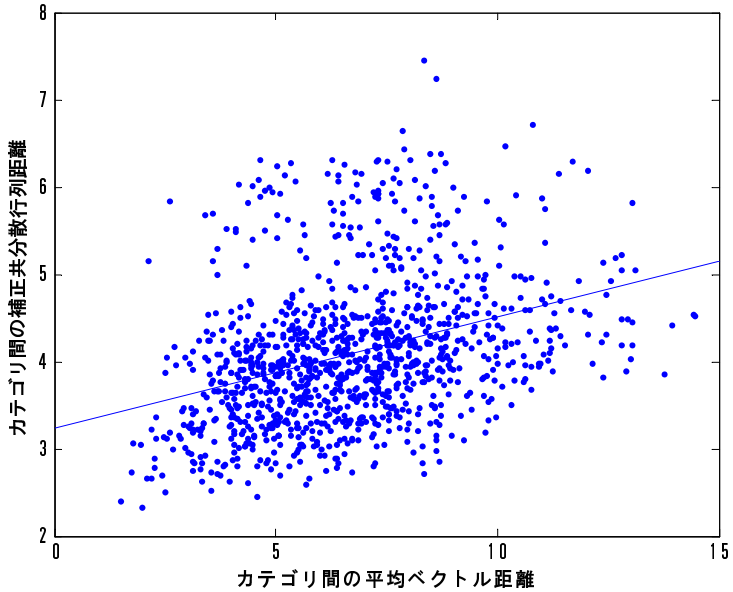

図 3.4: 英語の名詞カテゴリの滑らかさ ($S = 0.3491$)

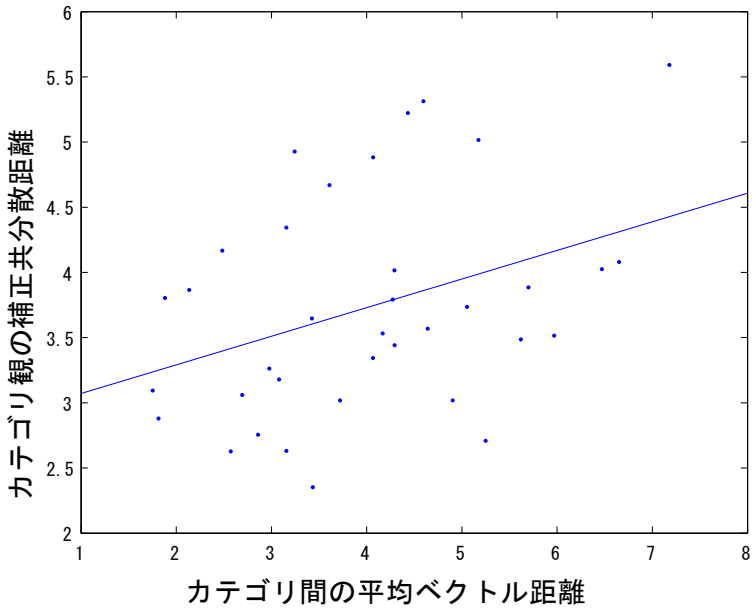

図 3.5: 日本語の上位カテゴリの滑らかさ ($S = 0.2598$)

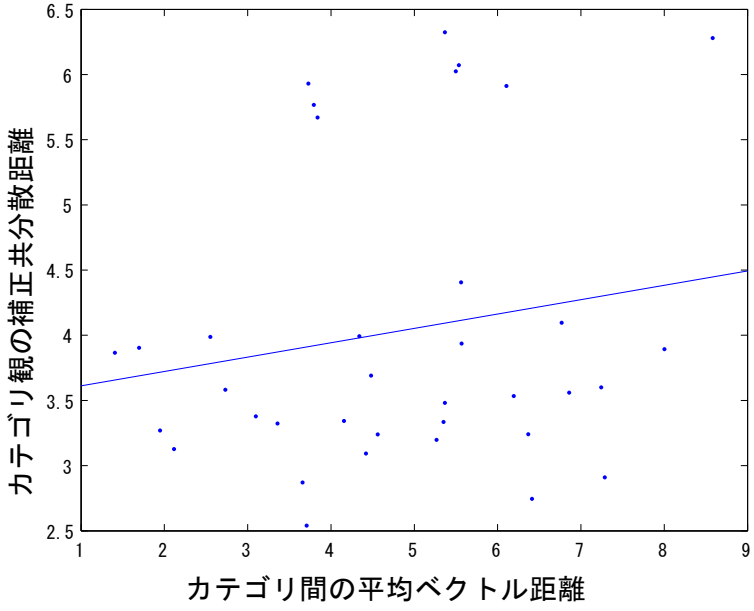

図 3.6: 英語の上位カテゴリの滑らかさ ($S = 0.1746$)

カテゴリ凝集性の発生を説明するためには，何が個々のカテゴリ境界を決定するのか (基底)，また複数のカテゴリ境界が互いにどのように関連するのか (効率性) について述べる必要がある．本研究では，カテゴリが一つの中心的表象を持ち，その中心からなだらかに「カテゴリらしさ」(ある事例が，あるカテゴリに属すると期待される尤度) が減少すると仮定する．自然カテゴリでは，カテゴリの典型性 (typicality) や親近性 (familiarity) などの幾つかの尺度で，なだらか勾配をもつ事が示されている [15]．このようなカテゴリ尤度の勾配パタンは，人が期待する事例分布の頻度と関連しており，尤度に基づくカテゴリ判断はベイズ理論的な決定モデルとして定式化できる．また，このカテゴリ決定モデルでは，カテゴリ尤度のパタンを，そのカテゴリに関する局所的な特徴の重要度と解釈する事ができる．次節で，このようなカテゴリモデルを裏付ける心理学的な知見について述べる．

カテゴリ表現の基底　本研究では，あるカテゴリに含まれる事例の頻度に関する，学習者の主観的な期待をカテゴリ尤度と呼ぶ．カテゴリ尤度はある事例が特定のカテゴリとしてみなされる相対的な確率を表すので，この判断を「類似性」と操作的に定義，または同一視する研究も多い[1)]．しかし，本研究ではカテゴリ尤度を「類似性」とは明確に区別する[2)]．

Rips[47] は興味深い実験によって，人が自然カテゴリに対して類似性とカテゴリ尤度を明確に区別する事を示した．Rips の実験では，協力者は，見慣れない 3 インチの円盤が，25 セント硬貨とピザのどちらに**類似**するか，また，どちらと**同じカテゴリ**に属するか，という質問に答えた．25 セント硬貨とピザはどちらも円盤状の物体で，直径を特徴次元と考えれば，実験刺激は 25 セント硬貨に近い．そのため，協力者は 3 インチの円盤は 25 セント硬貨に「類似」していると答えたが，驚くべき事に，多くの協力者は 3 インチの円盤はピザと同じ「カテゴリ」に属すると答えた[3)]．

[1)] Ashby[50] は，刺激の入力としての類似性とカテゴリ判断における類似性を区別した．

[2)] 「類似性」は，研究ごとに異なった意味を持つので，誤解の原因となる厄介な用語である [46]．少なくとも，ある対で与えられた事例間を直接評価した類似性と，何らかの課題の正答率，誤答パタンや反応時間などの操作的・間接的に得られる類似性との違いや,「何に基づく」類似性かなどの文脈の特定が必要である [57].

[3)] 新奇語汎用課題でも，新奇語を与えるか，類似性を問うか，といった教示によって汎用パタンは全く異なる [6, 5]．新奇語命名の文脈と「同じグループ」に分ける文脈は同じ汎用パタンを導く．

この結果は次のように解釈できる：3インチの円盤は知覚的に25セント硬貨に類似しているが，25セント硬貨の大きさは決して変わらないのに対して，ピザの大きさは変わりうるので3インチの円盤は25セント硬貨よりピザの事例としてあり得る．つまり，類似性だけでなく，協力者のこれまで観察してきた既知のカテゴリの頻度に関する事前知識がカテゴリ尤度を決定すると考えられる．この仮説は更なる実験 [48] によって確認され，また別な実験で同じ結論が繰り返し確認されている [58, 59].

Ripsの実験結果のより形式的な解釈は，カテゴリ尤度に基づくベイズ理論的な合理性によって説明できる．図3.7に円盤の直径を特徴次元として仮想的な25セント硬貨 (A: 左側) とピザ (B: 右側) のカテゴリ尤度を1次元正規分布で示した．25セント硬貨の頻度分布は分散 (一般化の範囲) が小さく，ピザの頻度分布の分散は大きい．Rips[47] の実験のように，ある人が図3.7の硬貨とピザのサイズに関する事前知識 (カテゴリ尤度) を持つ場合に，ある見慣れない円盤を，25セント硬貨かピザにカテゴリ化するとしよう．この場合，破線で示した直径より大きい円盤ならピザ，小さい円盤なら25セント硬貨とみなすのが最も誤りの少ない最適な判断である．なぜなら，破線より右側ではピザである尤度が高く，左側では25セント硬貨である尤度が高いからである．つまり，Rips[47] の実験では人が既知カテゴリの頻度の事前知識を基に誤りを少なくするように判断したため，新奇な対象をピザと一般化しやすかったと解釈できる．図3.7では最適なカテゴリ判断の境界は25セント硬貨の中心的な表象 (点線で示された分布の平均値) にピザの中心的表象より近い (類似する) 事から，類似性とカテゴリ判断の乖離が説明できる．

前述の新奇語汎用の際に重要な特徴パタンと，名詞カテゴリの特徴ばらつきパタンの一致も，同様に合理主義的なモデルで説明可能であると考えられる．カテゴリ尤度は，あるカテゴリに属する事例の特徴空間上の頻度であるため，確率的なカテゴリの定義そのものである．一方で，Rips[47] の実験から，個々のカテゴリに対する特徴の重要性を定義するとも解釈できる．例えば，25セント硬貨のカテゴリ化にはサイズは決定的な特徴であり，ピザのカテゴリ化にはあまり重要ではない．

カテゴリの詰め込み効率　前述のように，個々のカテゴリが尤度を持ち，その尤度がカテゴリ判断に影響するとしても，それだけでは図3.1のような滑らかな尤度の分布の説明にはならない．ベイズ理論的な合理性の下で各カテゴリの識

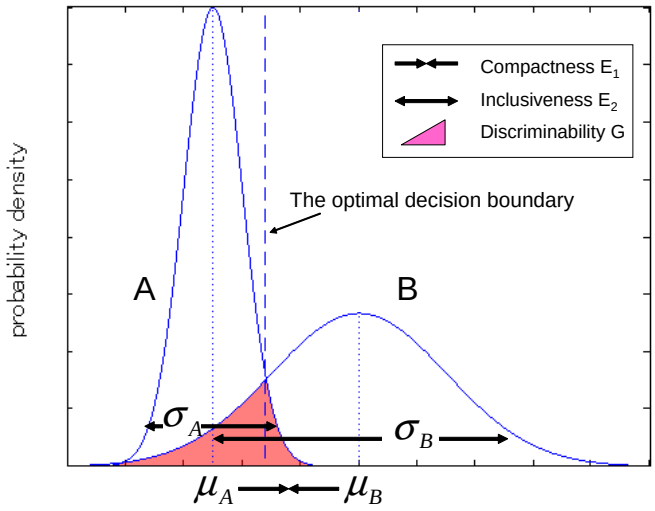

図 3.7: 仮想カテゴリ A,B の尤度

別性を最適化しながら，同時に高い一般性を保つとき，そのカテゴリ群全体はどのような構造をとるのだろうか．ここでは，個々のカテゴリから定義できる効率性を定義し，それを最適化するカテゴリ群全体の特性を調べるという方針をとる．提案モデルでは，カテゴリの「識別性」,「包含性」,「集約性」という 3 つの “圧力”の組み合わせによってカテゴリ効率を構成する．カテゴリの識別性は，ある異なる二つのカテゴリに含まれる事例が重複しない場合に高く，含まれる事例が重複する場合に低い．具体的には前節で述べた，最適な決定における最小限のカテゴリ誤判断確率として定義される．カテゴリの包含性とは，あるカテゴリの参照する “事例の特徴空間における範囲”であり，カテゴリに含まれる事例が多く，また多様な特徴を持つ事例を含むほど高い．図 3.7 では分散の大きさ σ にあたり，分散が大きいほどカテゴリが一般化されやすいが，カテゴリ誤り確率が高まる．カテゴリの集約性とは，カテゴリを表現するために要する特徴空間の “サイズ”であり，特徴次元が低く，特徴空間の領域が小さいほど高い[1)]．図 3.7 では中心間距離の $|\mu_A - \mu_B|$ にあたり，距離が大きいほどカテゴリ誤り確率は減る．しかし，冗長な特徴空間の領域 (カテゴリ A,B のどちらの尤度も低い領域) が大きくなり，特徴空間を保持・生成するための認知的資源

[1)] 集約性は，与えられたデータ点に関する適合性とも解釈できる．しかし，事例の分布構造の違いは，結論 (カテゴリの滑らかさ) に本質的な差を導かない．従って，本研究では敢えて事例の分布構造を特定せず，不定のまま議論を進める．ここでの事例分布の不定性は，弱い仮定: 事例は有限の特徴空間で表せる (集約性)，によって表現されている．

の無駄が増加する．これらの三つはトレードオフの関係にあり，全てを独立に最大化する事はできない．

この関係の概念的な図式を図 3.8(a) に示す．図中の楕円は，図 3.1 と同様に，カテゴリ尤度のあるレベルの等高線なので，楕円が大きいほど個々のカテゴリの包含性が高い．また，3 つのカテゴリ (楕円) を囲む点線が，3 カテゴリの集約性を表し，これが小さいほど集約性が高い．図中の白の両側矢印は，二つのカテゴリ間の識別性を意味し，矢印が長いほど，カテゴリ間の事例の重複が小さく，識別性が高い．図 3.8 の関係のなかで，識別性，包含性，集約性の全てを自由に高める事はできない．すなわち，集約性を高める (点線の領域を小さくする) ほど，識別性と包含性は低く (矢印が短く，楕円サイズが小さく) なり，また識別性を高める (白矢印の長さを大きく) ためには集約性と包含性が低くなる (広い領域か，楕円サイズが小さくなる) 必要がある．従って，互いに矛盾する 3 つを任意に最大化する事はできないが，互いを制約として均衡を保ちながら，制約付の最大化は可能である．この均衡的な最適化は，あたかも，できるだけ大きい荷物 (重ならないカテゴリ) をできるだけ小さいスーツケース (特徴空間) に効率よく “ 詰め込む”操作に対応する．ここから類推して，これをカテゴリの詰め込み効率化と呼ぶ．本研究では，これを数学的に定式化することで，詰め込み効率の高い特徴空間ほど，より滑らかな性質を有すること示す．その前に，次節では他の効率性モデルについて述べて，本研究の位置づけを行う．

先行研究における効率性　これまでにも自然カテゴリの性質を心理的な「効率性」によって捉える試みは行われてきた．その中でも，基本カテゴリは最も効率的に処理されると考えられるため [4]，心理的特性の関数として「効率性」を定義し，基本カテゴリの優位性を記述する理論が多くの研究で模索されてきた [24, 23, 22, 21]．本研究の詰め込み効率性もその一種である．以下ではこのような定量的な効率性に基づくモデルをメトリックモデルと呼ぶ．Mervis & Rosch [21] は，基本カテゴリの効率性として，カテゴリ間類似性とカテゴリ内類似性の比 (類似性比モデル) を候補に挙げている．このモデルでは，カテゴリ間類似性がカテゴリの識別性，カテゴリ内類似性がカテゴリの一般性を表し，両者の対比から効率性が定義される．

類似性比モデルは，詰め込みモデルと同様に，識別性や一般性を組み合わせて効率性を定義する．しかし，両者が決定的に異なる点はカテゴリの基底にある．二つのモデルの違いを端的に表したのが図 3.8(b),(c) である．詰め込みモ

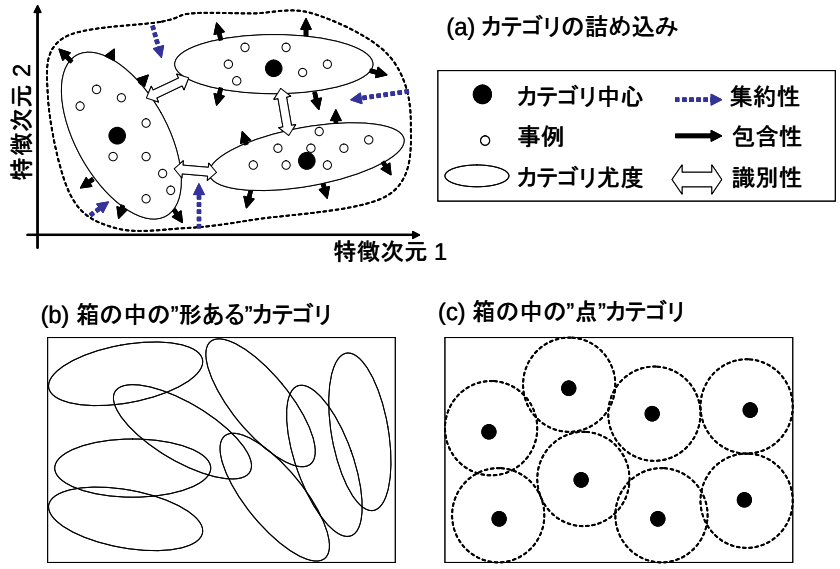

図 3.8: カテゴリの詰め込み

デルでは，個々のカテゴリは形，厚み，方向を持った “物体” のように扱われる (図 b) が，一方，類似性比モデルでは，個々のカテゴリは，等質な点のように扱われる (図 c)．言い換えれば，詰め込みモデルでは一つのカテゴリの周りで特徴次元の選択が局所的に行われると仮定し，類似性比モデルではカテゴリごとではなく，特徴空間全体 (特徴次元ごと) に大域的に特徴選択が行われると仮定するモデルである．本研究では，滑らかな特徴空間を形成するために，どちらのカテゴリの特徴表現が妥当であるか，シミュレーションによって検討する．

3.3 カテゴリ詰め込みの理論的定式化

本節では，カテゴリの詰め込みモデルを理論的に定式化し，詰め込み効率化とカテゴリの滑らかさとの解析的な関係を示す．詳細な数式の導出および，最適解の安定性や他のメトリックモデルとの関係については付録 A.4 で述べた．ここでは，以下の手順に従い，要点のみに絞って述べる．

1. カテゴリ尤度が，平均ベクトル (カテゴリ中心)，共分散行列 (カテゴリ尤度パタン) により定義される正規分布に従うと仮定する．
2. 次に，カテゴリ構造の滑らかさを，カテゴリ中心間距離とカテゴリ尤度パタンの距離の単調関数として定式化する．
3. 識別性，包含性，集約性を定義し，詰め込み効率性をそれらの関数として定義する．

4. 以上の三つの仮定から，詰め込み効率性を最適化するカテゴリ中心および尤度パタンが，滑らかである事を導出する．

カテゴリ尤度および滑らかさの定義　d 次元の特徴空間 $\Omega \supset \theta$ 上で，カテゴリ c_i $(i = 1, 2, \ldots, n)$ が特徴 θ を持つ尤度 $P(\theta|c_i)$ を以下の平均 μ_i，共分散行列 σ_i の正規分布で定義する．

$$P(\theta|c_i) = ((2\pi)^d|\sigma_i|)^{-\frac{1}{2}} \exp(-\frac{1}{2}(\theta - \mu_i)^t \sigma_i^{-1}(\theta - \mu_i)) \tag{3.5}$$

ただし上付きの ^{t} は転置を表す．平均ベクトル μ_i はカテゴリの中心的な特徴，共分散行列 σ_i はカテゴリのばらつきパタンまたは特徴次元に対する重み付け (Mahalanobis 距離) を表す．従って，確率分布パラメータ μ_i と σ_i によって，カテゴリの滑らかさ (類似のカテゴリが類似のカテゴリ尤度を持ち，非類似のカテゴリが非類似のカテゴリを持つ) は以下のように定義できる．

$$||\mu_i - \mu_j|| \approx h(||\sigma_i - \sigma_j||) \tag{3.6}$$

ただし，$h(X)$ は X の単調な関数で，$||\mu_i - \mu_j||$ と $||\sigma_i - \sigma_j||$ は二つの平均ベクトル，共分散行列 i, j のユークリッドノルムを表し，$\approx$ は近似を表す．

詰め込み効率性の定式化　次に，識別性，集約性，包含性の三つの制約を定式化し，詰め込み効率を定義する．n カテゴリの識別性は以下のように各カテゴリ尤度に基づいて，カテゴリの誤識別率として与えられる．具体的には，最適な判断基準における最大の誤り率 (Bhattarcheryya 上界) を近似的に誤識別率とする [60]．n カテゴリに拡張した Bhattarcheryya 上界 F_n を以下のように定義する．

$$F_n = \int_\Omega \prod_i P(\theta|c_i)^{\frac{1}{n}} d\theta \tag{3.7}$$

集約性 E_1 は，カテゴリの表現に用いる特徴空間の範囲に単調であるので，以下のように定義する．

$$E_1 = \sum_i^n \mu_i^t \mu_i \tag{3.8}$$

包含性 E_2 は，一つのカテゴリの含む事例の範囲であるので，以下のように定義する．

$$E_2 = \sum_i^n tr(\sigma_i^{-2}) \tag{3.9}$$

ただし $tr(X)$ は行列 X のトレースである．詰め込み効率は F_n, E_1, E_2 の組み合

わせからなり，集約性，包含性に対する相対的な識別性である．これは制約つきの最適化であるので，λ_1, λ_2 を定数とする Laggrange 乗数 $L_n = 2n\log(F_n) + \lambda_1 E_1 + \lambda_2 E_2$ を最適化する．具体的には以下の式である．

$$L_n = B^t A^{-1} B - C - n\log|n^{-1}A| - \sum_i^n \log|\sigma_i| + \lambda_1 E_1 + \lambda_2 E_2 \tag{3.10}$$

ただし，$A = \sum_i^n \sigma_i^{-1}$, $B = \sum_i^n \sigma_i^{-1}\mu_i$, $C = \sum_i^n \mu_i^t \sigma_i^{-1}\mu_i$ である．

詰め込み最適化　次に，カテゴリ中心 μ_i または尤度パタン σ_i $(i = 1, 2, \ldots, n)$ をパラメータとしてメトリック L_n の最小化した場合に，滑らかなカテゴリ (式 3.6) が発生する事を示す．この最適化の必要条件 $\frac{\partial L_n}{\partial \mu_i} = 0$, $\frac{\partial L_n}{\partial \sigma_i} = 0$ $(i = 1, 2, \ldots, n)$ から，以下の式が導出できる．

$$\frac{\partial L_n}{2\partial \mu_i} = -\sigma_i^{-1}(\mu_i - A^{-1}B) + \lambda_1 \mu_i \tag{3.11}$$

$$\sigma_i \frac{\partial L_n}{\partial \sigma_i}\sigma_i = (\bar{\mu} - \mu_i)(\bar{\mu} - \mu_i)^t + nA^{-1} - \sigma_i - \lambda_2 \sigma_i^{-1} \tag{3.12}$$

ただし，$\bar{\mu} = A^{-1}B$ は μ_i の重みつき平均である．さらに，式 (3.11), (3.12) をカテゴリ i, j について展開する事で，以下の近似的に滑らかな性質 (式 3.6) を導出できる．

$$\Delta\mu_{ij}^t \Delta\mu_{ij} = \lambda_1^2 tr\{\bar{\mu}\bar{\mu}^t(\lambda_1\sigma_i - I)^{-2}(\lambda_1\sigma_j - I)^{-2}\Delta\sigma_{ij}^2\} \tag{3.13}$$

$$tr(\lambda_2 \Delta\sigma_{ij}) = tr(\Delta\mu_{ij}(\bar{\mu}_{ij} - \bar{\mu})^t + (\bar{\mu}_{ij} - \bar{\mu})\Delta\mu_{ij}^t) \tag{3.14}$$

ただし，$\Delta\mu_{ij} = \mu_i - \mu_j$ である．従って，識別性，包含性，集約性の 3 制約によるカテゴリ詰め込み効率 (式 3.10) の最適化は，滑らかなカテゴリ (式 3.6) を導く事が解析的に示された．

3.4　シミュレーション

前節の実験では，名詞カテゴリの評定を分析した結果，実際に自然カテゴリが滑らかである事が示唆された．ここでは，４つシミュレーションを行うことで，提案理論の妥当性を示し，またその応用性について議論する．数学的定式化 (3.3 節) で既に示したように，もしこの滑らかさがカテゴリの詰め込み効率化により発生するとすれば，詰め込み効率の最適化シミュレーションによって図 3.3 と同様の滑らかな構造を再現する事が出来るはずである (シミュレーション 1)．

また，提案モデルには，カテゴリの効率性関数，カテゴリの表現素など複数の構成要素があり，メカニズムの詳細を知るためには，これらのどれが滑らかさの発生に必要・十分であるのか特定するべきである．そのため，カテゴリの効率性を提案する他のモデルが滑らかな構造を発生しうるか，詰め込みモデルと比較した (シミュレーション２).

語彙獲得の研究では，たった一つの新奇事例から新奇語の意味する対象を素早く推測する汎用行動を即時マッピングと呼ぶ．即時マッピングは，試行錯誤的な学習なしに，新奇事例に重要な特徴を特定する強力な汎化能力である．また，即時マッピングは幼児の語彙獲得を促進すると考えられており，そのメカニズムを解明する事は重要である．もし，滑らかな構造によって即時マッピングを実現できるならば，詰め込み効率モデルは，未学習の名詞カテゴリの汎用パタンを予測できるはずである．シミュレーション３では，未知の事例に対して，詰め込み効率的なカテゴリ尤度パタン (特徴重要性) を予測し，モデルの予測と実際の名詞カテゴリの尤度パタンを比較した.

詰め込みモデルの定式化では，与えられる事例の分布構造に弱い仮定 (i.e., 集約性と包含性) しかおかず，その構造を限定せずに一般的な議論を展開した．しかし，事例の分布に関するこのような非限定的な仮定は妥当なのだろうか．もしくは，事例の分布には何らかの特殊な構造が必要なのだろうか．これを確かめる一つの傍証として，特徴空間上に一様・無作為に散布した事例を自己組織化的にクラスタリング (教師なしカテゴリ化) する事で，滑らかな構造が発生しうるか検討した (シミュレーション 4).

3.5　シミュレーション１：カテゴリの詰め込み

このシミュレーションでは，詰め込みモデルによって最適化されたカテゴリ群の構造を視覚的に調べる事が目的である．既に数学的な定式化によって滑らかな構造の発生が示されたが，その具体例を分析するために無作為に初期化した特徴を持つカテゴリ群を詰め込みの効率性に基づいて最適なプロトタイプと一般化パタンを数値的に求め，その滑らかさを調べた.

3.5.1　手続き

カテゴリ詰め込み条件では，まず 2 次元特徴空間におけるカテゴリの平均ベクトルと共分散行列を乱数によって決定し，これを初期値として詰め込みの最適化を行った．最適化は式 (3.11), (3.12) に従って最急降下法を行った．具体的

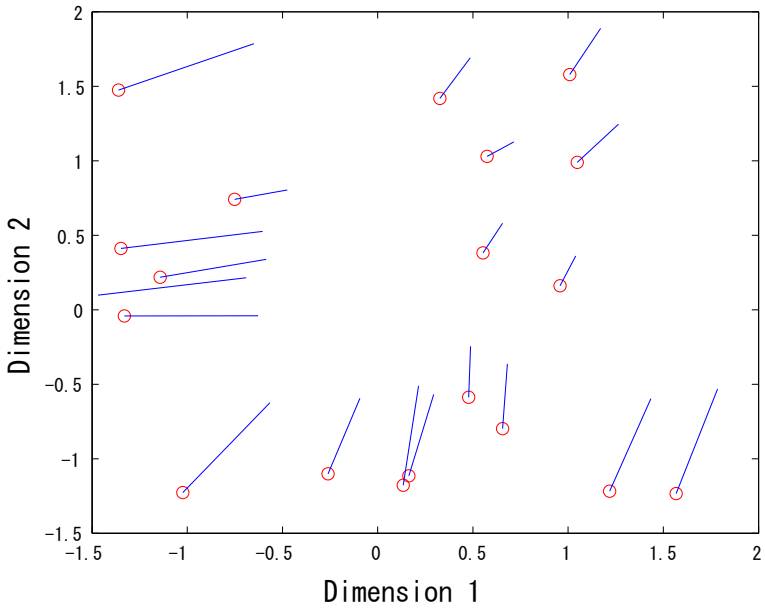

図 3.9: 詰め込み効率性を最適化する 20 カテゴリの分布構造の例

には，$\mu_i(t+1) = \mu(t) + \epsilon\frac{\partial L_n}{\partial \mu_i}$, $\sigma_i(t+1) = \mu(t) + \epsilon\frac{\partial L_n}{\partial \sigma_i}$ $(i = 1, 2, \ldots, 20)$ によって，更新率を $\epsilon = 0.05$ で逐次的に更新を 100 回繰り返す事で最終的なカテゴリ分布を得た．ただし，$\mu_i(t)$, $\sigma_i(t)$ は t 回更新を行ったパラメタである。初期値は，$\mu_i(0)$ を $[0, 1]$ の一様乱数値を要素として持つ 2 次元ベクトルとし，$\sigma_i(0)$ を $[0, 1]$ の一様乱数値を対角要素，$[-0.3, 0.3]$ の一様乱数値を非対角要素として持つ半正定な 2 次正方行列とした．

3.5.2 結果・考察

図 3.9 に詰め込み効率性を最適化する 20 カテゴリの 2 次元特徴空間における配置パタンの一例を示す．円がカテゴリの中心位置 μ_i，円から伸びた線分が共分散行列 σ_i の主軸方向[1)]を示す．また，このカテゴリの一例における滑らかさ指標の散布図を図 3.10 に示した．異なる乱数による初期値から詰め込みの最適化によって得られた平均の滑らかさ指標は 0.49 $(p < 0.001, N = 100)$ で有意に 0 より高かった．このシミュレーション結果は自然カテゴリ評定のカテゴリ構造 (3.1 節「心理実験による検討」) と一致して見られた滑らかな構造を示した．つまり，自然カテゴリの滑らかな構造が詰め込み原理によって得られた可能性を示唆する．

[1)] 最大固有値に対応する固有ベクトル．

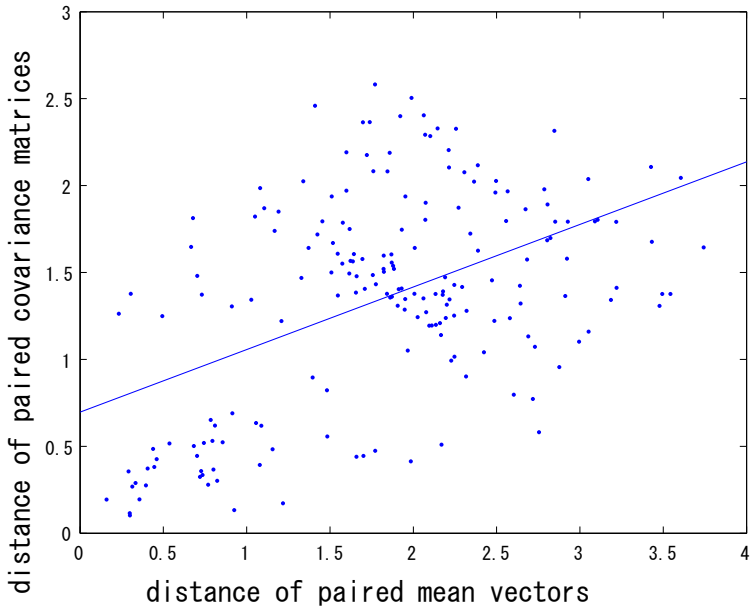

図 3.10: 詰め込み効率性を最適にするカテゴリ群の滑らかさ

3.6 シミュレーション２：カテゴリの効率性の検討

シミュレーション１では，詰め込みモデルによる滑らかなカテゴリの発生を示したが，これはモデルのどの仮定・性質に起因するのだろうか．詰め込み効率化とは異なる効率化に基づく情報圧縮のモデルでも，滑らかなカテゴリを構造化できるのだろうか．シミュレーション２では，他のモデルと比較する事で，滑らかなカテゴリの詳細な計算論的な条件を調べる．前述のように，先行研究のモデルに対する詰め込みモデルの違いは，カテゴリを表現する特徴空間の形式にある．もし，先行研究のモデルのように，カテゴリ固有の方向性を無視して (図 3.8c)，カテゴリの識別性・一般性を最適化するだけで滑らかな構造が発生すれば，詰め込みモデルのように局所的な特徴選択を仮定する必要は無い事が示される．逆に，カテゴリ固有の尤度を考慮する，詰め込みモデル (図 3.8b) のみで滑らかなカテゴリが発生するのであれば，局所的な特徴選択の必要性が支持される．

具体的には，詰め込みモデルと多クラス判別分析 (Multiclass Discriminant Analysis: MDA)[60] を用いて，これらのモデルが固有に持つメトリックと特徴空間の滑らかさについて分析した．MDA は，与えられたカテゴリに対して，カテゴリ間・カテゴリ内の分散比を最大化する特徴次元を選択するモデルである．

このモデルの指標は，Mervis & Rosch[21] の提案する，カテゴリ内類似性に対するカテゴリ間類似性の最大化の一形式であると考えられる．また，主成分分析 (Principal Component Analysis: PCA) も同様に，比較対象に加えた．PCA は，データのカテゴリは考慮せず，データ分散の最大化を行う特徴選択の一手法である．MDA の分散比の最大化，および PCA の分散の最大化はいずれも一つの識別性の基準とみなすことができる．

一般に，特徴選択のモデルでは，与えられた効率性の基準 (メトリック) を最適化 (最大・最小化) する特徴次元を計算するが，その計算過程では複数の “局所解”が現われる．例えば，MDA では 16 次元の特徴空間に対して，たかだか 16 の局所解が与えられる．局所解それぞれが最適化された特徴空間の 1 次元を表し，特徴次元ごとに MDA の基準を基にしてメトリックの最適性が与えられる．MDA では，特徴次元ごとにカテゴリ間・カテゴリ内分散比の大きさが計算され，この大きさが特徴空間の “良さ”を表すので，これを基準にして元の特徴空間より小さい部分空間を選択する事で，少数の良い特徴次元が選択できる．さて，このように特徴次元にモデルの基準固有に重み付けが与えられるので，この次元を適当に複数選択し構成した特徴空間に，メトリックと滑らかさをそれぞれ計算する事ができる．今，網羅的に，または無作為に特徴次元を選択して空間を構成すれば，良い特徴空間から悪い特徴空間まで様々な特徴空間に関して，それぞれ滑らかさを計算する事ができる．もし与えられたメトリックに関して，良い特徴空間ほど滑らかならば，そのメトリックの最適化と滑らかさに関連性があると考えられる．逆に，滑らかさがメトリックに影響されないならば，そのメトリックの最適化が滑らかさに関連するとは考えにくい．従って，多数の特徴空間に関して得られたメトリックと滑らかさの関係を検討した．

3.6.1 方法

3.6.1.1 データ 特徴選択には，名詞カテゴリの評定実験 (3.1 節, または第 2 章節を参照) で得られた評定データを用いた．評定データの 16 次元特徴空間の全ての点 ($N = 4992 = 104 \times 48$) とそれに対する 48 カテゴリの割り当て (PCA 除く) がモデルに与えられ，詰め込みモデル，MDA，PCA のそれぞれの基準を最適化する 16 次元特徴空間を計算した．データの共分散は，全て補正共分散を用いた (3.1.1.2 節参照).

3.6.1.2 滑らかさ指標 評定データの分析方法 (3.1.1 節) と同様に，式 (3.1) で滑らかさ指標を定義し，用いるデータの共分散行列を補正した．

3.6.1.3　詰め込みモデルによる特徴選択　カテゴリの共分散行列に対して，カテゴリの平均ベクトルを自由パラメタとして詰め込みモデルのメトリック (式 3.10) を最適化する事で求める特徴空間が計算された．具体的には，式 3.11 を解析的に解く事で，768(= 48 カテゴリ ×16 特徴次元) の局所解が得られる．得られた 768 の特徴空間はそれぞれ固有の詰め込み効率性が与えられ，これに対する特徴空間の滑らかさを分析した．

3.6.1.4　MDA・PCA による特徴選択　MDA ではカテゴリ間・カテゴリ内分散比，PCA では分散が最大化の基準として用いられた [60]．MDA，PCA からは，評定データの 16 次元に対して，それぞれ 16 次元に対応する局所解が得られる．得られた 16 次元特徴のうち 3,4,5,...,13 次元を無作為にそれぞれ 200 回復元抽出する事で，合計 2200 の異なる特徴空間を形成した．例えば，3,7,12 番目の特徴次元が選択された場合，この 3 次元のメトリックの平均が選択された特徴空間のメトリックとされた．得られた 2200 の特徴空間はそれぞれメトリックが与えられ，これが滑らかさの分析に用いられた．以下に PCA および MDA の最適化関数とその解を示す．

3.6.1.5　PCA　$X = (x_1, x_2, \ldots, x_n)$ を，j 番目の d 次元データを表すベクトル x_j を要素にもつ $d \times n$ 行列とする．このとき求める線形射影 w(d 次元ベクトル) は以下の関数を最大化する．

$$E_{PCA}(x) = w^t S w + \lambda w^t w \tag{3.15}$$

ただし，$S = \sum_{k=1}^{n}(x_k - \bar{x})(x_k - \bar{x})^t$ の散布行列 (共分散行列の $n-1$ 倍) で，$\bar{x} = n^{-1}\sum_k x_k$ は平均ベクトル，λ は定数である．式 (3.15) の解 w は以下の特性方程式で表される固有ベクトルである．

$$Sw + \lambda w = 0 \tag{3.16}$$

3.6.1.6　MDA　同様に，$X = (x_1, x_2, \ldots, x_n)$ を，j 番目の d 次元データを表すベクトル x_j を要素にもつ $d \times n$ 行列とする．このとき求める線形射影 w(d 次元ベクトル) は以下の関数を最大化する．

$$E_{MDA}(w) = \frac{w^t S_B w}{w^t S_W w} \tag{3.17}$$

ただし，S_B はクラス間散布行列 (between-class scatter matrix)，S_W はクラス内散布行列 (within-class scatter matrix) で，散布行列と以下の関係にある．

$$S = S_B + S_W = \sum_s (X_s - \mathbf{1}_s \bar{x_s}^t)^t (X_s - \mathbf{1}_s \bar{x_s}^t) + \sum_s n_s (\bar{x_s} - \bar{x})^t (\bar{x_s} - \bar{x})^t \quad (3.18)$$

ただし，X_s は与えられたグループ s に属するデータを表す $n_s \times d$ 行列で，n_s はクラス s に含まれるデータ数，また $\bar{x_s}$ はクラス s の平均ベクトル，$\mathbf{1}$ は要素が全て 1 の n_s 次元ベクトルである．式 (3.18) の解 w は以下の特性方程式で表される固有ベクトルである．

$$S_B S_W^{-1} w + \lambda w = 0 \quad (3.19)$$

3.6.2 結果・考察

各特徴空間のメトリックと滑らかさの散布図を図 3.11, 図 3.12, 図 3.13 に示す．この散布図は，各モデルの選択基準と特徴空間の滑らかさとの関係を表す．それぞれ，低い詰め込み誤り率 (詰め込みモデル)，高い分散比 (MDA)，高い残差分散 (PCA) が，効率の高い特徴空間を意味する．また，点線およびエラーバーは，滑らかさの 98%信頼区間を等間隔に区切った 10 区間における，各メトリックの平均および標準偏差を示す．どちらのモデルでも，全ての点に関する滑らかさの平均は正の値であったが，元の評定データは正の滑らかさを持つので (図 3.3，3.4)，これは自明な結果である．ここでは平均ではなく，メトリックに対する滑らかさのばらつき・相関の構造を考察する．

詰め込みモデルの滑らかさ選択性　結論から述べると，詰め込みモデルだけが滑らかさと明確な関連性を示した．図 3.11 は 768 の特徴空間の滑らかさ指標 (x 軸) と詰め込み誤り率 (y 軸) を表す．図中の底辺に点在する特異的な解を除いて，最も詰め込み効率のよい特徴空間は，最も滑らかな特徴空間と一致する．詰め込み指標の上位 1%(N=8) の特徴空間の平均滑らかさ指標 (S=0.2890) は全体の平均滑らかさ指標 (S=-0.0058) よりも有意に高かった ($t(7) = 5.9119, p < 0.001$)．従って，詰め込み効率化によって滑らかなカテゴリが発生する事が示唆される．しかし，散布図全体の構造は非対称な関係性を表している．つまり，高い滑らかさ指標を持つ特徴空間は効率よく詰め込まれているが，逆は成り立たず，効率よく詰め込まれた特徴空間は必ずしも滑らかとは限らない．この結果は，二つの可能性を示唆している．第一に，詰め込み効率最大と滑らかさ最大が一致する事から，詰め込み効率性は，滑らかな特徴空間を得るための必要十分であ

る，という可能性である．第二に，全体的な構造の非対称から，詰め込み効率性は，滑らかな特徴空間を得るための必要条件であるが十分条件ではない，という可能性である．この点については今後の検討が必要であるが，いずれの結論にしても，少なくとも詰め込み効率性と滑らかさが強く関連する事が示唆された．

MDA，PCA の滑らかさ選択性　図 3.12，図 3.13 は，それぞれシミュレーションで得られた特徴空間の MDA，PCA のメトリックの平均と滑らかさ指標の散布図を表す．基本的に二つのモデルの結果は類似の傾向を示したので，以下の考察は二つをまとめて行う．これら散布図では高い分散比・残差分散を持つ特徴空間は，高い滑らかさ指標を持つ特徴空間と一致せず，0.2 から 0.3 の中程度の滑らかさ指標を示した．MDA で分散比の上位 1%の特徴空間 (N=22) の平均滑らかさ指標 (S=0.2295) は全体の平均滑らかさ指標 (S=0.2518) よりも有意に低かった ($t(21) = -5.6676, p < 0.001$)．PCA で残差分散の上位 1%の特徴空間 (N=22) の平均滑らかさ指標 (S=0.2414) は全体の平均滑らかさ指標 (S=0.3254) よりも有意に低かった ($t(21) = -9.9180, p < 0.001$)．一方，分散比の低い特徴空間の滑らかさ指標は幅広い範囲にばらつきがみられた．この構造から，MDA の分散比や PCA の残差分散を基準としてより滑らかな構造を選択する事はできないと考えられる．

3.7　シミュレーション３：未知カテゴリの即時マッピング

シミュレーション３では，自然カテゴリの滑らかな構造が，詰め込み原理を持つ学習者の予測性，学習性にどのように有用であるか調べる．具体的には，詰め込みモデルによって，幼児の即時マッピングに相当する新奇語の素早い汎化を実現できる事を示す．ここでは，幼児の新奇語の即時マッピングを，学習者にとって未知の一事例から (複数事例の試行錯誤的学習をせず)，その事例の属する新奇カテゴリの分布を推定する事と定義する．カテゴリ分布のパラメタとして，カテゴリに属する事例の分散パタン (共分散行列) を推定すると考えよう．このとき，一事例の観察だけから分散パタンを正確に推定する事は原理的に不可能に思える (だからこそ幼児がそれを実現する事は驚嘆に値する)．しかし，もし幼児が学習する特徴空間に滑らかさ (i.e., ある 2 カテゴリ間の特徴類似性とカテゴリ尤度の類似性の単調な関係) がある事が仮定できれば，既に学習したカテゴリの分布から，新奇カテゴリの分布を推定する事ができるかもしれ

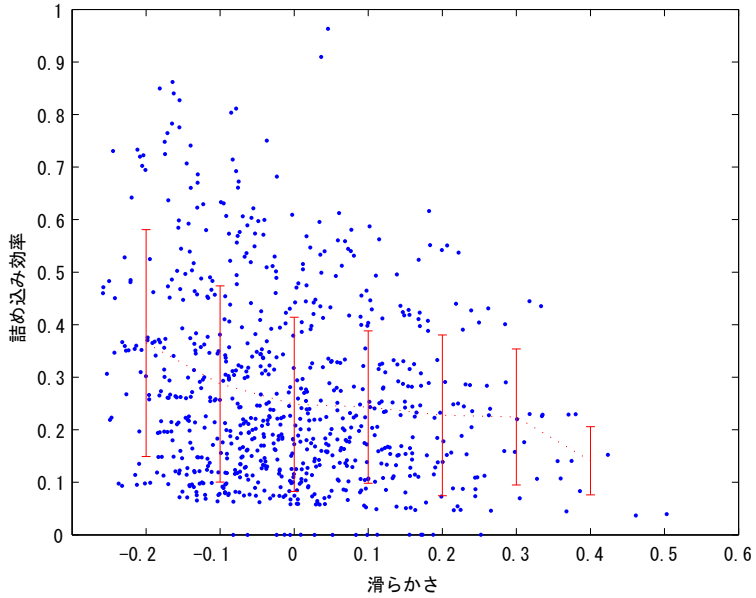

図 3.11: 滑らかさと詰め込み誤り率の散布図.

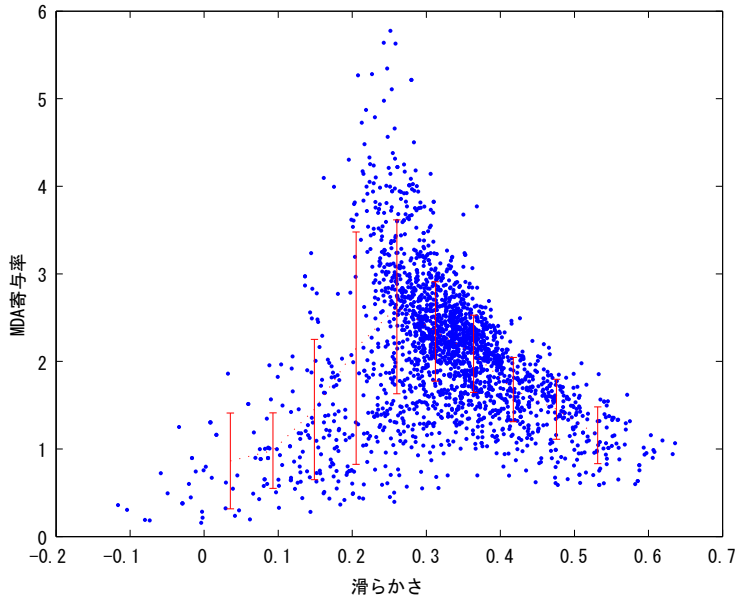

図 3.12: 滑らかさとカテゴリ間・カテゴリ内分散比の平均の散布図.

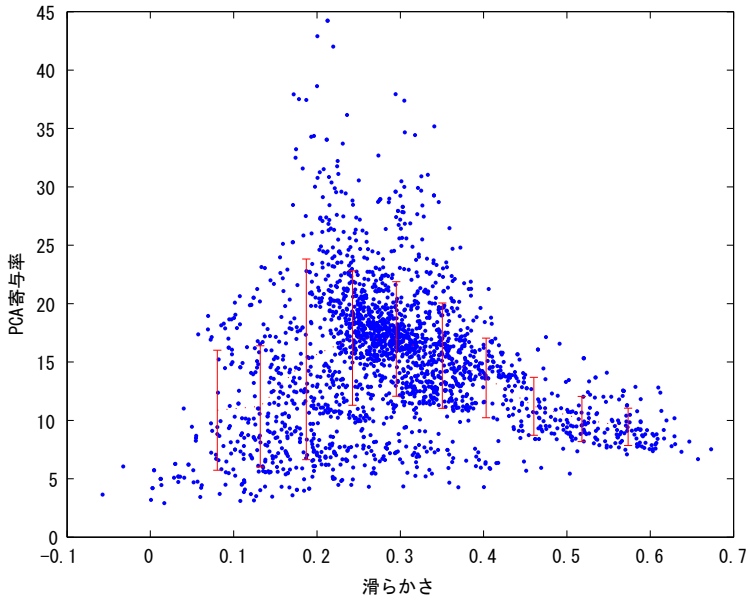

図 3.13: 滑らかさと残差分散の平均の散布図.

ない.

即時マッピングの実現可能性を検討するために，名詞カテゴリの評定データを用いて，新奇名詞カテゴリに対するモデルの予測精度を分析した．具体的には，48 カテゴリのうち一つを未知カテゴリとし，その他の既知カテゴリ群の分散パタンから，詰め込み効率を最適化するような新奇カテゴリの分散パタンの復元を行った．何の事前情報も与えられずに試行錯誤的にカテゴリの特徴パタンを学習する場合，たとえ個々の事例のカテゴリラベルに関するフィードバックが利用できても，正確にカテゴリ尤度の分布を推定するまでに相当数の反復学習が必要である．従って，この問題はカテゴリ事例のばらつきパタン (特徴重要性) が多数の自由度を持つ中で，どのように新奇語の意味を確定するのか，という Quine のパラドクス [2] を限定した特徴空間の中で定式化した問題とも解釈できる.

3.7.1 方法

シミュレーションの各試行では，48 の名詞カテゴリのうち 1 つが未知で，他の 47 のカテゴリのカテゴリばらつきは既知であると仮定する．モデルは未知のカテゴリの平均的な 1 事例[1)]を与えられ，詰め込み効率の基準で最適化によって，

[1)] 幼児の実験では，新奇名詞カテゴリとして与えられる事例がプロトタイプ (平均事例) である事は特に仮定されないが，シミュレーションでは平均事例を最も頻繁に発生する代表事例

未知カテゴリの分散パタンを予測する．このシミュレーションでは共分散行列の非対角要素は 0 として分散 (対角要素) のみが予測およびその評価に用いられた．その理由は，非対角要素を含めた詰め込み効率の数値最適解は，共分散行列が半正定行列であるという必要条件を逸脱して，解が不安定になる場合があるからである．従って，推定するすべての分散パタンは 48 カテゴリ ×16 特徴次元で，768 自由度であった．具体的な最適化手順は以下のとおりである．まず，未知カテゴリの分散行列は単位行列 (対角要素が全て 1 で他 0) に初期化された．次に，他のカテゴリの平均ベクトル，共分散行列はデータの値で固定したまま，未知カテゴリの対角要素のみが式 (3.12) によって更新された (詰め込み効率性をコスト関数とした最急降下法に対応する)．更新式は $\sigma_{t+1} = \sigma_t + \epsilon \frac{\partial L_n}{\partial \sigma_t}$ とした．ただし，σ_t は t 回目の更新をした分散行列で，更新率を $\epsilon = 0.001$, Laggrange 係数を $\lambda_2 = 5$ とし，σ_{200} を最終的な解とした．ここで得られる最適解の計算は，複数の事例からカテゴリ分布を推定する 通常の学習ではない 事に注意する必要がある．最適化が反復手順による事は本質ではなく，この計算の中では新奇カテゴリの 1 事例と他の既知のカテゴリのパタンしか用いていないので，新奇語の第一感の形成に対応する．48 未知カテゴリの予測された 16 次元の分散値と，それに対応する実際のデータでの分散値の相関を分析した．

3.7.2 結果・考察

即時マッピングのシミュレーションの結果，自然カテゴリの実際の分散パタンと，詰め込みによって予測されたカテゴリ分散パタン (図 3.14) の相関は 0.537 で有意に 0 より高かった ($p < 0.001$)．この結果から，既に学習した自然カテゴリのパタンによって，詰め込み効率化を行うカテゴリ学習者は，複数の事例に対する学習をせずに，新奇カテゴリの一般化パタンを予測できる事が示唆される．カテゴリ構造の予測性は，自然カテゴリ自体の構造に大きく依存している．自然カテゴリの構造が滑らかでない場合には既知の知識から新たなカテゴリの一般化パタンを予測する事はできない．逆に言えば，自然カテゴリは新たなカテゴリを予測しやすい滑らかな構造を形成すると言える．つまり，詰め込み原理によるカテゴリ学習者は滑らかな構造を持つカテゴリを形成しやすく，またその滑らかな構造を持つカテゴリは詰め込み原理による他のカテゴリ学習者にとって予測や学習をしやすい，という正の循環を生み出す可能性を示唆する．

とみなした．

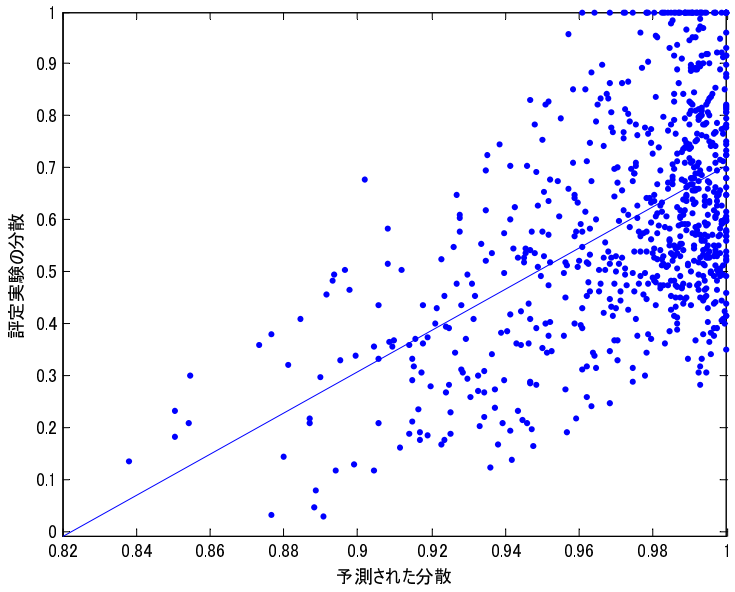

図 3.14: 評定実験のカテゴリ分散と詰め込みモデルによって予測されたカテゴリ分散

3.8 シミュレーション４：ランダム分布点のカテゴリ化

詰め込みモデルでは，事例の分布構造に関しては特定の構造を仮定せず，集約性，包含性などの弱い仮定のみを置いている．実際に，ほとんど顕著な構造を持たないような事例分布のカテゴリ化に対しても，滑らかな構造を発見する事ができるのだろうか．シミュレーション４では，これを検討するために，一様分布の特徴構造を持つ事例群をクラスタリング (教師なしカテゴリ化) をする事で，詰め込みモデルと，他のモデルの基準の違いを調べる．実際には、事例の頻度分布は一様分布ではなく何らかの相関構造があると考えられる [4] が，現実にはその相関構造を特定する事は難しい[1)]．しかし，最も構造の無い一様乱数的な事例分布からでも自己組織的に滑らかなカテゴリが形成されるなら，殆どの相関構造を持つ現実的な特徴セットに対して詰め込みモデルは滑らかなカテゴリを形成できるはずである．従って，詰め込みモデルによって，現実的な特徴セットから滑らかなカテゴリが自己組織化される十分条件として，一様分布の事例に対するカテゴリ化を調べる．

[1)] 知覚刺激のカテゴリ化と異なり，特に一般の名詞カテゴリでは，そもそも特徴次元 (これ自体が名詞カテゴリの一種) を何とすればよいかすら曖昧である．

3.8.1 方法

一様乱数によって生成された 2 次元の特徴値を持つ 100 の事例を 10 事例ずつの 10 カテゴリに分類し，モデルによるカテゴリの大局的構造の違いを調べた．詰め込みのメトリックとカテゴリ間とカテゴリ内の分散比のメトリックが同一の特徴を持つ 100 の事例セットに対して比較された．最適化は，逐次的な山登り法によって行った．具体的には，まず無作為に事例を 10 のカテゴリに割り当てて初期値とした．次に，無作為に選ばれた事例のペアのカテゴリを交換して与えられたメトリックが高くなる場合には交換し，低くなる場合には交換しない，という操作を 10000 回繰り返し，最終的に得られたカテゴリの割り当てを準最適解とみなした．メトリックは詰め込みの場合，式 (3.10) によって定義し，分散比モデルの場合，式 (3.18) によって定義した．

3.8.2 結果・考察

100 回のシミュレーションでの平均の滑らかさ指標は，詰め込みモデルでは $0.117(p < 0.001, N = 100)$，分散比を基準とした MDA モデルでは $0.009(p = 0.33, N = 100)$ であった．この結果は，一様分布の事例群であっても，詰め込みによるカテゴリ化では，偶然の偏りから滑らかな構造 (i.e., カテゴリ凝集性) が抽出できる事を示唆する．一方，分散比によるカテゴリ化は，カテゴリ凝集性を示さなかった．同じ 2 次元特徴を持った事例セットに対する詰め込みモデルと，分散比モデルによる準最適カテゴリの一例を，それぞれ図 3.15，図 3.16 に示す．それぞれの図で，同じマーカーの点が同じカテゴリに割り当てられた事例を示し，点線は同じカテゴリに属する事例の分散傾向を示している．詰め込みモデルによる準最適カテゴリでは，類似の一般化パタンを持つカテゴリによって構成されるクラスタが形成される傾向がある (図 3.15)．一方，分散比モデルによる準最適カテゴリは，一様に同じ分散傾向を持つカテゴリに分割される傾向がある (図 3.16)．以上の結果から，詰め込みモデルは，事例の特徴構造に，顕著な相関構造がない場合にも，滑らかなカテゴリを自己組織的に発見する事が可能である事が示唆される．一方，分散比モデルでは滑らかなカテゴリの自己組織化は困難である事が示唆された．

3.9 結論

本研究の実験およびシミュレーションから得られる結論をまとめる．まず結果の概要について述べ，次に新奇語の獲得戦略に関して考察する．そして，詰

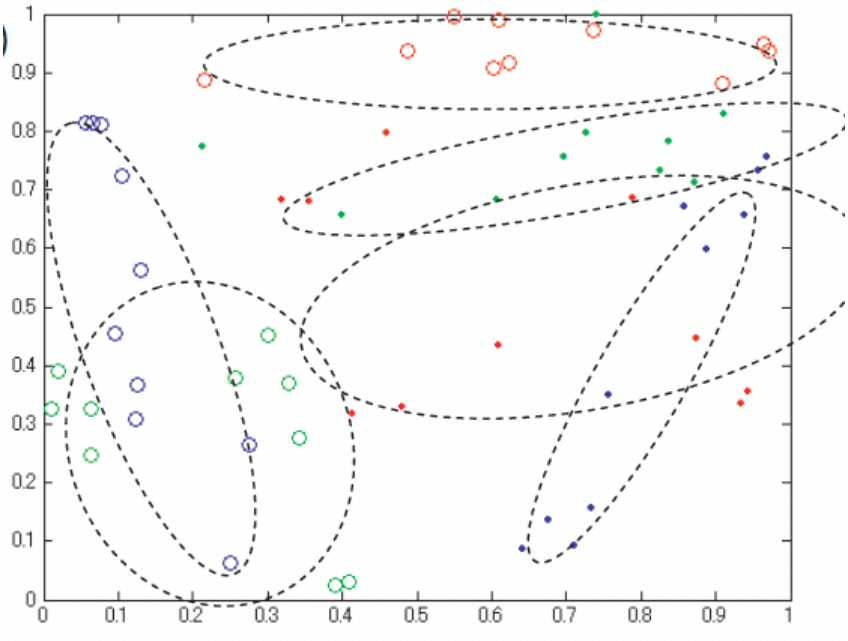

図 3.15: 詰め込み効率の最適化によるクラスタリング

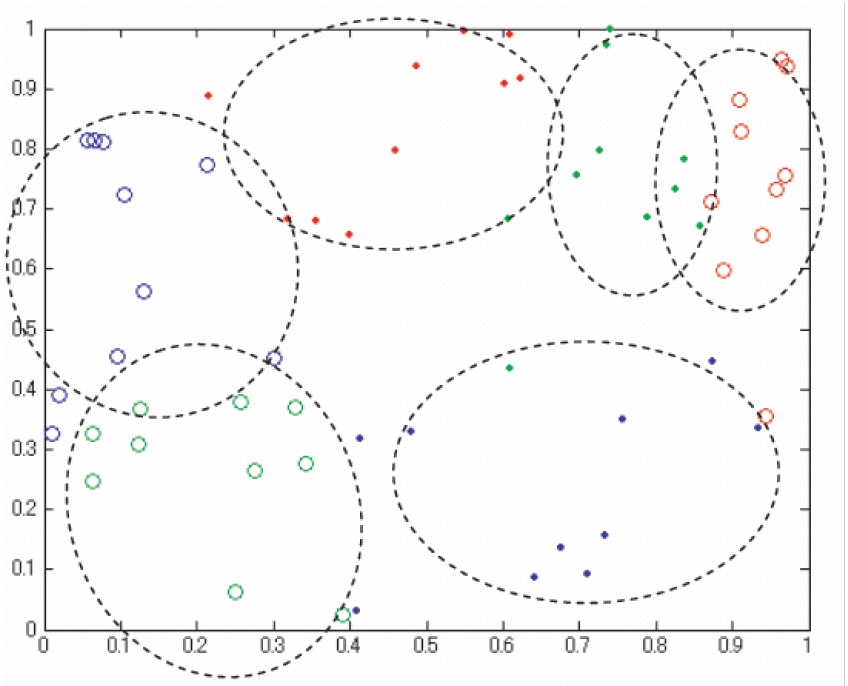

図 3.16: 分散比の最適化によるクラスタリング

め込みモデルの仮定を確認する事で理論的な課題について述べ，最後に，第 4 章以降の研究の展望について触れる．

本章では，自然カテゴリの基本性質である凝集性が，カテゴリの効率化によって自己組織的に形成される事を計算論的モデルで示した．凝集的な自然カテゴリは,「特定の特徴次元によって全体像を捉えられない」側面を持つので，現在のところカテゴリ凝集性の定量的尺度に関するコンセンサスは得られていない．しかし，本研究ではその特徴次元が漸次的に変化する構造は，それ自体が「特徴空間の特徴」(メタ特徴) といえる．そこで，特徴空間の曲率として捉える尺度「滑らかさ」を提案し，特定の特徴やカテゴリの名義的・表面的な違いに依存しない凝集性の構造を実験的に示した．また，カテゴリの凝集的構造を記述するだけではなく，その発生メカニズムを説明するカテゴリの詰め込みモデルを提案した．詰め込みモデルでは，カテゴリ凝集性が，カテゴリの誤識別率の最小化，および一般性と認知的経済性の最大化を，バランスよく満たすことで発生する．従来の理論的研究と異なり，提案したモデルでは事例の頻度によるカテゴリ尤度と類似性を明確に区別し，効率性の原理として取り入れた．詰め込み効率の最大化 (シミュレーション１) によって，実験で得られた結果と類似の滑らかさを持つカテゴリの再現を行った．詰め込みモデルの最大の特徴は，個々のカテゴリが，特徴次元の重要さを表す尤度パタンを局所的に持つ事である．詰め込みモデルのカテゴリ基底に関するこの仮定は，自然カテゴリ全体の構造を曲がった特徴空間として捉える事を意味する．シミュレーション２では，滑らかなカテゴリの発生に関して，この仮定が妥当であるか検討するために，特徴次元ごとに重みを最適化する先行研究のモデルと詰め込みモデルを比較した．

即時マッピングの実現可能性　続くシミュレーション 3 では，即時マッピングに相当するカテゴリ分散の予測を行い，またシミュレーション 4 ではランダムな事例から萌芽的なカテゴリ凝集性の発生について検討を行った．ここから示唆される即時マッピングとカテゴリ凝集性の萌芽は，自然カテゴリの形成における正のフィードバックの両輪であると考えられる．つまり，詰め込み効率化を行う学習者にとって，滑らかなカテゴリは予測しやすく学習に適し (即時マッピング)，逆に，詰め込み効率化を行う学習者は滑らかなカテゴリを自己組織化しやすい．つまり，何らかの先天的に与えられたカテゴリや特徴の構造を必要とせず，この正の循環によって凝集性を持つカテゴリ群が自己組織的に形成される可能性を示している．

即時マッピングは，語彙発達の当初から見られるわけではなく [38]，ある程度の知識が蓄積した後に発現する [34] と考えられる．従って，環境の構造に関して知識が無い状態で，萌芽的な凝集性を形成するメカニズムは極めて重要である．もし詰め込効率化によって概念形成をする複数の学習者がいれば，お互いに発見した概念を通じて意思疎通を繰り返すことで，共通の基盤としてカテゴリ凝集性が発生すると考えられる．このように形成されたカテゴリ凝集性は，既に特定の概念構造を形成している大人のコミュニティーに，新しく参入する学習者にとって予測・学習しやすい構造となっている．実際に，新しいカテゴリは複数の話者の間の相互の意思疎通によって効率的なカテゴリへと変化する事が知られている [61]．そもそも即時マッピングとは，大人の観察者が「正しい」と予期するカテゴリの一般化を子供が素早く学習する事である．このような複数の学習者の意思疎通の基盤を形成するのに詰め込みの原理は適当であると考えられる．

3.9.1 多様体仮説：曲面上に埋め込まれたカテゴリ

本研究で提案したカテゴリ詰め込みと，これまでに提案されたモデルの違いについてまとめ，その違いと関連してカテゴリ循環性の問題を再考する．詰め込みモデルでは，カテゴリが中心と尤度によって定義され，尤度の分布パタンはカテゴリごとに同じではない．一方，多くのこれまでに提案されたカテゴリ学習のモデルも，この尤度に相当する「注意」・「重み」を調節する機構を持つ．しかし，この「注意」は特徴次元に対するもので，個々のカテゴリや事例に対するものではない [51, 20]．Sakamoto, Matsuka & Love [62] は特徴次元ごとに注意を調節するモデルと個々の事例に対して注意を調節するモデルを比較している．その結果，事例ごとの注意モデルは，人のカテゴリ学習において例外的な事例が強く記憶される事を正しく予測する事ができたが，特徴次元ごとの注意モデルではそのような効果は見られなかった．つまり，少数の特徴次元がカテゴリを分けるような場合は，特徴次元ごとの注意モデルで人のカテゴリ学習を十分に予測できるが，例外的な事例が多い場合には事例ごとの注意が必要になる．

多様な概念を含む自然カテゴリ全体を考えると，これはほぼ「例外」だけから成り立つといっても過言ではない.「イヌ」のカテゴリ化で有効な特徴次元は，必ずしも「トリ」や「野菜」のカテゴリ化に有効とは限らない．従って，単一の特徴次元ごとの重みによりカテゴリ化する事は非現実的である．

このようなモデルの違いは，カテゴリを表現する特徴空間の幾何学的性質の違いとして捉える事ができる．特徴次元ごと重みの調節は，図 3.8(c) の長方形を縦または横に伸縮させる事に対応する．この変換では，ある特徴次元の上の点間距離の比は変化しない．一方，カテゴリごとの重みの調節は，図 3.8(b) の楕円を変形 (伸縮・回転) させる事に対応する．この変換では，ある特徴次元の上の点間距離の比は変化しうる．この特徴空間全体は，局所的なユークリッド座標系のパッチをつなげて構成する事に相当し，数学的にはリーマン多様体のような構造と考えることが出来る．言い換えれば，カテゴリごとの重みモデルに制約を加えて，楕円の大きさ・形を全てのカテゴリで一定にしたのが，特徴次元ごとの重みモデルである．

3.9.2 理論的な仮定の妥当性およびその補強

本研究で提案したモデルは，幾つかの自明ではない仮定を含んでいる．これらの仮定を再確認し要点を洗い出す事で，理論の妥当性を検討し，より深い理解への助けとなると考えられる．ここでは，モデルで仮定した，(1) カテゴリ尤度が正規分布で従う事，(2) 与えられたデータへの適合性の評価をしないこと，についてポイントをまとめて理論的な拡張性を示す．また，提案モデルを含めて複数の理論を統一的に見る観点から，(3) 他の統計的なモデルの基準との関連性を指摘する．

(1) カテゴリ尤度の正規性　詰め込みモデルの定式化 (3.3 節) では，全てのカテゴリの尤度分布が正規分布に従う事を仮定した．多くの基本カテゴリでは，プロトタイプ (中心的表象) を中心として事例の典型性になだらかな勾配がある [15] ため，この仮定は基本カテゴリの尤度分布の近似としては妥当であると考えられる．一方，より一般に，特に上位カテゴリや下位カテゴリ，また人工的に定義したカテゴリでは正規性の条件を満たさない事が多いと考えられる．このような基本カテゴリと一般のカテゴリの尤度分布の違いは，詰め込み理論により一貫して説明可能だろうか．また，詰め込み理論を階層的なカテゴリや，より一般のカテゴリの形式に拡張する事ができるだろうか．これらの発展的な疑問の足がかりとして，カテゴリ尤度が複数の正規分布の集合からなる場合 (混合正規分布) の詰め込みモデルの定式化を付録の A.4.6 節に示した．十分な数の混合正規分布を用いれば，任意の連続変数上の確率分布が十分に近似できると考えられるので，この定式化は詰め込み理論の正規性の仮定を緩和すると考えられる．また正規分布をカテゴリ内に複数含む事から階層的なモデルとみなせる．

混合正規分布による定式化では，詰め込み効率化によって同一カテゴリ内の二つの正規分布の中心位置が，異なるカテゴリに属する二つの正規分布の中心位置よりも近づく事を示せる．従って，混合正規分布を仮定した場合にも，詰め込み効率化の結果，最終的に得られる分布の形状はある点を中心とした単峰型である事が予想される．今後，カテゴリ学習の実験などにより，このような理論的な予想の妥当性を検討する事が課題として挙げられる．

(2) データ適合性　本研究の詰め込みモデルの定式化では，ベイズ理論に則って議論を展開した．しかし，この定式化ではカテゴリ尤度の関係のみに着目し，各カテゴリの事前確率や，事例の分布 (データ) を単純化 (i.e., 一様等頻度) と仮定してきた．ある事例の分布が与えられた場合には，カテゴリ表象はデータとの適合性が問われるべきであり，この場合の滑らかな構造の発生条件を調べる事は重要である．付録の A.4.7 では，データにカテゴリラベルが無く，このデータが混合正規分布から得られた場合 (i.e., 混合正規分布による教師なしクラスタリング) の定式化を示した．これは詰め込み効率化の最適化を制約条件とするクラスタリングとみなせる．この定式化から導かれる (現時点での) 定性的な結果は，データの適合性を考慮した場合にも，データ最適な解 (i.e., データから計算できる平均・共分散) と制約つきの最適解との差分が滑らかな構造となる事を示す．言い換えれば，学習初期のデータ数が少なく信頼性が乏しい場合に滑らかによる予測を利用し，データが十分に増えた場合にはデータのみからカテゴリ分布を推定する，という二枚腰の戦略に対応する．これは，幼児の即時マッピングと一貫した戦略である．従って，今後の課題として，実際のデータ分布を用いることで，データと詰め込み効率への重みづけの戦略を詳しく調べる事が期待される．

(3) 他の統計的モデルとの関連性　詰め込みモデルの識別性の関数 (式 3.7) は，正規分布に従う尤度を持つ 2 つのカテゴリの最小誤識別率の一つの近似的上界 (Bhattacheryya upper bound, [60]) の拡張として与えられる．付録の A.4.5 では，この関係から Corter & Gluck [24] が基本カテゴリを表現するメトリックとして提案したカテゴリ有用性 (Category utility) と識別性の関数 (式 3.7) に近似的な関係がある事を示した．また，これらのモデルの基準の近似的な関係をモンテカルロ法によって調べた (A.4.5.3)．この結果から，詰め込みモデルの識別性の関数とカテゴリ有用性はほぼ同等である事が示された．従って，モデルの持つ関数の比較から，カテゴリ有用性などの幾つかの統計的モデルは，カテゴ

リの汎化能力 (本研究では包含性と集約性として表される) の評価を欠いている事が示唆される．つまり，詰め込みモデルの他のモデルに対する違いは，(単純化したデータ構造の仮定の下で) 汎化能力を評価として加えた点である．

3.9.3 研究の展望：基底の安定性，階層性，文脈に対する柔軟性

本章で繰り返し述べてきたように，特徴空間の幾何学的性質を決定するカテゴリの表現基底は，詰め込みモデルの最も重要な仮定である．シミュレーション 2 では，特徴次元ごとに重み付ける分散比モデル (MDA) と比較する事で，この仮定の妥当性を検討した．続く第 4 章では，具体的な新奇語汎用課題の予測を行うことで，カテゴリの基底に関する仮定の妥当性を検討する．幼児の新奇語汎用に見られるパタンは，カテゴリ凝集性の具体的な切り口と位置づけられる．従って，これを説明する事でカテゴリの詰め込みの妥当性を，抽象的な「カテゴリの滑らかさ」に留まらず，具体的な心理量として検討する．

また，本章の議論では，煩雑さを避けるためにカテゴリ化の持つ二つの重要な性質を犠牲にしてきた．一つは，カテゴリと特徴の階層的な性質で，もう一つは，与えられた文脈に柔軟にカテゴリ化が変化する性質である．

一つの対象を，複数の階層に渡ってカテゴリ化する事 (e.g.,「動物」,「イヌ」,「プードル」) は，詰め込み効率化の観点からは，カテゴリの汎用範囲が重複するので冗長であると考えられる．それでは，このような従属的な階層関係が発生する事は効率化の観点から説明できないのだろうか．これまでのカテゴリの理論的研究では，カテゴリや特徴の階層性が存在する事を「前提」として，その階層性の違いを説明する事に焦点を当ててきた [24, 25, 1]．しかし，そもそもなぜ階層性が発生するのか，という素朴な問いが最も重要であり，答えることが困難であるように思える．そこで，第 5 章では，視覚的属性の階層的な構造の発生と，カテゴリ化の効率性との関係を検討する．

人は目的や文脈に応じて，適切なカテゴリを柔軟に構築・選択することが知られている [63]．カテゴリの詰め込みモデルには，このような動的な情報は考慮されておらず，むしろ，文脈に共通の静的なカテゴリ構造について議論してきた．第 6 章では，言語的な文脈によって変化する新奇語の汎用を説明するモデルを提案する．このモデルでは，カテゴリの全体的構造は文脈に対して不変で，全体の相対的な構造が変化しない点で，詰め込みモデルと一貫している．しかし，特徴空間を射影する方向だけが，与えられた言語的なカテゴリを識別する効率性によって変化する．文脈依存的モデルへの拡張は，日本語と英語の統語

的カテゴリと相関する新奇語の汎用パタンを説明する事で検討した.

第4章　カテゴリの表現基底

第3章で提案した詰め込みモデルは，カテゴリの凝集的な構造を「滑らかさ」により指標化し，一般的な形式でカテゴリ凝集性の発生メカニズムを説明した．ここでは，幼児の新奇語汎用行動に見られる「存在論的カテゴリ」の分化を主題として，具体的にモデルの適用を行う．前述のように，幼児は固形の物体 (Solid objects) には形の類似性，非固形の物質 (Non-solid substance) には材質の類似性を重視して新奇語を汎用する事が知られている [26, 32, 27]．概念発達の文献では，この二つの概念領域 (i.e., 固形の物体と非固形の物質) を「存在論的カテゴリ」と呼び，特に重要視する．幼児の物体・物質の存在論的カテゴリの理解が多くの概念形成の基礎となると考えられるためである [2, 33]．また，同時に二つの概念領域の分化は，二つの凝集的なカテゴリ群の形成ともみなせる．従って，存在論的な二つのカテゴリ領域の発生，そしてその堅牢性という観点から，これまでに提案されたモデルと比較する事で，詰め込みモデルの妥当性を検討する．

凝集的カテゴリ発生のための統計的基底　先行研究では，存在論的カテゴリの発生要因の一つとして，名詞カテゴリに潜在する統計的な偏りの学習が指摘されている [52]．Colunga & Smith [26] と Samuelson [27] は，統計的学習モデルによって存在論的カテゴリの形成モデルを提案している．しかし，これらの先行研究では，複数のモデルを比較していないので，統計的性質から存在論的カテゴリを形成するために，彼女らのモデルが最適であるのか明らかではない．従来，少数の人工カテゴリの学習のモデルとして，事例モデル [20, 18, 51] やプロトタイプモデル [16, 34] が用いられてきた．これらのモデルは，同径基底関数 (Radial Basis Function: RBF) の一種と考えることが出来る．RBF モデルはある中心点から同心円状に広がった複数の活性化基底の重ね合わせにより，入・出力の関係を近似する．第3章で提案した詰め込みモデルも，ガウス関数をカテゴリの基底としており RBF の一種である．一方，Colunga & Smith と Samuelson の提案した存在論的カテゴリ形成のモデルは，連続値ホップフィールドモデル (Continuous Hopfield Network: CHN) である [26, 27]．CHN モデルのユニットは双方向に全結合し，確率的に活性値を決定するのが特徴である．このモデルは事例やプロトタイプ単位ではなく，特徴空間全域を特徴次元ごとに更新する学習を行なう．

RBF モデル，CHN モデルのどちらでも，十分なユニット数があれば任意の精度で，学習セットの任意の入出力間の関数を表現する事ができる [64]．しかし，新奇語の汎用課題では，幼児 (またはそのモデル) にとって「未学習」パタンに対する汎化が調べられ，この汎化パタンにはモデルの内部表現の「くせ」が顕著に現れると考えられる．既に，第 3 章のシミュレーション４では，ランダム分布点に対する詰め込みモデルのカテゴリ化パタンを調べた．これに対して，本研究では，具体的な事例の特徴構造を幾つか設定し，RBF 型，CHN 型のモデルの存在論的カテゴリ形成を調べる事で，自然カテゴリの統計的基底を検討する．次に，存在論的な違いを示唆する新奇語汎用課題と，その一つの要因と考えられている名詞カテゴリの統計的な偏りを示唆する研究を紹介する．

新奇語汎用課題　Samuelson [27] は次のような実験を行い，15〜21ヶ月の幼児が固形物体の汎用の際に形バイアスを持つことを示した．

1. 実験者が標準刺激を提示し，その刺激に対して「This is my **wug**.」と未知の単語「**wug**」のラベル付けを可算/非可算名詞のどちらでもない，中立的な文法で行った．
2. 2 つの選択刺激（形類似刺激と材質類似刺激）を提示し「Can you get your **wug**?」とどちらの物体が「wug」であるかを幼児に強制選択させた．

標準刺激と選択刺激の固形性 (固形／非固形) が統制された要因で，知覚的特徴を統制された 2 つの選択刺激 (形類似／材質類似) のどちらを幼児が選択するか調べられた．固形物はビスケットやチョーク，非固形物はジェルやローションで作られた刺激が用いられた．

3 歳児の典型的なパタンは，固形の物体に対しては形の類似性，非固形の物質に対しては材質の類似性に基づく汎用である [26, 32]．ところが，以上で述べた Samuelson の実験では，15ヶ月児が固形の物体に対して形類似性に基づいて汎用し，一方で，非固形の物質に対しても形類似性に基づいて汎用する事が示された．15ヶ月児は形バイアスを非固形の物質にも汎用したと考えられ，この過剰汎化を「未熟な形バイアス」と呼ぶ．Samuelson[27] は，CHN モデルにより未熟な形バイアスを再現し，初期に獲得する語彙の統計的な偏りに，その要因があると主張している．

初期獲得語彙の性質　Samuelson & Smith [52] はマッカーサー乳幼児言語発達質問紙 (MacArthur Communicative　Development Inventory; MCDI) [43][1)]に記載されている幼児が獲得する典型的な名詞のリストの 312 名詞について，成人協力者による評定実験を行っている．評定は統語的クラス { 可算名詞/非可算名詞/曖昧な名詞 } と固形性 (solidity){solid/non-solid/曖昧 } とカテゴリ共通の知覚的特徴 { 形/ 色/材質/曖昧 } について行われている．この実験によれば，幼児の名詞は大きく 2 つの群にわかれ，固形 (solid) で，可算名詞であり，形の類似性で名詞の指示対象が定義される名詞群 (e.g. pillow, flower) と，非固形 (non-solid) で非可算名詞であり，材質の類似性で名詞の指示対象が定義される名詞群 (e.g. snow, butter) である．以後これを形-固形性の語彙性質と呼ぶ．Colunga & Smith[26]，Samuelson[27] のモデルでは，このような初期獲得名詞の統計的性質を単純化した特徴セットを学習している (詳細はシミュレーション 1 を参照)．第 3 章で示した「滑らかなカテゴリ」は，概念領域ごとに固有の特徴空間があり，それらが連続的である事を意味している．従って，形-固形性の統計的な関係は,「滑らかなカテゴリ」の具体例である．ただし，形-固形性の語彙性質には，非固形な物質との連続性は考慮されていない．重要な点は「固形」であれば「形」が名詞カテゴリを定義しており「非固形」であれば「材質」が名詞カテゴリを定義しているという点で，モデルではこの非明示的規則を統計的学習により獲得し，新奇な対象に対しても応用するとされている．

本研究の論点　本研究では，新奇語の汎用における形バイアスをモデル化することで，固形の物体と非固形の物質という二つの存在論的概念の形成メカニズムを検討する．特に，先行研究の CHN 型のモデルと，第 3 章で提案した RBF 型のモデルを比較する事で,「カテゴリの表現単位」を模索する．具体的に，以下の 3 点を検討した．

1. CHN モデル，RBF モデルではどのような学習を行なうか，またその学習は形バイアス発現を説明するのに適しているか．
2. 名詞カテゴリのどのような統計的構造が，形バイアス再現に必要か，また十分か．
3. 限定された知覚次元 (形，材質，固形性) についてのモデルでなく，より現実的なモデルに拡張可能か．

[1)] 18-30ヶ月の幼児の発話，理解などの言語発達を調査するため開発された用紙で，この時期に子供が獲得する語彙が記載されている．

1. の論点では，先行研究で提案されている CHN モデルと RBF モデルそれぞれの学習・汎化特性を検討する事で単に統計学習というだけでなく，さらに深い議論をすることが目的である．2. の論点では，1. のモデルの特性と不可分な学習対象の統計的な特性を調べる．3. の論点では，学習対象がより一般に拡張された場合にモデルが適用可能か議論する．　先行研究の CHN モデルでは知覚属性は形，材質，固形性に限定されているが，現実の幼児は無数の特徴の中から「形バイアス」を抽出しているはずである．そこで，モデルがより現実的な多次元の対象を学習して形バイアスを発現できるか検討する．

以上の論点 1., 2. はシミュレーション 1，2 で CHN モデルの検討を行なった．また，シミュレーション 1，2 で明らかになった先行研究の問題点を考慮してシミュレーション 3 では RBF モデルの検討を行った．最後に，シミュレーション 4 では，現実的な名詞カテゴリへの拡張に焦点を絞り，RBF モデルの検討を行なった．

4.1　シミュレーション 1：CHN モデル

Samuelson[52] は固形の物体は形の類似性によりカテゴリ化される事 (形-固形性の語彙性質) を示唆した．これを満たす条件下でも，学習セットの構造にはまだ自由度が残されており，幾つかの異なる条件を設定する事が出来る．先行研究 [26, 27] で検討された学習セットでは，固形の物体であれば材質次元で事例ごとに一様乱数値を持つように仮定されている．従って，シミュレーションにおいて，固形の事例の汎用に材質次元は全く役に立たないと考えられる．同様に，非固形の事例の汎用には形次元は全く役に立たない構造が仮定されていた．この仮定の意味する事は，固形の物体と非固形の物質は，完全に異なるカテゴリ化パタンを持ち，その領域内では形または材質の単一の特徴でカテゴリ化されている，という事である．自然カテゴリが多くの例外を持ち単一の特徴で記述できない事 [8] や，滑らかな性質を持つ (第 3 章) 事を踏まえると，先行研究におけるこの学習セットは，非現実的な事例の分布構造を仮定している可能性がある．そこでシミュレーション 1 では，先行研究で検討された学習名詞の統計的構造に加えて，検討されていない新たな二つの条件について，新奇語汎化課題のシミュレーションを行なった．新たに加えた学習セットの条件は，カテゴリの「多様性」と「未知性」である．先行研究では，全ての固形物体が材質次元で同じ平均・分散を持つので，材質次元が全くカテゴリ化に寄与せず (一様性),

また,「新奇事例」の特徴次元の一部は学習セットと重複していた (既知性). これに対し，今回のシミュレーションにおいて多様性を持つ学習セットでは，固形物体は材質次元でばらつきが大きいが，異なる平均を持つことが仮定された. また未知性を持つ学習セットでは，学習で一度も出現しない特徴を持つ新奇事例がテストに用いられるとした. 以上のように学習する名詞の統計的性質を変えることで，形バイアスの形成，そして固形性に関する存在論的なカテゴリの分化がどのように変化するか先行研究の CHN モデルによって検討した.

4.1.1 シミュレーション手続き

Samuelson[27] のモデルと同様の CHN モデルを構築した. 各ユニットが全てのユニットと結合を持つホップフィールド型のネットワークで，入力層，隠れ層，出力層を持ち Contrastive Hebbian Learning (CHL) [65] で結合荷重を最適化する (学習，出力動作の詳細は付録 A.2 を参照). 入力層は形状（12 次元の二値乱数, 詳しくは後述），材質（12 次元），その他（12 次元），固形性（3 次元: 固形/非固形/曖昧），統語（3 次元: 可算/非可算/曖昧）の計 42 次元で構成され，それぞれ物体の知覚的特徴と統語属性を表す. また物体に対応する語彙カテゴリを出力層に 22 次元，隠れ層に 20 次元のユニットを持つネットワークを構成した (図 4.1). ネットワークは後述する物体と語彙カテゴリを学習後，新奇語汎化課題を行い幼児の反応パタンと比較し議論を行なった.

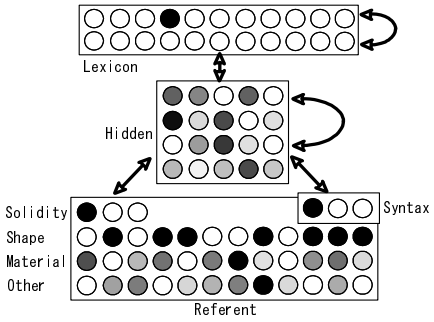

図 4.1: Samuelson(2002) のモデル

- 先行研究の語彙モデル

Samuelson & Smith[52] の知見（表 4.1）に基づき Samuelson[27] は形，材質，その他，固形性を物体の表現としてネットワークの入力とし，本実験でも同様の符号化を行った. 形類似，材質類似，その他のカテゴリ化がなされているもの

表 4.1: Samuelson (1999) の調査による初期獲得語彙の固形性カテゴリ，統語的カテゴリ，カテゴリ化の比率．括弧の隣の数値はモデルでの値で括弧内は評定実験の結果である．

	Solidity classification			Syntactic noun category			Category organization		
	Solid	Nonsolid	Ambiguous	Count	Mass	Ambiguous	Shape	Material	Ambiguous
Total	.64(.63)	.07(.04)	.29(.32)	.64(.74)	.14(.10)	.21(.16)	.50(.48)	.29(.16)	.21(.39)
Solid				.79(.85)	.00(.02)	.22(.13)	.79(.61)	.00(.11)	.22(.31)
Nonsolid				.00(.00)	1.0(.79)	.00(.00)	.00(.00)	1.0(.51)	.00(.39)
Ambiguous				.50(.65)	.25(.16)	.25(.19)	.00(.30)	.75(.15)	.25(.50)
Count noun	.79(.71)	.00(.00)	.22(.29)				.56(.59)	.11(.06)	.33(.38)
Mass noun	.00(.13)	.50(.00)	.50(.52)				.00(.00)	1.0(.58)	.00(.42)
Ambiguous	.67(.56)	.00(.06)	.33(.38)				.67(.28)	.00(.43)	.33(.39)

を，定義される次元は特定値 (0,1 の 2 値) で，他の次元を事例ごとに一様乱数 (0-1 の連続値) で値を生成した．例えば，形類似によりカテゴリが形成される語彙カテゴリの場合，形は「101101000101」のように 12 次元が固有の値で局所的に表現されるが，材質，その他の次元は提示事例ごとに一様乱数 (0-1 の連続値) により生成した値を割り当てた．また，物体の固形性は固形である場合「100」，非固形である場合「010」，曖昧の場合「001」で局所的に表現した．同様に可算/非可算の区別も，可算名詞なら「100」，非可算名詞なら「010」，曖昧なら「001」で表現した．22 個の語彙カテゴリは出力層において局所的に表された (e.g. 「0010...00」)．

学習コーパス構成比率は (可算名詞，固形物，形類似カテゴリの割合)，先行研究同様 [52] のコーパス調査結果に従った (詳細は表 4.1 を参照)．Samuelson [27] によれば，コーパス中の大部分の名詞は，形類似-固形-可算であり，この比率や相関が形バイアス獲得には重要であることが示唆されている．

- 語彙モデルの条件

先行研究と同じ標準条件に加えて，新奇語汎化課題において未学習の特徴が提示される未知条件，名詞カテゴリを規定しない特徴次元でカテゴリごとに固有の散らばりを持つ多様条件，の 3 条件を設定した．3 条件の学習語彙の統計的性質を概念的に示したのが図 4.2 である．この図では形，材質，固形性がそれぞれ 1 次元で，その他を除いた計 1 次元で物体が表現され，2 つの固形物体と 2 つの非固形物体のカテゴリの分布が白で表示されている．

標準条件

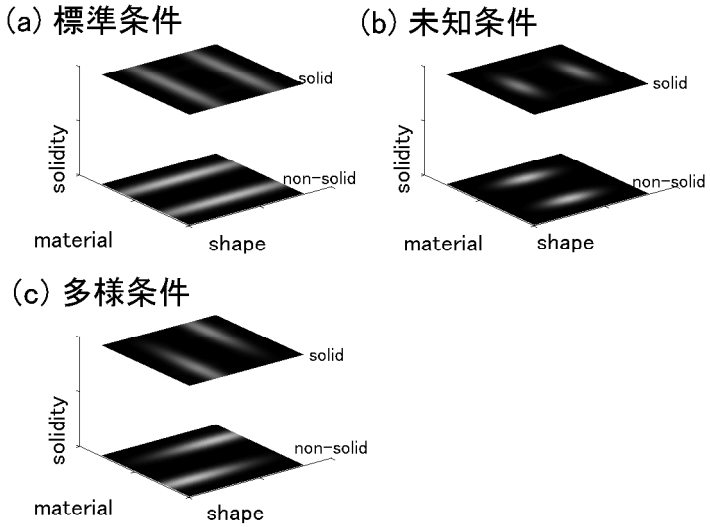

図 4.2: 名詞カテゴリの知覚特徴空間．白領域から学習刺激，黒領域から標準刺激が提示される．

標準条件 (図 4.2a) はカテゴリを規定しない特徴次元がどのカテゴリも一様頻度で出現し (一様性)，新奇語汎化課題で提示される刺激 (図 4.2 の黒領域) は学習した特徴 (図 4.2 の白領域) と同じ範囲から提示され (既知性)，Samuelson [27] と同じ条件である．

未知条件

一様性を持ち既知性がない学習を行なう条件で，カテゴリを規定しない特徴次元の値域を標準条件の 1/5 にした (図 4.2b)．図 4.2b のテスト刺激 (黒領域) が学習刺激 (白領域) より広いので未学習の特徴の組み合わせが課題で提示される．

多様条件

既知性を持ち一様性がない学習を行なう条件で，カテゴリ特徴の分布の平均値が異なる (図 4.2c)．この条件では固形物でも材質次元でカテゴリ固有の範囲を持つ (白領域がずれている) のである程度のカテゴリの判別が可能である．

- 新奇語汎用課題

モデルでは学習後に新奇語汎用課題として，未学習の標準刺激に対して，形，材質が異なる選択刺激のいずれかを強制選択する課題を行った．Samuelson [27] と同じく固形，非固形刺激の 2 条件があり，未学習の標準刺激はそれぞれ固形次元が solidity=solid，non-solid (図 4.2(a),(b),(c) の黒で表された超平面．実際には solidity は 3 次元で表される．) で固定され，その他の形，材質などの次元は特

徴は一様乱数 (0-1 の連続値) により生成された．次に，2 つの選択刺激は標準刺激と形または材質以外は同じ特徴値を持つが，形不一致刺激の場合は，形次元のみ再び一様乱数で特徴値を決定した (選択刺激は図 4.2(a),(b),(c) の黒の超平面上で標準刺激から形，材質軸に平行移動した点となる)．標準刺激と選択刺激 (形，材質不一致) の刺激に対する出力ベクトル (語彙カテゴリ) のパタンを式 (4.1)(4.2) を用いて形，材質の選択率を算出した．ただし標準刺激，選択刺激に対する出力ベクトル (語彙カテゴリ値) をそれぞれ $\mathbf{x} = (x_1, x_2, ..., x_n), \mathbf{y} = (y_1, y_2, ..., y_n)$ とし，材質不一致刺激の選択確率 P_{shape}(形類似選択) は式 (4.2) で定義され，標準刺激と材質，形不一致選択刺激の類似度 $s_{shape}, s_{material}$(式 4.1) により決定された．a は距離から類似度に変換する際のスケーリングを表すパラメータである．

$$s = \exp(-a(\sum_i (x_i - y_i)^2)^{\frac{1}{2}}) \tag{4.1}$$

$$P_{\text{shape}} = \frac{s_{\text{shape}}}{s_{\text{shape}} + s_{\text{material}}} \tag{4.2}$$

CHN モデルを検討した先行研究 [26, 27] では隠れ層ベクトルの距離を物体の心理的距離としているが，心理的距離から類似度の算出法は二つの研究で異なる．本研究では類似度を心理的距離の指数関数とする Colunga[26] の算出法を採用した．しかし先行研究と異なる点は，本実験ではすべて隠れ層ベクトルではなく出力層ベクトル距離を評価に用いた点である．これは続くシミュレーション 3，4 で行う異なる構造のモデルと評価基準をそろえるためである．

4.1.2 結果

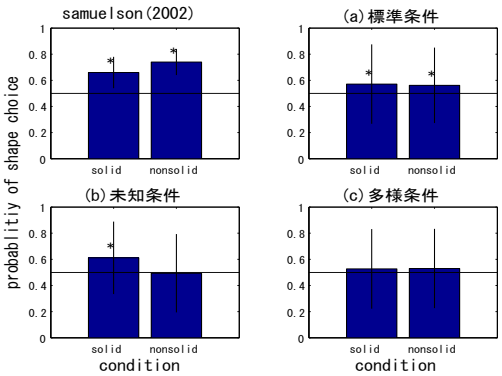

図 4.3: 形類似刺激選択率．チャンスレベル 50%に対し有意に平均が大きい条件を*で示す．

3条件における100回 (初期化の異なる4つのネットワークの各25回) の新奇語汎用課題の平均の形類似刺激選択率の結果を図4.3に示す．各条件における平均値は全てチャンスレベル (50%) との t 検定を行った．まず標準条件においてSamuelson[27] の行動実験 (図4.3左上) ，シミュレーションの結果と同様に固形，非固形条件でチャンスレベルに対して有意に高かった (固形条件:$t(99) = -2.57, p < 0.01$，非固形条件: $t(99) = -1.68, p < 0.05$)．未知条件では固形条件では標準条件の固形条件のみ有意に高かった (固形条件: $t(99) = -3.65, p < 0.001$，非固形条件:$t(99) = -0.29, p = 0.38$)．多様条件では2条件とも有意差は見られなかった (固形条件:$t(99) = -0.79, p = 0.22$，非固形条件:$t(99) = -0.79, p = 0.22$)．以上の結果から，標準条件に対し未知条件では固形条件の形バイアスは再現できたが，非固形条件での形バイアスの汎化 (未熟な形バイアス) は再現できず，また多様条件では固形，非固形の2条件共にチャンスレベルとなり形バイアスを再現できなかった (図4.3右下)．

語彙モデルの単純化を緩和した条件の形バイアスの再現性から，CHNモデルでは形-固形性の語彙性質以外の一様性，既知性が形バイアスの再現に強く影響する事が示唆される．続くシミュレーション2では3つの学習条件における詳細な汎化メカニズムを明らかにしシミュレーション1の考察を裏付けるために，小規模なCHNモデルによる実験を行った．

4.2 シミュレーション2：3次元-CHNモデル

シミュレーション1ではCHNモデルは語彙モデルに非常に敏感で，形バイアス獲得メカニズムが形-固形性の語彙性質だけではなく，一様性，既知性などの制約に依存することが示唆された．シミュレーション1では42次元の特徴で表された22の語彙カテゴリを学習したが，シミュレーション2では個別カテゴリの汎化パタンを可視化して分析する．そのために最低限の3次元の特徴で表された4つの語彙カテゴリを学習した．つまりシミュレーション2で用いる語彙モデルは形，材質，固形性の3次元で表された図4.2そのものである．

4.2.1 方法

ネットワークの入力は形，材質，固形性の各1次元計3次元からなり，出力はカテゴリに対応する語彙が4次元で局所的 ($(1,0,0,0)$ など) に表現され，隠れ層に8つのユニットを持つ．モデルの学習セットの各学習条件における語彙モデルを表4.2に示した．各2つずつの固形カテゴリ (obj0,1), 非固形カテゴリ (sbc0,1) が形

表 4.2: シミュレーション２，３で用いた語彙モデル

		標準条件			未知条件			多様条件		
	出力	Shape	Material	Solidity	Shape	Material	Solidity	Shape	Material	Solidity
obj 0	1000	0	R	1	0	.4*R+.3	1	0	R-.3	1
obj 1	0100	1	R	1	1	.4*R+.3	1	1	R+.3	1
sbc 0	0010	R	0	0	.4*R+.3	0	0	R-.3	0	0
sbc 1	0001	R	1	0	.4*R+.3	1	0	R+.3	1	0

(shape)，材質 (material)，固形性 (solidity) の 3 次元特徴で表現される．カテゴリは出力 4 次元の局所表現で表された．R は 0 から 1 の一様乱数で.4*R は 0 から 0.4 の一様乱数を表す．従って，図 4.2 の入力パタンを実装したものになる．特徴次元数，カテゴリ数が非常に小さくなり，コーパスの構成比率 (固形物:非固形物=1:1) を変更した以外は各カテゴリの確率分布の性質はシミュレーション 1 と変わらず，この語彙モデルはシミュレーション 1 と同じ統計的性質を持つ．特徴空間が 3 次元に限定されており，モデルの挙動が容易に可視化できるので，特徴空間における新奇語汎用課題の標準刺激の汎化パタンを分析した．新奇語汎用課題の際の固形，非固形の標準刺激は固形領域 ($solid = 0, 0 < shape < 1, 0 < material < 1$)，非固形領域 ($solid = 1, 0 < shape < 1, 0 < material < 1$) の 2 つの領域からそれぞれ一様乱数で生成した．それに対して形類似の選択刺激は材質次元のみ標準刺激と異なり乱数で再生成された．つまり標準刺激は固形平面上の任意の一点で表され，それに対し形，材質次元軸に垂直に平行移動した点が選択刺激である．

4.2.2 結果と考察

モデルに新奇語汎用課題で提示する固形刺激は 3 次元の入力空間上の固形平面 (solid=1) の正方形領域に表されるので，それに対する出力パタンを見ることで直接モデルの汎化形式を分析した．標準条件，未知条件，多様条件で新奇語汎用課題で生成された新奇な入力に対するネットワークの汎化 (最大出力値を示したカテゴリ:obj0, obj1, sbc0, sbc1) を solid=1 の平面上の格子点 (10×10: 0.05 から 0.95 までの 0.1 間隔) にプロットした結果を表す (図 4.4)．モデルの動作は確率的であるため，図 4.4 は 1 つのネットワークの学習例における 100 個の標準刺激に対する最頻汎化パタン (30 回試行中) を示している．各条件では，shape 軸に (a) 直交，(b) 直交，(c) 斜交した汎化境界が見られる．提示された標準刺激 (図 4.4 の各点) に対して形類似刺激は形軸に平行移動，材質類似刺激は材質方向に平行移動した点で表されるので，出力パタンが形軸に平行に同じ出

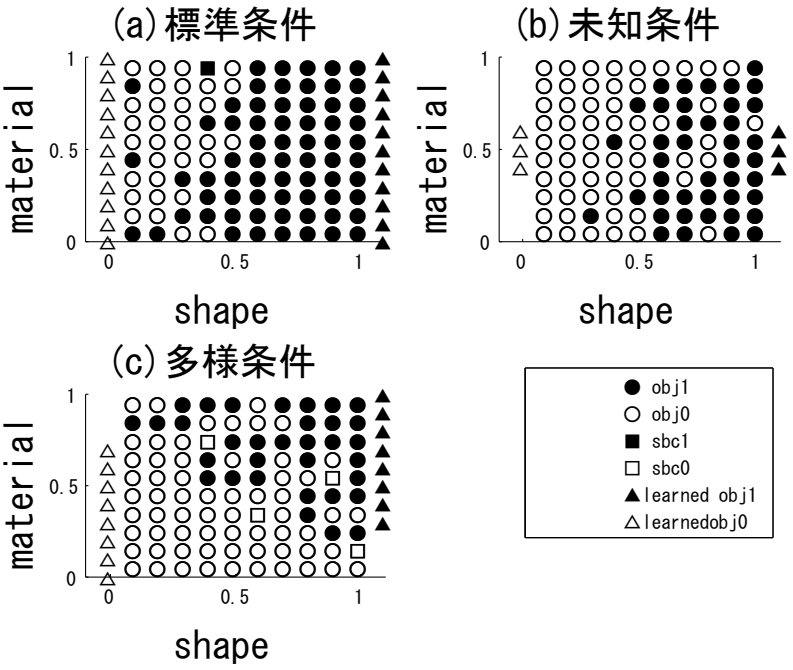

図 4.4: CHN モデルの固形平面上の汎化パタン.

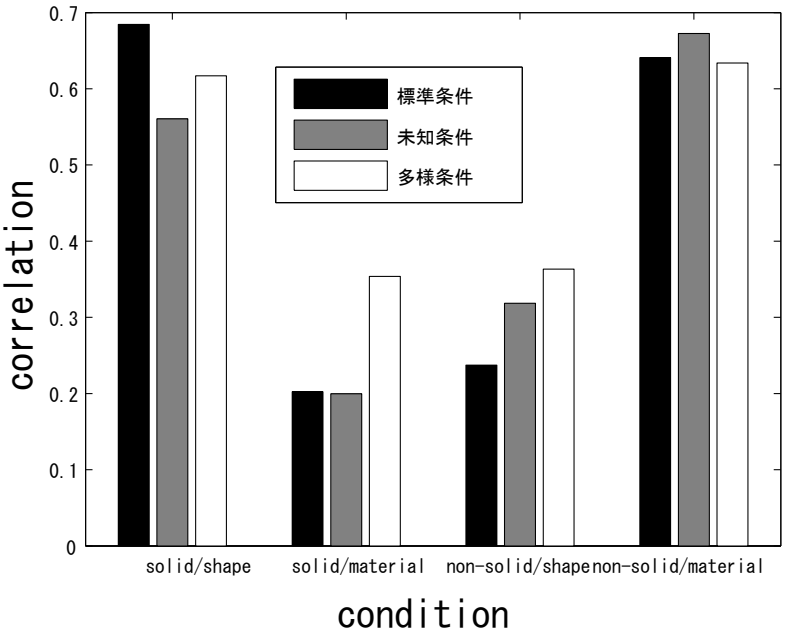

図 4.5: 固形/非固形刺激の汎化パタンと形/材質次元との相関.

力パタンであれば標準刺激に対して形類似刺激の類似度が高まり，選択確率が高くなる (形バイアス)．固形領域で obj0, obj1，非固形領域で sbc0, sbc1 が対称的に学習され汎化パタンも同様であったので以下では固形領域のみを議論する．標準条件・未知条件の固形領域 (solid=1) においてほぼ obj0 または obj1 の 2 カテゴリのどちらかに汎化し，形次元に対して垂直に汎化の分離面 (obj1:●と obj0:○の分離面) ができているので形バイアスが強いと考えられる．一方，多様条件では汎化分離面が形，材質軸に対して斜めに発生し，形バイアスが弱いと考えられる．

汎化分離面が形，材質軸に対して垂直なパタンを持つか測るための定量的指標として汎化パタン (入力空間の形状，材質座標値) と汎化カテゴリ値 $(obj0, obj1, sbc0, sbc1) = (1, 2, 3, 4)$ の Kendall 順位相関[1] の絶対値を用いて分析した (図 4.5)．例えば汎化カテゴリ値が汎化パタンの形次元に従い変化する場合，形次元の順位相関の絶対値は高くなる $(0 \leq |R| \leq 1)$ ので，汎化カテゴリ値と形状との相関が高ければ形バイアスが強いことを意味する．標準条件・未知条件では固形領域・非固形領域でそれぞれ形・材質次元に高い相関を持ち，形，材質バイアスを示すが，多様条件では固形領域でも材質次元に比較的高い相関を持ち，固形領域の形バイアス，非固形領域の材質バイアスが弱くなる事が示された．

標準条件や多様条件での汎化パタン (図 4.4 の左下) から特徴モデルは obj0,obj1 などの隣接するカテゴリから等距離の点にカテゴリ境界を作成する (ボロノイ分割) ように汎化パタンを決定するため，学習カテゴリの配置に対して敏感であると考えられる．そのため，カテゴリ境界が形次元に対して垂直ではない多様条件で，CHN モデルは形バイアスが弱かったと考えられる．この結果は，多様性を持つ現実的な名詞カテゴリの事例分布から，存在論的カテゴリを CHN モデルによって学習するのが困難である事を示唆する．

---

[1] ある二つの組になった系列 S_1, S_2 があり，系列 i, j の対を $O_{1ij} = sign(S_{1i} - S_{1j})$ と符号化する．ただし $sign$ は正値なら 1，負値なら-1，0 なら 0 に写像する符号関数である．このとき同順位修正を行なわない Kendall 順位相関係数は以下で表される

$$R_{12} = \frac{\sum_i \sum_j O_{1ij} O_{2ij}}{\sum_i \sum_j 1} \tag{4.3}$$

この場合 S_1, S_2 がそれぞれ特徴次元の座標値とカテゴリ値に対応している．

4.3 シミュレーション3：3次元-PSALモデル

シミュレーション3ではシミュレーション2で検討したCHNモデルと対比して，事例ごとに重みを調節するRBFモデルによる単純化された名詞カテゴリの学習を検討する．第3章で提案したカテゴリの詰め込みモデルと同様に，カテゴリごとに中心(プロトタイプ)を持ち，特徴次元の重みを調節する事でカテゴリ化を行うモデルを，ここではPrototype-Specific Attention　Learning (PSAL)モデルと呼ぶ[66, 67] (図4.6)．詰め込みモデルと異なるのは，入力層に特徴，出力層にカテゴリラベルが具体的に与えられ，詰め込み効率性の代わりに出力誤差を最小化する点である．シミュレーション1，2で分析したCHNモデルは「カテゴリ特異的に重要な特徴がある事」を仮定しないモデルであったため，特徴空間における個別カテゴリの分布よりも，隣接するカテゴリとの配置が汎化パタンに大きな役割を持っていた．一方PSALは「個別カテゴリの特徴に対し重み付ける」モデルであるので，隣接配置するカテゴリとの関係よりも，個別の特徴重み付けが汎化パタンに強い影響を持つと考えられる．

4.3.1 方法

PSALモデルは入力層，隠れ層，出力層の3層からなる一般化RBFモデルの一種で，隠れ層の基底ユニットごとに注意ユニット(入力の特徴次元に対する重みσ_{ji})を持ち，教師信号に対する二乗誤差を最小化するモデルである．出力層ユニットの活性値o_kは隠れ層ユニットの活性値h_jの荷重線形和で，以下の式で表される．

$$o_k = \sum_j w_{kj} h_j \tag{4.4}$$

また，隠れ層ユニットの活性値h_jは入力層ユニットベクトルI_iと基底ユニットベクトルr_jの荷重付き(注意ユニットσ_{ji})ユークリッド距離で決定され，以下の式で表される．ただしmは正の入力空間の距離基準パラメータでcは定数のスケーリングパラメータである．

$$h_j = \exp(-c(\sum_i \sigma_{ji}(r_{ji} - I_i)^m)^{\frac{1}{m}}) \tag{4.5}$$

学習は教師信号と出力との誤差を逆伝播し，層間の荷重と注意ユニットの重み，隠れ層基底ベクトルを最適化する(詳細は付録A.3.を参照)．

シミュレーション2と同じ入出力パタンに対してPSALモデルによる学習を行い，汎化パタンの分析を行った．モデルの各パラメータは$c = 1$，$m = 1$，

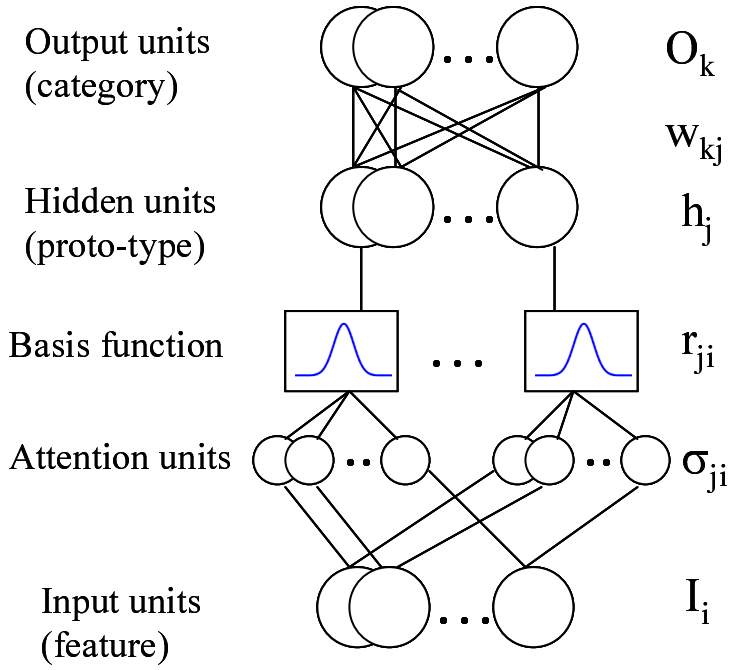

図 4.6: PSAL モデルのネットワークアーキテクチャ

$\lambda_w = 1$，$\lambda_\sigma = 0.1$，$\lambda_r = 0.1$ とし，学習回数は 100 エポック 400 回であった (パラメータの詳細は付録 A.3 を参照)．また基底ベクトルの初期位置は 4 つの入力カテゴリの平均位置とした．

4.3.2 結果・考察

実験 2 同様に出力パタンと形・材質次元との相関の分析を行った (図 4.8)．その結果全ての条件で実験 2 の標準条件同様に「形バイアス」を獲得する結果となった．つまり，PSAL モデルは，カテゴリ配置に依存した境界面を形成する CHN モデルとは異なり，カテゴリごとに分散の大きい特徴 (固形カテゴリの材質次元など) の重み付けを小さくするような汎化パタンを示した．では CHN モデルと PSAL モデルは一体何が違うのだろうか．実は PSAL モデルでも特徴モデルと同じく「等距離分割」をしてカテゴリ境界を決定していると考えられるが，その「距離基準」が異なっている．PSAL モデル中の特徴空間の距離基準はプロトタイプに特異的な特徴注意によって決定されるため，カテゴリを「等距離」で分割しても異なる結果になると考えられる．

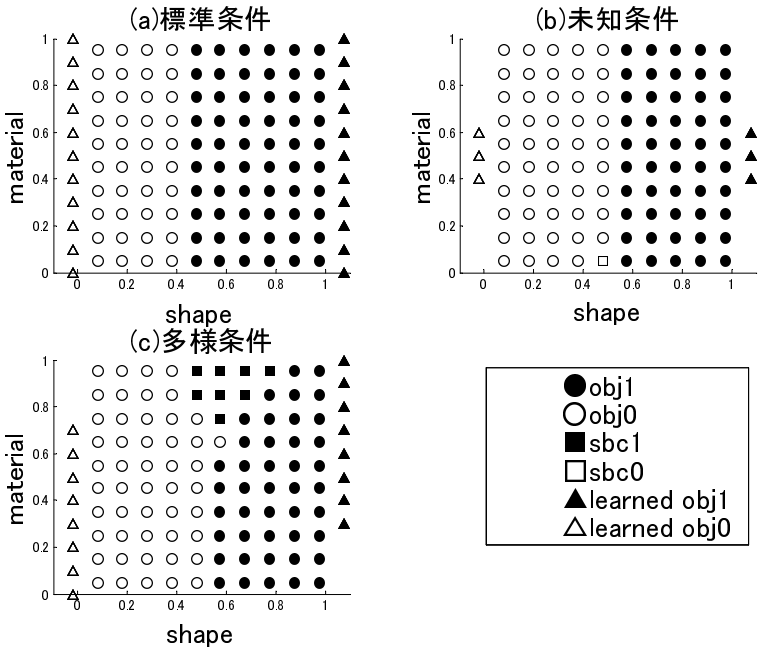

図 4.7: 固形平面上の PSAL モデルの汎化パタン

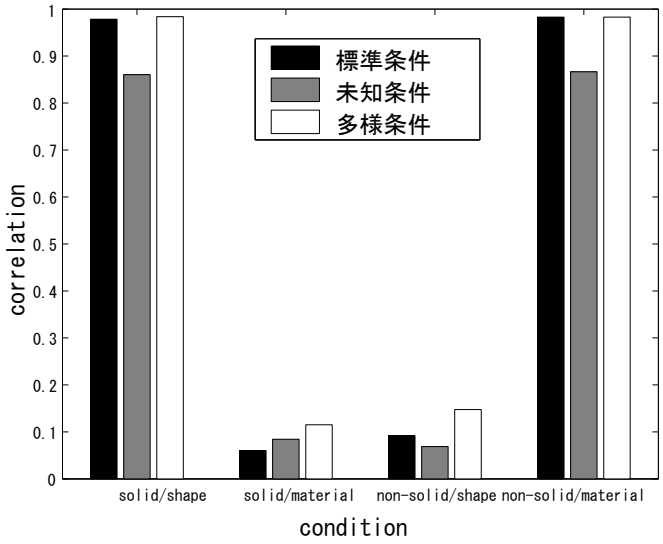

図 4.8: PSAL モデルの相関パタン．全ての条件で形・材質バイアスが見られた．

4.4 シミュレーション 4：PSAL モデルの名詞カテゴリへの適用

シミュレーション 1,2,3 の特徴選択問題では形，材質，固形性だけの限定した知覚的属性のみ物体属性として扱い，既にある程度の「特徴選択」済みの状況であった．知覚的，概念的，言語的情報が混在する日常で統計的学習だけで物体のカテゴリ化に有効な特徴選択が可能だろうか．本実験では形のみではなく，材質，動き，大きさなどの豊富な特徴を持つ知覚空間における特徴選択問題に対する PSAL モデルの有効性を検討することを目的としてシミュレーションを行った．さらに形訓練を受けた 18ヶ月児と通常の 33ヶ月児の新奇語汎用課題の結果と本実験の結果を比較し，モデル内で統語的カテゴリの有無による形バイアス変化の予測を行った．

4.4.1 方法

- 学習する語彙モデル

シミュレーション 4 で扱う「現実的な」コーパスには，第 3 章で用いた評定データ (詳細は第 2 章を参照) を利用する．MCDI の名詞の一部 (312 語中の 48 語) に対して 16 対の形容詞を用いて調べられている．対象となる属性は形，材質などの特定の属性のみに偏っていないので PSAL モデルの能力を試すのに適すと考えられる．

- 学習

PSAL モデルは入力層に物体属性 (16 次元)，隠れ層にはプロトタイプ (48 次元)，出力層には名詞カテゴリ (48 次元) を表すユニットで構成された．一回の学習には一つの名詞カテゴリが選ばれ，それに対応する無作為抽出された協力者個人の評定値 (形容詞次元) が入力として用いられ物体の属性は各次元 1-5 で表現された．調査データの 0.1%が欠損値であり，その値は 3(評定値 1-5 の中央値) で代用された．また教師信号は選出された名詞カテゴリが (0,1,0,...,0) のように局所的に表現された．

学習条件として，単に名詞カテゴリを学習する条件と，名詞カテゴリと可算/非可算名詞カテゴリを同時に学習する条件を設定し，学習後に新奇語汎用課題の成績を評価した．統語あり条件の場合，出力層は [68] に従い (第 6 章の 6.1 を参照) ，可算名詞，非可算名詞のそれぞれを (1,0)，(0,1) と符号化し出力層を 48+2=50 次元で構成した．モデルの各パラメータは $c = 1.5$，$m = 1$，$\lambda_w = 0.15$，$\lambda_\sigma = 0.15$，$\lambda_r = 0.05$(パラメータの詳細は付録 A.3 を参照) とし，学習回数は

48 回の学習を 1 エポックとし 400 エポックだった．また基底ベクトルの初期値は 48 の各カテゴリの全協力者評定の平均値とした．

- 新奇語汎用課題

Colunga & Smith[26] や Samuelson[27] の実験と同じく標準刺激が固形，また非固形である条件を設定し，形類似刺激の選択率で成績を評価した．新奇語汎用課題は，シミュレーション 1，2，3 と同様の方法で行ったが，シミュレーション 4 で学習したデータセットの特徴次元の表現が異なることに注意しなければならない．シミュレーション 1，2，3 では特徴は「形」「材質」など抽象的な上位概念であったが，シミュレーション 4 では「大きい (小さい)」「丸い (四角い)」などの形容語対による具体的特徴による分散表現であるので，直接比較が難しい．しかし，名詞カテゴリの評定実験 (第 2 章) では形容語の表現する知覚次元に関する評定も行っている (例えば,「丸い」は形をよく表現し，材質は表現しないなど)．そこで，先行研究の言語尺度の知覚表現適性に基づいて，形，材質表現に適する上位 2 形容詞対を形，材質次元として選択した．形次元は「丸い（四角い)」（形:0.83，材質-0.25）と「大きい（小さい)」（形:0.63，材質:-0.458）の 2 次元，材質次元は「潤った（乾いた)」（形:-0.75，材質:0.08）と「滑らかな（いびつな)」（形:0.54，材質:0.45）の 2 次元とした．但し，言語尺度の形と材質の表現適性値は適切 (1)〜不適切 (-1) で表現された協力者の平均評定値である．固形刺激条件では，標準刺激の「硬い (軟らかい)」の特徴次元が 5 であり，非固形刺激条件では 1 とした．標準刺激の固形性以外全ての特徴次元は一様乱数で 1-5 の離散値で生成された．それに対して形類似の選択刺激は材質次元 (上記の 2 次元) を一様乱数で再生成し，その他の次元は標準刺激と同じ値で生成された．また材質類似の選択刺激も形次元のみ同様に再生成された．

選択はシミュレーション 1 同様に式 (4.1),(4.2) で定義した出力層ベクトルによる物体間の類似度に基づき行った．シミュレーションは各条件 100 回 (初期化を変えた 4 つのネットワークの各 25 回) の平均を選択率とした．式 (4.1) のスケールパラメータは全ての条件で $a = 50$ とした．

4.4.2 結果・考察

図 4.9 は可算・非可算の統語情報を含む，または含まない学習条件での新奇語汎用課題の形類似刺激の選択率を示している．統語なし固形条件 ($t(99) = 5.52, p < 10^{-4}$)，統語なし非固形条件 ($t(99) = 1.68, p < .05$)，統語あり固形条件 ($t(99) = 5.75, p < 10^{-4}$)，でチャンスレベル (50%) より形類似刺激の選択率

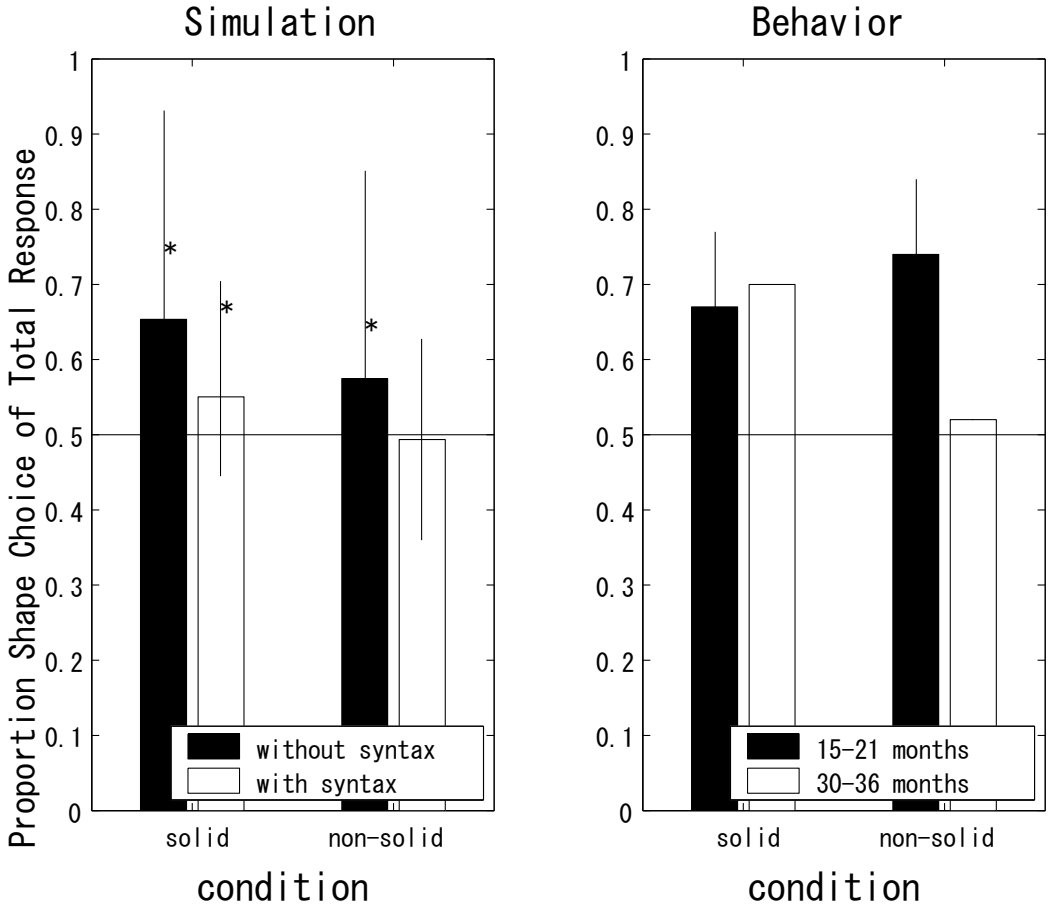

図 4.9: 新奇語汎用課題の形類似刺激選択率

が有意に大きかったが，統語あり非固形条件 $(t(99) = -.473, p = .68)$ では有意差は無かった．統語あり非固形条件を除く条件で，物体に対する形類似刺激の選好がチャンスレベル以上であることから，PSAL モデルが複雑な情報源を学習し形バイアスを示す事が示唆される．ただし，図 4.9 のように 15ヶ月齢の英語話者は固形物，非固形物を区別せず (形バイアスの過剰汎化)[27]，30ヶ月齢では区別して汎用する [69, 32]．一方，モデルの統語なし学習条件では，その区別が見られず 15ヶ月の反応パタンに類似し，統語あり条件では区別があり 30ヶ月の反応パタンに類似している．

以上のシミュレーションの結果は，30ヶ月齢のような固形性の区別のある形バイアスの獲得のために統語的情報が働く可能性を示唆している．心理実験から可算名詞/非可算名詞の統語情報の産出は 2 歳から 2 歳半の間に，理解は 24ヶ月齢で可能であることが示唆されている [33]．15ヶ月，30ヶ月齢は丁度この前

後に相当し，モデルのそれぞれ統語なし・統語あり学習条件と合致する．しかし，モデルのこの結果は，別な知見に矛盾する可能性がある．なぜなら，可算/非可算の統語クラスを学習しない日本語話者でも固形/非固形物を区別して形バイアスを適用すること [32] が示唆されているからである．この矛盾の説明として，一つには存在論的概念が知覚的属性の統計学習で十分に説明出来ず，何らかの推論システムが必要である可能性があり，もう一つは日本語，英語話者が学習するコーパスの統計的性質の違いにより幼児が異なる汎化バイアスを持つ可能性がある．日本語と英語の初期獲得語彙の構成は類似しているが，固形物，非固形物を参照する名詞の割合など異なる性質を持つ [70] ため，形バイアスは学習語彙の違いによっても影響されると考えられる．この考えに従えば，提案モデルは英語コーパスを学習したため，日本語話者ではなく統語クラスの学習経験が浅い英語話者と類似のパフォーマンスが得られた可能性がある．

新奇語のカテゴリ化パタンは，学習する言語に固有な構造によっても強く影響を受けると考えられる．しかし，ここではこれ以上の議論を避け，言語固有の統語的なカテゴリの影響については，第 6 章で詳しく研究を行う．

4.5 結論

形バイアスは幼児が新奇語を物体に適用する場合に顕著な現象であり，概念形成の重要な側面を反映していると考えられる．形バイアスが何に起因しているかは現在でも論争中であるが，本研究では統計的学習に起因するとした立場からその計算論的メカニズムを議論した．特に，既に提案されている CHN モデルとカテゴリ学習などで用いられる RBF モデルのどちらが適しているか検討を行なった．その結果，RBF モデルである PSAL モデルが小規模な仮想コーパスで先行研究より安定した形バイアスを示し，現実的なコーパスでも形バイアスの発現を示した．従って，第 3 章の詰め込みモデルの一つの仮定である，プロトタイプを中心としたカテゴリ表現の妥当性が示唆された．

4.5.1 プロトタイプによる学習

提案モデルの特性を考慮すると，幼児の新奇語カテゴリ化が事例またはプロトタイプを単位としており，それを基に上位の概念に拡張，汎化を行なうという事が示唆される．ではなぜ事例単位カテゴリ化を行なうのだろうか．一つの可能性として，問題領域の分割を行なう事により計算的な利点があるということが挙げられる．提案モデルは内部にプロトタイプを表すユニットを持ち，学

習時には事例に近いプロトタイプについて集中的に学習する．例えば，提案モデルでは「リンゴ」のある事例について学習を行なった場合，類似しない別のカテゴリ「カップ」についてはほとんど学習しない．一方，CHN モデルでは「リンゴ」で修正されたある特徴への重みを「カップ」が共通して持つ場合，影響する可能性がある．幼児の語彙獲得は大人が実験室で学習する人工カテゴリよりも遥かに大規模で複雑な問題である．第 3 章で議論したように，大規模な問題であるほど単一の特徴による境界は形成しにくく，例外も多くなると考えられる．大規模な問題を解く場合に,「リンゴ」に関する知識が,「カップ」や「ミルク」に適用されてしまう (知識の過剰汎化・相互干渉) と，逆に学習が遅くなるのではないだろうか．つまり，プロトタイプ単位の学習の意義は，問題領域を分割し,「全ての領域で応用できる知識」を期待しない点にある．ただし，逆に，プロトタイプごとに完全に独立に学習しては，極端に汎化能力が落ちる事になる．従って，特徴空間が孤立せず，汎化領域が凝集的な性質を持つための「のり」が必要である．そのメカニズムが詰め込み効率化 (第 3 章) であり，学習のプロトタイプ性と相補的な関係にあると考えられる．

4.5.2 統語的カテゴリの影響

シミュレーション 4 で用いたデータセットは形，材質のみならず固さ，動きなどの要因も豊富に含む多次元知覚空間で構成されていたが，PSAL モデルは可算/非可算カテゴリを同時に学習する事で固さと形の関係を抽出することができた．一方，統語情報を学習しない条件において，非固形物に対する形バイアスの過剰汎化が起こった．これを前述の議論を考慮して考えると，統語情報が知覚空間全体で大局的な問題領域の分割を行なうことで，物体/物質の存在論的カテゴリ知識を促進する効果があると考えられる．これは純粋な言語相対性と異なり，統語情報が潜在する知覚的に重要な要因に対する重み付けを変更する役割として働く可能性を示唆する．

第5章　カテゴリ化効率性と特徴の階層性

第3章, 第4章ではカテゴリや特徴次元をそれぞれ独立なものとし，その上でカテゴリ凝集性の発生メカニズムを調べてきた．同様に，多くのカテゴリ化の研究では何らかの意味で特徴次元の独立性[1)]が暗に仮定される事が多い．例えば，第4章で紹介したColunga & Smith[26] のモデルでは，形次元，材質次元は直交した特徴空間を張ると仮定し，形バイアスの発生を説明する．しかし，ある種の特徴次元の独立性が仮定できない場合には，どのようなカテゴリ化が行われるのだろうか．特に，カテゴリや特徴が階層性を持つ場合，上位と下位の階層の間には参照関係が存在し，独立性は仮定できない．本章では，特徴が階層的に定義・処理される (と想定される) 視覚的な物体に関して，そのカテゴリ化および個別化・分節化の効率性について議論する．

遮蔽や移動などの時間経過や場面変化に影響されず，ある物体を同一視しつづけ，他の物体と区別する事を物体の個別化と呼ぶ．一方，静的に呈示された隣接する複数の物体の結合関係 (物体境界) を推定する事を，物体の分節化と呼ぶ [72]．認知処理の時間的スケールは異なるものの，物体個別化・分節化と新奇物体のカテゴリ化は共に，物体が何らかの特徴に基づいて同一視または識別される必要がある点で共通している．これらの物体認知の発達を統一的・一般的な立場から俯瞰するために，本研究では，(1) 物体の形が他の特徴より優先的に発達する事 (形バイアス)，(2) またある特定の発達群では形バイアスが消失する事，を論点とした．本研究は最終的に，物体認知における特徴の階層的な構造および識別の効率性が，これらの心理的な現象を引き起こすメカニズムである事を提案する．まず，本研究で対象とする発達心理的な知見について述べる．次に，本研究で想定する特徴の階層性について説明し，具体的にモデルについて述べる．

5.1　発達心理学的な知見

物体の分節化・個別化の発達　生後1ヶ月の乳児は随意的に目を動かすことが困難である [75]．しかし，3ヶ月児は目に映る出来事を予測できる事から，自分

[1)] Ashby & Townsend [71] によれば，少なくともサンプリングの独立性，次元の直交性，刺激の分離・統合性，識別性能の等価性などの異なる水準の独立性がある

の目の動きを随意的にコントロールできる[1)]と考えられている [76]．物体認知能力の発達は早く，およそ生後4ヶ月を過ぎた乳児は様々な物体認知能力を示す．通常，物体はその形を急激に変えたり消滅したりする事は無く (物体の一貫性 (Coherence)・永続性 (Permanence))，4ヶ月児はこうした物体の遮蔽物に対する連続性や，物体の永続性を理解する [77, 78, 79]．物体の分節化 [73] および個別化 [74] も生後3ヶ月から4ヶ月の時期から可能になると考えられている．我々成人は，日常では物体を分節化および個別化し認識することを「課題」であるとは全く感じない．しかし，これは高度な熟達と事前知識によって成り立つ能力であると考えられる [80]．物体分節化が重要な能力であることは言うまでも無い．物体もしくは物体の境界を正確に見る能力がなければ，幼児は世界の出来事を全く学習できない [81, 7]．そのため，物体の境界位置を特定するために，幼児がどのような手がかりを用いるか調べられてきた．調べられてきた分節化の手がかりとして，物体間の距離などの空間的情報 [82]，動きや物体間の支持関係などの物理的な情報 [73]，形，色，肌理などの物体表面の特徴の情報 [83, 72] が挙げられる．

物体認知における形の優位性　特に，物体個別化に利用される物体表面の特徴を調べた研究によれば，形の異なる物体は早い時期 (4.5ヶ月) から分節化できるのに対し，肌理の異なる物体の分節化は比較的遅く (7.5ヶ月)，色の異なる物体を分節化はさらに遅い (11.5ヶ月) 事が知られている [72]．なぜこのように特徴の種類 (形，肌理，色) によって物体の分節化に発達の遅れが発生するのだろうか (論点1)．3, 4ヶ月児は大人とほぼ同じ色知覚を示すとみられ [84]，また，生後数日の新生児でも顔に類似した複雑なパタンを見分ける [85] ことから，単に肌理や色のパタンが識別できないためとは考えられない．物体認知における形特徴の優位性は物体個別化のみならず，自然カテゴリの分類，知覚，語彙獲得などでも一貫した傾向がみられる．基本カテゴリの多くでは，そのカテゴリメンバーが共通の形を持ちカテゴリを示すよい手がかりとなる [4]．それに加えて，生後3, 4ヶ月の乳児は形状類似を基にして，基本レベルに似たカテゴリを形成できる事が示されている [86]．また，人は様々な知覚特徴の中でも形状類似性に注目する傾向がある [87]．さらに，固形の物体に対する新奇名詞の汎用では形類似性が顕著な手がかりとなる [88]．

[1)] 逆に，眼球運動を自由に統制できなければ目に映る対象を予測できない (対偶命題) と考えられる．

以上で簡潔に述べた心理学的知見は，当然の事ながら，これらの現象は個々に発達の時期や課題の構造などで様々に異なっている．しかし，物体個別化と新奇物体のカテゴリ化は共に，物体が何らかの特徴に基づいて同一視または識別される必要がある点で共通している．実際に，多くの研究で，物体認知と物体のカテゴリ化の強い関係が示されている．例えば，4.5ヶ月児は物体のカテゴリ化の事前知識を利用して物体の分節化をおこなう事が知られている [80]．また，言語獲得期 (2,3 歳) には，物体のカテゴリ化と語彙獲得速度の相関がある事が示唆されている [89, 90]．このように発達のごく初期の段階から言語獲得の段階でも，物体の分節化とカテゴリ化には密接な関係が示唆されており，特に形が他の特徴に対して特別である事 (形バイアス) は共通している．一方で，次に述べるように，新奇名詞の形バイアスが消失し，他の特徴が優位性を持つ事例も報告されている．

非典型的な発達群における形バイアスの消失　第 4 章で述べたように，新奇語汎用における形バイアスを説明として，名詞カテゴリの頻度の偏りに敏感な統計的学習モデルが提案されている．[26, 27]．しかし，学習頻度の要因だけでは説明できない事例も報告されている．Jones [91] は，同年代の幼児に比べて低い語彙数を持つ非典型的な発達群 (Late talkers：以後,「非典型発達群」と呼ぶ) の 3 歳の健常児を対象として新奇語汎用行動を調べた．その結果，平均的な語彙数を持つ同年齢の統制群が典型的な形バイアスのパタンを示したのに対して，非典型発達群は形バイアスを示さず，むしろ肌理バイアスを示した．

前述のように，初期獲得語彙の多くは形類似性に基づくカテゴリである．このようなカテゴリ構造の統計的な偏りが，形バイアス形成の主要因であるとすると，非典型群が肌理バイアスを示したのは，肌理 (材質) 類似性に基づくカテゴリの多い非加算名詞を多数学習したからであると予測できる．しかし，Jones [91] の実験において，非典型発達群の語彙数は，統制群に比べて全体的に少なかったものの，学習した語彙の構成比率 (i.e., 可算名詞と非可算名詞の比率) は統制群と類似していた．もし非典型発達群が平均的幼児と同じ構成比率で学習すれば，学習頻度依存モデルの予測では，非典型発達群は肌理バイアスではなく，むしろ，若い幼児のように形バイアスの過剰汎化をするはずである [27]．つまり，学習頻度の要因だけでは，非典型発達群の新奇語汎用バイアスを説明できないと考えられる．

5.2 物体の階層表現の選択による形バイアスの形成

なぜ物体認知や物体のカテゴリ化で多くの場合，形の認識が他の特徴より優先されるのだろうか (論点１)，また，なぜ非典型的な発達群において形の優位性が消失するのだろうか (論点２).

本章では，論点１と論点２の発達心理的な現象を統一的に俯瞰するために，全ての物体認知に必要不可欠な物体の分節・個別化と特徴階層性の情報処理のモデルを提案する．このモデルでは，課題構造などの様々な詳細を敢えて単純化し，物体が「物体」として発見されるために，どのような特徴処理が効率的であるかに焦点を絞る．このような単純化されたフレームワークを検討することで，特徴の利用の発達順序や，特徴の優位性が変化するメカニズムを明らかにする事が目的である．特に論点２の非典型的な汎用バイアスは，学習頻度の要因だけでは説明できないと考えられる．そのため，提案モデルでは物体分節化の過程における特徴表象の形成，特に物体の視覚的特徴の潜在的な階層構造に焦点を絞って検討する．

5.2.1 階層的な情報処理における循環性

何らかの視覚的な物体が，原画像から形，肌理，色を特徴として切り出される過程について考えよう (図 5.1)．まず，形，肌理，色[1)]がそれぞれ独立な特徴として処理される場合 (図 5.1a) には，原画像からそれぞれある確率で特徴が識別され (図中の白抜きの矢印)，さらにそれぞれある確率でそれらの特徴が物体の分節化のための手がかりとなる (黒矢印)．この特徴処理の段階では，処理系にとって何が物体かまだ明らかではないが，特徴処理によって物体を分節化する事で，個別の物体が確立する．そして一旦，物体を確立すれば，その物体がどのような特徴を持つか答える事ができる (点線矢印)．従って，原画像の特徴の識別性 (白矢印)，特徴から物体の分節化 (黒矢印)，そしてある物体の特徴に関する事前知識の利用や特徴次元に対する注意 (点線矢印) が閉ループの中で相互参照し,「物体」が決定される．この構造は，カテゴリ化の循環性の構造 (図 1.1) と等価である．もし，図中の「物体の分節化」を「カテゴリの識別」と読みかえれば，点線矢印が「環境における特徴の構造がカテゴリを決定」，黒矢印が「カテゴリの領域的知識が注意すべき特徴を決定」となり，図 1.1 のループに一致する．一方，本研究で想定する特徴の階層構造は図 5.1(a) で表される．

[1)] この時点では「物体」の色ではなく，画像の色である

この図でも，特徴と物体は相互に参照する関係にあるが，特徴は原画像から独立に抽出されるのではなく，下位の特徴の組み合わせとして上位の特徴が処理される．例えば，色は最も下位の特徴で，原画像から直接抽出されるが，肌理は複数の色のパタンとして定義され，同様に最上位の形は色または肌理のパタンとして定義される (白矢印)．従って，もし色の識別確率が低い場合，それに依存して上位特徴である肌理や形の識別性も低くなる．特徴処理が階層的な場合と独立な場合では，どのような違いがあらわれるのだろうか．特徴間の従属関係は，物体の分節化に寄与する水準 (階層性の上位・下位) の選択と強く関係すると考えられる．

階層的な特徴処理では，上位の特徴が既に処理した下位の特徴を部分として持つので，全てを独立に処理するよりも少ない情報的な資源で処理が可能であると考えられる．これを処理効率の良さとし，もし特徴処理の階層性・従属性が物体の個別化やカテゴリ化における特徴の寄与率を決定するとすれば，以下の仮説が成り立つ．

- 仮説１：上位特徴に基づく物体の分節化・個別化・カテゴリ化の発達は，下位特徴に基づくそれより早い
- 仮説２：効率のよいカテゴリ学習者は上位特徴を重視するが，効率の悪いカテゴリ学習者は下位特徴を重視する

従って，上位の特徴である形が他の特徴より優先的に学習され，また逆に，学習者の個人差の範囲において，効率の悪い学習者はより下位の特徴である肌理や色を優先する傾向があるのではないだろうか．本研究では，これらの仮説を精緻化するために，物体のカテゴリ化および物体認識における特徴選択のモデルを提案する [92]．提案モデルでは，統計的な偏りや (ボトムアップ：図 5.1 の黒矢印) 特徴に対する注意 (トップダウン：点線矢印) が統制された状況で，ニューラルネットワークモデル (三層パーセプトロン) の内部表現 (白矢印) を視覚的な物体認識に対して最適化する．このシミュレーションの結果を発達心理学的な知見と照らし合わせ，提案モデルの妥当性を検討した．

5.3 シミュレーション

本シミュレーションの目的は，物体分節過程と物体を定義するシンボル的な特徴へのバイアスの関係を調べることである．そのために，我々は識別する物体の特徴を単純化し，カテゴリの学習頻度を統制し，単純化された視覚モデル

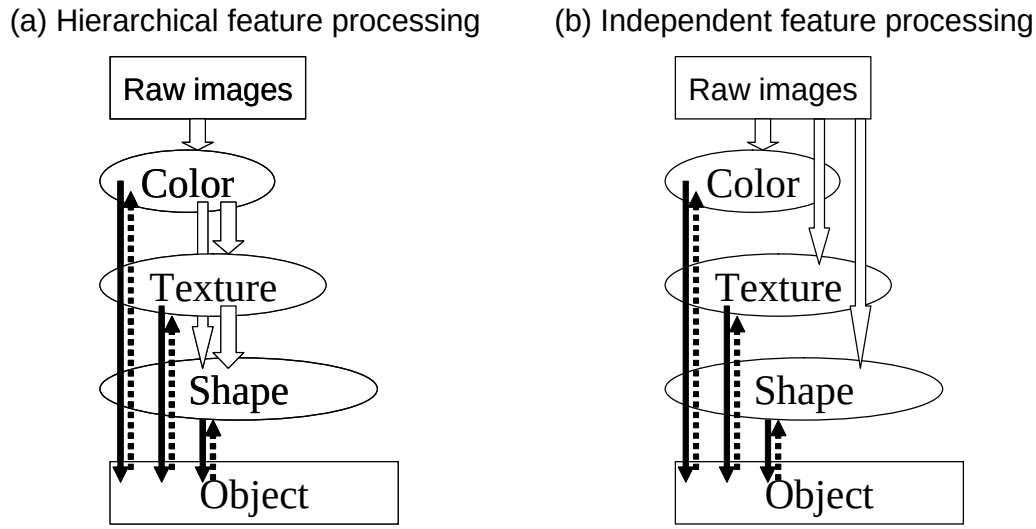

図 5.1: 階層的な特徴の循環的な情報処理

における物体の知覚特徴の統合に特に焦点を絞った．具体的には，形，色，肌理の特徴で定義された一つの物体が視覚シーン (ピクセル単位で定義) に提示され (図 5.2)，この視覚シーンから物体のシンボル的な特徴 (例えば,「明るい」「チェックパタン」の「丸い」物体) を抽出する過程をシミュレートする．シミュレーションでは形，肌理，色の特徴がそれぞれ 4 つの下位クラスを持っていた．この全ての 64 通りの組み合わせからなる視覚物体と，その物体と異なる肌理 (3 通り)，色 (3 通り) を持つ背景のセットを入力として等頻度で用いる．このシミュレーションは乳児が視覚的物体を分節化および個別化する過程に対応している．つまり，ある特定のクラスの形，肌理，色を持った物体を，様々なパタンの背景を無視して同一視し，また他の特徴を持つ物体に対して差別化するという物体個別化の課題である．この課題における形，肌理，色の三特徴の利用の発達を検討する．モデルでは，物体の 3 次元的な構造を全く考慮せず，2 次元的な対象として単純化したこの単純化は，三次元的な構造を考慮する必要のある複雑な物体の分節化を行う事は，乳児にとって困難であるという知見に基づく．Needham [93] によれば，生後 4.5ヶ月の乳児でもある箱の一側面のみが幼児に向けられた場合 (i.e., 箱が二次元的に見える場合) には分節化可能であるが，まったく同じ箱であっても箱の二側面が同時に幼児に向けられた場合 (i.e., 箱が三次元的に見える場合) は 7.5ヶ月未満の乳児は分節化に失敗する．ただし，乳

児が 3 次元視ができないわけではなく[1]，視覚パタンの複雑さの問題であると考えられている．従って，初期の物体分節化は主に二次元的で単純な視覚シーンに基づいて行われると仮定する．また，入力の特徴セットの学習頻度が一定である事は，このカテゴリ化に対してトップダウン的な偏り (e.g., 生得的に形が重要であると言う信念) や，形が異なり色や肌理の同一な物体セットだけが多数経験されるような経験頻度の偏りが無いというモデルの仮定を意味している．モデルの学習する入出力セットの頻度に偏りはなく，全てのモデルが同じ入出力セットを学習するが，個々の三層パーセプトロンは中間層ユニットとの結合加重の初期値が違うため，学習結果に個人差が生じる．非典型発達群は平均的な幼児よりも語彙の学習が遅く，物体のカテゴリ化と語彙獲得の時期に相関がある [89, 90] ことから，非典型発達群は物体カテゴリ化の「非効率的な学習者」であると考えられる．つまり，モデルの個体差の分析により，相対的に学習に成功していないモデルほど肌理特徴の識別率が高い場合が非典型発達群の肌理バイアス [91] に対応すると考えられる．

モデルの仮定をまとめると，(1) 学習する入力は 2 次元的な視覚像であり，(2) 形，肌理，色の全ての組み合わせが等頻度で出現し，(3) 異なる空間位置にある物体の形，肌理，色を同定 (出力) する課題である．このうち，(1) の仮定は，生後数ヶ月の前言語期と，1 歳半を過ぎた言語獲得期では大きく異なる．自発的に物体をつかみ，操作できるようになれば，他の感覚器からより豊富な情報が得られると考えられる．従って，本研究で仮定しないより豊富な情報源を基にして，名詞カテゴリに関する形バイアスを形成する可能性は十分にある．例えば，視覚的な形と触覚的な形には一致がみられ，肌理の視覚的パタンと触覚的なざらつきには相関があり，また光を発する物体は触れると熱いかもしれない．このような多種感覚の相関・一致は物体を構成するための強力な手がかりとなる．感覚器にはそれぞれ固有の違いがあると考えられるが，ある単純化の下では，特徴の階層性や物体の分節・識別は，感覚器に共通の情報処理構造であると考えられる．例えば，触覚的に「形」を識別するには，ある面の粗い領域と滑らかな領域を識別し，その境界の全体構造を構成しなければならない．ある点の触覚パタン (色に相当)，複数点の触覚パタン (肌理)，それらの境界が形成する触覚的な形という階層構造が，視覚による入力と同様に存在すると考えら

[1] 生後 10 日児も奥行きの弁別ができると考えられる [94].

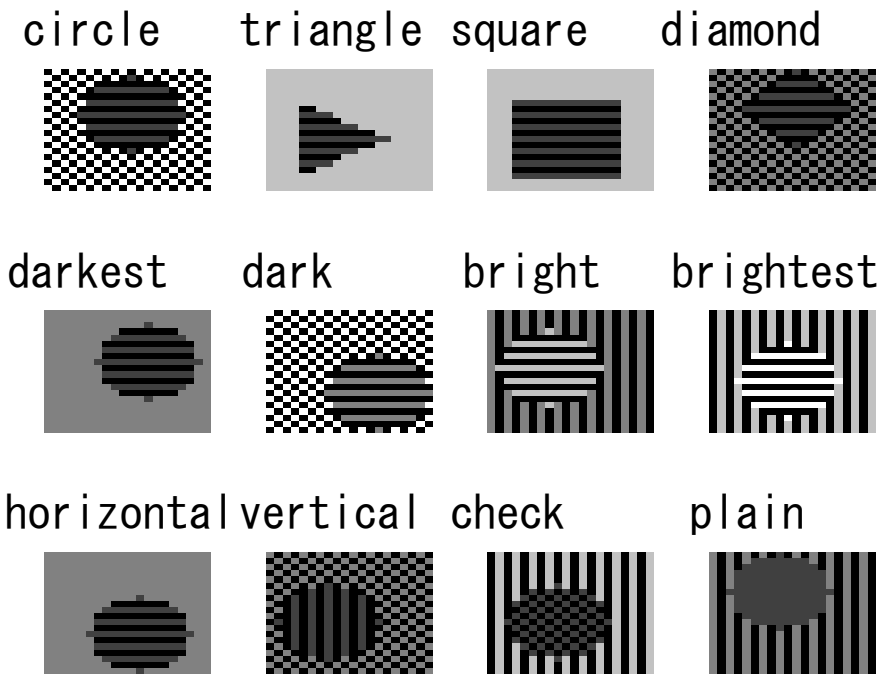

図 5.2: 形，色，肌理によって定義された視覚的物体

れる．当然のことながら，識別の精度や，一度に処理できる空間領域の広さなどは感覚器により様々に異なる．ある空間上の真の物体 (i.e., イデア) を認識において，本質的にある階層性を捉える事が，本研究の目的であり，感覚による射影の違いは単純化して議論する．

5.3.1 方法

5.3.1.1 モデルの構造 モデルの初期の情報処理は，人の初期視覚野で確認されているガボールフィルタ (Gabor filters[7]) による処理を仮定した (図 5.3)．ガボールフィルタは，エッジや，縞模様の傾きを検出する関数となっているため，入力画像セットにおける肌理パタンの抽出が最初に行われる．初期視覚フィルタを通過した信号は，主成分分析により相関する信号の一部を削減され，最終的に三層パーセプトロン (Multi-Layer Perceptron: MLP [60, 95]) により信号が特徴シンボルへと連想学習される．初期視覚フィルタを通過した後，主成分分析によって信号の約 5%の分散に当たる次元を削減し，相関する情報を取り除いた．次の三層パーセプトロンは主成分分析後の信号を入力として，提示された

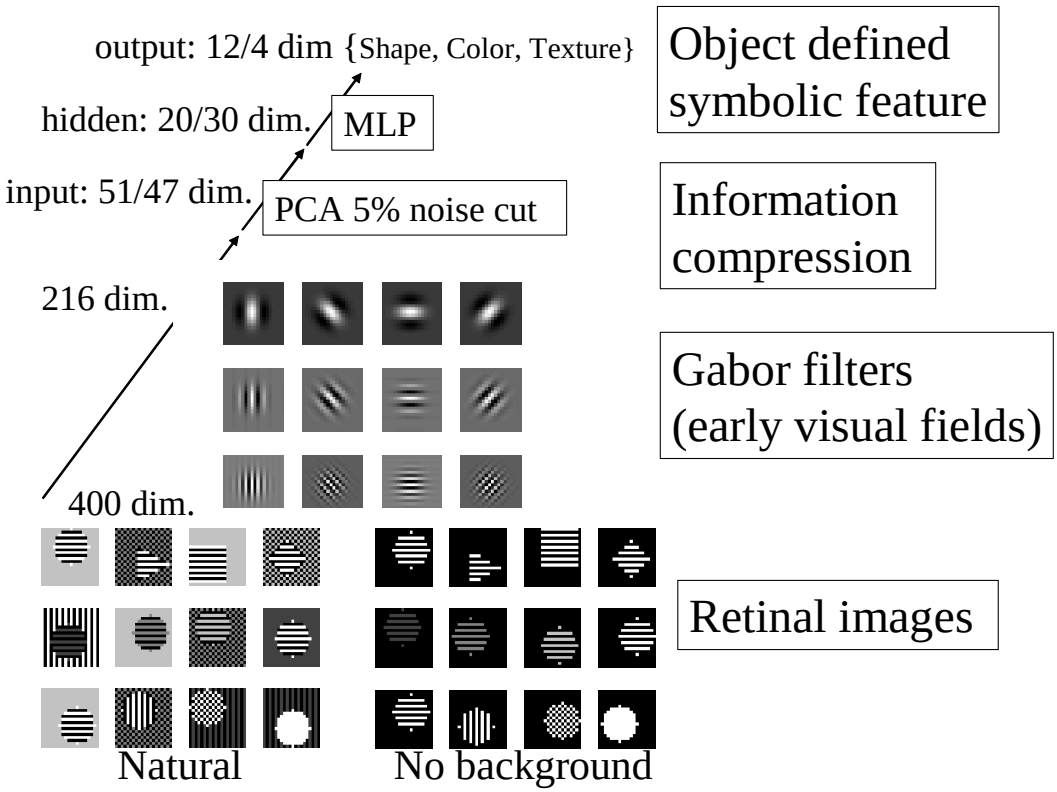

図 5.3: 物体特徴のシンボル化モデルの情報処理過程

視覚物体の形，肌理，色の下位クラス (e.g., 円形，縦縞，明るいなどの組み合わせ) の局所表現 (i.e., 3 特徴の 12 クラスを 12 次元のベクトルの 1,0 で明示的に表現) の出力を行う．三層パーセプトロンでは，ガボールフィルタからの局所的な色・肌理パタンの統合を行い，中間層にそれを分散的に処理するフィルタを形成する．モデルの評価は，形，肌理，色の下位クラスの識別性 (正答率) を各特徴の利用の指標とした．つまり，形の下位クラスの識別正答率が高い場合には，モデルはより物体分節化および個別化に対して形の特徴を利用しやすいとみなした．

5.3.1.2　シミュレーション条件　シミュレーションは，基準条件，単一特徴条件，大容量条件，背景固定条件，の計 4 条件が設定された．基準条件は他の 3 条件の比較の基準となる条件であり，他の条件では基準条件と一つのパラメータが異なる (表 5.1)．基準条件では， 3 層 (入力層：51 次元，中間層：20 次元，出力層：12 次元) の MLP が学習に用いられ，入力の物体セットに対して 400 回のバッチ処理 (1 回の訓練で全ての入力パタンに対する学習 (1 エポックと呼ぶ)

が行われ，つまり計 400 エポックの学習が処理された) が行われた．全ての条件で，100 の異なる初期化をされたネットワークのシミュレーションが行われた．

単一特徴条件では，MLP の出力が形，色，肌理の三つの特徴全部ではなく，いずれか一つの特徴のみの出力に変更され，この特徴セットにおける各特徴の識別性が調べられた．単一特徴条件では，形，肌理，色の個別の識別率を示すので，今回のシミュレーションで設定した画像セットに固有の識別率を表す統制条件にあたる．この単一特徴条件 (統制条件) に対して基準条件や他の条件での特徴統合の効果が議論された．

大容量条件では特徴符号化に対する容量の効果を調べるために，MLP の隠れ層のユニット数を他の条件に比べて多くした (隠れ層のユニット数が 20 から 30)．小さい中間層のユニット数で高い識別性を実現するにはより効率的に特徴を符号化する必要があるので，相対的に大容量条件は符号化の効率が悪いモデルの個体が発生しやすいと考えられる．従って，この条件では，肌理バイアスの発生メカニズムに対する特徴符号化の効率性の影響が調べられた．

背景固定条件では物体分節化による特徴抽出への影響を調べるために，入力となる視覚シーンの背景を単一の色，肌理のパタンに統一した (図 5.3 の”No background”を参照)．背景のパタンを一種類に固定することで，モデルが肌理や色の下位クラスを識別するために物体分節化をする必要がなくなる．なぜなら，固定された背景以外のパタンが物体の色や肌理となるので，物体を統合し厳密に大局的な輪郭パタンを構成する必要が無いからである．乳児は様々な背景をもつ視覚シーンを経験するため背景固定条件は通常では不可能な状況であるが，この特殊な状況では物体分節化の特徴抽出に対する影響を直接的に調べる事ができる．

5.3.1.3　視覚的物体の画像および出力の符号化　網膜に投影された視覚的物体は 20 × 20 ピクセルの画像 (図 5.2) で定義された．物体は背景の色と異なる形，肌理，色の属性を持ち，同一の特徴を持つ物体に対して無作為に決定された異なる三つの位置で入力セットが構成された．具体的に，ピクセルは５種類の色 (輝度) を持ち (0,0.25,0.5,0.75,1)，色のパタンにより肌理のクラス (縦縞，横縞，チェック，無地) が定義され，肌理または色の背景に対する対比によって形のクラス (円，三角，正方形，菱形) が定義される．物体の刺激セットは計 1728 パタン (形 (4) ×肌理 (4) ×色 (4) ×背景色 (3) ×背景肌理 (3) ×中心の空間位置 (3)) からなる．画像は以下の式で定義されるガボール関数 $g(x)$ により変換され，初

条件名	ユニット数			学習成功率 (数)
	入力層	隠れ層	出力層	
基準	51	20	12	71
単一特徴	51	20	4	73
背景固定	47	20	12	68
大容量	51	30	12	73

表 5.1: 各条件の多層パーセプトロンの入力，中間，出力層のユニット数および学習に成功した（100 シミュレーション中の）回数

期視覚過程のモデルとした．

$$g(x) = \exp(-\frac{x^2}{\sigma^2})\cos(2\pi f(x-\theta)) \tag{5.1}$$

ただし f と μ は周波数と位相を表し，$x = \sqrt{(y-y_0)^2 + (z-z_0)^2}$ は中心 (y_0, z_0) から特定の二次元座標 (y, z) へのユークリッド距離である。ガボールフィルタのセットの 216 の異なるパラメータを持つ関数から構成された (傾き (4 種)：0 °，45 °，90 °，135 °; 周波数 (3 種)：0.5，1.0，2.0，受容野のサイズ (2 種)：1, 2，網膜上の受容野位置 (9 種)) ．このガボールフィルタを通して，元の画像セットの約 15.3%(背景固定条件では 15.7%) の分散が失われた[1)]．ガボールフィルタを処理した後の信号は，主成分分析 (PCA) により 5%の分散にあたる寄与率の低い次元が削除され，最終的に背景なし条件では 47 次元，その他の条件では 51 次元の入力ベクトル表現が得られた．従って最終的に，元の画像の約 20%の分散を失った信号が得られた．PCA により得られた特徴次元を MLP の入力とした．入力は MLP により形 (e.g., 円)，色 (e.g., 暗い)，肌理 (e.g., 横縞) などのシンボル的な特徴の出力に結び付けられた．具体的には出力は局所表現により (e.g., (形，色，肌理)= (円, 明るい, 縦縞)=(1, 0, 0, 0, 1, 0, 0, 0, 1, 0, 0, 0)) のように表現された．各特徴における出力の最大値と，教師信号の 1 の値が一致した場合に正答と定義した．各特徴における正答率のチャンスレベルは，4 択であるので 25%であった．そのため学習しても 3 特徴の平均の正答率が 30%に達

[1)] フィルタによって失われた情報は以下の K の I に対する決定係数より得られた．ただし，$J = GI$ ，$K = (G^TG)^{-1}G^TJ$ ．G は 216 × 400 次のガボールフィルタを表す行列，I はフィルタ前の画像の 20 × 20 画素を表す 400 次元の列ベクトル，K はフィルタ後の画像 J と G の一般化逆行列により形成された 20 × 20 画素を表す 400 次元の列ベクトルである．

しないネットワークモデルは，学習過程に問題があった (e.g., 局所解に陥った) とみなし，分析からは除外した[1)]．

5.3.2 結果と考察

まず基準条件の 400 エポックの学習終了後の平均正答率およびその学習経過について述べ，次に他の条件との比較する．各 4 条件の最終エポックにおける平均正答率を図 5.4 に示した．エラーバーは標準偏差の 1/2 を示し，アスタリスクは各条件の三特徴の平均正答率の有意差 (一元配置分散分析による 5%水準) を示す．次に，最終エポックでの平均正答率に対する一要因分散分析を行った．その結果，物体を形，肌理，色の特徴ごとに独立に学習した単一特徴条件では，平均正答率に有意な差がなかった ($F(2, 210) = 0.83, p = 0.44$) が，他の条件では有意な差がみられた (基準条件：$F(2, 216) = 44.26, p < 0.001$； 大容量条件：$F(2, 216) = 32.22, p < 0.001$；背景固定条件：$F(2, 216) = 6.00, p < 0.01$)．この単一特徴条件の結果から，シミュレーションで用いた特徴セットは，単独で学習した場合に，どれも同程度の難易度であることが示唆される．つまり，他の条件で現れた各特徴の正答率の偏りが，今回設定した学習セット固有の特徴構造に依存する可能性を棄却できる．単独に特徴を符号化する事では形バイアスが発生しないことから，この結果をより強く解釈すると，他の条件での各特徴の正答率の偏りは，三層パーセプトロン内部の結合荷重が形，肌理，色を同時表現する分散的な表象を形成した結果であると考えられる．これについては後の分析でモデルの層間の結合の詳しい分析を行った．次に，基準条件の学習エポックごとの正答率について述べ，他の条件と比較する．まず，最終エポックにおける基準条件の平均正答率 (図 5.4) は Jones[91] の統制群の形バイアスパタンと一致した (図 5.5)．新奇語汎用課題は，ある一時点での形特徴の優位性であり同時期の幼児の横断的なパタンであるが，その特徴利用の発達順序は縦断的なパタンである．従って，乳児の物体個別化に対する特徴利用の発達順序とモデルの特徴識別率を比較するために，基準条件における正答率の学習経過を調べた (図 5.6)．各特徴の平均正答率に対して学習エポック数 (平均正答率 30%未満の最初の 30 エポックを除いた 37 水準，40, 50, …, 400 エポック) と特徴次元 (形，肌理，色) を要因として二要因分散分析を行った．その結果，学習エポックの有意な主効果 ($F(36, 10989) = 22.6, p < 0.001$) と特徴の有意な主効

[1)] モデルがランダムに 1728 の刺激に対して 4 択をランダムに答えた場合に，正答率 30%の基準を超える確率は 1/1000 以下である．

果 ($F(2, 10989) = 545.8, p < 0.001$) が見られた．この結果から，ネットワークモデルの学習が成功し，また 3 特徴の正答率が異なることが示された．さらに，交互作用な有意ではなかった (F(72, 10989)=1.04, p=.387) 事から，3 特徴の正答率の相対的な関係 (i.e., 形，肌理，色の順に正答率が高い) は学習エポックと関係なく一定であった事が示された．つまり，ネットワークモデルの集団において，横断的な正答率と縦断的な正答率は定性的に同じ順序であった (i.e., 初期に形の特徴がある水準に最も早く達する場合，どの学習エポックでも最も正答率が高い)(図 5.6)．さらに，基準条件での最終エポックの平均正答率に対する Turkey の多重比較検定によって，形の正答率は肌理の正答率より有意に高く，肌理の正答率は色の正答率より有意に高い事が示された．つまり，モデルの識別率は形，肌理，色の順にある一定の水準に達する．まとめると，モデルの基準条件の縦断的な正答率のパタンは，乳児が形 (4.5ヶ月)，肌理は (7.5ヶ月)，色 (11.5ヶ月) の順に物体個別化の手がかりとして特徴を利用する [72] 事に定性的に一致する．また，その横断的パタンは平均的な幼児の形バイアスパタン [91] に定性的に一致する．

一方，基準条件に対して背景固定条件，大容量条件では，形特徴の平均正答率だけが他の特徴に対して高いわけではなく，肌理特徴と形特徴の正答率が同程度に高かった (両方の条件で Turkey の多重比較検定で形と色，肌理と色の平均正答率のみに有意差 ($p < 0.05$) がみられ形と肌理の平均正答率に有意差が無かった)．つまり，これらの条件の結果は物体個別化 [72] や新奇語汎用課題 [91] での形バイアスのパタンとは一致しない．全ての視覚シーンが同じ背景で構成された背景固定条件では，モデルが物体を背景から分節化する必要がない．従って，背景固定条件と基準条件の正答率パタンの比較から，形特徴の利用が優先されるには物体分節化が必要である事が示唆される．前述のように，背景固定条件とは違い，基準条件は背景が様々に異なるため，物体の大局的なパタンを捉える物体分節化が必要とされる．つまり，基準条件で形識別率が他の特徴に対して優位である理由は，形状という大局的な特徴の選択が “物体を分離し背景を無視する”ために効率的であるためと考えられる．

5.3.2.1　学習個人差の分析　次に，モデルの “個体差” について分析を行った．学習する入出力関係は同じであるが，個々のネットワークは中間層ユニットとの結合加重の初期値の違いにより，学習結果に個体差が生じる．非典型発達群は平均的な幼児に対して，物体のカテゴリ化が相対的に「非効率的な学習者」

であると考えられる．一方，シミュレーションでは，大容量条件のモデルは中間層が多いために，効率的な情報の符号化をする必要が基準条件に比べて低い．従って，大容量条件では非効率的な学習を行うモデル個体が発生しやすいと考えられるので，これとモデルの学習パタンの分布と非典型発達群の新奇語汎用パタンを関連づけて議論する．

正答率の個体差の有無を調べるために，ネットワーク (100 の異なる初期値) と特徴 (形，肌理，色) を要因として，$30, 40, \ldots, 400$ エポックの基準条件の正答率に対する 2 要因分散分析を行った．その結果，モデル個体差の有意な主効果 ($F(99, 10800) = 256.8, p < 0.001$)，特徴の主効果 ($F(2, 10800) = 8.15, p < 0.001$)，およびモデル個体差と特徴間の有意な交互作用がみられた．つまり，平均的には形，肌理，色の順に正答率が高いが，この正答率のパタンを持たない個体も含まれる事を意味する．具体的に個体差の構造を調べるために，モデル個体内での 3 特徴の平均正答率の順に並べ替えて，基準条件と大容量条件でのモデル集団の個体差を分析した (図 5.7)．平均正答率順に並べ替えた成績の移動平均 (最も順位の近い 10 のモデルの平均で平滑化) を図 5.7 の左側にプロットした．第 1 位のモデルが最も 3 特徴の平均正答率が低く，例えば，個人内の平均正答率が 50 位のモデルは，その形，肌理，色の正答率を 45 位から 55 位までのそれぞれの特徴の平均正答率で置き換えられた．個人内の平均正答率 (順位) の低い下位モデル個体ほど，物体のカテゴリ化が「非効率的な学習者」であるとみなし結果の考察を行う．

基準条件のほとんどのモデル個体の正答率は形，肌理，色の順に高かった (図 5.7 左上)．一方，大容量条件の平均正答率の低いモデル個体では，肌理が形の正答率より高い傾向がみられた (図 5.7 左下)．図 5.7 の右側に示された 2 つの図はそれぞれ基準条件 (右上) と大容量条件 (右下) の形と肌理の平滑化平均正答率の差を示した．基準条件では全てのネットワークで形が肌理より高いが，大容量条件では肌理と形の正答率がモデル順位の中間付近で入れ替わることがわかる．形と肌理特徴の平滑化平均正答率の差とモデル順位との相関は基準条件で $-.226 (p = 0.55)$ で有意ではなく，大容量条件では $.692 (p < 0.01)$ で有意に相関ゼロに対して高かった．つまり，基準条件ではほとんどのモデル個体が形バイアスを示すが，特に大容量条件の場合には平均的正答率の低い「非効率的な学習者」が肌理バイアスを示すことが示された．大容量条件の結果は，同時期の平均的な幼児に対して語彙数の低い非典型発達群が肌理バイアスを示す (図 5.5)

という知見と一致すると考えられる．

5.3.2.2　モデル内部構造の分析　基準条件と大容量条件では中間層のユニット数のみが異なるが，なぜ中間層のユニット数の違いが，非効率的な学習者の肌理バイアスに結びついたのだろうか．二条件における中間層ユニットの特徴符号化を調べるために，中間層と出力層の間の結合荷重を分析した．出力層の各次元は局所表現によって形，肌理，色の特定の下位クラスを表すので，中間層と出力層の間の結合荷重は対応する特定の下位クラスとモデルが判断する平均的な確率の高さを符号化している．したがって，この結合荷重から，ある中間層ユニットとある出力層ユニットが同時に活性化する尤度が計算できる．この算出された尤度 (同時確率) から出力層ユニットと中間層ユニットの確率的独立性を調べるために両者の相互情報量を計算した．出力層ユニットと中間層ユニットが確率的独立である場合は，中間層ユニットは特徴の下位クラスを分散的に符号化する事を意味する (i.e., 図 5.1 の階層的処理)．逆に，両者の確率的従属の度合いが高い場合は，中間層ユニットが下位クラスを一対一対応に近い明示的な符号化 (i.e., 図 5.1 の独立処理) をする事を意味する．一般に明示的な符号化に比べて情報の符号化が分散的であるほど，より少ないユニットで多くの組み合わせの出力を表現できる [95]．従って，より少ないユニットを持つ基準条件のほうが大容量条件より分散的に情報を符号化するユニットが多い事が予想される．

三特徴を同時に学習しなかった単一特徴条件を除く 3 条件での各モデル個体の中間層と出力層の相互情報量と平均正答率のプロットを図 5.8 に示す．どの条件でも，平均正答率の高い効率的なモデル個体ほど相互情報量が低い，つまり分散的な情報表現となっている事が示された．基準，大容量，背景固定条件における学習失敗個体 (i.e., 平均正答率 30%未満) を除く個体の平均正答率と中間層-出力層の相互情報量とは負の相関係数をもち，それぞれ-0.92, -0.88, -0.85 であった．また，条件間を比較すると，予想通り，基準条件が大容量条件より分散的で，背景固定条件が最も局所的な表現をとっていた．

この結果は，中間層のユニット数に余裕の無い基準条件では，より分散的・階層的な符号化をする必要があり，そのために大局的な特徴である形を重視するモデルが多数を占めたと考えられる．一方，冗長な表現が許容される大容量条件では，より分析的な特徴である肌理を重視するモデルが発生したと考えられる．新奇語の汎用における非典型的なバイアスは，このシミュレーションの

類推として考える事が出来る．つまり，非効率的な学習者 (非典型発達群) の語彙数が少なく，また新奇語汎用の際に肌理特徴に注目しやすいのは，物体を符号化する際の「情報圧縮率」が低いためであると考えられる．記憶容量とカテゴリ化の関係を調べた研究において，この予測を支持する知見も報告されている．これによれば，記憶容量に強い負荷をかけた場合に乳児は中心的な特徴のみを把握する傾向があるが，記憶容量に負荷の無い場合，中心的な特徴も瑣末な特徴も両方とも把握する傾向がある [96]．このような研究結果を踏まえれば，基準条件は記憶容量の小さい学習者，大容量条件は記憶容量の大きい学習者の違いとして捉える事もできる．つまり，汎化能力を高めるために記憶容量が小さいほうが良いという意味で，本研究の結果は “starting small” [97] [1)]の考え方を支持すると考えられる．

まとめると，統計的学習モデルを物体分節化の領域における物体・特徴の連想に拡張した提案モデルは，定性的な形バイアスパタンと物体分節化で用いられる特徴の順序のパタンを同時に再現した．さらに大容量のモデルにおいて非典型発達群のパタンを，学習頻度と無関係な要因として，モデルの個体差により再現した．シミュレーションの 4 条件の比較により，平均的な幼児の形バイアスのパタンと非典型発達群の肌理バイアスのパタンは，学習者の内的な記憶容量，特徴の結合性，物体の分離過程に依存することを予測する．従って，実際の非典型発達群の物体の認識や記憶容量などを実験的に検討する事で，本研究の予測を検証する事が可能であると考えられる．

[1)] Elman[97] は単語系列から文法構造を学習するモデルを提案し，初期に単語の記憶容量を小さく設定するほうが学習を促進する事を示した．

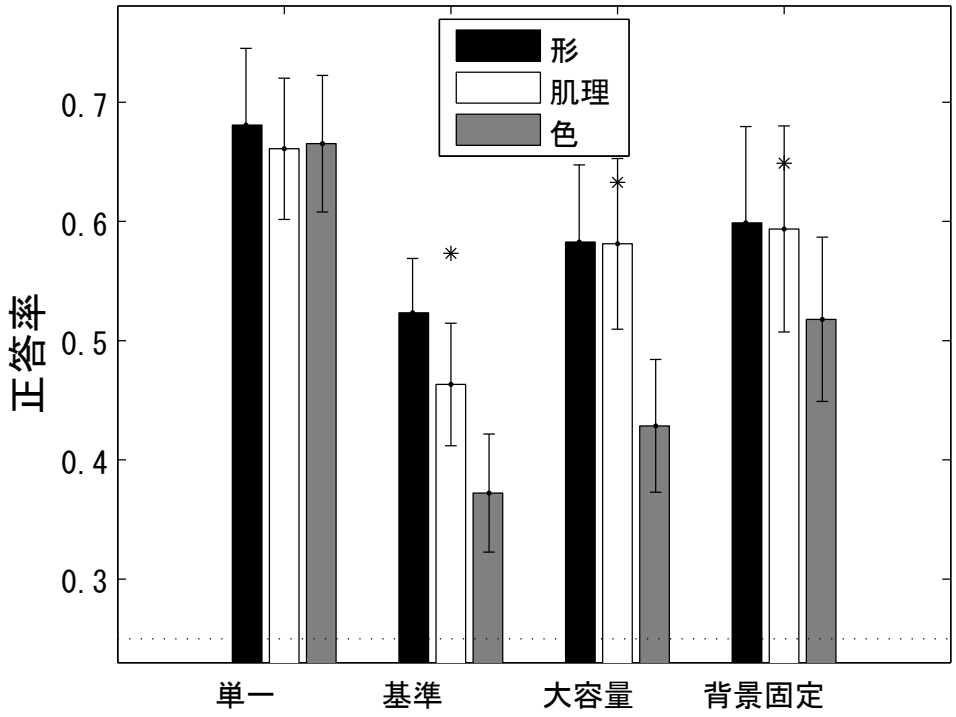

図 5.4: 各シミュレーション条件での平均正答率

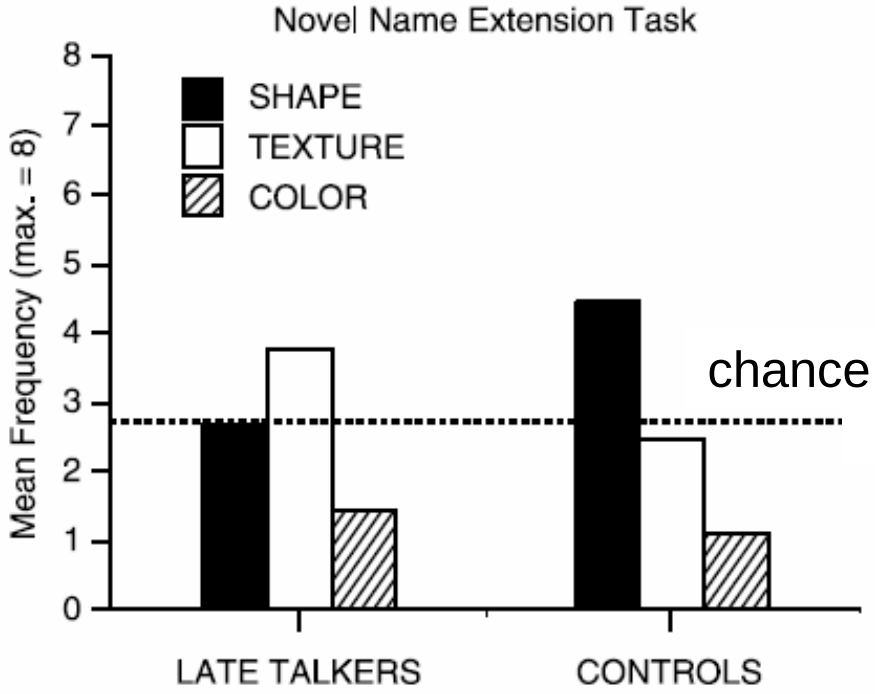

図 5.5: Jones (2003) の新奇語汎用課題の結果：(左) 非典型発達群 (右) 統制群

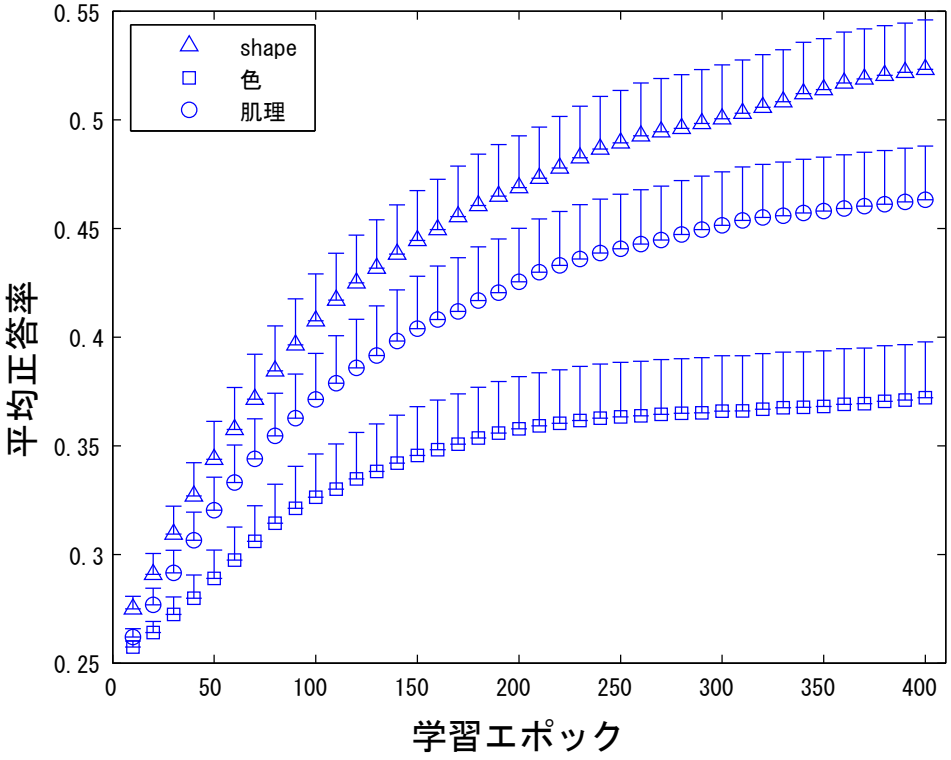

図 5.6: 学習エポックに対する基準条件の平均正答率の推移

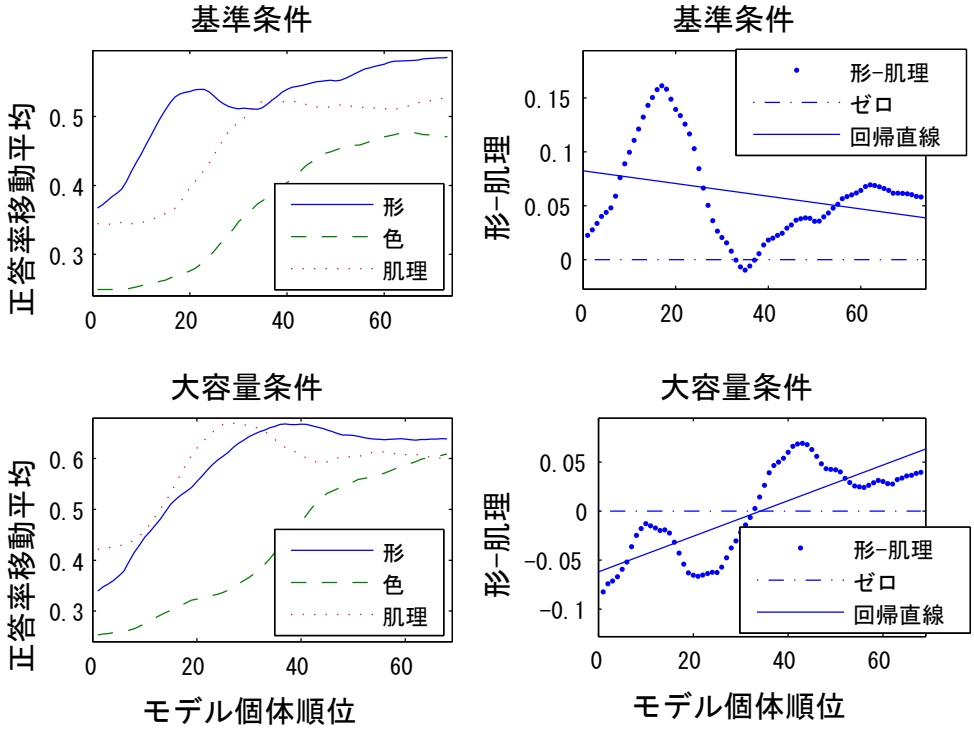

図 5.7: モデル個体内の平均正答率順に並べ替えて平滑化した正答率

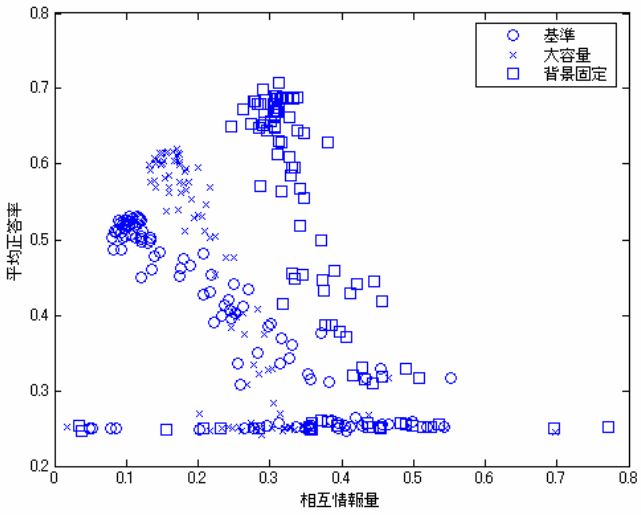

図 5.8: 中間層-出力層間の相互情報量と平均正答率のモデル個体散布図

第6章　文脈依存的なカテゴリの構造化

多くの異なる文化で,「イヌ」や「ボール」などの具体的なカテゴリは文化間で類似したカテゴリの構造を持つ事が多い．しかし，それらを下位カテゴリとして含む「動物」や「物体」などのより抽象的な上位カテゴリは，具体的なカテゴリよりも幾つかの文化の間の乖離が大きい事が知られている [98]．上位の概念はどのように形成されるのだろうか．また上位概念の知識は個別のカテゴリの獲得にどのような影響を及ぼすのだろうか．第 1 章で述べたように，幼児は「動物」,「物体」,「物質」などの存在の基礎的な違い (i.e., 存在論的カテゴリ) に敏感で，異なる新奇語の汎用パタンを示す．また，存在論的に異なる対象に対する新奇語の汎用パタンは，幼児の母語によっても異なる事が示唆されている [32, 36]．従って，新奇語汎用課題の比較言語的な研究は，上位概念の形成メカニズムを解明するためのよい切り口となると考えられる．本研究の目的は，新奇語の汎用にみられる存在論的カテゴリの構造を，統計的性質を要約する高次相関によって説明する事である．まず，関連する発達研究を紹介し，次に本研究の仮説を具体的に説明する．

異なる種類の対象に対する新奇語汎用　新奇語汎用課題を用いた様々な実験で一貫して，3種類の異なる知覚的特徴をもつモノに対して，それぞれ異なる3つの汎用パタンが見られた．　動物に典型的な特徴 (e.g., 目) を持つ物体に対して，それと複数の特徴が類似する限られた対象にのみに，幼児は名詞を汎用する．
固形で人工的なモノに対して，それと形状が類似する対象に，幼児は広く名詞を汎用する．また，　非固形で物質的なモノに対して，それと材質が類似する対象に，幼児は名詞を汎用する．これらの現象は非常に信頼性が高く，多くの言語で，多くの研究者により繰り返し追実験により確かめられてきた [32, 39, 5, 36]．

統語フレームによる種類特異的な名詞汎用の文脈的な変化　ある関連する研究分野では，英語を母語とする幼児の物体と物質に対する可算・非可算名詞の統語的カテゴリの影響が調べられている．可算名詞とは，複数形をとり語の前に “a”, “another”, “several”, “few”や数詞などを伴う名詞である．概して，可算名詞は個別で離散的だと我々が考えるモノに名づけられる．例えば “chairs”, “trucks”, “shirts”, “studies”, “hopes”などである．それに対して非可算名詞は複数形にならず，しかし代わりに語の前に “some”, “much”, “little” などがつく．つまり，非可算名詞は境界が無く連続的なひとまとまりだと我々が考えるモノに名づけ

られる．例えば，“water”, “sand”, “applesauce”, “research”, “justice” などがある．これまでの研究では可算的な統語フレーム (e.g., a mel, another mel) によって幼児はモノの形に注意を向け，一方，非可算的な統語フレーム (e.g., some mel, more mel) によって幼児はモノの材質に注意を向けることが示されている [99]．また別の研究では動物性に関連する言語的な手がかり (e.g., happy や人称代名詞 he や she などの記述) は動物性の指標となる目などの知覚的な特徴を持たないモノであっても，複数の特徴の類似性に注意を向ける事が示された [40, 100]．まとめると，これらの知見は新奇語汎用課題における幼児のカテゴリ形成に対して言語が文脈的な影響を及ぼすことを示している．このような新奇語汎用の際の文脈的手がかりの効果を統語属性のオンライン効果と呼ぶ．オンライン効果だけではなく，明示的な手がかりの与えられない場合 (オフライン) でも言語は人の概念に影響するのだろうか．次節では，存在論的な構造を捉え方の言語差について述べ，その後，オフラインの状況での幼児の新奇語汎用における言語差を紹介する．

存在論的な体系の言語差　言語間による幼児の新奇語汎用の違いは多数の研究を引きつけてきた．世界の全ての言語では動物と非動物を，物体と物質の区別をするが，その区別の体系化は異なっている．Lucy[101] は存在論的な体系化の違いは，その言語が対象を数えられる個別のモノとしての捉え方に集約されると考えた．さらに，彼はその解釈を図式化したものとして個別化連続体 (individuation continuum) を提案した．個別化連続体の一方の先端には，ほとんどの言語が個別で可算と捉える動物的なモノが，もう一方の先端には，ほとんどの言語が個別のモノと捉えない物質的なモノが置かれている (図 6.1)．また個別性連続体の中間には，いくつかの言語では個別なモノとして捉え，また別な言語では個別なモノとして捉えない物体的なモノが存在する．英語は可算・非可算を統語的に区別するので，個別性連続体上の物体と物質的なモノの間に境界をもつ．動物と物体などの一般的な可算名詞 (e.g., “cow” と “cup” など) は個別なモノとして捉えられる．一方，物質などの一般的な非可算名詞 (e.g., “milk”, “sand”, “wood” など) は境界のない連続的な存在として捉えられる．これに対して，日本語の個別化体系の場合，動物と物体と物質を含む “非動物” の間に境界があると考えられる．まず，日本語では複数形は強制的ではなく,「りんごがある」の意味として “There is an apple” または “There are apples” の両方が可能である．しかし，基礎的な存在の概念 (“there is”) や空間的な位置 (“be located”) に対して，日

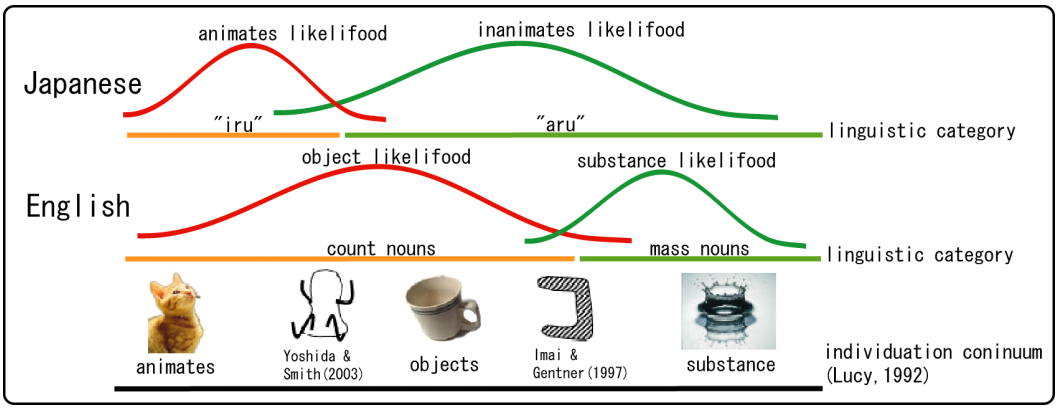

図 6.1: 存在論的カテゴリと言語固有の統語カテゴリ

本語では二つの動詞で動物と非動物を区別する．つまり,「ある」は “inanimate exists/ is located” を意味し,「いる」は “animate exists/ is located” を意味する．日本語話者はモノの位置について述べるごとに，このフレームを (“There is an X” のようにどんな場合でも) 用いるため， モノが動物か非動物かに注意を払わなければならない.「いる」は対象が意思ある動きを自らする事を概念化し,「ある」は対象が意思に無関係で自ら動けない事を概念化する．日本語では，これと同様に多くの動詞で自発的な動作と受動的な動作に異なる語彙が対応する．例えば,「つれていく」(bring) は対象が動物的である場合のみ用いられ,「もっていく」(bring) は対象が非動物的である場合のみ用いられる．どの場合でも英語では同じ動詞 (e.g., put, bring, pick up, hold など) を動物・非動物の区別無く用いるが，日本語では両者の区別をして異なる動詞を用いる．つまり，英語の個別化体系では物体 (動物・非動物を両方含む) と物質を区別するが，日本語の体系では動物と非動物 (物体と物質を両方含む) を区別する．Quine[102] と Lucy[101] はこのような言語的な違いは存在論的なカテゴリを形成するのに大きな影響を及ぼすと主張した．

新奇語汎用の言語差　英語と日本語の構造的な違いが幼児の新奇名詞の汎用に及ぼす影響を示唆する多数のデータが上がっている．Imai & Gentner [32] は英語話者および日本語話者 (2 歳児, 2.5 歳児, 4 歳児, および大人) が新奇な物体と物質に与えられた名詞をどのように汎用するか調べた．彼女らは以下の三種の刺激セットを用いた．固形で複雑な形の物体，固形だが単純な形の物体，非固形で単純な形の物質である．彼女らがこの三種の刺激セットを選んだ理由は，固形のモノと非固形のモノではとり得る形が異なるからである．固形のモノは非

常に複雑に (例えば角が多く複数の部分を持つモノなど) なり得える．一方，非固形の物質 (e.g., ホイップクリームなど) は角や複数の部分を持つ形などは通常とれない．従って単純な形の物体は両者の「中間」にあると考えられる (図 6.1)．Imai & Gentner は新奇語汎用課題で，幼児に新奇なモノとそれに対する新奇な名詞を提示した．実験では可算・非可算どちら名詞にも用いられる中立的な英語の統語フレームを用いた．このようにオンラインの言語的な影響を無くすことで，オフラインの言語的影響，つまり英語で常に可算・非可算名詞を区別してきた学習履歴の (日本語には無い) 影響が調べられた．その結果，日本語話者と英語話者の両方が複雑な形の物体に対して形の類似性，単純で非固形の物質に対して材質の類似性で新奇語を汎用する傾向が見られた．しかし，単純な形をした硬い物体に対する新奇語の汎用では言語差が見られた．英語話者の幼児はそれを物体のように扱い形類似性をもとに汎用したが，日本語話者はそれをより物質のように扱い材質の類似をもとに汎用した．

Imai & Gentner の実験で得られた言語差の一つの解釈は，両言語では境界が異なるという事である．Yoshida & Smith はこの考えを，人間から水しぶきまでの Lucy の個別化連続体の詳細を拡張した「知覚的特徴」による連続体 (図 6.1) を用いて提案した．図の y 軸には知覚的属性で特徴づけられたモノが (新奇語汎用課題で) 動物，物体，物質として扱われる両言語話者の仮想的な尤度が示されている．この表現では，Imai & Gentner が用いた単純で固形のモノや非固形のモノは物体と物質の境界付近に位置する．またこの表現において，Imai & Gentner の実験で観察された言語差は英語の尤度曲線が右側に移動したことにより現れ，英語の物体カテゴリが日本語の物体カテゴリより多くの種類のモノを含むことによって引き起こされている．もし，可算・非可算の統語的属性が英語での物体・物質の境界を日本語のそれと相対的に変化させるとすれば，動物性に関して多くの言語的な対比をもつ日本語は動物と物体の境界を変化させるだろうか．

Yoshida & Smith [36] は動物性の境界が日本語では英語に対してより右側に移動すると仮説を立てた．次のような根拠に基づいて彼女らはこの仮説を実験によって検証した．もし日本語話者および英語話者の幼児が曖昧な特徴を持つモノ (例えば，丸い体や頭をもち，しかし目や口，自発的動きなど特徴的な手がかりを欠く，おそらく動物と物体の境界に近いモノ) を見たら，日本語話者は英語話者よりそれを動物とみなす確率が高いだろう．この仮説を確かめるために，

彼らは日本語話者と英語話者に非常に貧弱な「人形」(体のような形と手足のように見えるパイプという二つのあいまいな動物的特徴のみを持つモノ) を提示した．この実験で，彼らは日本語話者の幼児がまるで動物に対するように，その曖昧なモノに対して複数の特徴によって新奇語を汎用し，英語話者は同じモノに対して物体に対するように，新奇語を形の類似性により汎用する事を示した．これは動物と物体の間の英語話者と日本語話者の境界が異なり，またそれは言語と知覚的特徴の相関の相互作用による，という仮説を支持する結果である．次に，本研究では，存在論的カテゴリの境界移動を，情報圧縮の観点から説明する仮説について考える．

6.1 情報圧縮による境界移動仮説の説明

本研究では，個別のカテゴリの統計的な性質の要約 (i.e., 情報圧縮) によって存在論的な構造の形成および境界の移動の理論的な説明を提案する [68, 103]．このモデルで鍵となるのは次の二つの仮定である．

仮定 (1) 存在論的な区別 (e.g., 動物/非動物) は，より具体的な特徴 (e.g., 丸い/四角い, うるさい/静か，など) の線形的な重み付けによって表現できる

仮定 (2) その線形荷重は，特徴空間上の事例データの分散最大化の基準によって選択される

このようなデータ分散を基準とした情報圧縮のモデルとして，本研究では，主成分分析 (PCA) や多クラス判別分析 (MDA) を用いる．既に第 3 章で示したように，カテゴリの凝集的構造の発生には局所的な特徴選択を必要とするので，PCA や MDA はこれを説明できない．一方，自然カテゴリの大域的な構造である，存在論的な区別 (上位概念) の発生を説明するためには，特徴空間全体に渡る分散を利用するモデルが適すると考えられる．

モデルの仮定 (1)，(2) から導かれる予測として，存在論的カテゴリの境界移動は，言語固有の特徴次元の追加によって変化する分散構造を反映すると考えられる (固有の文脈への敏感性)．つまり，ここでは言語共通に存在する名詞の特徴空間 (e.g., 知覚的特徴など) に加えて，名詞が「いる」/「ある」や，可算，非可算などの言語的な文脈を特徴として含む特徴空間を考える．このとき，言語によって異なる文脈の追加は，名詞カテゴリの分散構造を変化させるので，モデルにより選択される線形重み付けも変化する．このように，特徴空間の構造化 (i.e., 存在を動物/非動物と見るか，固形の物体/非固形の物質と見るか) への

言語固有の文脈の効果をモデル化する．もしこの予測が正しいならば，Yoshida & Smith [36] の提案する境界移動仮説が主張するような存在論的な構造変化を再現できるはずである．さらに，そのより具体的な検討として，新奇語汎用課題における汎用パタンの言語差をモデルにより説明する事で評価できると考えられる．

また，モデルが存在論的カテゴリの形成を説明するためには，与えられた文脈に敏感であるだけではなく,「無意味な」文脈に対して鈍感であるという意味での安定性が必要である．もし偶然に発生した雑音のような「文脈手がかり」に対しても，名詞の大域的な概念構造を敏感に変化させるモデルでは,「動物/非動物」,「固形/非固形」といった特定構造の発生を説明するには不十分である．

以上をまとめて，本研究は以下の手順で議論を展開する．まず，初期に獲得する名詞カテゴリの特徴空間 (第 2 章の実験結果) に対して，分散を基準とする特徴選択により，存在論的な構造を抽出可能か検討する (名詞・特徴データの再分析)．次に，言語固有の文脈の追加によって起こる特徴選択の変化が，日本語・英語話者の固有のパタンに対応するか検討を行う (シミュレーション 1)．またこれに加えて，この特徴選択が偶然発生するノイズ的な文脈に対して安定であるか調べる．最後に，モデルのより定量的な評価として，新奇語汎用課題のシミュレーションを行い，その言語差を説明する (シミュレーション 2)．

6.2　名詞・特徴データの再分析：名詞カテゴリの言語固有の構造

物体・物質の存在論的カテゴリは固形・非固形性，形・材質類似性，可算・非可算属性などの複数の要因の高次の相関によって定量化できると考えられる [52]．ここでは主成分分析による名詞カテゴリの特徴選択が存在論的な区別を形成するか調べる．具体的には，第 2 章の評定実験で得られた名詞の特徴データを再分析を行う．既に，第 2 章の分析では，主成分空間 (図 2.1) が，大きさ，固形性や動きなどと解釈できる名詞のパタンを持つ事を述べた．ここでは，存在論的なカテゴリと相関すると考えられる名詞の統語的な分類を基準として，名詞カテゴリに潜在する存在論的な構造を尺度化して分析する．

6.2.1　分析方法

実験データの分析には，第 2 章と同様に，主成分分析 (PCA) を共変動する特徴の抽出に用いた (2.2.4 節を参照)．

6.2.1.1 分散比による存在論的カテゴリの指標

相関する高次の特徴次元がどのように存在論的カテゴリを符号化するのか調べるために，名詞・形容語実験 (48 名詞カテゴリ × 16 形容語対) の結果に対して PCA を適用した．この分析では，存在論的カテゴリに相関する一側面として可算・非可算属性に対する識別性を調べる．名詞カテゴリの統語属性は表 6.1 に示した．以下で定義するカテゴリ間・カテゴリ内分散比によって PCA の特徴次元の符号化する存在論的構造について分析する．例えば，PCA の主成分の「可算名詞」・「非可算名詞」カテゴリに対する F 値は，その特徴次元での可算名詞に属するカテゴリの分散と非可算名詞に属するカテゴリの分散によってカテゴリ内分散 (W) が計算され，可算名詞と非可算名詞に属するカテゴリの平均間の分散 (B) によって計算される．

$$m_i = \frac{1}{n_i} \sum_{x \subset D_i} x \tag{6.1}$$

$$W = \sum_{i=n} \sum_{x \subset D_i} (x - m_i)(x - m_i)^T \tag{6.2}$$

$$B = (m_1 - m_2)(m_1 - m_2)^T \tag{6.3}$$

$$F = \frac{B}{W} \tag{6.4}$$

m_i は統語属性 D_i に属する名詞の特徴値 x の平均値，カテゴリ内分散 W は統語属性 D_i に属するカテゴリの分散で定義され，カテゴリ間分散 B は m_i の分散で定義される．カテゴリ間・内の分散比 F によって特徴次元の統語的カテゴリ (i.e., 可算・非可算名詞や「いる」「ある」に対応する名詞) に対する分散の寄与を定義する．PCA は分散の大きさによって特徴次元を選択するが，F 値は分散比であるので，必ずしも PCA の第一主成分の F 値が大きいとは限らない事に注意する必要がある．もし大きな分散を持つ主成分が存在論的カテゴリに関する大きい F 値を持つならば，共分散の要約によって存在論的知識を抽出できる事を示唆する．

6.2.2 結果と考察

6.2.2.1 名詞カテゴリの評定に潜在する存在論的な構造

もし PCA によって存在論的な構造が名詞評定から抽出する事ができるならば，より高い寄与率を持つ主成分にその構造が現れるはずである．可算・非可算や「いる」・「ある」の統語属性はそれぞれ物体・物質，動物・非動物の存在論的なカテゴリと相関すると考えられる [52, 36]．従って，各主成分次元での名詞カテゴリの統語属性に対する

名詞カテゴリ	日本語	英語	足	名詞カテゴリ	日本語	英語	足
蝶	c	i	1	椅子	c	a	0
ネコ	c	i	1	ドア	c	a	0
魚	c	i	0	冷蔵庫	c	a	0
カエル	c	i	1	テーブル	c	a	0
ウマ	c	i	1	雨	m	a	0
サル	c	i	1	雪	m	a	0
トラ	c	i	1	石	c	a	0
腕	c	a	0	木	c	a	0
目	c	a	0	水	m	a	0
手	c	a	0	カメラ	c	a	0
膝	c	a	1	カップ	c	a	0
舌	c	a	0	鍵	c	a	0
ブーツ	c	a	0	お金	m	a	0
手袋	c	a	0	紙	m	a	0
ジーンズ	c	a	0	はさみ	c	a	0
シャツ	c	a	0	植木	c	a	0
バナナ	c	a	0	風船	c	a	0
タマゴ	c	a	0	本	c	a	0
アイスクリーム	c	a	0	人形	c	a	1
牛乳	m	a	0	糊	m	a	0
ピザ	c	a	0	飛行機	c	a	0
塩	m	a	0	列車	c	a	0
トースト	c	a	0	自動車	c	a	0
ベッド	c	a	0	自転車	c	a	0

表 6.1: 日本語と英語の名詞カテゴリおよび統語カテゴリ．i は “いる”，a は “ある” が用いられる日本語名詞，c は英語の可算名詞,m は非可算名詞を表す．また，“足” の項目はカテゴリに含まれる事例が足を持つ (1)/持たない (0) ことを表す.

分化を，存在論的な構造として分析した．具体的には，名詞の統語属性 (表 6.1) をカテゴリとして，名詞・形容語実験で得られた平均評定の各主成分におけるカテゴリ間・カテゴリ内分散比 (F 値) を分析した (表 6.2)．図 6.2 は日本語話者の分析結果を示し，実線は各主成分の寄与率 (残差分散) を表し，破線は F 検定 (自由度 1，46) の有意水準 $p < 0.05$ の境界を表す．図 6.2 から，第一主成分から第四主成分などの高い寄与率を持つ次元がより統語カテゴリに対して分化した構造を持つことが示唆される．第一主成分では，名詞カテゴリの可算・非可算カテゴリに対する分散比に有意差があり ($F(1, 46) > 4.130, p < 0.05$),「いる」・「ある」カテゴリに対する分散比が有意な傾向を持っていた ($F(1, 46) > 3.7, p < 0.06$)．また，名詞・形容語実験で得られた 16 次元特徴と形容語選択実験で選択されなかった 25 次元特徴 (日本人協力者のみ) の平均評定値の全分散に関して，同様に統語属性のカテゴリ間・内分散比を算出した．16 次元の特徴は日本語話者・英語話者の両方の評定で，可算・非可算と「いる」・「ある」の両方に対して分化した構造を持っていた ($F(1, 46) > 3.7, p < 0.06$)．しかし，形容語選択実験で選択されなかった 25 次元 (41 次元から選択された 16 次元を除いた形容語対) の評定値は両方の統語属性に関して分化した構造を持たなかった ($F(1, 46) < 3.3$)．以上の結果をまとめると，名詞カテゴリは，第一主成分 (1 次元)，分散に基づき選択した 16 次元，選択されなかった 25 次元の順に統語属性に対してより分化した構造を持つ事が示された (表 6.2)．従って，PCA によって存在論的な構造が名詞カテゴリの評定データの主成分として選択される事が示唆された．言い換えれば，この結果は複数の具体的な特徴次元に共通する共変動の成分として存在論的な構造が表される事を意味する．

6.2.2.2　主成分の構造　さらに，第一，第二主成分の中で最も大きい 5 つの因子負荷量を持つ形容語対とその二次元特徴空間における動物・物体・物質の模式的な構造を図 6.3a に示した．この事から第一主成分は「固形性」もしくは「大きさ」と解釈できる．また図 2.1 では動物や乗り物などの動的なモノが上部に配置され，家具や液体などの静的なモノが下部に配置されているので，第二の主成分は「動き」を表すと考えられる．各カテゴリの平均評定に対する主成分分析によって算出された主成分の F 値を図 6.2 に示す．この結果から，第一主成分は可算・非可算 (黒いバー) に，第二主成分は「いる」・「ある」(白いバー) の区別と相関する構造を表している．

以上の結果をまとめると，類似した名詞カテゴリに対して特徴構造は日本語・

英語話者で共通し，この名詞カテゴリの共変動する特徴の情報圧縮によって,「固形性」や「動物性」に対応する合成的な特徴が得られる事が示唆された．この結果は，幼児は個形性に注目して物体と物質に対して異なる新奇語汎用をする事 [33] や，動物性の違いに注目して動物と非動物に対して異なる新奇語汎用をする [45] 事などに一致する．つまり，複数の断片的な特徴の合成変量として，個別化連続体のような抽象的な概念を分散的に定量化できる事を示唆している．また，英語話者と日本語話者の名詞の特徴構造は，固形性と動物性に対する分化という観点で類似する事が示された．この結果は日本語・英語話者の幼児は物体と物質や動物と非動物の存在論的境界が異なる [32, 36] という知見と相反するようにみえる．しかし，多くの研究で，大人と幼児のカテゴリ化と類似性判断は異なる事が示されており [6, 47](詳しくは第 3 章を参照)，本研究の特徴評定は新奇語汎用課題と違い，類似性判断に近かった可能性がある．例えば，新奇語の命名を行う場合 [5] などの「カテゴリ化」を行うときには系統的に特定の特徴に重視する．しかし，類似性判断や自由分類課題では幼児は系統的に特定の特徴に注意するという傾向は見られない [6]．つまり，幼児の新奇語汎用課題と異なり，本研究で得られた評定データは特定の特徴へのバイアスが小さく，事例の類似性の表象に近いと考えられる．もし，幼児が物体に対する言語共通の特徴に加えて，言語固有の統語的な特徴を併せて学習したとするとどのように存在論的カテゴリに影響するだろうか．次のシミュレーション 1 では，評定実験で得られた言語間で類似の特徴空間に加えて言語固有の属性を考慮する事で，幼児の新奇語汎用における言語差の説明を行う．本研究の仮説では，それぞれの言語固有の統語的特徴に相関する存在論的カテゴリがより強調されると考えられる．次に，我々はこの仮説に従って，統語的カテゴリを併せて情報圧縮した場合の構造について調べた．

6.3　シミュレーション 1：存在論的カテゴリの境界移動

前節の再分析では，主成分分析 (PCA) による分析で名詞カテゴリの評定から存在論的な構造が抽出される事を示した．シミュレーション 1 では，この名詞カテゴリの特徴を言語共通な構造とみなし，これに言語固有の統語属性を加えた特徴空間から得られる主成分の構造を調べる．前述のように，存在論的な境界移動を説明するモデルに要求される条件は，(1) 与えられる統語属性に「敏感」に主成分の構造を変化させるが，(2) その構造はノイズ的な文脈手がかりに

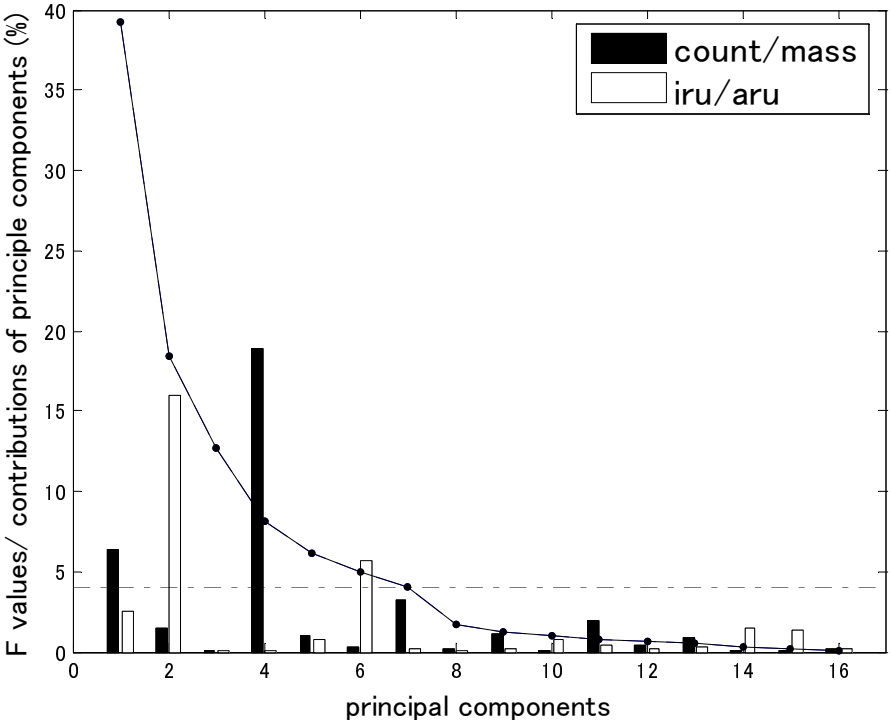

図 6.2: 主成分と言語固有の統語カテゴリの F 値

は「鈍感」で安定的である事である．本シミュレーションでは，この 2 点に論点を絞って議論を進める．

統語属性を特徴の一つとして学習する効果は二つの種類がある．物体に対する呼称などの際に，文脈として名詞に統語フレームが与えられる (e.g.,「X がある」) オンラインの効果と，文脈では統語フレームが明示されず (e.g.,「X だよ」)，その他の特徴の学習履歴における統語属性の影響であるオフラインの効果である．モデルで統語属性を含むすべての特徴の重みを利用する事をオンラインの効果，統語属性以外の特徴の重みだけを利用する事をオフラインの効果とした．シミュレーション 1 では特にオフラインの効果に焦点を絞る．シミュレーションでは，名詞カテゴリの特徴次元に加えて，統語的な区別 (e.g.,「いる」・「ある」) を特徴として，PCA による情報圧縮を行う．これは，他の特徴次元と統語次元を併せて教師なし学習する過程に対応する．モデルにおけるオフラインの効果とは，学習時に統語次元が与えられるが，テスト時に統語次元の情報が与えられない場合の特徴空間，または，学習時にも統語次元が与えら

		日本語話者		英語話者	
		可算/非可算	いる/ある	可算/非可算	いる/ある
41 次元	F(1,46)	2.13	3.23		
全分散	P	0.1515	0.0788		
16 次元	F(1,46)	4.130	3.763	3.760	5.043
全分散	P	0.048*	0.059	0.059	0.030*
第一	F(1,46)	6.36	2.56	5.07	3.54
主成分	P	0.015*	0.116	0.0291*	0.066

表 6.2: 名詞カテゴリの統語属性に関する識別性．*は $p < 0.05$，**は $p < 0.001$ を表す．

れない場合との特徴空間の差である．シミュレーションでは，モデルの条件 (1) を調べるために，日本語・英語固有の統語属性に関するオフラインの効果を分析した．また，ノイズ的な文脈に対する安定性 (要求 (2))) を調べるために，ランダムな値で生成した人工的な統語属性を与えた場合の主成分の変化を調べた．

6.3.1 方法

言語固有のカテゴリに相関する名詞カテゴリの構造　選択された特徴次元上で，名詞カテゴリがどのような構造をとるか分析を行った．具体的には，実験１の名詞・形容語実験で得られた日本語・英語名詞の評定データに PCA を適用し，その第一主成分の統語カテゴリに対する識別性を分析する．識別性は，各名詞に割り当てられた統語的な属性に対する特徴空間 (e.g., 第一主成分) の F 値 (式 6.4) で定義する．言語固有の統語カテゴリは可算・非可算名詞および「いる」「ある」のそれぞれに対応する二値で，英語の辞書および日本語を母語とする著者によって与えられた (表 6.1)．日本語と英語での実験は異なる数の被験者を持つので，協力者個人データから算出する F 値は異なる検定力をもつ．そのため，F 値を評定値の協力者平均に対して算出した．

４つの条件で特徴空間の統語属性に対する識別性を分析した．それぞれ，統語なし条件，日本語・統語あり条件，英語・統語あり条件，ランダム・統語あり条件である．統語なし条件では，名詞・形容語実験の 16 次元特徴値 (日本語・英語話者の両方) の第一主成分で，名詞カテゴリの統語属性に対する F 値を分析した．他の３つの統語あり条件では，名詞・形容語実験の 16 次元特徴値 (日

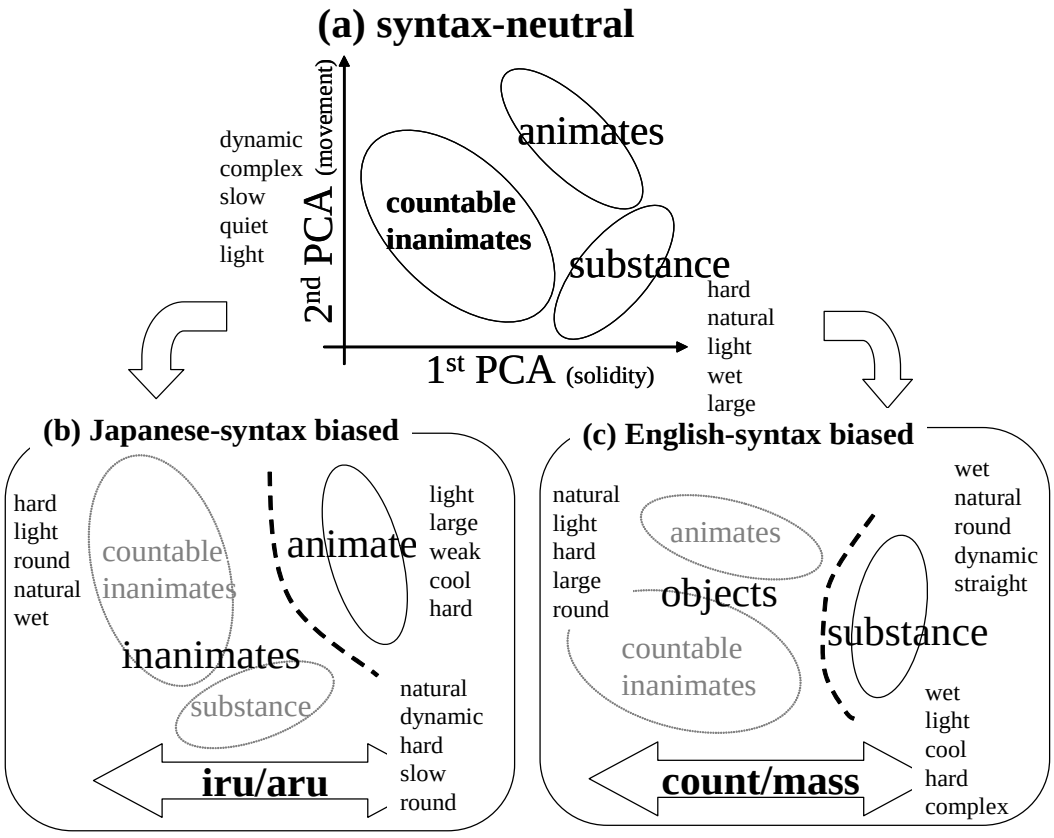

図 6.3: 存在論的カテゴリの移動を表す模式図．図中に最大の重みを持つ 5 つの形容語対 (その一つのみを示す) を示す．詳細は本文を参照.

本語・英語話者の両方) と統語属性 (表 6.1) を併せた 17 次元特徴値の第一主成分で，名詞カテゴリの統語属性に対する F 値を分析した．日本語・統語あり条件では，日本語話者の評定値と「いる」・「ある」の統語属性を併せた 17 次元特徴を，英語・統語あり条件では英語話者の評定値と可算・非可算の統語属性を併せた 17 次元特徴を分析対象とした．同様に，ランダム・統語あり条件では，乱数によって作成した人工的カテゴリを統語属性として加えた 17 次元特徴を分析した．各統語属性と同様に，名詞カテゴリに割り当てられた幾つかの関連する属性についても分析を行った．Samuelson & Smith [52] の調査では，本研究で分析する名詞カテゴリを含む 312 のカテゴリについて形，色，材質の類似性によって形成されるカテゴリであるか，また固形の物体・非固形の物質を事例として持つカテゴリか，また名詞の統語属性について評定を行った．この評定の結果を名詞カテゴリの上位分類と定義し，統語あり条件で得られる名詞カテ

ゴリの構造と上位分類との相関を分析した．

３つの統語あり条件では，1 次元の統語属性をモデルに与えられるパラメータと仮定し，統語属性の効果を連続的に変化させて分析する．統語属性の効果は，他の特徴の全分散に対する統語属性の分散比 α により定義する．従って，$\alpha = 0$ の場合が統語なし条件に相当し，$\alpha = 1$ の場合が統語あり条件に相当する．また，統語あり条件では，統語属性の「オフライン」の効果を調べた．具体的には，統語属性を含む 17 次元の特徴値が主成分分析された後，統語属性を含まない残りの 16 次元特徴の重みのみで (統語属性の重みを 0 と仮定して) 第一主成分を構成した．つまり，主成分分析は日常的な名詞学習の履歴を表し，統語属性を含む特徴を学習すると仮定する．しかし，文脈として (オンラインで) 統語属性が明示的に与えられない場合の名詞カテゴリの特徴構造を分析するために，学習によって得られる統語属性に対する重みを除く他の特徴次元のみを分析する．オフラインの統語属性の効果を分析するために，他の 16 次元を入力として統語属性の 2 カテゴリ出力を学習する多クラス線形判別分析 (MDA) と比較した．MDA は与えられる 2 カテゴリのカテゴリ間・内の分散比を最大とする 16 次元特徴に対する線形の重み付けを推定する．MDA で得られる 48 名詞カテゴリの構造と統語あり条件のオフラインの 48 名詞カテゴリの構造とを比較する．

6.3.2　結果・考察

統語属性の効果を調べるために，日本語・統語あり条件と英語・統語あり条件の結果とそれに対応する判別分析 (MDA) の結果を比較した．統語属性の効果 α に対する PCA と MDA による 48 名詞カテゴリの第一主成分の特徴値の相関係数の絶対値を図 6.4(c) に示した．この結果から，PCA で統語的な効果が高いほど，MDA によって得られる名詞カテゴリの構造に近づく事が示された．従って，加えられた統語属性に対するバイアス (i.e., α) が十分に大きい場合，主成分分析は統語的カテゴリに対する教師ありの連想器となり，統語属性に相関する構造を発見する事が示唆された．

名詞カテゴリ主成分の統語的カテゴリに対する識別性　得られた特徴空間が統語カテゴリに対してどの程度の識別性を持つか，分散比 (F 値：式 6.4) を指標として分析した (表 6.3)．統語なし条件では日本語・英語話者の評定値の両方で，可算・非可算に対応する名詞カテゴリは有意な差を示したが，「いる」・「ある」に対応する名詞カテゴリは有意な差を示さなかった．一方，日本語・統語あり条件では，「いる」・「ある」に対応する名詞カテゴリは有意な差を示し，可算・

非可算に対応する名詞カテゴリは有意な差を示さなかった．これに対して，英語・統語あり条件では，可算・非可算に対応する名詞カテゴリは有意な差を示し,「いる」・「ある」に対応する名詞カテゴリは有意な差を示さなかった．さらに，100 の異なる乱数によって生成した二値カテゴリを統語属性として，ランダム・統語あり条件での F 値の相乗平均の分析を行った．その結果，得られた第一主成分は人工的な統語属性に対して有意差を示さなかった ($p > 0.05$)．つまり，主成分分析によって抽出される構造は，無意味なノイズに対応する人工カテゴリに対して堅牢である (敏感ではない) ことが示された．これらの結果から，モデルの統語あり条件では，統語なし条件に比べて言語固有の統語属性に相関する名詞カテゴリの構造が得られる事が示された．しかし，ランダムな人工統語属性には現実の統語属性ほど影響されないため，モデルはノイズに対して安定性を持つことが示唆される．

		日本語話者			英語話者		
		可算/非可算	いる/ある	ランダム	可算/非可算	いる/ある	ランダム
統語	F(1,46)	6.36	2.56	0.15	5.07	3.54	0.40
なし	P	0.015*	0.116	0.703	0.0291*	0.066	0.529
統語	F(1,46)	0.61	22.10	3.68	20.70	0.001	3.26
あり	P	0.439	0**	0.061	0**	0.973	0.077

表 6.3: 統語あり・なし条件での統語属性に関する識別性．*は $p < 0.05$，**は $p < 0.001$ を表す．

知覚的特徴の選択に対する統語属性の影響　次に統語あり条件の名詞カテゴリ構造を調べるために，上位分類に対する相関を分析した．日本語・統語あり条件と英語・統語あり条件での固形性・非固形，形，色，材質の上位分類と名詞カテゴリの相関を統語属性の効果 α の関数として図 6.4 a, b に示す．α が大きい場合，言語固有の統語属性に相関する構造となる (図 6.4c)．これを踏まえて日本語・統語あり条件の結果から,「いる」・「ある」の統語属性とより相関する名詞カテゴリは，固形性・非固形性や形，色，材質などの上位分類と相関が低くなる事が示された (図 6.4a)．つまり，日本語固有の統語属性によって，名詞カテゴリの構造が固形性・非固形性や，形，色，材質の単独特徴の類似性による上位分類ができない構造へと偏向する．一方，英語・統語あり条件の結果 (図 6.4b) から，可算・非可算の統語属性とより相関する名詞カテゴリは，固形性・

非固形性と形，色，材質などの上位分類と相関が高くなる事が示された．つまり，英語固有の統語属性によって，名詞カテゴリの構造が固形性・非固形性や，特に形，材質の単独の類似性によって上位分類できる構造へと偏向する．シミュレーションによるこの結果は，新奇語汎用課題で日本語話者は固形性の区別を曖昧にし，英語話者は固形性を明確に区別する事 [32] に定性的に一致する．また，日本語話者と異なり，英語話者は動物と物体の中間的な刺激を形の類似性に基づき新奇語汎用する事 [36] とも一致する．

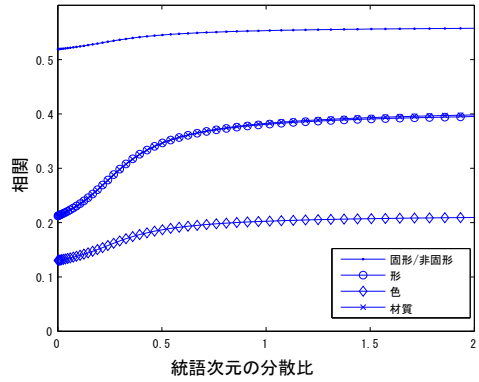

(a) 英語の統語属性

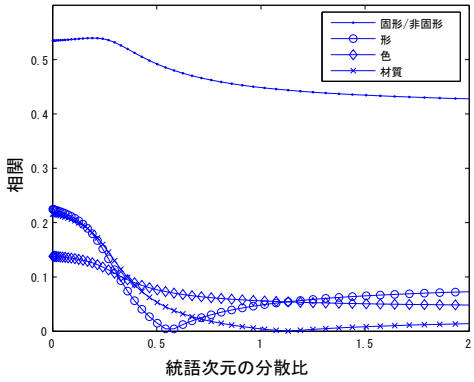

(b) 日本語の統語属性

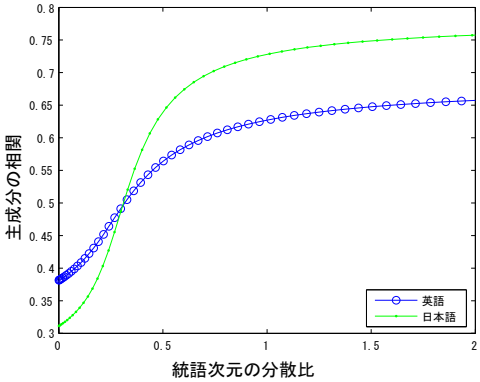

(c) MDA と PCA の主成分の相関

図 6.4: 統語属性の効果 (横軸) に対する各項目の相関

統語あり条件の階層クラスタリング分析　さらに，統語あり条件の名詞カテゴリの形成するクラスタを詳細に調べるために，第一主成分に対する階層クラスタ分析を行った (図 6.5, 6.6)．図中のアスタリスクは非可算名詞カテゴリ，ドルマークは「いる」が用いられる名詞カテゴリを意味する．日本語・統語あり条

件の主成分を階層クラスタ分析した結果を図 6.5 に，英語・統語あり条件の主成分を階層クラスタ分析した結果を図 6.6 に示す．日本語・統語あり条件では，「eye」や「hand」は，シミュレーションでは「ある」に対応するカテゴリに割り当てられたにも関わらず，動物 (e.g.,「cat」,「tiger」,「fish」などの「いる」の統語属性に対応するカテゴリ群，図 6.3) と共にクラスタを形成する事が示された．この結果は，新奇語汎用課題で「eye」や「hand」などが動物性の手がかりとなるという知見と一致する ([39, 45, 88, 36]．これに対して，英語・統語あり条件 (図 6.6) では，動物や体の部分のカテゴリが分散して，クラスタを形成しなかった．この結果は，比較言語実験で日本語話者が手足のついた物体を動物とみなしたのに対して，英語話者が同じ物体を人工物とみなした事と一致する [36]．この結果から，モデルは統語的属性に従って二つのクラスタに単に名詞を識別しただけではなく，統語属性に相関する「動物性」を抽出したと考えられる．

まとめ　評定実験の分析結果とシミュレーション 1 の結果をまとめて，モデルでの統語的属性による存在論的構造の移動を図 6.3 に示した．図 6.3 a には統語なし条件の第一，第二主成分による全体構造の模式図を示した．第一主成分，第二主成分のそれぞれで最も特徴の重みの絶対値が大きかった 5 対の形容語のリストも示されている．また，日本語・統語あり条件での第一主成分の模式図を図 6.3b に示し，その第一主成分で最も重みの絶対値が大きい 5 対の形容語のリストを示した．階層クラスタ分析 (図 6.5) で示したように，日本語・統語あり条件では,「いる」・「ある」それぞれに対応する名詞がクラスタを形成している．そのためクラスタ内の名詞カテゴリを識別する特徴を分析するために,「いる」に対応する名詞群のみに対して主成分分析した場合の重みを動物のクラスタの形容語リストを図 6.3b に示した．同様に,「ある」に対応するクラスタ内の名詞群を識別する形容詞リストを図 6.3c に示した．シミュレーションによる結果から，主成分分析に基づくモデルは存在論的カテゴリの形成および統語属性による境界の移動を，これまでの実験的知見に一貫して説明できる事が示された．このモデルでは，名詞カテゴリの特徴の一つとして言語固有の統語属性を加えることで，分散を最大化する主成分分析は統語属性に相関する特徴に偏った重みを形成する事でおこる．このモデルは，新奇語汎用での幼児の特徴選択が，統語属性などの文脈的な手がかりを利用した効率的なカテゴリ化である事を予測する．この予測が正しいならば，言語固有の統語属性に偏った特徴の重みによっ

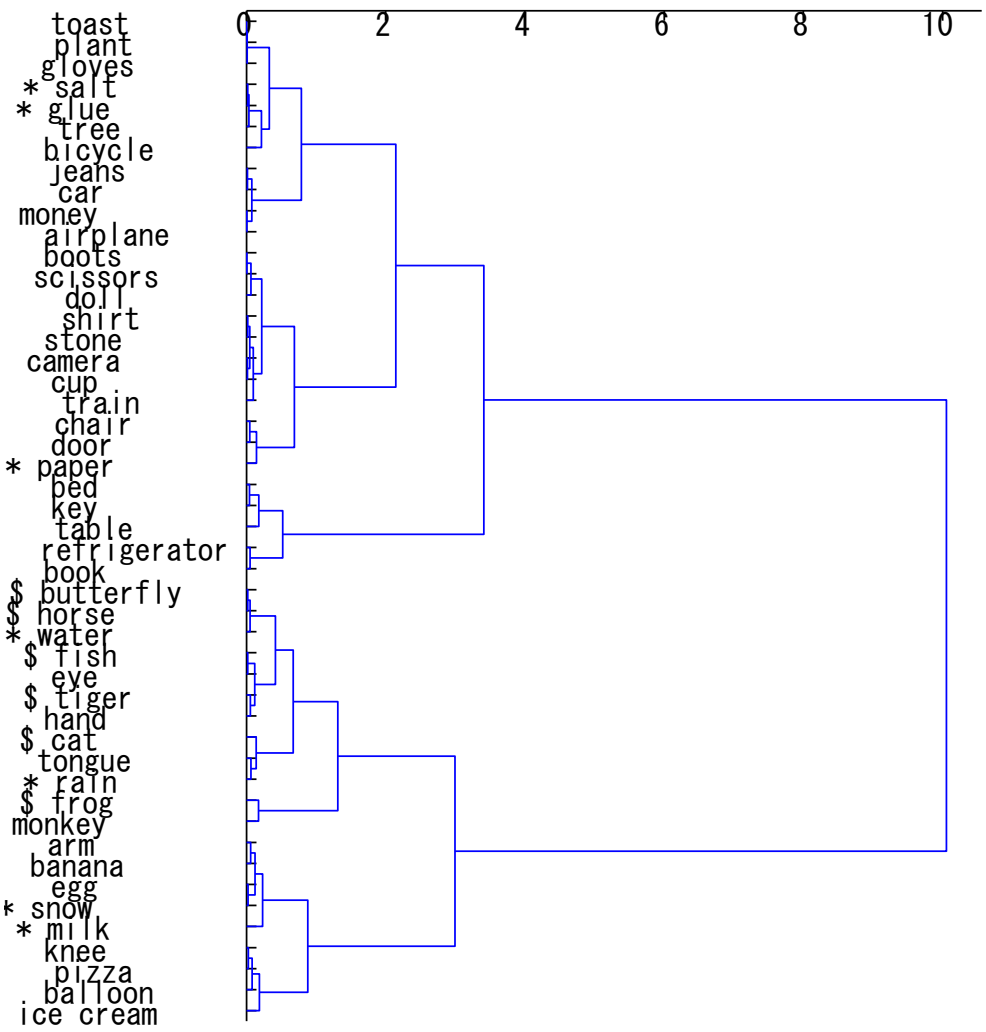

図 6.5: 日本語・統語あり条件の階層クラスタリング.

て，日本語・英語話者の新奇語汎用パタンを再現できるはずである．次節では，具体的に言語比較実験のシミュレーションを行うことで，この仮説を定量的に検討する．

6.4 シミュレーション 2：新奇語汎用の言語差

シミュレーション 2 では Yoshida & Smith[36] の日本語話者と英語話者の新奇語汎用課題のモデル化を行う．シミュレーション 2 の目的は，動物的と人工的な刺激に対する新奇語の汎用パタンに関して，日本語・英語話者の言語差を

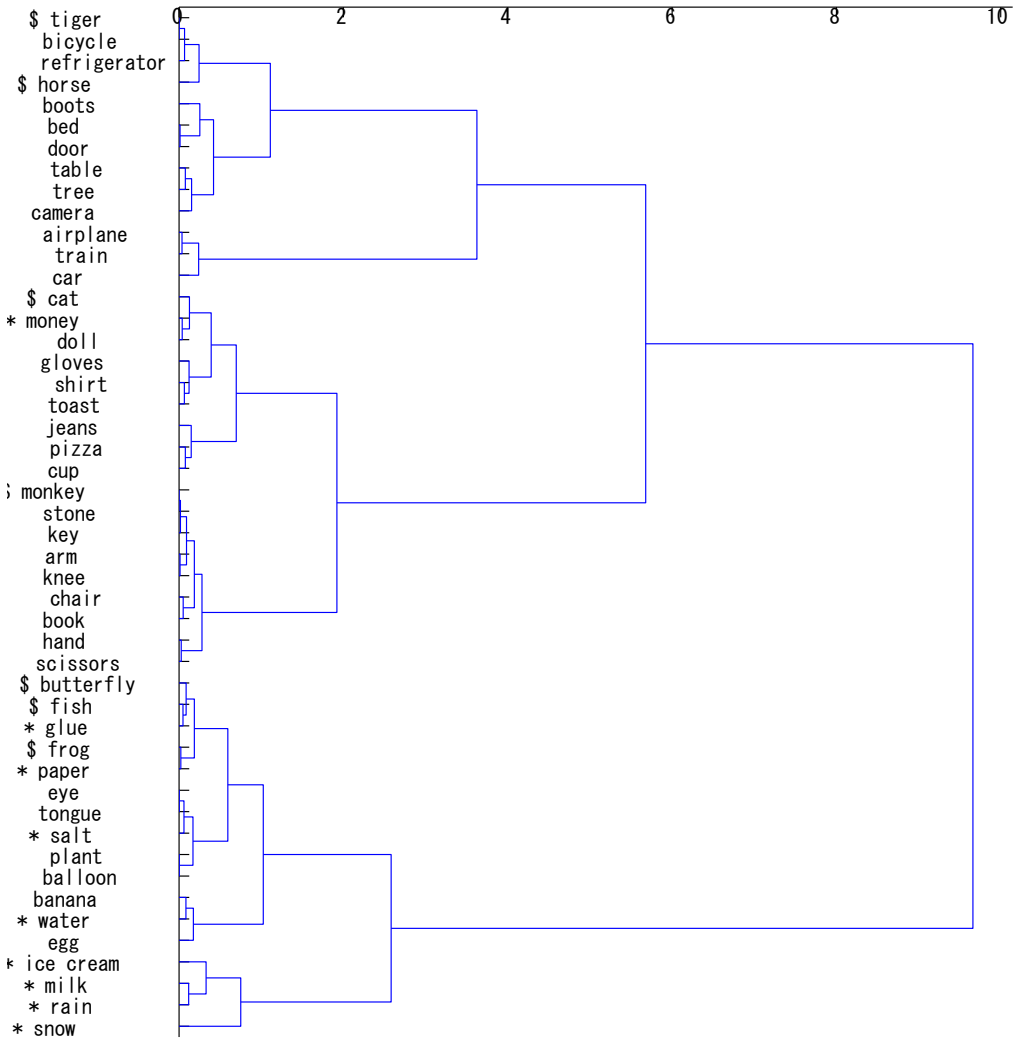

図 6.6: 英語・統語あり条件の階層クラスタリング

再現する事である．モデルでは，新奇語汎用の言語差は，言語固有の統語的属性の影響によると仮説を立てた．具体的には，新奇語汎用において重視する特徴は，統語属性のオンラインまたはオフラインの効果 (シミュレーション 1) を受けると仮定し，Yoshida & Smith [36] の実験をシミュレートした．以下では，この新奇語汎用課題の詳細を述べ，それからそのモデル化について説明する．

6.4.1 日本語・英語話者による新奇語汎用の比較言語実験

Yoshida & Smith [36] は 3 歳児の日本語，英語モノリンガルを協力者として三つの実験を行った．三実験のそれぞれが教示の違い，もしくは日本語・英語

話者の違いの 2 条件を持ち，計 6 条件の新奇語汎用課題が行われた．また，それぞれの条件では，3 次元の知覚的特徴 (i.e., 形，肌理，色) に関して，標準刺激とテスト刺激の類似性が操作された (6 つの組み合わせが設定された：同一，形・肌理類似，形・色類似，形類似・肌理類似・色類似)．一般に，幼児は動物的な物体に対して，その形と肌理の両方を重視して新奇語の汎用を行う事が示唆されている [39]．また，幼児は人工的な物体に対してその形のみを重視して新奇語の汎用を行う [5]．実験では，動物・人工物の「中間」と想定される曖昧な刺激が用いられ，幼児の新奇語汎用パタンから，幼児の解釈した刺激の種類 (i.e., 動物または人工物) が分析された．

実験 1 の目的は，日本語モノリンガルの新奇語汎用に関して，統語フレームの文脈の影響 (i.e., オンラインの効果) を調べる事であった．実験 1 の結果，半動物的な刺激[1)]を「X が**いる**」と命名した場合は，幼児はそれを動物とみなした．しかし，同じ半動物的な刺激を「X が**ある**」と命名した場合には，幼児はそれを人工物とみなす事が示された．つまり，実験 1 からは，日本語モノリンガルが,「いる」・「ある」の統語的文脈に敏感に新奇語汎用パタンを変える事が示唆される．

一方，実験 2 と実験 3 は，中立的な統語フレームを用いて文脈の影響 (i.e., オフラインの効果) を排除して行われた．実験 2 では半動物的な刺激，実験 3 では明らかに人工的な刺激に対して，日本語・英語モノリンガルの新奇語汎用パタンが調べられた．実験 2 の結果，日本語モノリンガルは半動物的な刺激を動物とみなすが，英語モノリンガルは人工物とみなして新奇語を汎用する事が示された．つまり，実験 2 からは，中立的な文脈でも，統語フレームの学習履歴のオフライン効果によって，新奇語の汎用に言語差がある事が示唆される．また，実験 3 の結果，日本語・英語モノリンガルは共に，人工的な刺激を人工物とみなし類似の新奇語汎用を示した．実験 3 は，実験 2 の対照条件であり，日本語・英語モノリンガルの言語差が，単なる反応バイアスでは説明できない事を示唆する．以上 3 つの実験から，Yoshida & Smith[36] は，日本語・英語固有の統語フレームの影響によって,「動物」と「物体」の存在論的な境界が移動するという境界移動仮説を提案した．

[1)] 手足のように見えるパイプの付属した丸みを帯びた物体であった

6.4.2　文脈手がかりを利用した新奇語汎用のモデル

本シミュレーションでは，幼児は与えられた手がかりを最大限に利用して新奇語汎用を行うと仮定する．この戦略によって幼児は的外れな推量を避け，新奇語のカテゴリに関して素早く推測する事ができると考えられる．つまり，もし文脈で与えられる手がかりによって新奇語が動物的なモノに汎用するべき事を示唆する場合，幼児は既知の動物的なモノに重要な特徴に基づいて新奇語を汎用すると考える．具体的には，Yoshida & Smith [36] の実験 1 では，教示によって，新奇語は「いる」が用いられる名詞である事を暗示された．この場合，「いる」を用いるような名詞カテゴリ群 (i.e., 動物的な対象) の識別に有用な特徴を重視して，幼児は新奇語を汎用すると仮定する．同様に，別な条件で，教示で新奇語に「ある」を用いた場合，非動物を参照する名詞カテゴリ群の識別に重要な特徴を重視して，幼児は新奇語を汎用すると仮定する．

実験 2，3 では，文脈上の手がかりは与えられず，実験 2 では曖昧な半動物的なモノ，実験 3 では明らかに人工的なモノが刺激として用いられた．そのため，実験 2 では名詞カテゴリ全体に関する知識が新奇語の汎用に用いられると仮定した．しかし，統語フレームを学習した事によるオフライン効果により，日本語・英語話者の特徴空間は異なる．具体的には，シミュレーション 1 で示した特徴空間の主成分から，知覚特徴に対する重みを算出する事で，言語固有の統語的区別の識別に特化した特徴によって、新奇語汎用パタンを予測する．実験 3 は明らかに人工的な刺激が用いられたので，人工的なモノを意味する名詞カテゴリの識別に有用な特徴によって，新奇語汎用パタンを予測する．それぞれの条件に対応する特徴の重みは，名詞の評定実験 (第 2 章) で得られた名詞の特徴データに判別分析を適用して推定された．また，特徴重みから新奇語の汎用確率を算出する選択モデルには，一般化線形モデル (Generalized Linear Model: GLM)[55] を用いた．GLM は多くのカテゴリ学習のモデルで用いられるカテゴリ選択のモデル [26, 51, 27] を下位に含む一般化されたモデルである．もし幼児の新奇語汎用において，既知の名詞カテゴリの知識の適用が，次元圧縮の手法と同様の特徴要約によって行われているならば，このシミュレーションによって幼児の新奇語汎用パタンを再現する事ができると考えられる．

6.4.3　方法

6.4.3.1　特徴類似性とその重みに基づく汎用モデル　特徴バイアスと刺激間の特徴類似性とそれに対する重みから，新奇語汎用の確率 (心理的距離) を計算す

るために，一般化線形モデル (GLM) を用いた．GLM では，従属変数，独立変数，リンク関数，誤差の確率分布を与え，独立変数に対応する係数を推定する．新奇語汎用の場合，従属変数として汎用確率 P_{yes}, 独立変数として標準刺激とテスト刺激の特徴類似性 X を与え，独立・従属変数の関係を表すリンク関数 $L(\bullet)$ と誤差分布を決定する事で，特徴バイアスに対応する係数 β が算出される (式 6.5)．

本研究では，二つの一般化線形モデルを立てて新奇語汎用課題をシミュレートする．一つのモデルは，新奇語汎用確率のデータから，最適な特徴バイアスを推定する「最適モデル」である (式 6.5)．

$$L(P_{yes}) = \beta_S X_S + \beta_C X_C + \beta_T X_T + \beta_0 \tag{6.5}$$

$$X = \begin{cases} 0 & \text{(feature match)} \\ 1 & \text{(feature mismatch)} \end{cases} \tag{6.6}$$

Yoshida & Smith [36] の実験では，命名される標準刺激と一般化されるテスト刺激は，3 次元の知覚的な特徴の類似性が統制されていた．最適モデルでは，標準刺激とテスト刺激の形，肌理，色の類似性を表す変数 X_S, X_T, X_C (式 6.6: 各変数は類似 (0) と非類似 (1) のいずれかの値をとる) と，それ対応する特徴バイアス β_S, β_T, β_C および反応バイアス β_0(定数項) の線形結合によって，刺激間の心理的な距離 (非類似性) をモデル化した．心理的な距離と汎用確率は，リンク関数 $L(P_{yes})$ によって関連付けられている．最適モデルでは，新奇語汎用データ P_{yes} から，特徴バイアス β_S, β_T, β_C を推定する．

GLM のリンク関数と誤差分布として，線形関数と正規分布 (式 6.7)，ロジット関数と二項分布 (式 6.8)，対数リンク関数とポワソン分布 (式 6.9) を用いた．

$$L_{Linear}(x) = x \tag{6.7}$$

$$L_{Logit}(x) = \log\left(\frac{x}{1-x}\right) \tag{6.8}$$

$$L_{Log}(x) = \log(x) \tag{6.9}$$

最適モデルは，全条件の合計で 24 自由度 (3 実験 × 2 条件 × 4 自由度 (形，肌理，色，定数)) をもつ．以上の対数尤度の最適化によるパラメタ推定には MATLAB 7.0 の statistical toolbox に含まれる “glmfit” などの関数群を利用した．

6.4.3.2　特徴データから新奇語汎用バイアスを推定するモデル　もう一つのモデルは，新奇語汎用における形，肌理，色に対するバイアス W_s, W_t, W_c を，新

奇語汎用データではなく，名詞カテゴリの特徴データから推定する「MDA モデル」である (式 6.10).

$$L(P_{yes}) = \beta_1(W_S X_S + W_C X_C + W_T X_T) + \beta_0 \tag{6.10}$$

最適モデルと同様に，MDA モデルは形，肌理，色の類似性と反応バイアスに対応する変数 X を持つ．異なる点は，MDA モデルでは新奇語汎用における特徴バイアス W_S,W_T,W_T を，新奇語の汎用データとは独立に，実験条件ごとに定数として推定する点である (推定方法は 6.4.3.3 節で後述)．従って，GLM(6.10) で推定する係数はスケールを表す β_1 と反応バイアス β_0 の 2 つのみである．

最適モデル同様に，GLM のリンク関数，誤差分布は 3 つの異なるモデルを用いた．まとめると，MDA モデルは全条件の合計で 14 自由度をもつ (3 実験× 2 条件× 2 自由度 (スケール，反応バイアス)+ 2 自由度の全実験で共通のパラメタ m と r(詳しくは次節を参照)).

新奇語汎用データから最適な汎用バイアスを推定する最適モデルは，GLM による選択モデルのデータ適合性の上限を表すと考えられる．従って，特徴データから汎用バイアスを推定する MDA モデルと最適モデルを比較する事で，情報圧縮による新奇語汎用パタンの予測性を定量的に検討する．

6.4.3.3　文脈的手がかりと既知名詞カテゴリに基づく特徴重みの推定　MDA モデルでは，新奇語汎用における特徴バイアスを，Yoshida & Smith[36] の実験 (6.4.1 節) の文脈手がかりを利用して予測される特徴の重みにより推定する．これは，名詞カテゴリの特徴評定データ (2.2.3 節の名詞・形容語実験を参照) に対して，以下のように MDA を適用する事で形容語特徴次元の重みを算出する．

Yoshida & Smith [36] の実験１では，日本語モノリンガルが,「いる」・「ある」二条件の教示によって新奇語汎用を行った．これに対し,「いる」条件の場合，MDA モデルでは，モデルでは統語フレーム「いる」が用いられる名詞カテゴリ (表 6.1) の識別性 (カテゴリ間・内の分散比) が最大になる特徴の重みを推定する．この特徴の重みは日本人の評定による名詞カテゴリに基づいて，MDA によって算出した．同様に，実験１の「ある」条件に対応する特徴の重みは,「ある」に対応する名詞カテゴリの識別性を最大化する特徴の重みを MDA によって算出した．

実験２では，日本語・英語モノリンガルが，中立的な統語フレームで半動物的で曖昧な刺激の新奇語汎用を行った．これに対して，モデルでの日本語モノリ

ンガルの新奇語汎用パタンは,「いる」・「ある」の統語フレームの識別性を最大化する特徴の重み (i.e., シミュレーション 1 のオフラインの効果) とした．この特徴の重みは，日本語名詞カテゴリの特徴評定を用いて MDA で算出した．同様に，モデルでの英語モノリンガルの新奇語汎用パタンは，可算・非可算名詞の統語フレームの識別性を最大化する特徴の重みとした．この特徴の重みは，英語名詞カテゴリの特徴評定を用いて MDA で算出した．

実験 3 では，日本語・英語モノリンガルが，中立的な統語フレームで (手足の付属していない) 人工物の新奇語汎用を行った．これに対応して，モデルでの日本語モノリンガルの新奇語汎用パタンは，足の無い人工物 (表 6.1) に対応する名詞カテゴリの識別を最大化する特徴の重みとした．この特徴の重みは，日本語名詞の特徴評定を用いて MDA で算出した．同様に，英語モノリンガルの新奇語汎用パタンは，人工物を暗示する非可算名詞カテゴリ (表 6.1) の識別を最大化する特徴の重みとした．この特徴重みは英語名詞の特徴評定を用いて MDA で算出した．

6.4.3.4　形容語の特徴重みから知覚特徴バイアスの推定　前節で述べた特徴重みの推定は，形容語対 (e.g., 「丸い/四角い」) を特徴次元としての重みであるので，新奇語汎用課題に用いるためには，これを知覚属性 (e.g., 形) の重みに変換する必要がある．具体的には，形容語が表す属性の評定データによって知覚属性の重みを算出した (式 6.11, 6.12).

$$W_p = \sum_{i \subset \text{adjectives}} b_{ip}|w_i| \tag{6.11}$$

ただし，W_p は形，肌理，色を含む知覚属性 p の重み，w_i は MDA で推定される形容語特徴 i の重みである．b_{ip} は属性 p を表現する形容語対 i の適性 (正規化した評定平均値) である．つまり，式 6.11 では，形容語対 i の特徴次元の重み $|w_i|$ と，それに対応する属性の表現適性 b_{ip} の線形和から，知覚属性の重み W_p が計算される．

また，表現適性 b_{ip} は以下のように評定平均値 a_{ip}[1)] を $[0, 1]$ に正規化した値である．正規化には以下の閾値 m，スケールパラメタ r のロジスティック関数を

[1)] 詳しくは 2.2.3 節の形容語・属性実験を参照.

用いた (式 6.12).

$$b_{ip} = (1 + \exp(-r(a_{ip} - m)))^{-1} \approx \begin{cases} 1 & (a_{ip} \geq m) \\ 0 & (a_{ip} < m) \end{cases} \tag{6.12}$$

ロジスティック関数のパラメータ m と r は実験 1,2,3 のシミュレーション全ての条件で同じ値を用いた.

6.4.3.5　モデル選択　幼児の新奇語汎用データに対応する MDA モデルの適合性は，データに最も適合する最適モデルと比較する事でおこなった．データに対する適合性の指標は，以下の式で定義される Akaike's Information Criterion [104](AIC, 式 6.13) および Bayesian Information Criterion [105](BIC, 式 6.14) の二つを用いた．AIC と BIC はモデルのデータに対する適合性を表す対数尤度とモデルの自由度 (または自由度と対数データ数の積) の和によって定義される．従って，AIC と BIC はどちらもモデルの自由度あたりの適合性を調べる指標となっている．一般に BIC は AIC に比べて自由度の小さなモデルを選択する傾向がある．データ数は実験 1,2 で $N = 240$，実験 3 の場合のみ $N = 200$ であった (4 試行× 10 協力者× 6 条件 (実験 3 の場合 5 条件)).

$$\text{AIC} = -2\log(\text{likelihood}) + 2\,\text{dim} \tag{6.13}$$

$$\text{BIC} = -2\log(\text{likelihood}) + \log(N)\,\text{dim} \tag{6.14}$$

6.4.4　結果と考察

最適モデルで三つのリンク関数を比較した結果，線形，ロジットリンク関数に対して，対数リンク関数によるモデルが 6 条件 (i.e., 3 実験× 2 条件) 全てで最もデータに適合した (表 6.4 の線形・ロジットの AIC を参照)．従って，以下では対数リンク関数によるモデルの結果のみについて述べる．グリッドサーチによって推定された式 6.12 のパラメータは $m = 3.71$ と $r = 17$ であった．対数リンク関数による最適モデルおよび MDA モデルの結果を表 6.4, 図 6.7 に示す．表 6.4 にパラメータの推定値および AIC の値を示す．AIC または BIC が小さいモデルがよりデータに適合する事を意味し，アスタリスクはより適合するモデルを示す．図 6.7 に Yoshida & Smith[36] の実験の新奇語汎用確率を黒のバーで，MDA モデルの予測を灰色のバー，最適モデルの予測を白のバーで示す．エラーバーは実験データの場合，標準偏差，モデルの場合，95%信頼区間を表す．実験 1（いる・ある条件）の結果を上段，実験 2(半動物的な刺激を用いた日本語・

英語条件) の結果を中段，実験 3(人工的刺激を用いた日本語・英語条件) の結果を下段に示す．また，各グラフの横軸の ID, T, C, ST, S, SC はそれぞれ同一，肌理類似，色類似，形と肌理類似，形類似，形と色類似の刺激を用いた条件を意味する．MDA モデルと最適モデルの AIC を比較すると，実験 2 と 3 の日本語話者条件では MDA モデルは最適モデルよりデータに適合し，BIC の比較では，全ての条件で MDA モデルのほうが最適モデルよりデータに適合した．図 6.7 では，最適モデルの方が行動データによく適合するように見えるが，最適モデルは MDA モデルより自由パラメータが多い．AIC と BIC は異なる基準で自由度の多さも同時に考慮するため，その結果として MDA モデルが適合する場合がある．さらに，最適モデルと MDA モデルの適合性の違いに対して尤度比検定を行った結果，5%の有意水準で実験 3 の英語話者条件以外は有意な差は見られなかった．以上の結果は，MDA によって推定された特徴の重みは幼児の一般化パタンを再現するのに適していた事を意味する．つまり，幼児の新奇語の汎用パタンは，名詞カテゴリの特徴空間から予測可能で，ある名詞群の識別性の最大化する事 (i.e., 統語属性のオフラインの効果や文脈手がかりを利用) で推定できると考えられる．

また，これに加えて，モデルは Yoshida & Smith[36] の実験では行われなかった条件の結果も予測する．彼女らの実験では，標準刺激とテスト刺激の形と色が類似した場合の新奇語汎用 (SC 条件) は実験 1,2 では行われたが，実験 3 では行われなかった．これに対して，モデルは実験 3 の SC 条件の新奇語汎用率に関する予測を示した (図 6.7)．

6.5 結論

まとめ 本研究では，名詞カテゴリの共変動する複数特徴を情報圧縮する事で，固形性や動物性などの存在論的な構造と相関する要因を選択できる事を示した．さらに，その構造に加えて言語固有の統語属性も同様に情報圧縮する事が，「言語に偏向した存在論的構造」を導く事を示した．また，その結果として幼児の新奇語汎用課題に見られる存在論的カテゴリの境界移動 [36] を説明できる事を示した．これまでの研究でも，幼児のモノの種類に特異的な汎用行動は一般的な英語名詞の統計的な規則性を反映する可能性が示唆されてきた [5, 33, 39, 52]. Samuelson & Smith [52] は，存在論的に「重要な」構造 (e.g., 動物，固形の物体，非固形の物質) には，それぞれに固有の特徴 (e.g., 形，材質) と強い相関関

		実験 1		実験 2		実験 3	
		日本語話者		日本語	英語	日本語	英語
		いる	ある	動物		非動物	
	データ数	240	240	240	240	200	200
線形	AIC	268.27	288.33	279.08	301.67	216	240.43
ロジット	AIC	207.92	222.29	212.18	213.37	171.39	182.66
最適モデル 対数線形	切片 β_0	0.0358	-0.061	-0.009	-0.037	-0.002	0.008
	形 β_S	-1.968	-1.670	-2.213	-1.203	-1.809	-1.424
	肌理 β_T	-0.740	-0.292	-0.771	-0.166	-0.076	-0.002
	色 β_C	-0.313	-0.054	-0.371	-0.034	-0.281	-0.283
	自由度	4	4	4	4	4	4
	対数尤度	-94.86	-103.98	-95.402	-101.03	-83.766	-84.599
	AIC	197.72*	215.96*	198.8	210.07*	175.53	177.20*
	BIC	214.51	229.88	212.73	223.99	188.73	191.02*
MDA モデル 対数線形	切片 β_0	-0.068	-0.028	0.0688	0.053	-0.008	0.146
	スケール β	-2.293	-1.818	-6.801	-34.335	-1.909	-1.454
	形 βW_s	-2.144	-1.641	-2.235	-1.087	-1.734	-1.048
	肌理 βW_T	-0.636	-0.216	-0.638	-0.223	-0.229	-0.144
	色 βW_C	-0.225	-0.201	-0.502	-0.241	-0.211	-0.577
	自由度	2	2	2	2	2	2
	対数尤度	-97.77	-106.66	-96.88	-103.14	-83.81	-90.73
	AIC	199.53	217.32	197.75*	210.27	171.62*	185.46
	BIC	206.49*	224.28*	204.71*	217.24*	178.22*	192.06

表 6.4: 新奇語汎用の行動データ (Yoshida & Smith, 2003) に対する MDA モデル，最適モデルの適合性.

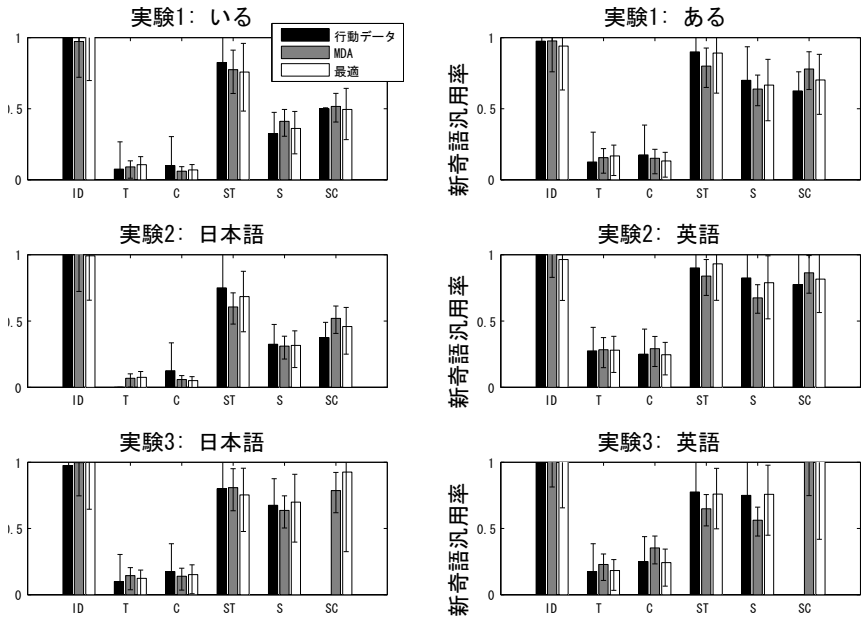

図 6.7: 新奇語汎用パタン.

係がある事を示した[1)]．しかし，これまでの研究では，なぜ他の特徴に対して形や材質，固形性などが重要であるかを説明できず，また，動物・物体・物質のような上位概念を表現する基盤は明らかではなかった．このような先行研究に対する本研究の一つの貢献は，特徴選択の計算論的基盤を明示的に議論した点である．本研究で提案するモデルは，具体的な形容語で構成された特徴空間に基づき，存在論的な構造が特徴の重みつき加算によって表現できる事を示した．またその重みは，高次共分散の最大化を基準として推定できる．このモデルの意味するところは，第 3 章の研究と比較して考える事でより明確になる．

本章のモデルと第 3 章のモデルの最も大きな違いは，特徴空間を効率に従って最適化するときの特徴空間の幾何学的な性質にある (3.2 節，3.6 節も参照)．第 3 章の詰め込みモデルでは，カテゴリ凝集性の発生を，局所的な重み付けの接続による滑らかな構造体を基にしたカテゴリの効率化によって説明した．また，線形射影による効率化では，カテゴリの凝集性の発生は説明できない事を示した．これに対して，本章のモデルは，存在論的なカテゴリの発生を，線形射影を基にしたカテゴリの効率化によって説明した．本章で対象とした，存在論的

[1)] 本研究の第 3 章でも，この知見を基に，カテゴリ凝集性を一般的に議論した.

なカテゴリは，自然カテゴリの「領域」(domain) あるいは「種類」(kind) の一つであると考えられ，このような複数の領域が発生 (凝集性) を説明するのが詰め込みモデルである．一方，特徴データのもつ潜在的な複数領域の中から，特定の領域の対比 (e.g., 動物/非動物や物体/物質) を選択するのが，本章のモデルであると考えられる．つまり，詰め込みモデルは自然カテゴリの「輪郭」の構造化をモデル化し，本章のモデルでは「ある視点から見た (射影の) 輪郭」をモデル化した事になる．この類推は，詰め込みモデルがカテゴリを局所的に操作し，その相対的な構造を変化させるのに対し (e.g., 粘土のような柔軟な造型に対応)，本章のモデルが，線形射影 (i.e., 特徴空間の回転，伸縮などの操作，つまり固定された造型に対する視点変換に対応) により，元々のカテゴリ間の相対的の構造を変化させない点で正しい．まとめると，詰め込みモデルは自然カテゴリの骨格的となる意味の形成を説明し，本章のモデルは，具体的な文脈を手がかりとして，意味の特定の側面を選択する事を説明したと考えられる．

他の理論的研究との関連性　本研究の計算論的モデルである主成分分析は，既に提案された幾つかのモデルと深い関連性を持つ．Younger [106] は 10ヶ月の乳児が特徴間に潜在する相関に敏感である事を示唆した．後に，自己符号器 (auto encoder) と呼ばれる一種のコネクショニストモデルによって，この乳児の相関に対する感受性を説明できる事が示された [107]．自己符号器モデルは逐次処理 (オンライン処理) する非線形の主成分分析に対応するため，主成分分析と同様に共分散を基に次元圧縮するモデルである．従って，自己符号器モデルが Younger の実験結果を説明できる事から，Mareschal[107] の研究は乳幼児が共変動する変数を基にした情報圧縮する事を示唆する．この理論的な背景を踏まえれば，本研究は，幼児の新奇語汎用における高次の特徴発見と，乳児のカテゴリ化を同じモデルで関連付けたと考えられる．

また，本研究は，多次元の特徴空間データを用いた事で，先行研究のモデルの拡張としても位置づけられる．Colunga & Smith [26] は，名詞カテゴリが「物体」と「物質」に分化し，形や材質バイアスが発生する過程をモデル化した．この研究では，コネクショニストモデルが事例の形，材質，固形性，統語属性などの特徴と名詞カテゴリとを連想学習する事で，その間の物体・物質の統計的規則性の抽出が行われた．このモデルと本研究のモデルは統計的性質の要約と言う点で類似の計算原理を持つ．しかし，最も大きな違いは，本研究では特徴セットとして明示的に固形性や形などを表現せず，名詞カテゴリの記述に意味

のある特徴を選択する過程に焦点を絞った点である．Colunga & Smith の研究では，関連する特徴のみに限定して連想学習した場合に物体・物質の存在論的区別が発生する事が示された．しかし，本研究は先行研究を拡張して，なぜ固形性などの特徴が「重要な属性」として現れるのかを議論した．実験の再分析では特徴選択により固形性と考えられる要素が自己組織化される事を示し，シミュレーション 1 ではその存在論的な構造，上位概念の変化や安定性について調べた．従って，本研究は潜在的する多くの特徴からなぜ特定の特徴が選択され，他の特徴が選択されないのか説明を与え，統計的学習に基づく Colunga & Smith などの仮説を拡張したと考えられる．

展望　既に述べたように，本研究のモデルは，名詞カテゴリの上位概念の対比構造を選択すると考えられる．しかし，しかし，本研究で提案したモデルにはまだ改善の余地が残されている．その最も大きな問題点とは，新奇語汎用課題のモデル化で「特定のカテゴリ領域」を仮定によって与えた点である．シミュレーション 2 では，ある特徴が特定のカテゴリ群を指示する手がかりとなると仮定し，与えられたカテゴリ群を識別する特徴の重みを推定した．例えば,「いる」の統語フレームが与えられた場合,「いる」の特徴を持つ名詞カテゴリに関する識別を最大化する戦略を仮定した．もし特定のカテゴリ群が与えられれば,モデルは特徴の重みを推定する計算的基盤に関して説明する．しかし，なぜ文脈的に利用できる情報は他にもあるにも関わらず「いる」・「ある」を新奇名詞の汎用範囲を狭める制約として用いるのだろうか．つまり，本研究のモデルには文脈手がかりの顕著性，信頼性や有効性などの議論の余地がある．この問題を解決する一つの手がかりは，特徴評定の内に潜在する領域特異的な構造にあるかもしれない．従って，詰め込みモデルによって発生する特異的な領域と，文脈の手がかりとなる顕著な特徴との関係を調べる事が今後の課題として挙げられる．

また，この後の課題として興味深いのは，名詞だけではなく，動詞などの他の概念対象にも本研究の手法が応用可能か，という点である．既に行われた動詞の評定実験の結果，動詞の特徴空間が体の部分と強く関連する事が示されている [108, 109, 110]．これらの研究も名詞カテゴリと同様に，動詞と体の部分との連合関係を分析することで，幾つかの体の部分に固有の動詞群がクラスタを形成する事が示されている．このような動詞のクラスタ構造は自己中心的な表現を反映する可能性があり，更なる研究が求められる．

第 7 章　総合考察：意味認知の幾何学的変化

本論文では，カテゴリおよび特徴に関して，表現形式の効率性を共通するテーマとして，各章で個別の話題について述べてきた．表現の効率性は，カテゴリ化のシステムに与えられる環境や，達成するべき課題などから与えられると考えられ，さらに心理実験的な知見に対する整合性を持たなければならない．序論では，分類される対象 (入力)，分類するべき課題 (出力)，カテゴリ表象 (内部表現)，そしてそれらの効率性のバランスという 4 つの観点から，カテゴリ化の計算理論について議論を展開した．カテゴリの内部表現は，分類される対象や課題が何であるのか，またそのカテゴリ効率と相補的な関係にある．この総合考察では，特にカテゴリの内部表現について深く掘り下げて議論したい．以下ではまず，本論文の各章の研究を簡単に振り返る．本論文の研究をまとめて，概念発達に関して最も重要な点は，モデルの内部表現の特徴 (i.e., 特徴空間の特徴またはメタ特徴) を含めたモデル選択を，無限後退 (i.e., メタメタ特徴によるメタ特徴の選択) に陥らずに行う事である．本論文では，基本カテゴリのメタ特徴 (i.e., 滑らかさ：第 3 章を参照) により定量化し，そのメタ特徴選択の計算論的条件 (i.e., 詰め込み効率化) を議論した．幾つかの先行研究では，カテゴリ化のメタ特徴は，幾何学的性質の違いと関連付けて議論されている．これを踏まえて，本章は，メタ特徴の選択が発達的な変化に伴い遷移する，という仮説を提案する．メタ特徴の選択を推進する駆動力として，幾つかの要因が考えられる．また，これを裏付ける知見として，特定のメタ特徴に必要な認知能力の発達に関する先行研究を例に説明する．最後に，幾つかの理論的な研究を取り上げて，メタ特徴の選択の推進力について考察する．

7.1　各章のまとめ

第 3 章では，自然カテゴリの凝集性が発生するための計算論的な条件について研究を行った．特定の特徴群により構造化される特定のカテゴリ群が “クラスタ” を形成し，このクラスタ群が形成する自然カテゴリの集団的構造をカテゴリ凝集性と呼ぶ．本研究では，カテゴリの凝集性を，特徴空間が連続的に変化する性質として捉える統計量 (i.e., 滑らかさ) を提案した．滑らかさは，特定の特徴次元の名義的な違いによらず，特徴空間の変化の程度，すなわちメタ特徴を記述する尺度である．従って，カテゴリ凝集性の発生は，特徴の選択では

なく，メタ特徴 (滑らかなカテゴリ群) の選択問題として定式化できる．第 3 章では，数理解析的手法，シミュレーションによって，カテゴリ効率性およびカテゴリが固有の特徴重みを持つ事 (i.e., 詰め込み効率性) が凝集性の発生に必要である事を示した．このようにカテゴリごとに固有の特徴重み付けを持つカテゴリモデルは，全体として曲がった空間で形成されるマップによりカテゴリ化を行うと解釈できる．このモデルは，例えば，自己組織化写像 (Self Organizing Map) [111] や Isomap [112] などのように高次元のデータを低次元の位相的構造に圧縮する手法の一種とみなせる．ただし，本研究では，このような次元圧縮モデルにおいて，与えられたデータ構造に対する適合性ではなく，マップ自体の効率性 (i.e., 識別性，一般性) とそのマップ上に形成されるカテゴリパタン (i.e., 凝集性) の一般的な関係を導いた．

第 3 章の研究は，敢えてデータ構造を単純化し，また幾つかの自然カテゴリの重要な性質に関する議論を避けてきた．自然カテゴリは具体的な知覚的特徴に基づいて記述され，階層性を持ち，また普遍的構造だけではなく文化・言語に固有の違いを持つ．第 4 章, 第 5 章, 第 6 章では，それぞれこれらの自然カテゴリの性質を，第 3 章で提案した計算理論に取り入れるための研究を行った．

第 4 章では，第 3 章の計算理論で最も重要な仮定である，カテゴリ固有の特徴選択を，具体的な幾つかの事例分布条件に関して検討した．具体的には，異なる種類の事例に対して，異なる新奇語の汎用パタンを形成するシミュレーションを行い，複数の事例分布の条件に対するモデルの結果を比較した．プロトタイプごとに特徴重みを調節する提案モデルと，特徴次元ごとに重みを調節する先行研究のモデルを検討した結果，先行研究のモデルよりも，提案モデルのほうが複数のカテゴリ化領域を獲得するのに適する事が示唆された．従って，第 3 章でのカテゴリ表現の仮定は，新奇語の汎用など発達的知見の点でも妥当である事が示唆された．

第 5 章では，特徴処理の階層的構造とカテゴリ化効率の関係について調べた．具体的には，未分化な視覚像から，シンボル的な形・肌理・色などの高次特徴を形成する過程をシミュレートした．視覚的な物体の形，肌理，色の特徴は階層的な関係にあり (e.g., 形 (輪郭) は色，肌理などのより低次特徴の組み合わせからなる)，実際に大脳皮質では階層的に情報処理されると考えられている [41]．ここでは特に，物体の分節化・個別化を行う場合に，階層性の中のどの水準の特徴 (形，肌理，色) を利用する事が効率的であるか調べた．シミュレーション

の結果，モデルの内部表現の自由度にあたる隠れ層のユニット数に応じて，シンボル化されやすい特徴が変化する事が示された．従って，発達研究で観察されるように形の特徴が他に比べて先行して分化するための条件として，ごく少数の中心的な内部表現に制限する事が必要である事が示唆された．

第 6 章では，ある特定のカテゴリ化を暗示する文脈が与えられる場合に，そのオンライン・オフライン効果についてのモデルを提案した．幼児の新奇語汎用課題には，言語に共通なパタンと，言語に固有なパタンがあることが示唆されている [32, 36]．いくつかの発達研究では，言語固有の統語的なカテゴリ (i.e., 英語では可算・非可算名詞，日本語では「いる」・「ある」の用法に対応する名詞クラス) の学習が，言語固有の新奇語汎用パタンを形成すると考えられている．本研究は，このような言語固有の効果は，言語共通的な特徴空間を，特定の文脈手がかりに最適な「射影」方向に重み付けた結果であると仮説を立てた．つまり，特徴空間そのものが変化するというよりも，その場で与えられた手がかり (e.g.,「X がいる」/「X がある」の文脈) に相関する特定の成分だけ (e.g., 手がかりに相関する特徴「目がある」/「目がない」) を特徴とみなすのである．この仮説は，評定実験で得られた日本語・英語名詞の特徴空間から，言語固有の新奇語汎用パタンをモデルで予測する事で確かめられた．つまり，統語的カテゴリの影響による名詞カテゴリ空間の変動 [36] を，統語カテゴリの予測性を最大化するような特徴空間の回転・射影 (線形写像) として説明できることが示唆された．第 3 章では，カテゴリ凝集性の説明には特徴空間の曲面的な非線形写像が必要で，線形射影では困難である事が示唆された．これを踏まえて考察すると，言語固有の効果，つまり特定の文脈に関する訓練や専門化の効果は，自然カテゴリの本質的な構造化に影響が低く，それよりも表層的な段階で起こるのかもしれない[1)]．

以上で述べた各章の研究は全て，何らかの形でカテゴリの内部表現や特徴空間の構造，もしくは最適化するべきカテゴリの構造 (i.e., 特徴空間の曲面的表現，文脈効果の線形射影による表現，階層性の木構造) を中心に議論を行った．従って，これらのモデルの前提となる，カテゴリ表現の幾何学的性質について改めて確認しておきたい．本研究で主に対象とした基本カテゴリの幾何学的性質を理解する上で，以下ではより一般に，知覚的な対象や抽象的で概念的な対

[1)] 幾つかの研究では [2]，ある分野・領域に関する専門化が概念形成の本質とする考え方があり，論争中である．

象の幾何学的性質に関する研究を紹介する．また，ここで挙げる理論的な条件だけではなく，実際の幼児が，ある幾何学的なモデルに従ってカテゴリ化を行うためには，幾つかの認知機能が必要となる．そこで，ある幾何学的なモデルによるカテゴリ化を実現するために，必要となる発達的な条件についてまとめる事で，概念構造の幾何学的な発達について本研究の仮説を提案する．

7.2 効率と幾何学的構造

カテゴリ化する対象の構造によって，表現に適した幾何学的構造は異なると考えられる．つまり，自然カテゴリの記述に適したモデルの幾何学的構造を特定する事が，そのメカニズムの解明に繋がると考えられる．ここで，幾何学的な構造とは，心理的・物理的対象の間の関係を定める公理の集合である．例えば，ある対象群をユークリッド空間上の点として表せる，という命題は，ユークリッド空間の持つ次のような関係を認める事である．ユークリッド空間では，距離の最小性[1)]，距離の対称性[2)]や三角不等式[3)]などが至る所で成り立つ．現在の多くのカテゴリ学習のモデルは，ある特定の特徴次元からなるユークリッド空間やその拡張を基に定式化されている．一方，第 1 章で述べたように，集合論的なカテゴリ観では，点間の「距離」のように連続的な尺度は存在せず，集合の包含関係だけによりカテゴリが関連付けられる．このような幾何学的性質では，あるカテゴリに含まれる事例の「典型性」などの心理的特性の勾配を説明できないために，現在ではあまりモデル化に利用されていない．

幾何学的性質として含まれる公理が多いほど，表現される対象に関して制約が強く，未知の対象に対する予測が可能になると考えられる．この意味で，ユークリッド空間によるモデルは制約が強く，集合論的カテゴリ観は制約が弱い．図 7.1 に 3 種類の幾何学的構造をグラフによる表現で示した．ユークリッド空間は図 7.1a のように，至るところで頂点に結合する辺の数が一定に制約され，その制約ゆえに空間上の任意の点で近傍の空間に関する予測性が高い．当然のことながら，制約の弱い幾何学的モデルが表現能力に劣るという事ではなく，現象の表現に適したモデルを選択する必要がある．距離基準を持ちながら，ユークリッド空間ほど強い制約を持たないものの一つとして，例えば，グラフによ

1) 点 A から点 A の距離は，点 A と任意の点 B の距離以下である
2) 点 A から点 B への距離と点 B から点 A への距離が等しい
3) 距離 AB と距離 BC の和は距離 AC よりも長い

るモデルがある (図 7.1c)．グラフによるモデルでは，ある対象を頂点とし，頂点間の辺によって対象間の距離を表す．一般にグラフ構造はクラスタリングなどで用いられ，階層性を表す「木構造」[113] や，相互に循環参照をする複雑な「ネットワーク」[30] を表す事ができる．このようなグラフにおいて，任意の点に対して，一定数・等距離の隣接頂点を持つように制約を置けば，これをユークリッド空間と同等の幾何学的な構造体とみなせる．

それでは，心理的な自然カテゴリの表現として，どのような幾何学的な構造が適しているのだろうか．Tversky & Hutchinson [114] は，独創的な方法で幾何学的構造と心理的対象の関連付けを行った．既に述べたように，グラフ的なモデルと，ユークリッド的なモデルの一つの違いは，隣接する点に関する制約の有無である．従って，最近傍点の数を分析する事で，ある対象をモデル化するのに適した幾何学的性質を調べる事ができると考えられる．そこで，Tversky & Hutchinson [114] は，100 もの異なる距離評定のデータを分析する事で，知覚的な対象 (e.g., 色，文字，香り, 聴覚刺激など) は，一定数以下の最近傍点をもつが，一方，概念的な対象 (e.g., 動物，感情, 国, トリ，武器など) は，最近傍点の数にばらつきが見られる事を示した．つまり，知覚的な対象は，距離基準が一様に制約されたユークリッド的な構造を，概念的な対象は，距離基準に制約の弱いグラフ的な構造をとる事を示唆した．

7.2.1　幾何学的性質の選択の必要性

このような研究を背景として，本研究で扱った発達初期に獲得される自然カテゴリ (基本カテゴリ) は，知覚的・概念的のどちらで，またどのような幾何学的な表現形式が適切なのだろうか．端的に言えば，距離基準が厳密に一様なユークリッド幾何 (知覚的) でも，距離基準が任意的なグラフ構造 (概念的) でもなく，その中間的な幾何学的モデルが基本カテゴリの表現に適するのではないだろうか (図 7.1b)．Rosch et al. [4] は，基本カテゴリを「知覚的な共通性を持つ，最も一般的 (抽象的) なクラス」と表現した．つまり,「イヌ」や「イス」などの基本レベルのカテゴリは，多くの人に共通する知覚的なプロトタイプを持つが，上位カテゴリの「動物」や「家具」などは，それらに共通した「形」を絵にする事ができない．また「ダックスフント」や「ロッキングチェアー」は同じく知覚的プロトタイプを持つが,「イヌ」や「イス」に含まれる．Rosch et al. [4] はこのような構造の一つの要因は，識別性と一般性によるカテゴリの効率化にあると主張した．しかし，本章で提案するこれを捉えるもう一つの切り口は，基

本カテゴリの表現は，幾何学的な制約と予測性の均衡的な「縁」にあるという考え方である[1)]．つまり，知覚的な参照を持つ基本カテゴリは，局所的にユークリッド空間的な構造を持つが，全体的には複数の異なるユークリッド空間が接続した複雑な構造になる (詳しくは第 3 章を参照)．例えば,「イヌ」に含まれる下位カテゴリは知覚的共通性を持つので，比較的小さい次元のユークリッド空間で表すことができ,「イス」もまた同様にユークリッド空間で表す事ができるとする．両方のユークリッド空間を構成する特徴次元は同じではなく，それぞれに固有の特徴を持つが，しかし，両者は任意の結合をしているわけではなく連続的・滑らかに “曲がった”空間上で接続すると考えられる．このような曲がった空間 (リーマン多様体) におけるカテゴリ表現は，ユークリッド空間のように至るところで重みづけが一定 (曲率が一定) ではなく，グラフのように任意の近傍と接続するわけではないため，丁度両者の中間に当たる自由度と予測性を持つと考えられる (図 7.1b)．このような幾何学的クラスについて表 7.1 の左側にまとめた．

ここで，一つの重要な問題が浮かび上がる．すなわち，幾何学的クラスを適切に選択する推進力は何か，というメタ特徴選択の問題である．無限後退的な議論を避けるためには，メタ特徴選択の問題を「メタメタ特徴」によって解決するわけにはいかない．ここでは，推進力の候補として，二つの要因を考える．一つは，認知発達の遅れから生じる，認知機能の制約である．言うまでも無く，特定の幾何学的クラスのカテゴリ表現をするには，それを実現するための基礎的な認知機能が必要である．例えば，ある一定齢に満たない幼児は，ある特定の特徴次元に選択的に注意する事が困難で，対象を全体的な類似性から判断する傾向がある [115]．従って，必要な認知機能の成熟は一つの要因として考えられる．しかし，十分な認知機能を備えたときに，どの幾何学的クラスの表現を選択すべきか，という問題は残されている．そこで，もう一つの推進力は，内部表現そのものに関する効率化 (i.e., 内部表現素の間の相互作用) である．本研究の第 3 章では，メタ特徴 (i.e., 滑らかさ) を制約する詰め込み効率性を提案した．これは，ユークリッド幾何的な構造 (距離基準の一様性，図 7.1a) から，リーマン幾何的な構造 (距離基準の多様な空間，図 7.1b) の範囲で，ある曲率を持っ

[1)] 幾何学的クラスの選択を含むモデル選択と，ある幾何学的クラスのモデルを仮定した上での特徴選択は異なる．つまり，幾何学的クラスを選択した上で，Rosch et al. の主張する識別性・一般性が定義できる．

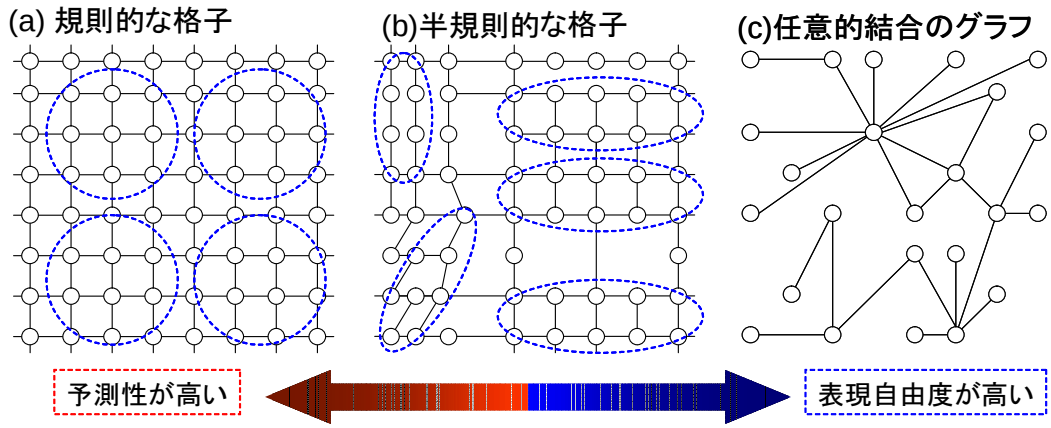

図 7.1: 幾何学的構造の変化

た特徴空間を選択する拘束力とみなせる．また，同様に, 大規模なグラフの統計的な性質に関する最近の研究からは，特定の性質を持つグラフ構造の説明には，グラフ上の要素間の相互作用が重要である事が示されている [116, 117, 118]．一方，これとは対照的に，例えば，認知機能を説明する多くのコネクショニストモデルでは，内部表現そのものに関して拘束条件を置かずに,「環境」として与えられた入出力関係によって内部表現を構造化する．しかし，幾何学的クラスの選択に関して，入出力関係だけで十分な制約となるかは疑問が残る．このような理論的な展望に関しては，認知発達の必要条件に関して述べた後に詳しく述べる．次節では，リーマン幾何的な表現，およびそれがグラフのようにさらに柔軟な構造になるための必要条件について述べ，関連する認知発達との合致する点について述べる (表 7.1 右側).

7.3　カテゴリ表現の発達的変化

以上で述べた幾何学的表現に関する主張が正しいとすれば，それを実現するための認知発達が伴わなければならない．例えば，ユークリッド幾何的な表現

	カテゴリの表現		発達的変化		
カテゴリ対象	幾何学的クラス	表現の性質	時期	知覚的カテゴリ化	新奇語汎用
知覚的	物体単位の分化		0,1 歳	物体の恒常性・個別化	試行錯誤的
知覚的・中間的	ユークリッド幾何	高い予測性	2,3 歳	全体的類似性	形・全体性バイアス
中間的	リーマン幾何	自由度・予測性	4,5 歳	次元選択的注意の発達	形・分類学的基準
概念的	グラフ・ネットワーク	高い自由度	8 歳〜	次元同一性の発達	分類学的基準

表 7.1: 表 7.1 カテゴリ表現の幾何学的構造とそれに対応する必要な発達的変化

からリーマン幾何的な表現に移り変わるためには，少なくとも，ある特定の対象に関して特定の特徴類似性に選択的に重みづける事が必要である．このように知覚的対象から概念的対象に適したカテゴリ表現を発達させるために必要な幾つかの認知発達がいつ起こるのだろうか．ここでは網羅的な研究紹介ではなく，代表的な少数の研究を挙げて，本研究の仮説との関連性を述べる．第一章で取り上げたように，0，1 歳の時期は物体の恒常性 [119] や物体の分節化・個別化 [73, 72] など物体の表現やその属性が確立する時期である．この前言語期には初期の語彙獲得に必要な物体の様々な性質が獲得されると考えられる．第 5 章では，この時期におこると考えられる知覚的特徴のシンボル化と，物体の個別化，内部表現に用いる容量の違いとの関係をモデルによって検討した．1 歳前後から，1 語・2 語文の発話が始まり，それから 1 歳半ぐらいまでの間は試行錯誤的な語彙の獲得が起こる時期である．この時期の新奇語汎用では，系統的なパタンがみられず素早い語彙学習 (即時マッピング) はまだ見られない [52]．1 歳の後半から 2 歳にかけて語彙爆発と呼ばれる，語彙獲得の速度が高まる現象が見られる [38]．2，3 歳ごろの新奇語汎用では，系統的に物体の全体的特徴や形状の類似性を重視する傾向があり，新奇語の参照対象を試行錯誤なしに適切に予測する即時マッピングがみられる．本論文では，特にこの時期の新奇語汎用課題に関して研究を進めた．この時期の新奇語汎用パタンは単純に全ての対象について形類似性を重視するわけではなく，固形な物体には形を重視するが，非固形な物質には材質を重視し，また動物的な対象には複数の特徴を重視する傾向がある．つまり，物体・物質・動物などの複数の概念領域の対象に対して，異なる特徴に選択的に重みをつけた特徴空間を持つと考えられる．物体・物質・動物などの概念領域の境界は必ずしも厳密に固定されておらず，幼児の学ぶ母語によって多少の変化がある [36]．第 6 章では，その概念領域の変化が，言語固有の統語構造に特化した特徴空間の射影方向によって説明できる事を示した．また，第 4 章では，そもそも複数領域が安定して分化するために，十分なカテゴリ表現を検討し，各々に重み付けをもつプロトタイプ的表現が適する事を示した．この表現は次に述べる幾何学的構造を張るための基底となると考えられる．幾つかの異なる特徴を持つカテゴリの全体構造は，異なる特徴重みを持つ概念領域が張り合わされて全体を形成するリーマン幾何学で表現できる．このようなカテゴリ表現を持つためには，少なくとも，知覚的な特徴次元に対する選択的注意が可能でなければならない．知覚的対象の自由分類課題では，大き

さ，色などの特徴を持つ対象に対して，特徴次元選択的な重み付けが可能になるのは 3 歳から 4 歳にかけての時期である [115]．新奇語汎用の際の形バイアスなどと類似して，2，3 歳の幼児は自由分類課題において全体的な類似性を重視する傾向があるが，4，5 歳の幼児はある特徴次元に関する類似性を重視する傾向がある [115]．従って，3 歳ぐらいの幼児が，異なる特徴次元に重み付けたユークリッド空間によって知覚的なカテゴリを表現する事は十分可能である．また，物体・物質・動物の複数の領域が，互いに独立に存在するのではなく，その中間的な新奇語汎用パタンが観察されること [26] もリーマン幾何学的な表現の可能性を支持している．さらに発達が進み 5 歳ぐらいになると，3 歳ごろにみられた知覚属性を中心としたパタンではなく,「分類学的基準」に沿った概念的な属性を重視した新奇語汎用パタンが増加する [120]．ここで分類学的基準に沿う新奇語汎用とは,「にんじん」と「ロケット」のように形が似ているが別なカテゴリに属するものより,「にんじん」と「じゃがいも」のように生物学上の同じカテゴリに属するものを選択するパタンのことである．Imai et al. [120] によれば，新奇語汎用の様式は単純な知覚的類似性から，分類学的基準へと発達に従って移行する．既に述べたように，概念的な対象のカテゴリ表現は，より柔軟で自由度の高いグラフ・ネットワーク的な表現が適すると考えられている [114, 30]．概念を頂点とし，概念間の関係を頂点間の辺とするグラフ構造を表現するためには，少なくとも個々の概念が離散的な様式で認識される必要がある．これは発達の初期段階で物体やそのカテゴリが連続的な知覚的特徴の空間で表現されることと大きく異なる．知覚的対象の自由分類課題では，8 歳を過ぎた子供や成人は，ある特徴における段階のある”類似性”よりも，”同一性”を強く重視する [115]．つまり，5 歳より若い幼児は類似性と同一性が線形的であるが，成熟した大人では同一性が不連続的に特別視されているか，もしくは指数的に類似性への感度が変化する．Smith [115] によれば，このような発達的な傾向は，連続的な特徴に基づくカテゴリ化から離散的な概念表象への遷移を反映する可能性が高い．第 5 章のシミュレーションでは，より内部表現に冗長性が少ないほど，物体の肌理属性よりも形属性を表現するユニットが増加し，物体の大局的属性を符号化する傾向がみられた．ここから分かることは,「物体」とは何か，また物体を表現する属性をどのように分化するのか，という点にある程度の冗長性が含まれおり，この冗長性を解消し特定のパタンが生じるための要因として，認知的資源の制限が重要な鍵を持つと考えられる．前述のように，発達初

期には知覚的物体は物体全体の類似性で分類されるが，次第に個々の特徴に選択的な類似性が利用可能になる．この発達経過は，発達初期にはカテゴリ化に用いる認知的資源が小さく限られており，その資源が拡大されていくにつれて，より細分化した特徴へ注意が分化すると考えれば辻褄が合う．このような発達初期の認知資源の制限は，文法獲得のパタンの説明でも主張されている [97].

次節では，意味的な認知課題に関する理論的な研究を取り上げ，幾何学的性質の選択を制約する推進力について考察する．具体的には，概念発達に関してコネクショニストモデルで説明できること，そしてモデルの限界について述べる．この限界は幾何学的構造の自由度に基づいた解釈ができ，高次の概念構造を表現するための重要な手がかりになると考えられる．

7.4 幾何学的性質の選択：理論研究の展望

7.4.1 コネクショニストモデルによる意味認知の説明

Rogers & McClelland [1] は，自然カテゴリの多岐にわたる課題が，並列分散処理モデル (Parallel Distributed Processing model; PDP モデル) によって再現可能である事を示した．特に，ここでは彼らのモデルによるカテゴリ凝集性の説明について述べる．PDP モデル[1)]は，入力としてカテゴリラベル (主語：“bird”, “swallow” など)，出力として特徴 (述語：“fly”，“feather”, “bird” など) と関係を表す特徴 (動詞：“can”, “has”, “is” など) を持ち，入・出力間が中間のユニットを経由して連結された三層パーセプロトンである．このモデルには，データとして特定の組み合わせの文が与えられ，“swallow” に対して “can fly”，や “dog” に対して “is mammal” を正しく出力するように繰り返し学習した．

Rogers & McClelland [1] はその他の多くの認知的な現象と共に，カテゴリ凝集性に対しても PDP モデルによる説明を与えている．彼らによれば，カテゴリ凝集性とは，入出力の特徴次元における高次相関のことである[2)]．高い高次相関を持つ特徴次元は，変数の分散を共有するので，少数の結合荷重を変更するだけでより多くの出力エラーを減らす事ができる．従って，PDP モデル (また一般のコネクショニストモデル) では高次相関の高い変数ほど学習が促進さ

[1)] ほとんどのシミュレーションでは，特に Rumelhart ネットワークと呼ばれるモデルが用いられた．

[2)] 高次相関とは，2 変数の対による相関だけではなく，3 変数以上にも拡張された共変成分である．正確には，共分散行列または相関行列の固有値を指す．従って，主成分分析で言う主成分の寄与率と同値である．

れ，また，それらの変数は内部表現を共有する事で，カテゴリの凝集化が起こる．従って，人のカテゴリ化が共変成分に敏感であるために[1)]，自然カテゴリの凝集性が発生すると彼らは結論した．幾つかの疑問点はあるものの，この主張は統計的モデルまたは情報圧縮の核心であり，興味深い．

7.4.1.1　高次相関を計算する範囲の非限定性　一方，PDP モデルによるカテゴリ凝集性の説明には，幾つかの些細ではない疑問点も残されている．その一つは,「高次相関」がどのような範囲で計算されるか，詳細な議論がされておらず，不明確である点である．もし，前述の主張のように，ある概念が共変成分の冗長性を最小化した変数であるとすれば，最終的に残る概念は，互いに限りなく無相関・独立であるはずである．しかし，これは入力として，“swallow”, “canary”(二つは高い相関を持つ) が与えられる事と矛盾する．モデルでは，入力として与えられる概念間の相関が最小化される事で，“bird” の概念が凝集化すると考える．だが，その豊富に相関する冗長性を持つ「入力」自体は，どこで計算される事で概念として残っているのだろうか．従って，もし高次相関によって概念の発生を説明しようとすれば，独立に高次相関を計算する複数のモデルが必要となる (e.g., “bird” と “canary” は異なる水準で計算する)．この事は，Rogers & McClelland[1] 自身も示唆しており，学習に先立って，ある程度ネットワークの配線を適切に選択する必要 (i.e., 概念領域の分化) があると述べている．従って，入出力として与えられた高次相関だけでは，高次相関そのものの「計算範囲」を制約できないと考えられる．つまり，内部表現構造の幾何学的クラスを選択するのに，入出力関係に潜在する高次相関だけでは不十分である．

7.4.2　複雑なネットワークとしての自然カテゴリの表現

入出力の学習だけではモデルの幾何学的クラスを限定できないという洞察は極めて重要である．最近のグラフモデルに関する研究から，大規模な社会的構造 (e.g., 友人関係や WWW リンク関係のグラフ) は特定の統計的性質を共有する事が分かってきた．このようなグラフの特徴は，グラフの個々のノードに与えられた意味づけ (入出力の構造) ではなく，グラフのノード間の相互作用が構造化を促進する点である．コネクショニストモデルでは，一般的に学習初期に全ての結合がランダムな値に設定されるので，無作為にノードが結合されたラ

[1)] 実際に，人は相関に敏感である [121, 106].

ンダムグラフとみなせる．このランダムグラフは，入出力関係に適合するように結合を強化・縮小され，最終的にカテゴリ表象を分散的に形成する．初期状態にランダムグラフを仮定する事は，一つの強い制約となり，(ランダムグラフに近い) 分散的な構造を選好し，集中的・局所的な構造を作りにくい副作用を持つ．これに加えて，コネクショニストモデルでは，入出力関係に与えられた構造しか内部結合に作用しない．言うまでもなく，コネクショニストモデルはこの方式によって様々な研究で成功を収めているが，その多くは小規模に単純化された問題である．内部表現を「白紙」とする事は，構造に仮定しない事ではなく，ランダムグラフへの強い選好を仮定する事である．この強い仮定がモデルの可能性を限定している事は大いに考えられる．より複雑で大規模な問題，つまり現実的に脳が解決する問題を考える上では，ネットワークトポロジー (幾何学的構造) に関するより詳細な議論が必要ではないだろうか．

近年，複雑なネットワーク構造を分析する強力な理論が開発されつつある．その中の代表的なモデルが，”スモールワールド”ネットワークや”スケールフリー”ネットワーク (Small-world network [118], Scale-free network [116])：総称して複雑ネットワーク [117] と呼ぶ) である．ここでは詳細な説明を行わないが，ごく簡単に言えば，ランダムグラフとは異なり，ある結合数を持つノードの頻度がべき則に従う統計的性質を持つ．つまり，少数の集中的な結合を持つ “ハブ”と呼ばれるノードと，大多数の疎な結合を持つノードが混在したネットワーク構造をなす．現実の例として，友人関係，論文引用，ウェブサイトのリンクなど様々な種類のネットワークがこれらのモデルに当てはまるといわれている．最近の研究では，大規模なコーパスを基にして，名詞カテゴリのネットワーク構造を分析する事で，文脈を含めたより柔軟なカテゴリ構造が調べられている [29, 30]．このような研究から，名詞カテゴリの文脈を複雑ネットワークで記述できる事が示唆された．この事は，文脈の中継地点となる集中的なリンクを持つ少数の一般的なカテゴリと，個々の事例に対応する大部分の特殊なカテゴリが混合した構造を意味している．このような集中的な結合と分散的な結合のべき分布的な混合は，より多い結合を持つノードほど，さらにリンクを増加しやすいときに発生する．つまり，全てのノードが一様に等価ではなく，逆に「貧富の格差」が拡大するような相互作用をするときにべき分布が発生する．従って，名詞カテゴリの意味的なネットワークがべき的性質をもつ事は，与えられた入出力を写し取った結果というよりも，概念 (カテゴリの内部表現) そのもの

が競合的な相互作用をした結果であると考えられる．

7.5 おわりに

本研究で一貫して議論したように，冗長性の高い知覚的類似性を特定のカテゴリに分化し，その最も効率の高い水準にあるのが基本カテゴリであると考えられる．本研究では，それらのカテゴリの構造が識別性・一般性のバランスの下で最適な状態として表現でき，また特徴空間の幾何学的な性質の選択とみなせると結論づける．しかし，もしそうであるならば，それ以降に発達すると考えられる，より抽象的な概念群が，逆に，あまりにも冗長性・自由度が高すぎる構造を持つ事は，大きな矛盾・疑問として残る．知覚から基本カテゴリ，基本カテゴリから概念への発達は，あたかも冗長性の減少・増大を描くU字型の発達のようである．その意味で，U字型曲線の変化点である基本カテゴリは概念発達の最も重要な鍵の一つかもしれない．メタ特徴選択の問題は，言うなれば，幾何学の公理系の選択でもある．従って，公理系の間，つまりグラフ的な離散の世界とユークリッド的な連続一様の世界の間を，連続的に繋ぐ理論こそが意味認知の真の理解に繋がるように思われる．

参考文献

[1] T. T. Rogers and J. M. McClelland. *Semantic Cognition: A Parallel Distributed Processing Approach*. The MIT Press, Cambridge, MA, 2004.

[2] W. V. O. Quine. *Word and Object*. MIT Press, Cambridge, MA, 1960.

[3] R. Brown. *Words and Things*. Free Press, New York, 1958.

[4] E. Rosch, C. B. Mervis, W. D. Gray, D. M. Johnson, and P. Boyes-Braem. Basic objects in natural categories. *Cognitive Psychology*, Vol. 8, pp. 382–439, 1976.

[5] B. Landau, L. B. Smith, and S. S. Jones. The importance of shape in early lexical learning. *Cognitive Development*, Vol. 3, pp. 299–321, 1988.

[6] E. M. Markman and J. E. Hutchinson. Children's sensitivity to constraints on word meaning: Taxonomic versus thematic relations. *Cognitive Psychology*, Vol. 16, pp. 1–27, 1984.

[7] D. Marr. *Vision*. Freeman, San Francisco, 1982.

[8] G. Murphy and D. L. Medin. The role of theories in conceptual coherence. *Psychological Review*, Vol. 92, pp. 289–316, 1985.

[9] N. Chomsky. *Syntactic Structures*. Mouton, Den Hague, 1957.

[10] D. L. Medin, E. B. Lynch, and K. O. Solomon. Are there kinds of concepts. *Annual Review of Psychology*, Vol. 51, pp. 121–147, 2000.

[11] E. E. Smith and D. L. Medin. *Categories and concepts*. Harvard University Press, Cambridge, MA, 1981.

[12] A. M. Collins and Quillian M. R. Retrieval time from semantic memory. *Journal of Verbal Learning and Verbal Behavior*, Vol. 8, pp. 240–247, 1969.

[13] G. S. Cree and K. McRae. Analyzing the factor underlying the structure and computation of the meaning of chipmunk, cherry, cheese, and cello (and many other such concrete nouns). *Journal of Experimental Psychology: General*, Vol. 132, pp. 163–201, 2003.

[14] S. L. Armstrong, L. R. Gleitman, and H. Gleitman. What some concepts might not be. *Cognition*, Vol. 13, pp. 263–308, 1983.

[15] E. Rosch and C. B. Mervis. Family resemblances: Studies in the internal

structure of categories. *Cognitive Psychology*, Vol. 7, pp. 573–605, 1975.

[16] S. K. Reed. Pattern recognition and categorization. *Cognitive Psychology*, Vol. 3, pp. 382–407, 1972.

[17] J. D. Smith and J. P. Minda. Prototypes in the mist: The early epochs of category learning. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, Vol. 24, pp. 1411–1436, 1998.

[18] D. L. Medin and M. M. Schaffer. Context theory of classification learning. *Psychological Review*, Vol. 85, pp. 207–238, 1978.

[19] R. M. Nosofsky. Choice, similarity, and the context theory of classification. *Journal of Experimental Psychology: Learning, Memory, and Cognition*.

[20] J. K. Kruschke. Alcove: An exemplar-based connectionist model of category learning. *Psychological Review*, Vol. 99, pp. 22–44, 1992.

[21] C. B. Mervis and E. Rosch. Categorization of natural objects. *Annual Review of Psychology*, Vol. 32, pp. 89–115, 1981.

[22] D. L. Medin. *Structural principles of categorization*, pp. 203–230. Erlbaum, Hillsdale, NJ, 1983.

[23] J. V. Jones. Identifying basic categories. *Psychological Bulletin*, Vol. 94, pp. 423–428, 1983.

[24] J. E. Corter and M. A. Gluck. Explaining basic categories: Feature predictability and information. *Psychological Bulletin*, Vol. 111, pp. 291–303, 1992.

[25] G. L. Murphy and M. E. Lassaline. *Hierarchical structure in concepts and the basic level of categorization*, pp. 93–132. Psychology Press, Hove, East Sussex, UK, 1997.

[26] E. Colunga and L.B. Smith. From the lexicon to expectations about kinds: A role for associative learning. *Psychological Review*, Vol. 112, pp. 347–382, 2005.

[27] L. K. Samuelson. Statistical regularities in vocabulary guide language acquisition in connectionist models and 15-20 month olds. *Developmental Psychology*, Vol. 38, pp. 1016–1037, 2002.

[28] C. Kemp, A. Perfors, and J. B. Tenenbaum. Learning overhypotheses. In

Proceedings of the Twenty Eighth Annual Conference of Cognitive Society, pp. 417–422, 2006.

[29] T. K. Landauer and S. T. Dumais. A solution to plato 's problem: the latent semantic analysis theory of acquisition, induction, and representation of knowledge. *Psychological Review*, Vol. 104, pp. 211–240, 1997.

[30] T. L. Griffiths, M. Steyvers, and J. B. Tenenbaum. Topics in semantic representation. *Psychological Review*.

[31] F. C. Keil. *Theories, concepts, and the acquisition of word meaning*, pp. 197–224. Cambridge University Press.

[32] M. Imai and D. Gentner. A cross-linguistic study of early word meaning: universal ontology and linguistic influence. *Cognition*, Vol. 62, pp. 169–200, 1997.

[33] N. N. Soja, S. Carey, and E. S. Spelke. Ontological categories guide young children's inductions of word meanings: object terms and substance terms. *Cognition*, Vol. 38, pp. 179–211, 1991.

[34] L. B. Smith, S. S. Jones, B. Landau, L. Gershkoff-Stowe, and L. Samuelson. Object name learning provides on-the-job training for attention. *Psychological Science*, Vol. 13, pp. 13–19, 2002.

[35] A. E. Booth and S. R. Waxman. Word learning is 'smart': evidence that conceptual information affects preschoolers ' extension of novel words. *Cognition*, Vol. 84, pp. B11–B22, 2002.

[36] H. Yoshida and L. B. Smith. Shifting ontological boundaries: how japanese- and english- speaking children generalize names for animals and artifacts. *Developmental Science*, Vol. 6, pp. 1–34, 2003.

[37] R. Brown. *What's in a word? On the child's acquisition of semantics in his first language*. Free Press, New York, 1958.

[38] S. Carey and E. Bartlett. Acquiring a single new word. *Papers and reports on child language development*, Vol. 15, pp. 17–29, 1978.

[39] S. S. Jones, L. B. Smith, and B. Landau. Object properties and knowledge in early lexical learning. *Child development*, Vol. 62, pp. 499–516, 1991.

[40] H. Yoshida and L. B. Smith. Early noun lexicons in english and japanese. *Cognition*, Vol. 82, pp. 63–74, 2001.

[41] M. Ahissar and S. Hochstein. The reverse hierarchy theory of visual perceptual learning. *Trends in Cognitive Science*, Vol. 8, pp. 457–464, 2004.

[42] C. E. Osgood, G. J. Suci, and P. H. Tannenbaum. *The measurement of meaning*. Univ. of Illinois Press, 1957.

[43] L. Fenson, P. Dale, J. S. Reznick, E. Bate, J. Hartung, S. Pethick, and J. Reilly. *MacArthur Communicative Development Inventories*. CA: Singular Publishing, San Diego, 1993.

[44] 大山正, 今井省吾, 和気典二. 新編感覚・知覚心理学ハンドブック. 誠信書房, 1994.

[45] S. S. Jones and L.B. Smith. How children know the relevant properties for generalizing object names. *Developmental Science*, Vol. 5, pp. 219–232, 2002.

[46] N. Goodman. *Fact, Fiction, and Forecast*. Harvard University Press, Cambridge, 1955.

[47] L. J. Rips. *Similarity, typicality, and categorization*. Cambridge University Press, Cambridge, England, 1995.

[48] L. J. Rips and A. Collins. Categories and resemblance. *Journal of Experimental Psychology: General*, Vol. 122, pp. 468–486, 1993.

[49] J. R. Anderson. *The adaptive character of thought*. Lawrence Erlbaum Associates, Hillsdale, NJ, 1990.

[50] G. F. Ashby and N. A. Perrin. Toward a unified theory of similarity and recognition. *Psychological Review*, Vol. 95, pp. 124–150, 1988.

[51] R. M. Nosofsky. Attention, similarity and the identification-categorization relationship. *Journal of Experimental Psychology: Learning Memory, and Cognitition*, Vol. 15, pp. 39–57, 1986.

[52] L. K. Samuelson and L. B. Smith. Early noun vocabularies: do ontology, category structure and syntax correspond? *Cognition*, Vol. 73, pp. 1–33, 1999.

[53] S. Hidaka, J. Saiki, and L. B. Smith. Semantic packing as a core mechanism of category coherence, fast mapping and basic level categories. In *Proceedings of The Twenty Eighth Annual Conference of Cognitive Soci-*

ety, pp. 1500–1505, 2006.

[54] S. Hidaka, J. Saiki, and L. B. Smith. Semantic packing: an account for category coherence. In *Proceedings of The Seventh International Conference on Cognitive Modelling*, pp. 130–135, 2006.

[55] P. McCulloch and J. A. Nelder. *Generalized linear models (2nd Ed.)*. Chapman & Hall, 1989.

[56] B. Efron. Bootstrap methods: Another look at the jackknife. *Annals of Statistics*, Vol. 7, pp. 1–26, 1979.

[57] D. L Medin, R. L. Goldstone, and D. Gentner. Respects for similarity. *Psychological Review*, Vol. 100, pp. 254–278, 1993.

[58] J. H. Holland, K. J. Holyoak, R. E. Nisbett, and P. R Thagard. *Induction*. MIT Press, Cambridge, MA, 1986.

[59] R. E. Nisbett, D. H. Krantz, C. Jepson, and Z. Kunda. The use of statistical heuristics in everyday reasoning. *Psychological Review*, Vol. 90, pp. 339–363, 1983.

[60] R. O. Duda, P. E. Hart, and D. G. Stork. *Pattern Classification (2nd ed.)*. John Wiley & Sons, New York, 2000.

[61] A. B. Markman and V. S. Markin. Referential communication and category acquisition. *Journal of Experimental Psychology: General*, Vol. 127, pp. 331–354, 1998.

[62] Y. Sakamoto, T. Matsuka, and B. C. Love. Dimension-wide vs. exemplar-specific attention in category learning and recognition. In *Proceedings of the 6th International Conference on Cognitive Modeling*, pp. 261–266, 2005.

[63] L. W. Barsalou. Ideals, central tendency, and frequency of instantiation as determinants of graded structure in categories. *Journal of experimental psychology. Learning, memory, and cognition*, Vol. 11, pp. 629–654, 1985.

[64] A. N. Kolmogorov. On the representation of continuous functions of several variables by superposition of continuous functions of one variable and addition. *Dokl. Akad. Nauk SSSR*, Vol. 114, pp. 953–956, 1957.

[65] J. R. Movellan. Contrastive hebbian learning in the continuous hopfield model. In *Connectionist Models Proceedings of the 1990 Summer School*,

pp. 10–17, 1990.

[66] 日高昇平, 齋木潤. 幼児の新奇語カテゴリ化のモデル研究. 認知科学, Vol. 12, pp. 235–251, 2005.

[67] S. Hidaka and J. Saiki. Prototype-specific learning for children's vocabulary. In *Proceedings of The Fourth IEEE International Conference on Development and Learning*, p. 201, 2005.

[68] S. Hidaka and J. Saiki. A mechanism of ontological boundary shifting. In *The Twenty Sixth Annual Meeting of the Cognitive Science Society*, pp. 565–570, 2004.

[69] E. Colunga and L. B. Smith. Committing to an ontology: A connectionist account. In *The Twenty Second Annual Meeting of the Cognitive Science Society*, 2000.

[70] E. Colunga and L. B. Smith. Learning to learn words: A cross-linguistic study of the shape and material biases. In *the 24th Annual Boston University Conference on Language Development*, 2000.

[71] G. F. Ashby and J. T. Townsend. Varieties of perceptual independence. *Psychological Review*, Vol. 93, pp. 154–179, 1986.

[72] T. Wilcox. Object individuation: infants' use of shape, size, pattern and color. *Cognition*, Vol. 72, pp. 125–166, 1999.

[73] A. Needham and R. Baillargeon. Object segregation in 8-month-old infants. *Cognition*, Vol. 62, pp. 121–149, 1997.

[74] T. Wilcox and R. Baillargeon. Object individuation in infancy: The use of featural information in reasoning about occlusion events. *Cognitive Psychology*, Vol. 37, pp. 97–155, 1998.

[75] M. Johnson. *Developmental cognitive neuroscience*. Blackwell, Oxford, 1997.

[76] M. M. Haith, C. Hazen, and G. S. Goodman. Expectation and anticipation of dynamic visual events by 3.5-month-old babies. *Child Development*, Vol. 59, pp. 467–479, 1988.

[77] R. Baillargeon. Object permanence in 3 1/2- and 4 1/2-month-old infants. *Developmental Psychology*, Vol. 23, pp. 655–664, 1987.

[78] P. J. Kellman and E. S. Spelke. Perception of partly occluded objects in

infancy. *Cognitive Psychology*, Vol. 15, pp. 483–524, 1983.

[79] P. J. Kellman, E. S. Spelke, and K. R. Short. Infant perception of object unity from translatory motion in depth and vertical translation. *Child Development*, Vol. 57, pp. 72–86, 1986.

[80] A. Needham, G. Dueker, and G. Lockhead. Infants' formation and use of categories to segregate objects. *Cognition*, Vol. 98, pp. 215–240, 2005.

[81] R. Baillargeon, L. Kotovsky, and A. Needham. *Physical reasoning in infancy*. MIT Press, Cambridge, MA, 1995.

[82] E. S. Spelke, C. von Hofsten, and R. Kesteubaum. Object perception and object directed reaching in infancy: Interaction of spatial and kinetic information for object boundaries. *Developmental Psychology*, Vol. 25, pp. 185–196, 1989.

[83] A. Needham. Object recognition and object segregation in 4.5-month-old infants. *Journal of Experimental Child Psychology*, Vol. 78, pp. 3–24, 2001.

[84] M. H. Bornstein. *Chromatic vision in infancy*, pp. 117–182. Academic Press.

[85] R. L. Fantz. Pattern vision in newborn infants. *Science*, Vol. 140, pp. 296–297, 1963.

[86] P. D. Eimas and P. C. Quinn. Studies on the formation of perceptually based basic-level categories in young infants. *Child Development*, Vol. 65, No. 3, pp. 903–917, 1994.

[87] I. Bierderman. Recognition-by-components: A theory of human image understanding. *Psychological Review*, Vol. 94, No. 2, pp. 115–147, 1987.

[88] B. Landau, L. B. Smith, and S. S. Jones. Object shape, object function, and object name. *Journal of Memory and Language*, Vol. 38, pp. 1–27, 1998.

[89] A. Gopnik and A. Meltzoff. The development of categorization in the second year and its relation to other cognitive and linguistic developments. *Child Development*, Vol. 58, pp. 1523–1531, 1987.

[90] A. Gopnik and A. Meltzoff. Categorization and naming: Basic-level sorting in eighteen-month-olds and its relation to language. *Child Develop-*

ment, Vol. 63, pp. 1091–1103, 1992.

[91] S. S. Jones. Late talkers show no shape bias in object naming. *Developmental Science*, Vol. 6, pp. 477–483, 2003.

[92] S. Hidaka and J. Saiki. Feature discovery in object individuation. In *Proceedings of The Fifth International Conference on Development and Learning*, 2006.

[93] A. Needham. Factors affecting infants' use of featural information in object segregation. *Current Directions in Psychological Science*, Vol. 6, pp. 26–33, 1997.

[94] T. G. R. Bower. *Development in infancy.* W. H. Freeman and Co., San Francisco, 1974.

[95] D. E. Rumelhart, J. L. McClelland, and the PDP Research Group. *Parallel Distributed Processing Foundations.* The MIT Press, Cambridge, MA, 1986.

[96] P. C. Quinn. The categorical representation of visual pattern information by young infants. *Cognition*, Vol. 27, pp. 145–179, 1987.

[97] K. Plunkett and V. Marchman. Finding structure in time. cognitive science. *Cognitive Science*, Vol. 14, pp. 179–211, 1990.

[98] B. C. Malt. Category coherence in cross-cultural perspective. *Cognitive Psychology*, Vol. 29, pp. 85–148, 1995.

[99] N. N. Soja. Evidence for a distinct kind of noun. *Cognition*, Vol. 51, No. 3.

[100] A. E. Booth and S. Waxman. Word learning is 'smart': Evidence that conceptual information affects preschoolers' extension of novel words. *Cognition*, Vol. 84, pp. B11–B22, 2002.

[101] J. A. Lucy. *Language diversity and thought: A reformulation of the linguistic relativity hypothesis.* Cambridge University Press, Cambridge, 1992.

[102] W. V. O. Quine. *Ontological relativity and other essays.* Columbia University Press, New York, 1969.

[103] S. Hidaka and J. Saiki. A connectionist account of ontological boundary shifting. In N.R. et al. Pal, editor, *ICONIP 2004, Lecture Note in*

Computer Science 3316, pp. 22–25, Berlin, 2004. Springer-Verlag.

[104] H. Akaike. A new look at the statistical model identification. *IEEE Trans. Automat. Control*, Vol. 19, pp. 716–723, 1974.

[105] G. Schwarz. Estimating the dimension of a model. *The Annals of Statistics*, Vol. 6, No. 2, pp. 461–464, 1978.

[106] B. A. Younger. The segregation of items into categories by ten-month-old infants. *Child Development*, Vol. 56, pp. 1574–1583, 1985.

[107] D. Mareschal and R. French. Mechanisms of categorization in infancy. *Infancy*, Vol. 1, No. 1, pp. 59–76, 2000.

[108] L. B. Smith and S. Maouene, J. Hidaka. *The Body and Children's Word Learning*, pp. 168–192. Oxford University Press, Oxford, 2007.

[109] J. Maouene, S. Hidaka, and L. B. Smith. Body parts and the first 100 verbs.

[110] J. Maouene, S. Hidaka, and L. B. Smith. Children and adults rely on body parts for early-acquired verbs. In *Proceedings of The Fifth International Conference on Development and Learning*, 2006.

[111] T. Kohonen. *Self-Organizing Maps*. Springer, Heidelberg, 1995.

[112] J. B. Tenenbaum, de Silva V., and J. C. Langford. A global geometric framework for nonlinear dimensionality reduction. *Science*, Vol. 290, pp. 2319–2323, 2000.

[113] S. Sattath and A. Tversky. Additive similarity trees. *Psychometrika*, Vol. 42, pp. 319–345, 1977.

[114] A. Tversky and J. W. Hutchinson. Nearest neighbor analysis of psychological spaces. *Psychological Review*, Vol. 93, pp. 3–22, 1986.

[115] J. D. Smith and J. H. Shapiro. The occurence of holistic categorization. *Journal of Memory and Language*, Vol. 27, pp. 386–399, 1989.

[116] A. L. Barabasi and R. Albert. Emergence of scaling in random networks. *Science*, Vol. 286, pp. 509–512, 1999.

[117] S. H. Strogatz. Exploring complex networks. *Nature*, Vol. 410, pp. 268–276, 2001.

[118] D. J. Watts and S. H. Strogatz. Collective dynamics of 'small-world' networks. *Nature*, Vol. 393, pp. 440–442, 1998.

[119] E. S. Spelke. Principles of object perception. *Cognitive Science*, Vol. 14, pp. 29–56, 1990.

[120] M. Imai, D. Gentner, and N. Uchida. Children's theories of word meaning: The role of shape similarity in early acquisition. *Cognitive Development*, Vol. 9, pp. 45–76, 1994.

[121] D. L. Medin, M. W. Altom, S. M. Edelson, and D. Freko. Correlated symptoms and simulated medical classification. *Journal of Experimental Psychology: Learning and Memory, and Cognition*, Vol. 8, pp. 37–50, 1982.

[122] A. P. Dempster, N. M. Laird, and D. B. Rubin. Maximum likelihood from incomplete data via the em algorithm. *Journal of Royal Statistical Society Series B*, Vol. 39, pp. 1–38, 1977.

付録

A.1 評定実験に用いた語彙および結果

A.1.1 言語尺度

評定実験に用いた日本語と英語の対応表を以下に示す.

選択された形容語対		選択されなかった形容語対	
動的，静的	dynamic, static	よい，悪い	good, bad
潤った，乾いた	wet, dry	好き，嫌い	pleasant, unpleasant
軽い，重い	light, heavy	美しい，汚い	clean, dirty
大きい，小さい	large, small	騒がしい，静かな	noisy, quiet
複雑な，単純な	complex, simple	派手な，地味な	bold, conservative
素早い，遅い	quick, slow	明るい，暗い	bright, dark
騒がしい，静かな	noisy, quiet	陽気な，陰気な	cheer, gloomy
安定な，不安定な	stable, unstable	鋭い，鈍い	sharp, dull
温かい，冷たい	warm, cool	緊張した，緩んだ	tense, loose
自然な，人工的な	natural, artificial	粗末な，優雅な	coarse, elegant
丸い，四角い	round, square	突起した，平らな	pointy, flat
強い，弱い	strong, weak	質素な，豪華な	spartan, luxurious
精巧な，雑な	finely crafted, rough hewn	古風な，今風な	old-fashion, modern
真っ直ぐな，曲がった	straight, curved	かわいい，不細工な	pretty, ugly
なめらかな，いびつな	smooth, bumpy	均一な，不均一な	even, uneven
硬い，軟い	hard, soft	特殊な，平凡な	special, general
物体の属性		太い，細い	thick, thin
形	shape	面白い，退屈な	amusing, boring
色	color	荒々しい，ゆったりした	turbulent, calm
肌理	texture	すっきりした，ごてごてした	neat, messy
材質	material	新鮮な，古い	fresh, stale
動き	movement	規則的な，不規則な	regular, irregular
匂い	smell	濃い，薄い	dense, sparse
味	taste	甘い，辛い	sweet, salty
音	sound	高い，低い	high, low
温度	temperature	長い，短い	long, short
機能	function		

表 A.1: 評定に用いた形容語対および物体の属性を表す語

A.1.2 語彙調査の評定結果

日本語話者平均値を別ページの表にまとめた.

	動的(静的)	うるおった(乾いた)	軽い(重い)	大きい(小さい)	複雑な(単純な)	遅い(素早い)	静かな(騒がしい)	安定な(不安定な)
蝶	0.31	0.546	0.053	0.87	0.452	0.548	0.166	0.483
ネコ	0.25	0.512	0.299	0.712	0.466	0.827	0.579	0.512
魚	0.3	0.12	0.351	0.584	0.577	0.784	0.316	0.399
カエル	0.214	0.161	0.137	0.8	0.649	0.709	0.74	0.529
ウマ	0.188	0.486	0.813	0.096	0.425	0.865	0.425	0.354
サル	0.048	0.543	0.423	0.611	0.568	0.911	0.957	0.661
トラ	0.13	0.6	0.854	0.101	0.392	0.817	0.57	0.445
腕	0.183	0.582	0.5	0.49	0.438	0.643	0.522	0.349
目	0.226	0.159	0.288	0.476	0.243	0.692	0.349	0.425
手	0.144	0.438	0.308	0.517	0.397	0.675	0.5	0.353
膝	0.322	0.716	0.438	0.611	0.495	0.529	0.409	0.401
舌	0.228	0.12	0.262	0.704	0.478	0.625	0.476	0.418
ブーツ	0.478	0.733	0.55	0.421	0.649	0.375	0.505	0.534
手袋	0.623	0.642	0.137	0.695	0.702	0.451	0.267	0.238
ジーンズ	0.332	0.829	0.536	0.45	0.599	0.627	0.553	0.329
シャツ	0.611	0.829	0.104	0.44	0.709	0.589	0.329	0.284
バナナ	0.661	0.394	0.31	0.63	0.743	0.515	0.44	0.406
タマゴ	0.673	0.387	0.183	0.861	0.712	0.481	0.308	0.599
アイスクリーム	0.654	0.147	0.173	0.695	0.719	0.567	0.452	0.536
牛乳	0.596	0.104	0.404	0.524	0.709	0.522	0.286	0.308
ピザ	0.428	0.536	0.387	0.291	0.481	0.611	0.701	0.49
塩	0.697	0.76	0.149	0.873	0.736	0.613	0.327	0.392
トースト	0.546	0.779	0.151	0.726	0.762	0.606	0.454	0.385
ベッド	0.805	0.637	0.863	0.096	0.7	0.332	0.151	0.103
椅子	0.579	0.813	0.457	0.553	0.712	0.49	0.379	0.257
ドア	0.337	0.81	0.606	0.255	0.712	0.534	0.481	0.313
冷蔵庫	0.659	0.459	0.95	0.091	0.31	0.42	0.394	0.202
テーブル	0.786	0.815	0.817	0.236	0.728	0.34	0.257	0.154
雨	0.346	0.07	0.353	0.675	0.643	0.678	0.572	0.651
雪	0.601	0.226	0.127	0.817	0.651	0.346	0.077	0.435
石	0.844	0.861	0.804	0.418	0.788	0.303	0.159	0.221
木	0.721	0.409	0.876	0.087	0.49	0.298	0.183	0.163
水	0.433	0.019	0.363	0.488	0.704	0.714	0.272	0.351
カメラ	0.32	0.712	0.517	0.594	0.13	0.752	0.471	0.317
カップ	0.724	0.476	0.327	0.695	0.786	0.452	0.32	0.262
鍵	0.692	0.813	0.267	0.861	0.313	0.526	0.334	0.363
お金	0.315	0.666	0.498	0.531	0.502	0.613	0.563	0.644
紙	0.76	0.853	0.048	0.594	0.796	0.541	0.282	0.332
はさみ	0.341	0.82	0.257	0.733	0.663	0.697	0.505	0.411
植木	0.788	0.386	0.661	0.452	0.476	0.337	0.175	0.233
風船	0.385	0.591	0.026	0.635	0.815	0.454	0.276	0.68
本	0.899	0.796	0.588	0.55	0.397	0.364	0.126	0.175
人形	0.764	0.653	0.26	0.675	0.558	0.339	0.192	0.298
糊	0.721	0.267	0.284	0.728	0.75	0.452	0.279	0.411
飛行機	0.156	0.788	0.942	0.029	0.067	0.865	0.697	0.433
列車	0.125	0.774	0.945	0.055	0.293	0.769	0.764	0.347
自動車	0.06	0.786	0.891	0.123	0.159	0.853	0.786	0.332
自転車	0.133	0.728	0.5	0.49	0.512	0.752	0.6	0.495

	冷たい (温かい)	自然な (人工的な)	丸い (四角い)	弱い (強い)	雑な (精巧な)	まっすぐな (曲がった)	なめらかな (いびつな)	硬い (柔らかい)
蝶	0.579	0.084	0.421	0.111	0.678	0.553	0.313	0.776
ネコ	0.553	0.202	0.202	0.517	0.502	0.627	0.334	0.829
魚	0.219	0.101	0.397	0.34	0.57	0.476	0.298	0.642
カエル	0.288	0.091	0.236	0.298	0.474	0.582	0.409	0.808
ウマ	0.782	0.142	0.406	0.728	0.654	0.32	0.3	0.476
サル	0.692	0.137	0.281	0.615	0.445	0.55	0.522	0.666
トラ	0.565	0.07	0.337	0.952	0.558	0.382	0.385	0.538
腕	0.707	0.305	0.377	0.611	0.626	0.538	0.365	0.57
目	0.541	0.3	0.096	0.296	0.8	0.387	0.284	0.685
手	0.736	0.216	0.276	0.505	0.668	0.51	0.288	0.75
膝	0.589	0.323	0.238	0.462	0.577	0.68	0.43	0.341
舌	0.774	0.272	0.236	0.385	0.635	0.613	0.238	0.858
ブーツ	0.536	0.803	0.556	0.587	0.601	0.346	0.353	0.425
手袋	0.849	0.695	0.272	0.459	0.561	0.55	0.388	0.861
ジーンズ	0.422	0.649	0.673	0.769	0.49	0.368	0.478	0.358
シャツ	0.478	0.697	0.721	0.512	0.58	0.363	0.368	0.685
バナナ	0.476	0.132	0.31	0.365	0.428	0.757	0.346	0.822
タマゴ	0.514	0.166	0.041	0.142	0.58	0.63	0.25	0.618
アイスクリーム	0.017	0.625	0.197	0.245	0.512	0.612	0.185	0.873
牛乳	0.236	0.166	0.385	0.457	0.563	0.411	0.18	0.784
ピザ	0.892	0.776	0.089	0.45	0.442	0.671	0.466	0.738
塩	0.31	0.236	0.488	0.522	0.555	0.459	0.462	0.375
トースト	0.865	0.582	0.856	0.37	0.45	0.428	0.462	0.671
ベッド	0.769	0.654	0.851	0.712	0.603	0.291	0.272	0.526
椅子	0.413	0.653	0.666	0.613	0.582	0.413	0.387	0.209
ドア	0.332	0.738	0.865	0.706	0.584	0.245	0.43	0.118
冷蔵庫	0.07	0.885	0.925	0.731	0.767	0.248	0.425	0.099
テーブル	0.454	0.625	0.594	0.707	0.575	0.425	0.344	0.13
雨	0.113	0.075	0.296	0.505	0.457	0.291	0.38	0.671
雪	0.06	0.065	0.166	0.26	0.627	0.401	0.226	0.892
石	0.202	0.065	0.202	0.817	0.361	0.683	0.692	0.05
木	0.716	0.043	0.365	0.777	0.601	0.329	0.468	0.286
水	0.142	0.072	0.351	0.536	0.584	0.351	0.168	0.767
カメラ	0.393	0.798	0.873	0.587	0.887	0.351	0.44	0.159
カップ	0.584	0.688	0.257	0.45	0.555	0.55	0.349	0.274
鍵	0.219	0.868	0.63	0.671	0.779	0.563	0.675	0.113
お金	0.243	0.844	0.51	0.639	0.666	0.471	0.51	0.286
紙	0.358	0.601	0.923	0.279	0.546	0.171	0.298	0.651
はさみ	0.197	0.817	0.656	0.745	0.577	0.406	0.495	0.163
植木	0.635	0.233	0.442	0.56	0.604	0.464	0.488	0.478
風船	0.596	0.63	0.053	0.091	0.488	0.63	0.25	0.887
本	0.519	0.644	0.928	0.572	0.702	0.255	0.375	0.236
人形	0.505	0.748	0.272	0.341	0.69	0.529	0.363	0.644
糊	0.332	0.6	0.346	0.401	0.481	0.514	0.269	0.825
飛行機	0.318	0.928	0.454	0.839	0.901	0.403	0.373	0.077
列車	0.476	0.861	0.894	0.825	0.752	0.293	0.462	0.099
自動車	0.418	0.897	0.709	0.825	0.839	0.469	0.459	0.096
自転車	0.409	0.714	0.519	0.488	0.606	0.575	0.522	0.282

A.2 Contrastive Hebbian Learning

本研究では Colunga & Smith (2005) [26] と Samuelson (2002)[27] がシミュレーションに用いた Contrastive Hebbian Learning([65]) を追実験に用いている．以下にその計算手続きを示す．ネットワーク全体のエネルギー関数は以下の式で表される

$$F = E + S \tag{A.1}$$

ただし E と S は

$$E = -\frac{1}{2}\mathbf{a}^t\mathbf{W}\mathbf{a} = -\frac{1}{2}\sum_{i=1}^{n}\sum_{j=1}^{n} a_i w_{ij} a_j \tag{A.2}$$

$$S = \sum_{i=1}^{n}\int_{rest}^{a_i} f_i^{-1}(a)da \tag{A.3}$$

ただし a_i はユニット i の活性値，w_{ij} はユニット i と j の結合荷重，$rest = f(0)$ である．ネットワークのエネルギー関数は以下の式に従って更新することで単調に減少する．

$$\frac{da_i}{dt} = \lambda(-a_i + f_i(net_i)) \tag{A.4}$$

ただし f_i はシグモイド関数で T は温度パラメータである．

$$f(x) = \frac{1}{1 + e^{\frac{-x}{T}}} \tag{A.5}$$

ネットワークの初期状態から十分に上記の更新をする事で定常状態の活性値 $\hat{a}$ が得られる．CHL では隠れ層のユニットのみを自由に更新する固定フェーズと隠れ層と出力層のユニットを自由に更新する自由フェーズを持ち，それぞれのフェーズでの定常状態の活性値を $\hat{a_i}^{(+)}$,$\hat{a_i}^{(-)}$ とする．このネットワークで入力に対する出力を生成する際には自由フェーズを動作させ，出力層の定常状態の活性値を出力パタンとして定義する．また学習時にはまず固定フェーズで動作させ，一定回数更新し定常状態後に自由フェーズで一定回数更新し定常状態の活性値を得る．ユニット i, j 間結合 w_{ij} は 2 つのフェーズの活性値を用いて以下のように更新する．

$$\Delta w_{ij} \propto \hat{a_i}^{(+)}\hat{a_j}^{(+)} - \hat{a_i}^{(-)}\hat{a_j}^{(-)} \tag{A.6}$$

結合荷重は全て-0.5 から 0.5 の範囲の連続値の擬似一様乱数で初期化された．実験 1 では固定，自由フェーズの更新回数 1000 回，更新率 $\lambda = 1$，温度 $T = 0$ (へ

ビサイド関数)，重みの学習率 0.72 で学習サンプルの誤差の絶対和が 0.01 以下になった場合に更新を終了した．1 回に 1 サンプルを学習するオンライン学習で異なる初期化を行なった 4 つのネットワークで平均 227 回の重み更新が行なわれた．実験 2 では固定，自由フェーズの更新回数は 500 回，重みの学習率は 0.005，重みの更新は異なる初期化の 4 つネットワークの 500 回に固定して行なわれた．また温度 T を 0.5 から 0 まで固定，自由フェーズの更新回数に比例して下げて行なわれた．他の条件は実験 1 と同じである．

A.3 PSAL の数学的定式化

PSAL (Prototype-specific Attention Learning) モデルは 3 層のフィードフォワード型で，隠れ層のユニットの活性関数に指数族関数などの放射状の関数を持つ RBF (Radial Basis Function) の 1 種である．隠れ層の基底ユニットは入力空間におけるカテゴリのプロトタイプの位置を表し，エラー駆動型の学習によりその位置を最適化する．

出力層ユニットの活性値 o_k は隠れ層ユニットの活性値 h_j の荷重線形和で，以下の式で表される．

$$o_k = \sum_j w_{kj} h_j \tag{A.7}$$

また，隠れ層ユニットの活性値 h_j は入力層ユニットベクトル I と基底ユニットベクトル r_j の荷重付きユークリッド距離で決定され，以下の式で表される．ただし m は正の入力空間の距離基準パラメータで c は定数のスケーリングパラメータである．

$$h_j = \exp(net_{ji}) \tag{A.8}$$

ただし

$$net_{ji} = -c(\sum_i \sigma_{ji}(r_{ji} - I_i)^m)^{\frac{1}{m}} \tag{A.9}$$

出力層ユニットの活性値 o_k とそれに対する教師信号 t_k の誤差を以下の式で定義する．

$$E = \frac{1}{2}(t_k - o_k)^2 \tag{A.10}$$

PSAL モデルは教師信号と出力との誤差を逆伝播し，層間の荷重と注意ユニットの重みを以下の更新式で最適化する．ただし ΔW_{kj} は隠れ層と出力層間の結合荷重の更新量，λ は定数の学習率，$\Delta\sigma_{ji}$ は注意ユニットの更新量，Δr_{ji} は隠

れ層ユニットの基底ベクトル，$\lambda_w, \lambda_\sigma, \lambda_r$ は学習率である．

$$\Delta w_{kj} = -\lambda_w \frac{\partial E}{\partial w_{kj}} = -\lambda_w \frac{\partial E}{\partial o_k}\frac{\partial o_k}{\partial w_{kj}} \tag{A.11}$$

$$\Delta w_{kj} = -\lambda_w \delta_k h_j \tag{A.12}$$

ただし

$$\delta_k = t_k - o_k \tag{A.13}$$

また隠れ層の荷重 σ_{ij} の更新式は偏微分の連鎖則より

$$\Delta \sigma_{ji} = -\lambda_\sigma \frac{\partial E}{\partial \sigma_{ji}} = -\lambda_\sigma \sum_k \frac{\partial E}{\partial o_k}\frac{\partial o_k}{\partial h_j}\frac{\partial h_j}{\partial net_{ji}}\frac{\partial net_{ji}}{\partial \sigma_{ji}} \tag{A.14}$$

$$\sum_k \frac{\partial E}{\partial o_k}\frac{\partial o_k}{\partial h_j} = \sum_k \delta_k w_{kj} \tag{A.15}$$

$$\Delta \sigma_{ji} = -\lambda_\sigma (\sum_k \delta_k w_{kj}) \frac{1}{2} c h_{ji} net^{\frac{1}{m}} (h_{ji} - I_i)^m \tag{A.16}$$

また同様に基底ユニットの位置 r_{ji} の更新式も E の偏微分より

$$\Delta r_{ji} = -\lambda_r \frac{\partial E}{\partial r_{ji}} = -\lambda_r \sum_k \frac{\partial E}{\partial o_k}\frac{\partial o_k}{\partial h_j}\frac{\partial h_j}{\partial net_{ji}}\frac{\partial net_{ji}}{\partial r_{ji}} \tag{A.17}$$

(A.15) 式より

$$\Delta r_{ji} = -\lambda_r (\sum_k \delta_k w_{kj}) c h_{ji} net^{\frac{1}{m}-1} (\sigma_{ji}(r_{ji} - I_i))^{m-1} \tag{A.18}$$

A.4 詰め込みモデルの数学的定式化

A.4.1 詰め込み効率性関数の導出

n カテゴリ $(c_1, c_2, \ldots, c_i, \ldots, c_n)$ が d 次元特徴空間 $\Omega = \mathbf{R}^d$ 上の点で表現できる事例群を持つと仮定する．また，カテゴリ c_i の事例が特徴 $\theta \subset \Omega$ をもつ尤度 $(\theta|c_i)$ を，中心的表象 (プロトタイプ)μ_i と尤度パタン (特徴重要性)σ_i をパラメタとしてもつ確率分布 $P(\theta|c_i) = P(\theta|\mu_i, \sigma_i)$ によって表現できるとする．具体的には，$P(\theta|\mu_i, \sigma_i)$ を d 次元正規分布 (平均ベクトル μ_i, 共分散行列 σ_i) で表す (式 A.19).

$$P(\theta|\mu_i, \sigma_i) = ((2\pi)^d |\sigma_i|)^{-\frac{1}{2}} \exp(-\frac{1}{2}(\theta - \mu_i)^t \sigma_i^{-1} (\theta - \mu_i)) \tag{A.19}$$

上付きの ^{t} は転置を表す.

識別性に対応するコスト関数 F_n は，最適な判断基準における最小誤識別率の近似的な上界を表す以下の式である．

$$F_n = \int_\Omega \prod_i P(\theta|c_i)^{\frac{1}{n}} d\theta \tag{A.20}$$

式 (A.20) は，正規分布に従う 2 カテゴリの最小誤識別率の近似的上界 (Bhattacheryya upper bound, [60]) の n カテゴリへの拡張とみなせる．

式 (A.20) と式 (A.19) より，

$$F_n = \int_\Omega \prod_i^n ((2\pi)^d |\sigma_i|)^{-\frac{1}{2}} \exp(-\frac{1}{2}(\theta - \mu_i)^t \sigma_i^{-1}(\theta - \mu_i)) \tag{A.21}$$

さらに，F_n(式 A.21) は以下のように展開できる．

$$F = \exp(\frac{1}{2n}(B^t A^{-1} B - C))((2\pi)^d |nA^{-1}|)^{\frac{1}{2}} (\prod_i^n ((2\pi)^d |\sigma_i|)^{-\frac{1}{2n}}) \int_\Omega N(\theta|A^{-1}B, nA^{-1}))d\theta \tag{A.22}$$

ただし，

$$\begin{aligned} A &= \sum_i^n \sigma_i^{-1} \\ B &= \sum_i^n \sigma_i^{-1}\mu_i \\ C &= \sum_i^n \mu_i^t \sigma_i^{-1}\mu_i \end{aligned} \tag{A.23}$$

で，積分項の $N(\theta|A^{-1}B, nA^{-1})$ は平均 $A^{-1}B$，共分散行列 nA^{-1} の多次元正規分布である．さらに，$\Omega = \mathbf{R}^d$ であるので，積分項は $\int_\Omega N(\theta|A^{-1}B, nA^{-1}))d\theta = 1$ である．よって以下の識別性の対数コストを表す $G_n = \log(F_n)$ を得る ($\sum_i^n \log(2\pi)^d = n\log(2\pi)^d$ に注意)．

$$G_n = \frac{1}{2n}(B^t A^{-1} B - C - n\log|n^{-1}A| - \sum_i^n \log|\sigma_i|) \tag{A.24}$$

カテゴリのパラメタによる G_n だけの最適化 (i.e., $\frac{\partial G_n}{\partial \mu_i}$ または $\frac{\partial G_n}{\partial \sigma_i}$) は，自明で無意味な解を導く (i.e., 中心表象の発散 $(\mu_i - \mu_j)^t(\mu_i - \mu_j) \to \infty$，またはカテゴリ尤度の無限小化 $|\sigma_i| \to 0$)．従って，識別性 G_n に加えて，集約性と包含性を表すコスト関数 E_1 と E_2 を次のように定義し，制約付の最適化を行う．

$$E_1 = \sum_i^n \mu_i^t \mu_i \tag{A.25}$$

$$E_2 = \sum_i^n \log|\sigma_i| \tag{A.26}$$

E_1 は，カテゴリ中心間の距離が一定である事，E_2 は，カテゴリ尤度の縮退を避け，分散の大きさが一定以上である事を意味する制約である．G_n, E_1, E_2 を同時に満たす最適解は，以下の Lagrange 乗数法によって得られる．

$$L_n = 2nG_n + \lambda_1 E_1 + \lambda_2 E_2 \tag{A.27}$$

ただし，λ_1，λ_2 は定数である．よって，詰め込み効率性は以下の式で表される．

$$L_n = B^t A^{-1} B - C - n \log |n^{-1} A| + (\lambda_2 - 1) \sum_i^n \log |\sigma_i| + \lambda_1 \sum_i^n \mu_i^t \mu_i \tag{A.28}$$

A.4.2　詰め込み効率の解析的な最適解

詰め込み効率関数 L_n を最適化するカテゴリ中心パラメータ μ_i の構造を調べる．L_n を最適化する μ_i は $\frac{\partial L_n}{\partial \mu_i} = 0$ を満たす事が必要条件であるので，$\frac{\partial L_n}{\partial \mu_i} = 0$ $(i = 1, 2, \ldots, n)$ からその集団的性質を調べる．偏微分 $\frac{\partial L_n}{\partial \mu_i} = 0$ の計算は以下のとおり．$x^t x$ の偏微分は $\frac{\partial x^t x}{\partial x} = 2x$ である事に注意して

$$\frac{\partial L_n}{\partial \mu_i} = \frac{\partial}{\partial \mu_i}(B^t A^{-1} B - C) + \lambda_1 \sum_j^n (\frac{\partial}{\partial \mu_i} \mu_j) \cdot \mu_j \tag{A.29}$$

また A, B, C の μ_i に関する偏微分は，それぞれ $\frac{\partial A}{\partial \mu_i} = 0$, $\frac{\partial B}{\partial \mu_i} = \sigma_i^{-1}$, $\frac{\partial C}{\partial \mu_i} = 2\sigma_i^{-1}\mu_i$ であるので，以下を得る．

$$\frac{\partial L_n}{2\partial \mu_i} = -\sigma_i^{-1}(\mu_i - A^{-1}B) + \lambda_1 \mu_i \tag{A.30}$$

ここで，$\frac{\partial L_n}{\partial \mu_i} = 0$ であるので，

$$(I_d - \lambda_1 \sigma_i)\mu_i = A^{-1}B \tag{A.31}$$

ただし，I_d は n 次単位行列である．

式 (A.31) は $i = 1, 2, ..., n$ で成り立つので，

$$\begin{pmatrix} (I_d - \lambda_1 \sigma_1)\mu_1 \\ (I_d - \lambda_1 \sigma_2)\mu_2 \\ \vdots \\ (I_d - \lambda_1 \sigma_n)\mu_n \end{pmatrix} = \begin{pmatrix} A^{-1}B \\ A^{-1}B \\ \vdots \\ A^{-1}B \end{pmatrix} \tag{A.32}$$

この n 個の行列方程式から，μ_i の最適解が以下の固有方程式の解である事を示せる．ここで，行列をブロック要素として持つ大行列 $\mathbf{\Phi}$, $\mathbf{A}_0^{-1}$, $\mathbf{\Sigma}$ を以下のよう

に置く.

$$\mathbf{\Phi} = \begin{pmatrix} \sigma_1^{-1} & \sigma_2^{-1} & \dots & \sigma_n^{-1} \\ \sigma_1^{-1} & \sigma_2^{-1} & \dots & \sigma_n^{-1} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_1^{-1} & \sigma_2^{-1} & \dots & \sigma_n^{-1} \end{pmatrix} \tag{A.33}$$

$$\mathbf{A}_0^{-1} = \begin{pmatrix} A^{-1} & \mathbf{0}_d & \dots & \mathbf{0}_d \\ \mathbf{0}_d & A^{-1} & \dots & \mathbf{0}_d \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{0}_d & \mathbf{0}_d & \dots & A^{-1} \end{pmatrix} \tag{A.34}$$

$$\mathbf{\Sigma} = \begin{pmatrix} \sigma_1 & \mathbf{0}_d & \dots & \mathbf{0}_d \\ \mathbf{0}_d & \sigma_2 & \dots & \mathbf{0}_d \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{0}_d & \mathbf{0}_d & \dots & \sigma_n \end{pmatrix} \tag{A.35}$$

ただし， $\mathbf{0}_d$ は d 次 正方ゼロ行列である. このとき，式 (A.32) 以下の固有方程式 (A.37) の形で書き直す事ができる.

$$\begin{pmatrix} I_d - \lambda_1\sigma_1 & \mathbf{0}_d & \dots & \mathbf{0}_d \\ \mathbf{0}_d & I_d - \lambda_1\sigma_2 & \dots & \mathbf{0}_d \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{0}_d & \mathbf{0}_d & \dots & I_d - \lambda_1\sigma_n \end{pmatrix} \begin{pmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_n \end{pmatrix} = \mathbf{A}_0^{-1}\mathbf{\Phi} \begin{pmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_n \end{pmatrix} \tag{A.36}$$

$$(\mathbf{I}_{dn} - \lambda_1\mathbf{\Sigma} - \mathbf{A}_0^{-1}\mathbf{\Phi})\mu = 0 \tag{A.37}$$

ただし，$\mu = (\mu_1^t, \mu_2^t, \dots, \mu_n^t)^t$ である．従って，L_n を最適化する μ_i は，式 (A.37) の固有ベクトルとして表せる事が示された. また，式 (A.37) 左辺の行列式 $D_n = \det(\mathbf{I}_{dn} - \lambda_1\mathbf{\Sigma} - \mathbf{A}_0^{-1}\mathbf{\Phi})$ は，以下の通り展開可能である．この行列式の形は，μ_i と σ_i の強い関連性を示唆し，後に導出する滑らかな構造を暗示すると考えられる.

$$D_n = |I_d - (\sum_{i=1}^{n} \dot{\sigma}_i \check{\sigma}_i^{-1})| \prod_{i=1}^{n} |\check{\sigma}_i| \tag{A.38}$$

ただし，$\check{\sigma}_i = I_d - \lambda_1\sigma_i$, $\dot{\sigma}_i = A^{-1}\sigma_i^{-1}$ である.

A.4.2.1　詰め込み効率の共分散パラメータの最適解　ここでは，カテゴリの共分散 σ_i による詰め込み効率関数 L_n の最適化 $\frac{\partial L_n}{\partial \sigma_i} = 0$ を展開する．この偏微分方程式の展開には，幾つか技巧的な点があるが，次の行列微分の公式を用いて展開可能である．ただし，以下の公式中の行列 $A(x)$ は一般の正方行列とする．

$$\frac{1}{|A(x)|}\frac{d|A(x)|}{dx} = tr(A(x)^{-1}\frac{d}{dx}A(x)) \tag{A.39}$$

特に, スカラー x が行列 A の要素である場合 (i.e., $x = a_{ij}$),

$$\frac{1}{|A(x)|}\frac{d|A(x)|}{da_{ij}} = tr(A(x)^{-1}\frac{d}{da_{ij}}A(x)) = \hat{a}_{ji} \tag{A.40}$$

ただし，a_{ij} は 行列 A の i 行 j 列の要素で，$\hat{a}_{ji}$ は逆行列 A^{-1} の j 行 i 列の要素である．

これらの公式を用いて展開する事で，以下の 3 式を得る．

$$\frac{\partial}{\partial \sigma_i}\log(2\pi|A^{-1}|) = \frac{1}{(2\pi|A^{-1}|)}\frac{\partial 2\pi|A^{-1}|}{\partial \sigma_i} = tr(A\frac{\partial A^{-1}}{\partial \sigma_i}) \tag{A.41}$$

$$\frac{\partial A^{-1}}{\partial \sigma_i} = \frac{\partial (\sum_i^n \sigma_i^{-1})^{-1}}{\partial \sigma_i} = A^{-1}\sigma_i^{-1}\frac{\partial \sigma_i}{\partial \sigma_i}\sigma_i^{-t}A^{-t} \tag{A.42}$$

$$\frac{\partial (B^tA^{-1}B - C)}{\partial \sigma_i} = \sigma_i^{-1}(A^{-1}B - \mu_i)(A^{-1}B - \mu_i)^t\sigma_i^{-1} \tag{A.43}$$

従って,

$$\frac{\partial 2nG}{\partial \sigma_i} = \sigma_i^{-1}(A^{-1}B - \mu_i)(A^{-1}B - \mu_i)^t\sigma_i^{-1} + n\sigma_i^{-1}A^{-1}\sigma_i^{-1} - \sigma_i^{-1} \tag{A.44}$$

式 (A.28) より, $L_n = 2nG_n + \lambda_1 E_1 + \lambda_2 E_2$ であるので,

$$\frac{\partial L_n}{\partial \sigma_i} = \sigma_i^{-1}(A^{-1}B-\mu_i)(A^{-1}B-\mu_i)^t\sigma_i^{-1}+n\sigma_i^{-1}A^{-1}\sigma_i^{-1}-(\lambda_2-1)\sigma_i^{-1} = 0 \tag{A.45}$$

$i = 1, 2, \ldots, n$ に対して，以下の行列方程式を得る．

$$(A^{-1}B - \mu_i)(A^{-1}B - \mu_i)^t + nA^{-1} + (\lambda_2 - 1)\sigma_i = \mathbf{0} \tag{A.46}$$

この関係式は，次節で滑らかな構造の導出に用いる．

A.4.3 滑らかな構造の発生

ここでは，カテゴリの「滑らかさ」を定義し，詰め込み効率関数の最適化が滑らかなカテゴリを導く事を示す．類似のカテゴリ (i.e., 小さい中心間距離) は，類似の特徴重要性 (i.e., 類似の尤度分布パタン) を持つとき，カテゴリは「滑らか」であると言う．従って，形式的に，中心間距離と共分散の類似性が単調な関係にあるとき滑らかである (式 A.47).

$$||\Delta\mu_{ij}|| \approx h(||\Delta\sigma_{ij}||) \tag{A.47}$$

ただし，$h(X)$ は X の単調関数で，$\approx$ は近似を表す．また，$\Delta\mu_{ij} = \mu_i - \mu_j$, $\Delta\sigma_{ij} = \sigma_i - \sigma_j$ とする.

式 (A.47) の一つの形式は，本文第 3 章の式 (3.1) である.

A.4.3.1 カテゴリ中心の最適化による滑らかさの発生 ここでは，詰め込み効率関数 L_n をカテゴリ中心 μ_i を動かす事で最適化し，これがカテゴリの滑らかな構造を導く事を示す．式 (A.30) より，

$$\frac{\partial L}{\partial 2\mu_i} = -\sigma_i^{-1}(\mu_i - A^{-1}B) + \lambda_1\mu_i = 0 \tag{A.48}$$

これは，任意の $i, j = 1, 2, \ldots, n$ について成り立つので，$\frac{\partial L}{\partial 2\mu_i} = 0$ と $\frac{\partial L}{\partial 2\mu_j} = 0$ である．これを利用して，$||\Delta\mu_{ij}|| = \Delta\mu_{ij}^t\Delta\mu_{ij} = (\mu_i - \mu_j)^t(\mu_i - \mu_j)$ を展開する事で，以下の関係式が導かれる.

$$\Delta\mu_{ij}^t\Delta\mu_{ij} = \lambda_1^2\bar{\mu}^t(\lambda_1\sigma_i - I)^{-2}\Delta\sigma_{ij}^2(\lambda_1\sigma_j - I)^{-2}\bar{\mu} \tag{A.49}$$

ただし，$\bar{\mu} = A^{-1}B$ である.

任意の n 次正方行列 X, Y に対して，$tr(XY) = \sum_{i,j} x_{ij}y_{ij} = tr(YX)$ であり ($tr(X)$ は X のトレースを表す)，また特に，n 次ベクトル x に対しては，$x^tYx = tr(x^tYx) = tr(xx^tY) = tr(Yxx^t)$ である事に注意して，両辺のトレースをとると，

$$\Delta\mu_{ij}^t\Delta\mu_{ij} = \lambda_1^2 tr\{\bar{\mu}\bar{\mu}^t(\lambda_1\sigma_i - I)^{-2}(\lambda_1\sigma_j - I)^{-2}\Delta\sigma_{ij}^2\} \tag{A.50}$$

Cauchy-Shuwarz の不等式を用いて,

$$||\Delta\mu_{ij}|| \leq \lambda_1^2 tr\{\bar{\mu}\bar{\mu}^t(\lambda_1\sigma_i - I)^{-2}(\lambda_1\sigma_j - I)^{-2})\}||\Delta\sigma_{ij}^2|| \tag{A.51}$$

ただし，$tr\{\Delta\sigma_{ij}^2\} = ||\Delta\sigma_{ij}^2||$ である．式 (A.51) は式 (A.47) の一形式とみなせる．従って，詰め込み効率関数の μ_i $(i = 1, 2, \ldots, n)$ の最適化は，カテゴリの滑らかな構造の必要条件を与える事が示された.

A.4.3.2　尤度パタンの最適化による滑らかさの発生　前節と同様に，尤度パタン (共分散 σ_i) による詰め込み効率関数の最適化の関係式 (式 A.46) から，滑らかな構造 (式 A.47) を導出する．

最適化の必要条件 $\sigma_i \frac{\partial L_n}{\partial \sigma_i} \sigma_i = 0$ から，式 (A.46) より，

$$\sigma_i + \lambda_2 \sigma_i^{-1} = (\bar{\mu} - \mu_i)(\bar{\mu} - \mu_i)^t + \bar{\sigma} \tag{A.52}$$

ただし，$\bar{\sigma} = nA^{-1}$ である．

$\sigma_i \frac{\partial L_n}{\partial \sigma_i} \sigma_i - \sigma_j \frac{\partial L_n}{\partial \sigma_j} \sigma_j = 0$ の二つの関係式から，

$$\Delta\sigma_{ij} - \lambda_2 \sigma_i^{-1} \Delta\sigma_{ij} \sigma_j^{-1} = \Delta\mu_i \Delta\mu_i^t - \Delta\mu_j \Delta\mu_j^t \tag{A.53}$$

ただし，$\Delta\sigma_{ij} = \sigma_i - \sigma_j$, $\Delta\mu_{ij} = \mu_i - \mu_j$, $\Delta\mu_i = \bar{\mu} - \mu_i$ である．これをさらに展開して，

$$\Delta\sigma_{ij} - \lambda_2 \sigma_i^{-1} \Delta\sigma_{ij} \sigma_i^{-1} = \Delta\mu_{ij}(\bar{\mu}_{ij} - \bar{\mu})^t + (\bar{\mu}_{ij} - \bar{\mu})\Delta\mu_{ij}^t \tag{A.54}$$

ただし，$\bar{\mu}_{ij} = \frac{1}{2}(\mu_i + \mu_j)$ である．

さらに両辺のトレースをとって展開する事で，

$$tr(\lambda_2 \Delta\sigma_{ij}) = tr(\Delta\mu_{ij}(\bar{\mu}_{ij} - \bar{\mu})^t + (\bar{\mu}_{ij} - \bar{\mu})\Delta\mu_{ij}^t) \tag{A.55}$$

Cauchy-Shuwarz の不等式を用いて，

$$\lambda_2 ||\Delta\sigma_{ij}|| = 2tr(\Delta\mu_{ij}(\bar{\mu}_{ij} - \bar{\mu})^t) \leq 2||\Delta\mu_{ij}||||\bar{\mu}_{ij} - \bar{\mu}|| \tag{A.56}$$

式 (A.56) は式 (A.47) の一形式とみなせる．従って，前節の結論と同様に，詰め込み効率関数の σ_i $(i = 1, 2, \ldots, n)$ の最適化は，カテゴリの滑らかな構造の必要条件を与える事が示された．

A.4.4　最適解の安定性

ここでは，カテゴリ中心による最適解 $\frac{\partial L_n}{\partial \mu_i} = 0$ $(i = 1, 2, \ldots, n)$ が安定である事を示す．解の安定性は，$\frac{\partial L_n}{\partial \mu_i} = 0$ の解が詰め込み最適である事の十分条件を与えるため，重要である．具体的には，二次偏微分を要素とする Hessian 行列 (Hesse 行列) を算出し，Hessian 行列の固有値を解析する．1 次偏微分 $\frac{\partial L_n}{\partial \mu_i}$ は式 (A.30) で与えられる．これをさらに μ_j で偏微分する事で，以下の 2 次偏微分方程式を得る．

$$\frac{\partial^2 L}{2\partial\mu_i \partial\mu_j} = \delta_{ij}(\lambda_1 I_d - \sigma_i^{-1}) + \sigma_i^{-1} A^{-1} \sigma_j^{-1} \tag{A.57}$$

Hessian 行列 $\mathbf{H}$ は $\frac{\partial^2 L}{2\partial\mu_i\partial\mu_j}$ を i 行, j 列の要素とする行列である．

これを展開すると，以下のように書き直せる．

$$\mathbf{H} = \sigma^{-1}A^{-1}\sigma^{-t} - \mathbf{\Sigma} + \lambda I_{dn} \tag{A.58}$$

ただし，$\sigma^{-1} = (\sigma_1^{-1}, \sigma_2^{-1}, \ldots, \sigma_n^{-1})^t$ である．

ここで，σ_i $(i = 1, 2, \ldots, n)$ は，実対称行列であるので，半正定行列 (semi-positive definite: i.e., 固有値が全て 0 以上) である．これは，任意のベクトル $x = (x_1, x_2, \ldots, x_n)^t$ に関して，常に $x\sigma x \geq 0$ である事と同値である．

これと同様に，任意の dn 次ベクトル $x^t = (x_1^t, x_2^t, \ldots, x_n^t)$ (ただし，x_i $(i = 1, 2, \ldots, n)$ を d 次ベクトルとする) に対して，Hessian 行列の 2 次形式 (i.e., $x^t\mathbf{H}x$) の符号を調べる．

式 (A.57) から，$x^t\mathbf{H}x = \sum_i^n \sum_j^n x_i^t H_{ij} x_j$ であるので，

$$x^t\mathbf{H}x = \sum_i^n \sum_j^n x_i^t\{\delta_{ij}(\lambda_1 I_d - \sigma_i^{-1}) + \sigma_i^{-1}A^{-1}\sigma_j^{-1}\}x_j \tag{A.59}$$

展開して，以下の式を得る．

$$x^t\mathbf{H}x = x^t(\lambda_1 I_{dn} - \mathbf{\Sigma})x + (\sum_i^n x_i^t\sigma_i^{-1})A^{-1}(\sum_j^n \sigma_j^{-1}x_j) \tag{A.60}$$

明らかに，$(\sum_i^n x_i^t\sigma_i^{-1})A^{-1}(\sum_j^n \sigma_j^{-1}x_j) \geq 0$ であるので，$\mathbf{H}$ が半正定であるためには，$x^t(\lambda_1 I_{dn} - \mathbf{\Sigma})x$ が半正定であればよい．この条件は，$\mathbf{\Sigma}$ の全ての固有値が非負である事と同値である．そして，Σ は σ_i^{-1} を対角要素として持つブロック行列であるため，この条件は常に成り立つ (前述のように，全ての i に対し，σ_i は正定である事に注意)．言い換えれば，$\mathbf{\Sigma}$ の固有値は，σ_i^{-1}s を用いて，$|\lambda_1 I_{dn} - \mathbf{\Sigma}| = \prod_i |\lambda_1 I_d - \sigma_i^{-1}|$ と書けるからである．従って，カテゴリ中心による最適解 $\frac{\partial L_n}{\partial \mu_i} = 0$ $(i = 1, 2, \ldots, n)$ は安定である事が示された．

A.4.5 他のメトリックモデルとの関係

詰め込みモデルの識別性の関数 (式 A.20) は，正規分布に従う尤度を持つ 2 つのカテゴリの最小誤識別率の一つの近似的上界 (Bhattacheryya upper bound, [60]) の拡張として与えられる．次節では，カテゴリの最適決定基準における誤り上界について説明する．また，Bhattacherrya 上界と，Corter & Gluck [24] が基本カテゴリを表現するメトリックとして提案したカテゴリ有用性 (Category utlity) には，近似的な関係がある事を示し，詰め込みモデルの識別性の関数 (式 A.20) との関係について述べる．

A.4.5.1　Bhattacheryya上界の拡張　もし，ある人が特定の特徴$\theta \subset \Omega_i$を持つ事例を，カテゴリc_iであると推定したとすると，その正答率は$\sum_i \int_{\Omega_i} P(c_i,\theta)d\theta$で与えられる．　特に，2カテゴリの識別の場合 ($n = 2$)，誤答率$\epsilon$は，$\epsilon = \int_{\Omega_2} P(c_1,\theta)d\theta + \int_{\Omega_1} P(c_2,\theta)d\theta$で与えられる.ただし，$\Omega_1, \Omega_2$は，それぞれカテゴリ$1, 2$と推定された事例の特徴の特徴空間における領域である．このとき，識別の戦略Ω_1, Ω_2が最適である場合，識別誤りの最小値$\hat{\epsilon}$は，$\hat{\epsilon} = \int_\Omega \min(P(c_1,\theta), P(c_2,\theta))d\theta$で与えられる．なぜなら，ある特徴$\theta$に対して，$P(c_1,\theta)$,$P(c_2,\theta)$のうち，最大確率のカテゴリ$\max(P(c_1,\theta), P(c_2,\theta))$を選択をする事で，正答率を最大化できるからである．

しかし，最大値$\max(P(c_1,\theta), P(c_2,\theta))$または最小値$\min(P(c_1,\theta), P(c_2,\theta))$は，微分不可能な点を持ち，またその値を正確に形式化するのが難しいため，解析には向きである．

従って，最大値，最小値の代用として，近似的な誤り上界を用いる．$a, b \geq 0$, $0 \leq \beta \leq 1$を満たす任意のa, b, βに対して，恒等不等式$\min(a,b) \leq a^\beta b^{1-\beta}$が成り立つ．これを適用して，以下の不等式が成り立つ．

$$\hat{\epsilon} \leq \int P(c_1,\theta)^\beta P(c_2,\theta)^{1-\beta} d\theta \tag{A.61}$$

ベイズの定理から，カテゴリciを与えたときの特徴θが出現する条件付確率を$P(\theta|c_i)$として，$P(c_i,\theta) = P(\theta|c_i)P(c_i)$が成り立つので，

$$\hat{\epsilon} \leq P(c_1)^\beta P(c_2)^{1-\beta} \int P(\theta|c_1)^\beta P(\theta|c_2)^{1-\beta} d\theta \tag{A.62}$$

この不等式の右辺をChernoff上界と呼ぶ．特に，$P(\theta|c_i)$が，それぞれ平均μ_i，共分散σ_iの正規分布 ($i = 1, 2$)で与えられるとき，Chernoff上界Cは$C = P(c_1)^\beta P(c_2)^{1-\beta}\exp(-k_C)$である．ただし，

$$k_C = \frac{\beta(1-\beta)}{2}(\mu_2-\mu_1)^t(\beta\sigma_1 + (1-\beta)\sigma_2)^{-1}(\mu_2-\mu_1) + \frac{1}{2}\log\frac{|\beta\sigma_1 + (1-\beta)\sigma_2|}{|\sigma_1|^\beta|\sigma_2|^{1-\beta}} \tag{A.63}$$

Chernoff上界は任意パラメータ$0 \leq \beta \leq 1$を持つが，最小の上界を持つβの解析形は困難である．しかし，上界最小を与える$\hat{\beta}$は$\beta = \frac{1}{2}$に近い事は示されている [60]．従って，Chernoff上界において$\beta = \frac{1}{2}$とした，よりゆるい次善の上界$B = \sqrt{P(c_1)P(c_2)}\exp(-k_B)$をBhattacheryya上界と呼ぶ．ただし，

$$k_B = \frac{1}{4}(\mu_2-\mu_1)^t(\sigma_1+\sigma_2)^{-1}(\mu_2-\mu_1) + \frac{1}{2}\log\frac{|\sigma_1+\sigma_2|}{2\sqrt{|\sigma_1||\sigma_2|}} \tag{A.64}$$

また, $n=2$ のとき，$F_2=\exp(-kB)$ である．

また、一般の n の場合 (式 A.20)，$F_n=\int_\Omega \prod_i P(\theta|c_i)^{\frac{1}{n}}d\theta$ であるので，

$$F_n=\int_\Omega \{P(\theta|c_j)P(\theta|c_k)\}^{\frac{1}{n}}\prod_{i\neq j,k}P(\theta|c_i)^{\frac{1}{n}}d\theta \tag{A.65}$$

従って，$\prod_{i\neq j,k}P(\theta|c_i)^{\frac{1}{n}}$ の分散が十分に大きい場合 (i.e., $n(\sum_{i\neq j,k}\sigma_i^{-1})^{-1}\to\infty$)，$F_n\approx\alpha F_2$ となる．カテゴリ i,j の Bhattacheryya 上界を $B_{ij}=\sqrt{P(c_i)P(c_j)}\int P(\theta|c_i)^{\frac{1}{2}}P(\theta|c_j)^{\frac{1}{2}}d\theta$ として，各カテゴリの分散が十分に大きい条件で以下の近似が成り立つ．

$$F_n=\prod_i P(c_i)^{\frac{1}{n}}\int\prod_i P(\theta|c_i)^{\frac{1}{n}}d\theta\approx\sum_i\sum_{j\neq i}B_{ij} \tag{A.66}$$

実際に，詰め込みモデルでは，包含性 E_2 によって分散を大きくする方向への圧力がかかっている ($\sigma_i\to\infty,\ i=1,2,\ldots,n$) ため，式 (A.66) の両辺は近い値になると考えられる．しかし，これは厳密な収束の意味ではなく，実際の計算上のメトリックの違いには注意が必要である．

A.4.5.2　相互情報量およびカテゴリ有用性 [24] との関係　Corter & Gluck [24] は，以下の式 A.67 で定義されるメトリック $U(c_i)$ をカテゴリ有用性 (Category utility) と呼んだ．カテゴリ有用性は，相互情報量 $\sum_i P(c_i)\int(P(\theta|c_i)\log(P(\theta|c_i))-P(\theta)\log(P(\theta)))d\theta$ と類似の形を持つ亜種と考えられ，基本カテゴリを特徴づけるとされる．

$$U(c_i)=P(c_i)\int(P(\theta|c_i)^2-P(\theta)^2)d\theta \tag{A.67}$$

カテゴリ有用性の総和は $U=\sum_i U(c_i)$ である．

$$U=\sum_i P(c_i)\int P(\theta|c_i)^2d\theta-\int P(\theta)^2d\theta\sum_i P(c_i) \tag{A.68}$$

カテゴリ有用性 U が Bhattacheryya 上界と関係を持つ事を以下に示す．$\sum_i P(c_i)=1$, $\sum_i P(\theta,c_i)=P(\theta)$, $B_{ij}=\sqrt{P(c_i)P(c_j)}\int P(\theta|c_i)^{\frac{1}{2}}P(\theta|c_j)^{\frac{1}{2}}d\theta$ である事に注意して式 A.68 を展開すると，

$$U=\sum_i(P(c_i)^{-1}-1)\int P(\theta,c_i)^2d\theta-2\int\sum_i\sum_{j\neq i}(\frac{dB_{ij}}{d\theta})^2d\theta \tag{A.69}$$

特に，$P(\theta|c_i)$ が正規分布 (または指数族確率分布) である場合 (i.e., $P(\theta|c_i)=N(\mu_i,\sigma_i)$), $\int_\Omega P(\theta|c_i)^kd\theta=\sqrt{k}$ が成り立つので，

$$U=\sqrt{2}(1-\sum_i P(c_i)^2)-2\sqrt{2}\sum_i\sum_{j\neq i}B_{ij} \tag{A.70}$$

従って，カテゴリが正規分布であり，$P(c_i)$ が一定である場合，全てのカテゴリ対の Bhattacheryya 上界の和と一致する．

A.4.5.3　メトリックの近似的関係性の数値実験　ここでは，モンテカルロ法を用いてメトリックの近似的な関係を調べる．ランダムなパラメタを持つ 20 の 1 次元正規分布を 500 回発生させ，生成されたカテゴリ分布のメトリックを測った．平均は $[-3, 3]$，分散は $[0.2, 2]$ の一様乱数値とした．詰め込みモデルの識別性 (F_n), カテゴリ有用性 (U), カテゴリ対の Bhattacheryya 上界 $(B = \sum_{i,j\neq i} B_{ij})$，最大値メトリック $(\mathrm{Max} = \int \max_i(P(\theta|c_i)d\theta)$，カテゴリ対の最小値メトリック $(\mathrm{Min} = \sum_{i,j\neq i} \min(P(\theta|c_i), P(\theta|c_j)))$ の 5 つを検討した．F_n, U, B は理論的な数値を算出し，Max, Min は厳密な解析形が無いので，$[-10, 10]$ の範囲で 0.01 刻みの関数値の和から算出した．各メトリックの相関係数を表 A.2 に示す．数値実験のパラメタの範囲では，詰め込みモデルの識別性 F_n は，最適な判断基準における正答率 Max と負の相関を持つので，誤識別率のよい近似となっている．

$\tau\backslash R$	Max	F	U	B	Min
Max	1	-.867	.855	-.877	-.863
F	-.681	1	-.791	.938	.806
U	.659	-.601	1	-.903	-.949
B	-.686	.785	-.740	1	.938
Min	-.658	.620	-.814	.796	1

表 A.2: 各メトリックの Pearson 積率相関係数 (上三角) と Kendall 順位相関係数 (下三角)

A.4.6　詰め込み効率関数の階層的な性質

ここでは，n 個の正規分布の識別誤差を表す F_n と，その部分集合 $\{c_1, c_2, \ldots, c_m\}$ に関する語識別率 F_m $(m < n)$ の関係性を示す．この関係式から，カテゴリを階層的にグループ化したときの誤識別率の関係が明らかになる．また，言い換えれば，一つのカテゴリの中に複数の正規分布 (混合正規分布) を内包するときの誤識別率 F_n を導出することになる．従って，カテゴリが階層的な構造を持つ場合や，個々のカテゴリの分布が非正規分布である場合に，経験分布を混合正規分布として表す場合にこの拡張が有効であると考えられる．

まず，詰め込み効率関数の導出の式に戻り，そこから異なるグループ化を施した関係式を求める．元の n カテゴリに対する誤識別率は以下の通り式 (A.20)

で与えられる．

$$F_n = \int_\Omega \prod_i P(\theta|c_i)^{\frac{1}{n}} d\theta \tag{A.71}$$

この F_n は次のように展開可能である．

$$F_n = (\prod_i^n ((2\pi)^d |\sigma_i|)^{-\frac{1}{2n}}) \int_\Omega \exp(-\frac{1}{2n}(\theta^t A\theta - \theta^t B - B^t\theta + C))d\theta \tag{A.72}$$

ただし，$A = \sum_i^n \sigma_i^{-1}$, $B = \sum_i^n \sigma_i^{-1}\mu_i$, $C = \sum_i^n \mu_i^t\sigma_i^{-1}\mu_i$ ($\sigma_i = \sigma_i^t$ に注意) である．

次に，この式 (A.72) を複数のグループに分割することを考える．サブグループ Φ_i は n_i 個のカテゴリを含み ($\Phi_1 \supset \{c_1, c_2, \ldots, c_{n_i}\}$)，すべてのサブグループの和集合が全カテゴリの集合となると考える ($\{c_1, c_2, \ldots, c_n\} = (\Phi_1 \cup \Phi_2 \cup \ldots \cup \Phi \cup \ldots \Phi_m)$)

このとき，各サブグループに含まれるカテゴリの平均・共分散パラメタをまとめると，次のように式変形できる．

$$F_n = (\prod_i^n ((2\pi)^d |\sigma_i|)^{-\frac{1}{2n}}) \int_\Omega \exp(-\frac{1}{2n}(\theta^t(\sum_j A_j)\theta - \theta^t(\sum_j B_j) - (\sum_j B_j)^t\theta + (\sum_j C_j)))d\theta \tag{A.73}$$

ただし，$A_i = \sum_{j\subset\Phi_i} \sigma_j^{-1}$, $B_i = \sum_{j\subset\Phi_i} \sigma_j^{-1}\mu_j$, $C_i = \sum_{j\subset\Phi_i} \mu_j^t\sigma_j^{-1}\mu_j$ である．

この式を変形して，

$$\begin{array}{rcl} F_n & = & (\prod_j \exp(\frac{1}{2n}(B_j^t A_j^{-1} B_j - C_j)))(\prod_i^n ((2\pi)^d|\sigma_i|)^{-\frac{1}{2n}}) \\ & \times & \int_\Omega \prod_j \exp(\frac{-1}{2n}(\theta - A_j^{-1}B_j)^t A_j(\theta - A_j^{-1}B_j)) \end{array} \tag{A.74}$$

積分の項は，$n_i A_i^{-1} n_i^{-1} B_i$ を平均ベクトル，$n_i A_i^{-1}$ を共分散行列とする正規分布 $N(\theta|A_i^{-1}B_i, n_i A_i^{-1})^{\frac{n_i}{n}}$ の積とみなせるので，

$$F_n = \Big(\prod_{i=1,2} D_i K_i\Big) M \int_\Omega \prod_i N(\theta|A_i^{-1}B_i, n_i A_i^{-1}))^{\frac{n_i}{n}} d\theta \tag{A.75}$$

ただし，$D_i = \exp(\frac{1}{2n}(B_i^t A_i^{-1} B_i - C_i))$, $K_i = ((2\pi)^d |nA_i^{-1}|)^{\frac{1}{2}}$, $M = \prod_i^n ((2\pi)^d|\sigma_i|)^{-\frac{1}{2n}}$ である．

$F_n = \int_\Omega N(\mu_i, \sigma_i)d\theta$ であるので，その拡張としてグループ化した正規分布の重みつき平均ベクトル $A_i^{-1}B_i$ と共分散行列の調和平均 $n_i A_i^{-1}$ に対して $F_B = \int_\Omega \prod_i N(A_i - 1B_i, n_i A_i^{-1})d\theta$ とすれば，F_B はグループ化した集合 $\{\Phi_1, \ldots, \Phi_m\}$ の間の誤識別率を表すと考えられる．よって，

$$\log(F_B) = \log(F_n) - \log\left(\Big(\prod_{i=1,2} D_i K_i\Big) M\right) \tag{A.76}$$

$\log(F_B) = \log(DKM) - \sum_i \log(D_i K_i) - \log(M)$ を展開すると，

$$\log(F_B) = \frac{1}{2n}(B^t A^{-1} B - \sum_i B_i^t A_i^{-1} B_i) + \log(K) - \sum_i \log(K_i) \qquad \text{(A.77)}$$

従って，$G_B = \log(F_B)$ および $L_B = G_B + \lambda_1 E_1 + \lambda_2 E_2$ から，階層性を内包する詰め込み効率性を定義できる．L_B は Phi_i $(i = 1, \ldots, m)$ をグループ化したときに，グループ内の誤識別率 $F_W \equiv \log\left(\left(\prod_{i=1,2} D_i K_i\right) M\right)$ を全体の誤識別率から差し引いたグループ間の誤識別率とみなせる．

また，グループ間の誤識別率による詰め込み効率性 L_B の平均ベクトル μ_i $(c_i \subset \Phi_j)$ に関する偏微分をとると，

$$\frac{\partial L_B}{\partial \mu_i} = \sigma_i^{-1} A^{-1} B - \sigma_i^{-1} A_j^{-1} B_j + \lambda_1 \mu_i \qquad \text{(A.78)}$$

従って，同じグループに属するカテゴリ c_i, c_j に関して $\{c_i, c_j\} \subset \Phi_k$ $(\frac{\partial L_B}{\partial \mu_i} = 0$ より)，$\sigma_i \mu_i - \sigma_j \mu_j = 0$ が成り立つ．一方，同一グループに属さないカテゴリ $c_i \subset \Phi_k$, $c_j \subset \Phi_m$ $(k \neq m)$ に対して，$\sigma_i \mu_i - \sigma_j \mu_j = A_k^{-1} B_k - A_m^{-1} B_m$ となる．この事から，複数の正規分布からなる混合正規分布を 1 つのカテゴリの尤度とした場合，階層的な詰め込み効率性の最適化により，グループ内の正規分布群は全体として平均 $A_k^{-1} B_k$ の正規分布に近づく傾向がある．また，もしカテゴリ内のすべての正規分布の分散が同一ならば $(\sigma_i = \sigma_j)$，階層的な詰め込みモデルは，階層無しの元のモデルに縮退する．

A.4.7 混合正規分布モデルによるクラスタリングモデルへの拡張

第 3 章では，一貫してデータフィットの項目を単純化した上で議論をしてきたが，データフィットに適当なモデルを仮定する事で理論の拡張が可能である．この拡張により，詰め込みモデルの定式化では明らかにされてこなかったあるカテゴリ i の生成される周辺確率分布 $P(c_i)$(または事前分布) の意味が明確になる．

A.4.7.1 混合正規分布モデル (Gaussian Mixture Model) まず，n 個のガウス分布の混合からなる確率分布を考える．また，学習者にとってあるデータがどのカテゴリに属するか不明であるとする．$\mathbf{X} = (x_1, x_2, \ldots, x_K)^t$ を $K \times d$ 次のデータを表す行列とする．ただし，$d \times 1$ 次ベクトル x_k は i 番目の観察されたデータとする．

$$P(x_k; \omega) = \sum_i^n P(\theta = x_k | c_i) P(c_i) \qquad \text{(A.79)}$$

ただし，$P(c_i)$ はカテゴリ i の周辺分布で $(\sum_i^n P(c_i) = 1)$，分布パラメタの集合を $\omega \supset \{\mu_1, \mu_2, \ldots, \mu_n, \sigma_1, \sigma_2, \ldots, \sigma_n\}$ とする．

このとき，データの集合が発生する対数尤度を $\mathrm{LL} = \log(P(\mathbf{X};\omega))$ として，特徴の発生する尤度が正規分布 $P(\theta|c_i) = N(\theta|\mu_i, \sigma_i)$ であることに注意すると，以下を得る．

$$\mathrm{LL} = \sum_{k=1}^{K} \log\Big\{ \sum_{i}^{n} P(c_i) N(x_i|\mu,\sigma) \Big\} \tag{A.80}$$

Jensen の不等式より，$\log(\sum_k q_k x_i) \geq \sum_k q_k \log(x_i)$ for any $x_i > 0$, $q_k \geq 0$ and $\sum_k q_k = 1$．従って，対数尤度の下限を以下の式で表せる．

$$\begin{aligned}
\mathrm{LL} &= \sum_{k=1}^{K} \log\Big\{ Q_{ik} Q_{ik}^{-1} \sum_i^n P(c_i) N(x_i|\mu,\sigma) \Big\} \\
&\geq \sum_{k=1}^{K} \sum_i^n Q_{ik} \log\Big\{ Q_{ik}^{-1} P(c_i) N(x_i|\mu,\sigma) \Big\} \\
&= \sum_{k=1}^{K} \sum_{i=1}^{n} Q_{ik} \Big\{ \log P(c_i) - \tfrac{1}{2}\log|\sigma_i| - \tfrac{1}{2}(x_k-\mu_i)^t \sigma_i^{-1}(x_k-\mu_i) - \log Q_{ik} \Big\} + \text{const.}
\end{aligned} \tag{A.81}$$

両辺の等号成立は，$Q_{ik} = P(c_i|x_k) = \frac{P(x_k;\omega)}{\sum_i^n P(x_k;\omega)}$ のとき，つまり，Q_{ik} が条件つき確率 $P(c_i|x_k)$ に一致するときである．また，最大対数尤度を得るためには，右辺の下限を最大化すればよい．よって右辺の定数を除いた以下の式を得る．

$$\mathcal{F}(\mathbf{X};\omega) = \sum_{k=1}^{K}\sum_{i=1}^{n} \hat{Q}_{ik} \Big\{ \log P(c_i) - \frac{1}{2}\log|\sigma_i| - \frac{1}{2}(x_k-\mu_i)^t \sigma_i^{-1}(x_k-\mu_i) \Big\} \tag{A.82}$$

目的となるコスト関数 $\mathcal{F}(\mathbf{X};\omega)$ は EM(Expectation-Maximization) アルゴリズムなどによって最適化される事が多い．EM アルゴリズムでは，ある確率分布が与えられた下でのパラメータの最大化 (M ステップ) と，パラメタが与えられたときの期待値 (E ステップ) を循環的に繰り返し計算して解を得る方法である [122]．次に EM アルゴリズムの E ステップ，M ステップの計算式を示す．

A.4.7.2 M ステップ：Q_{ik} を固定したときのコスト関数 $\mathcal{F}$ の各パラメタによる最大化

$P(c_i)$ の解 $\sum_i P(c_i) = 1$ であるので, これを制約として $\hat{\mathcal{F}} = \mathcal{F} + \lambda(1 - \sum_i P(c_i))$ の $P(c_i)$ による偏微分を計算する (ラグランジュ乗数法).

$$\frac{\partial \hat{\mathcal{F}}}{\partial P(c_i)} = P(c_i)^{-1} \sum_{k=1}^{K} \hat{Q}_{ik} - \lambda \tag{A.83}$$

$\frac{\partial \hat{\mathcal{F}}}{\partial P(c_i)} = 0$ であるので,

$$P(c_i) = \frac{\sum_{k=1}^{K} \hat{Q}_{ik}}{\sum_{k=1}^{K}\sum_{i=1}^{n} \hat{Q}_{ik}} \tag{A.84}$$

μ_i の解

$$\frac{\partial \mathcal{F}}{\partial \mu_i} = \sum_{k=1}^{K} \hat{Q}_{ik} \Big\{ -\sigma_i^{-1}(x_k - \mu_i) \Big\} \tag{A.85}$$

$\frac{\partial \mathcal{F}}{\partial \mu_i} = 0$ であるので,

$$\mu_i = \frac{\sum_{k=1}^{K} \hat{Q}_{ik} x_k}{\sum_{k=1}^{K} \hat{Q}_{ik}} \tag{A.86}$$

σ_i の解　σ_i による偏微分は,

$$\frac{\partial \mathcal{F}}{\partial \sigma_i} = \sum_{k=1}^{K} \hat{Q}_{ik} \Big\{ \frac{1}{2}\sigma_i^{-1} - \frac{1}{2}\sigma_i^{-1}(x_k - \mu_i)(x_k - \mu_i)^t \sigma^{-1} \Big\} \tag{A.87}$$

$\frac{\partial \mathcal{F}}{\partial \sigma_i} = 0$ であるので,

$$\sigma_i = \frac{\sum_{k=1}^{K} \hat{Q}_{ik}(x_k - \mu_i)(x_k - \mu_i)^t}{\sum_{k=1}^{K} \hat{Q}_{ik}} \tag{A.88}$$

A.4.7.3　E ステップ：Q_{ik} の期待値　既に述べたように，$\mathcal{F}$ は $Q_{ik} = P(c_i|x_k) = \frac{P(x_k;\omega)}{\sum_i^n P(x_k;\omega)}$ のとき最大 (かつ等号成立) である．M ステップで一時的に推定した各パラメタによって $\hat{Q}_{ik}$ の期待値は以下の通りである．

$$\hat{Q}_{ik} = \frac{\hat{P}(c_i)|\sigma|^{-\frac{1}{2}} \exp\{-\frac{1}{2}(x_i - \hat{\mu}_k)^t \hat{\sigma}_i (x_i - \hat{\mu}_k)\}}{\sum_i^n \hat{P}(c_i)|\sigma|^{-\frac{1}{2}} \exp\{-\frac{1}{2}(x_i - \hat{\mu}_k)^t \hat{\sigma}_i (x_i - \hat{\mu}_k)\}} \tag{A.89}$$

A.4.7.4　ガウス混合分布と詰め込み効率の組み合わせによるコスト関数　前節までは，データの集合 $\mathbf{X}$ に対して最大尤度を与えるようなガウス混合分布を求める手順を示した．詰め込みモデルでは，識別性 G_n に加えて集約性 E_1 や包含性 E_2 の制約を仮定したが，集約性・包含性の代わりに，与えられたデータに対する最大対数尤度 (の下限)$\mathcal{F}$ を制約とする事も可能である．これは，得られたデータに適合するガウス混合分布を推定するときに，そのガウス分布同士が重複しないように制約を置いたと解釈できる．以下では，この条件で滑らかな構造が発生しうるか，ガウス分布パラメタの解析によって調べる．混合分布の最大対数尤度の下限を制約とした新たなコスト関数 $\mathcal{L}_n$ は次の式で表せる．

$$\mathcal{L}_n = G_n + \lambda \mathcal{F} \tag{A.90}$$

A.4.7.5　クラスタリングにおける滑らかさの導出　コスト関数 (式 A.90) を各カテゴリ分布のパラメタで微分をする事によって，滑らかさの導出を行う。$\frac{\partial G_n}{\partial \mu_i} = -\sigma_i^{-1}(\mu_i - A^{-1}B)$, $\frac{\partial \mathcal{F}}{\partial \mu_i} = \sum_{k=1}^{K} \hat{Q}_{ik} \Big\{ -\sigma_i^{-1}(x_k - \mu_i) \Big\}$, であるので，以下

を得る．

$$\frac{\partial \mathcal{L}_n}{\partial \mu_i} = -\sigma_i^{-1}(\mu_i - A^{-1}B) + \sum_{k=1}^{K} \hat{Q}_{ik}\Big\{ -\sigma_i^{-1}(x_k - \mu_i)\Big\} \tag{A.91}$$

また，式(A.44)より，$\frac{\partial 2nG}{\partial \sigma_i} = \sigma_i^{-1}(A^{-1}B-\mu_i)(A^{-1}B-\mu_i)^t\sigma_i^{-1}+n\sigma_i^{-1}A^{-1}\sigma_i^{-1}-\sigma_i^{-1}$ である．よって，

$$\begin{array}{rcl} \frac{\partial \mathcal{L}_n}{\partial \sigma_i} & = & \sigma_i^{-1}(A^{-1}B-\mu_i)(A^{-1}B-\mu_i)^t\sigma_i^{-1} + n\sigma_i^{-1}A^{-1}\sigma_i^{-1} - \sigma_i^{-1} \\ & + & \lambda \sum_{k=1}^{K} \hat{Q}_{ik}\Big\{\frac{1}{2}\sigma_i^{-1} - \frac{1}{2}\sigma_i^{-1}(x_k-\mu_i)(x_k-\mu_i)^t\sigma^{-1}\Big\} \end{array} \tag{A.92}$$

$\frac{\partial \mathcal{L}_n}{\partial \sigma_i} = 0$ であるので，

$$(A^{-1}B-\mu_i)(A^{-1}B-\mu_i)^t + nA^{-1} - \sigma_i + \lambda\sum_{k=1}^{K}\hat{Q}_{ik}\Big\{\sigma_i - (x_k-\mu_i)(x_k-\mu_i)^t\Big\} = 0 \tag{A.93}$$

式(A.91)と式(A.93)を用いて計算をする事によって，以下の部分的な滑らかさの式を得る．

$$\begin{array}{l} (1-\lambda M)\mathrm{tr}\Big\{(\sigma_i - \sigma_j + \frac{\lambda}{1-\lambda M}(X_i - X_j))(\sigma_i - \sigma_j + \frac{\lambda}{1-\lambda M}(X_i - X_j))^t\Big\} \\ = \frac{1}{2}(\Delta\mu_{ij}((M+3)(\mu_i+\mu_j) - 3\bar{\mu})^t + ((M+3)(\mu_i+\mu_j) - 3\bar{\mu})\Delta\mu_{ij}^t) \end{array} \tag{A.94}$$

ただし，$M_i = \sum_{k=1}^{K}\hat{Q}_{ik}$, $X_i = \sum_{k=1}^{K}\hat{Q}_{ik}x_kx_k^t$ である．

式(A.94)は，詰め込み効率のみが最適化されたとき($\lambda = 0$)に，滑らかなな構造が発生するか，もしくはデータフィットが行われた場合には，データ共分散と共分散パラメタの差が平均ベクトルの差(部分的な滑らかさ)になる事を意味する．言い換えれば，学習の最初期などで，もしカテゴリのデータ事前分布が全て同程度(つまりデータが得られていない場合)であれば($X_i \approx X_j$)，学習者は詰め込み効率のみを信頼し結果として滑らかさが発生する．逆に，データが十分に得られている場合には，データを信頼すればよい事を表している．

研究業績

学術論文

(1) 日高昇平, 齋木潤. 幼児の新奇語カテゴリ化のモデル研究. 認知科学, Vol. 12, pp. 235–251, 2005. (第 4 章で引用)

学会発表・国内学会

(2) 日高昇平, 齋木潤. 環境情報による語彙獲得バイアス変化のモデル研究. 日本認知科学会第 20 回大会発表論文集, pp. 322–323, 2003. [6 月 6 日-8 日, 電気通信大学]

(3) 日高昇平, 吉田華子, 齋木潤. 発達研究固有の実験的制約を考慮した定量的分析方法〜バイリンガルの新奇語汎化課題に対する応用〜. 日本認知科学会第 22 回大会発表論文集, pp. 224–225., 2005. [7 月 29 日-31 日, 京都大学] (認知科学, Vol. 13, pp. 484–487, 2006 に再掲載)

(4) 日高昇平, 齋木潤. 視覚的物体の分節化における全体的特徴の発見. 日本認知心理学会第 5 回大会発表論文集, 2007. [5 月 26 日-27 日, 京都大学]

(5) 日高昇平, L. B. Smith. なぜ自然カテゴリは“ 自然 ”か：曲面上に詰め込まれたカテゴリ. 日本認知科学会第 24 回大会発表論文集, pp. 16–21, 2007. [9 月 3 日-5 日, 成城大学]. (第 3 章で引用)

学会発表・国際学会 (査読あり)

(6) S. Hidaka and J. Saiki. A mechanism of ontological boundary shifting. In *The Twenty Sixth Annual Meeting of the Cognitive Science Society*, pp. 565–570, 2004. [4-7 Aug, Chicago, IL, USA] (第 2 章, 第 6 章で引用)

(7) S. Hidaka and J. Saiki. A connectionist account of ontological boundary shifting. In N.R. et al. Pal, editor, *ICONIP 2004, Lecture Note in Computer Science 3316*, pp. 22–25, Berlin, 2004. Springer-Verlag. [22-25, November, Calcutta, India] (第 6 章で引用)

(8) S. Hidaka and J. Saiki. Prototype-specific learning for children's vocabulary. In *Proceedings of The Fourth IEEE International Conference on Development and Learning*, p. 201, 2005. [19-21 July, Osaka, Japan] (第 4 章で引用)

(9) S. Hidaka and J. Saiki. Feature discovery in object individuation. In *Proceedings of The Fifth International Conference on Development and*

Learning, 2006. [31 May- 3 Jun, Bloomington, IN, USA] (第 5 章で引用)

(10) S. Hidaka and J. Saiki. A solution to current limitations in the analysis of developmental data. In *The Fifteenth Biennial International Conference on Infant Studies*, 2006. [19-22 Jun, Kyoto, Japan]

(11) S. Hidaka, J. Saiki, and L. B. Smith. Semantic packing as a core mechanism of category coherence, fast mapping and basic level categories. In *Proceedings of The Twenty Eighth Annual Conference of Cognitive Society*, pp. 1500–1505, 2006. [July 26-29, Vancouver, BC, Canada] (第 3 章で引用)

(12) S. Hidaka, J. Saiki, and L. B. Smith. Semantic packing: an account for category coherence. In *Proceedings of The Seventh International Conference on Cognitive Modelling*, pp. 130–135, 2006. [5-8 April, Trieste, Italy] (第 3 章で引用)

招待講演

(13) 日高昇平. カテゴリ化バイアスの発現メカニズム. 第 2 回心の処理過程の脳的モデル化研究会, 2005. [1 月 26 日, 北海道大学].

書籍の章

(14) L. B. Smith and S. Maouene, J. Hidaka. *The Body and Children's Word Learning*, pp. 168–192. Oxford University Press, Oxford, 2007. (第 6 章で引用)

受賞

(15) 2005 年度日本認知科学会大会発表賞 (発表題目「発達研究固有の実験的制約を考慮した定量的分析方法〜バイリンガルの新奇語汎化課題に対する応用〜」) [2005 年 12 月 3 日, 日本認知科学会]

謝辞

本研究を進めるにあたり，終始懇切丁寧なご指導をして下さいました京都大学大学院情報学研究科の乾敏郎教授，京都大学大学院人間・環境学研究科の斎木潤教授，インディアナ大学心理・脳科学部の Linda B. Smith 教授に心から御礼申し上げます．特に，本論文の多くは齋木教授との共同研究から得られたものです．齋木教授との議論では大いに刺激を受け，それが本研究に生かされています．また，Smith 教授には，インディアナ大学において様々な学び・発表・議論の場をご提供いただき，発達心理学，数理心理学，認知科学，認知言語学などの幅広い知見に理解を深める事ができました．ここに深く感謝致します．また，共同研究者のインディアナ大学の吉田華子さん (現ヒューストン大学，心理学部助手)，Josita Maouene さんに感謝致します．最後に，本研究に関して援助して下さいました京都大学大学院情報学研究科の認知情報論研究室，京都大学大学院情人間・環境学研究科の認知・行動科学研究室，インディアナ大学の認知発達研究室 (Cognitive Development Lab., Indiana University) の皆様に感謝致します．

本研究の一部は，平成 18 年度科学研究費補助金 特別研究員奨励費「視覚特徴の階層性がもたらす物体のカテゴリ化バイアス」(No. 182935)，平成 18 年度京都大学教育研究振興財団第 1 号事業海外派遣助成，大学院生交流経費　(21 世紀 COE「心の働きの総合研究拠点」,2005 年度後期，2006 年度前期)，若手研究者養成経費　(21 世紀 COE「心の働きの総合研究拠点」, 2005 年度), 文部科学省 21 世紀 COE プログラム (京都大学，D-2), Grants-in-Aid for Scientific Research from JMEXT (No. 15650046), the National Institutes of Mental Health, R01 MH60200-06 による援助を受けて行われた．