

Interactions between Perceptual and Conceptual Learning

Goldstone, R. L., Stevers, M., Spencer-Smith, J., & Kersten, A. (2000)

In E. Diettrich & A. B. Markman (Eds.) *Cognitive Dynamics: Conceptual Change in Humans and Machines*. (pp. 191-228). Lawrence Erlbaum and Associates.

概要

認知科学の主要な立場

- 認知の基盤 (foundation) として、知覚は確固 (stable) として固定されている
- 確固とした知覚の基に概念が構築される (建築物におけるブロックのメタファー)

著者の主張

- 認知の基盤は柔軟で、動的に調整される
- 知覚と概念は相互依存的な関係にある

本稿の目的

知覚学習と概念学習の相互作用に関する著者達の研究をレビュー

レビューする項目

- 理論的考察 [Goldstone, Schyns, & Medin, 1997; Schyns, Goldstone, & Tahibaut, 1998]
- 知覚学習と概念学習の相互作用に関する実験
- 計算機モデル (ニューラルネット) によるシミュレーション

1. Fixed and flexible feature sets

1.1. 認知科学における主要な立場: Fixed features アプローチ

状況は少数の固定された要素によって記述可能

- Jakobson, Fant, & Halle (1963): 音素を構成する少数の特徴 (有声音・鼻音・甲高さ)
- Schank (1972): 行為を構成する少数の概念 (物理的移動・前進・把持・取り込み)
- Biderman (1987): オブジェクト認知を構成する少数の基本図形 (楔形・円柱)
- Wierzbicka (1992): 多様な概念を構成するプリミティブな意味要素 (良い・大きい・時間)

カテゴリ化の研究でも Fixed features アプローチは支配的

- Bruner, Goodnow, & Austin (1956): カテゴリ化の実験において、実験室に来る被験者はプリミティブなカテゴリ化の次元 (色・数・形状など) を保持し、実験室ではその次元を用いてカテゴリを学習。

Fixed features アプローチの利点

- 節約性: 多様な現象を少数の要素の組み合わせによって記述可能

Fixed features アプローチが見逃してきた問題

- 新規特徴の学習: 特徴とカテゴリの結びつきを学習するだけでなく、特徴そのものを学習することもある
- 概念から知覚への影響: 学習された概念が新たな知覚的特徴を発達させることもある

1.2. 著者が提案するアプローチ: 柔軟な特徴セット

- 課題要求・経験に応じて、知覚特徴は柔軟に変化
- 認知を構成する固定されたプリミティブは存在しない

1.2.1. 神経心理学的証拠

特定の刺激のパターンに対応して調整される神経細胞の存在 (Weinberger, 1993)

- 頻繁な音の繰り返しによって、選択的に調整される細胞が聴覚野に存在
- 3-D 物体を特定の角度から繰り返し呈示することで、その物体の認識に調整される細胞が下側頭野に存在
- 親近性の高い顔に選択的に反応する細胞が下部側頭葉に存在
- 実験的なトレーニングによって、特定の方向の動きに特化した脳電位が存在

1.2.2. 熟達化における証拠

エキスパート世界を異なる形で構成化している

熟達化は領域における刺激に特化した知覚的なツールを発達させるプロセスと捉えられる

- 放射線診断 [Mylse-Worsley et. al, 1988]
- ひよこの雄雌の区別 [Biederman & Shiffrar, 1987]
- ピールのテイスティング [Peron & Allen, 1988]

1.2.3. 本稿で紹介する研究

知覚学習と概念学習の相互作用を検討した実験的研究をレビュー

- 既存の知覚次元の感作 (Sensitization of existing perceptual dimension)
- 新規な知覚次元の感作 (Sensitization of novel perceptual dimension)
- 知覚的再体制化 (Perceptual reorganization)
- 知覚的ユニット化 (Unitization)

2. Dimension sensitization [Goldstone, 1994]

2.1. 背景

課題に適応した知覚が発達するとは? 注意される特徴の変化

- 重要な特徴に注意が向けられ、関係のない特徴には注意が向けられない...知覚次元の感作

知覚次元の感作に関する実験的証拠...視覚探索の研究

- ターゲットに關与する特徴は続く課題でも、処理を促進
- ディストラクタに含まれる特徴は処理を妨害...負の感作

特定の次元に注意が向けられるだけでなく、次元内の特定の領域が感作することもある

- 2種類の子音と母音の組 (de, be) に含まれる物理的特徴を連続して変化...領域の感作
- ある次元で de が be に聞こえるようになる...トレーニングによって、次元中の特定の領域に感作している証拠
- 実験室でのトレーニングによっても同様の現象が観察 [Pisoni, Aslin, Perey, & Hennessy, 1982]

Goldstone, 1994 では視覚的なカテゴリ化課題における、知覚次元の感作・負の感作・領域の感作を検討

2.2. 方法

2.2.1. 刺激

サイズと輝度を操作した四角形 (Fig8.1)

2.2.2. 実験の手続き

[1] カテゴリ化の訓練 (1.5 h): 四角形が一つずつディスプレイに呈示 カテゴリの判断 フィードバック

[2] 転移課題 (Same/Different 判断課題): 隣接した2つの四角形/同じ四角形を呈示され、その2つが同じか異なるかを判断

2.2.3. 実験操作

カテゴリ化の訓練で受けるフィードバックによって操作

- サイズ群: カテゴリ A は 1・2 列, カテゴリ B は 3・4 列
- 輝度群: カテゴリ A は 1・2 行, カテゴリ B は 3・4 行
- 統制群: トレーニング無し

2.2.4. 結果 (Fig. 8.2 はサイズ群, Fig. 8.3 は輝度群)

指標として d' を計算. 実験群の d' から統制群の d' を引く

- 値が正の場合は黒の四角・負の場合は白の四角で表現. 四角形の大きさが絶対値を表す

結果 1: 次元の感作

- サイズ群では縦よりも横で成績が向上, 輝度群では横よりも縦で成績が向上

結果 2: 次元中の特定の領域で感作

- サイズ群では2列目, 3列目で検出力が増加, 輝度群では2行目, 3行目で検出力が増加

結果 3: 負の感作

- 輝度群の横は白い四角のみ
- トレーニング時に無視するようにしていた次元は統制群よりも成績が低下 (負のプライミングと類似した効果)

3. Sensitization of novel dimensions

次元の感作は知覚学習と概念学習のインタラクションを示すもの

- 知覚が概念学習の基礎になり, 学習された概念が知覚を方向付ける

だが, 上記の実験は既存の次元が感作されたことを示すのみ. 実験室で新規な次元は学習されるのだろうか?

実験室の訓練によって新規次元が学習されるなら, 視覚のエキスパートが素人とは異なる体制化を行っている証拠になる

エキスパートは知覚的なオブジェクトに対するボキャブラリーが豊富

以下では, この知見をより頑健なものとした実験を示す.

3.1. Sensitization of entire novel dimensions [Goldstone & Steyvers, 1999]

完全に無作為な刺激を作成し, 被験者が元々保持する次元の影響を無効化

3.1.1. 刺激の作成

無作為に複数の顔を抽出し, 顔画像間のモーフィングによって刺激を作成

- 次元 1: 顔 A から顔 B へのモーフィング,
- 次元 2: 顔 C から顔 D へのモーフィング
- Steyvers (1999)に記述されている方法を用いて 16 の顔画像を作成

3.1.2. 実験の手続き

[1] Goldstone (1994) と同様の手続きでカテゴリ化のトレーニング

eg., Fig. 8.4. における 1 列目, 2 列目をカテゴリ A, 2 列目, 3 列目をカテゴリ B と学習. 行間での顔画像の差異は無視 (次元 1 に基づいてカテゴリ化をし, 次元 2 は関連しないものとして無視する)

[2] トレーニング完了後に新たなカテゴリ化課題 (転移課題) を実施

3.1.3. 実験条件 (Table 8.1)

7 つの実験群

- 全部で 4 つの次元を用意し, トレーニング課題と転移課題の次元で操作
- 転移課題は常に次元 1 に基づいてカテゴリ化, 次元 2 は関連しないものとして無視

3.1.4. 結果 (転移課題における正答率 Fig. 8.5)

統制条件 (3/4 トレーニングと転移で全く違う次元) との比較によって検討

結果 1: 統制条件よりも高かった条件: 1/2, 1/3, 3/2

- トレーニング課題において, 関連付けるべき次元, 無視すべき次元が学習された

結果 2: 統制条件よりも低かった条件: 3/1, 2/3

- トレーニング課題において関連付けた次元, 無視した次元が転移課題において邪魔に

結果 3: 完全に逆転した条件が統制条件よりも良かった

- 関連付けるべき次元と無視すべき次元が逆転した場合は, 負の転移が起きると考えられた
- 説明: 次元間の区別は一緒であった. 次元そのものの構成の効果と捉えられる

著者の研究室におけるその後の実験でも確認

3.2. Sensitization of regions of novel dimensions [Goldstone, Steyvers, & Larimer, 1996]

上記の研究では新規な次元の構成のみで, 領域の感作については触れていなかった

3.2.1. 刺激の作成 (Fig.8.6)

[1] 無作為に 2 つのベジェ曲線を作成

[2] 無作為な2つのベジェ曲線を線形にモーフィングし、60のベジェ曲線を作成

[3] 7つを選択

3.2.2. 実験の手続き

カテゴリ化のトレーニング Same/Different 判断課題

3.2.3. 実験条件

Left split 群: ベジェ曲線3とベジェ曲線4の間でカテゴリ分け

- カテゴリ A: 1, 2, 3
- カテゴリ B: 4, 5, 6, 7

Right Split 群: ベジェ曲線4とベジェ曲線5の間でカテゴリ分け

- カテゴリ A: 1, 2, 3, 4
- カテゴリ B: 5, 6, 7

統制群: 転移課題と全く異なるベジェ曲線を使ってカテゴリ化

3.2.4. 結果 (Fig.8.7)

Fig. 8.7a: 近接したベジェ曲線間の弁別力 (d')

Fig 8.7b: Right-split 群と Left-split 群の差

結果 1: Left-split 群, Right-split 群は統制群よりも成績がよい

- 刺激そのものに対する学習の効果 (Gibson & Walk, 1956)

結果 2: Left-split 群と Right-split 群では弁別力の高い刺激対が異なった

- Left-split 群, ベジェ曲線3と4
- Right-split 群, ベジェ曲線5と6

次元中の特定の領域に対しても感作が生じた

3.3. A neural network model of dimensional sensitization

上記の心理実験をシミュレートするニューラルネットモデルを作成 (Fig. 8.8)

3.3.1. SOS モデルの Overview

3層ネットワーク

- 第1層: ピクセルベースの表現を入力としたフィルタ
- 第2層: 知覚特徴, ボキャブラリーに相当するディテクターユニット
- 第3層: カテゴリに相当するユニット

リンク

- 第1層 第2層: 教師無し学習 (自己組織化マップに基づく)
- 第2層 第3層: 教師あり学習 (実験者からのフィードバックに相当)

3.3.2. 第1層

ガボールフィルタ (Daugman, 1985)

特定の角度に特化して数値を出力するフィルタ (Fig.8.9)

脳内視覚野に実在

ピクセル画像を入力とし, ガボールフィルタを通すことで情報を削減

4種類のフィルタ (0度, 45度, 90度, 135度)を36のピクセル位置に配置

第1層の構成は144(36×4)のガボールフィルタユニット

3.3.3. 第2層・第3層

第2層は14のディテクターユニットが1次元に配置されることで構成

第1層の活性化パターンに応じて各ユニットが活性化

第1層から第2層へのリンクのウェイトは自己組織化マップに基づく競合学習により調整(式1による更新)

- 競合学習: 入力画像と最もマッチするベクトルを保持するディテクターユニットが勝者となり, ウェイトが強化
ガボールフィルタユニットの活性パターンを区別できるようにディテクターユニットのウェイトが調整
- 自己組織化マップ: 勝者ではないディテクターユニットもユニットの配置に応じて活性値を割り当てられる

$$\text{式 1: } \Delta w_{ji}^{\text{det}} = ELN_{(i,j,\text{winner})}(a_i^{\text{in}} - w_{ji}^{\text{det}}),$$

W_{ji}^{dete} : ガボールフィルタユニット i からディテクターユニット j へのウェイトの更新値

L : 学習定数

N : 勝者とディテクター j の距離 (0: 遠い ~ 1: 近い)

$(a_i^{\text{in}} - w_{ji}^{\text{det}})$: ガボールフィルタ i の活性値からディテクター j のウェイトを引いた値

E : 入力刺激に対するカテゴリユニットのエラー数

E が本モデルの特徴 (E 以外は自己組織化マップに依拠)

- 第3層は2つのカテゴリユニットから構成(カテゴリA, カテゴリB)
- 第3層は刺激の入力に対して教師信号をもつ
- 第2層から第3層へのリンクは教師あり学習によって調整(式1における E を含む)
- 間違う危険性の高い刺激については, 近隣のユニットを活性化し, 弁別力を向上させる(SOS信号を送る)
- 間違う危険性は2つのカテゴリのボーダーラインで高い ボーダーラインに近い入力を与えられた場合はディテクターユニット配置が密になる

3.3.4. シミュレーション

2回のモデルの実行

異なる領域でカテゴリ分離がなされるトレーニング (Left-split, Right-split に対応)

シミュレーション結果 (Fig. 8.10)

- Fig. 8.10a: Left-split の実行結果 (14のディテクターユニットの活性値/刺激のナンバー)
- Fig. 8.10c: Right-split の実行結果 (14のディテクターユニットの活性値/刺激のナンバー)

ディテクターユニットは刺激に応じて位相的に配置

モデルは無作為に抽出されたベジェ曲線の特徴を正しく捉えた(自己組織化マップの効果)

カテゴリの分離に関わる刺激近辺でディテクターユニットの活性値が密に

領域の感作をシミュレート (SOS信号の含まれる学習アルゴリズムの効果)

- Fig. 8.10b: Left-split の感度 (近接したベジェ曲線に対するディテクターユニット間の距離)
- Fig. 8.10d: Right-split の感度 (近接したベジェ曲線に対するディテクターユニット間の距離)

2回の実行では異なる位置で感度が上昇...心理実験の結果をシミュレートすることに成功

4. The segmentation of objects into parts [Pevtow & Goldstone, 1994]

4.1. 背景

全体の中での部分の自然性 [eg., /と\を部分とした文字として X は V よりも自然]

[Palmer, 1977, 1978]: 部分の自然さを決定する物理的要因を検討し, 部分の自然さを量化するモデルを提案

ラインの距離, 閉じた領域かどうか, 向きの同一性, 2つの線領域の類似性...

4.2. 研究の動機

部分の自然さに対する経験(カテゴリ化)の影響

カテゴリを区別する部分(診断の決め手となる部分)が変化したら, 全体に対する知覚が変化?

4.3. 刺激

Fig. 8.11 の A, B, C, D を基本図形(被験者に呈示するものランダムに線を一本追加した)

4.4. 手続き

[1] カテゴリ化の訓練

[2] 部分・全体判断課題: 全体と部分を呈示され, 部分を全体が含むか判断

- 呈示される部分が診断の決め手となった場合
- 呈示される部分が診断の決め手とならなかった場合
- 呈示される部分が, 全体から診断の決め手となった部分を引いたものの場合
- 呈示される部分が, 全体から診断の決め手とならなかったパーツを引いた場合

4.4.1. 実験操作 (カテゴリ化の訓練におけるフィードバック)

診断の決め手となる特徴が異なる 2 群

- 縦群: カテゴリ 1 は A と B, カテゴリ 2 は C と D
- 横群: カテゴリ 1 は A と C, カテゴリ 2 は B と D

4.4.2. 結果 (Fig. 8.12)

反応時間を指標

- 結果 1: カテゴリ化のキーになった部分が呈示されたときに (present, absent) ,Nondiagnostic よりも Diagnostic のほうが速くなった

カテゴリ化によって全体から部分へのセグメンテーションが進行した

- 結果 2: 呈示される部分が, 全体から診断の決め手となった部分を引いたものの場合に, Nondiagnostic よりも Diagnostic のほうが遅くなった

カテゴリ化の効果は刺激そのものに対する注意を促進すること

全体からの差分が診断の決め手である現象には効果を持たない?

4.5. シミュレーションモデル

4.5.1. モデルの構成

2 種類のネットワーク(Fig.8.13)を使用

カテゴリ化ネットワーク...カテゴリ化のトレーニングに対応

- 3 層ネット (入力層×1, ディテクター層×2, カテゴリユニット×2)
- 教師なし学習 (入力層 ディテクター層) と教師あり学習 (ディテクター層 カテゴリユニット)の組み合わせ
入力層 ディテクター層: 競合学習によって, 2 次元ピクセルの入力を弁別するウェイトを徐々に学習
ディテクター層 入力層: 教師信号をディテクターの活性値に反映させることでカテゴリ化の効果をモデル化

セグメント化ネットワーク...部分・全体判断課題に対応

- 2 層ネット (入力層, ディテクター層, カテゴリユニット無し)
- 入力層への入力ピクセルレベル (1 枚の画像に含まれる全てのピクセルを入力)
- リンクはカテゴリ化ネットワークにより学習済み
- さらに, ピクセルレベルの入力からの競合学習アルゴリズム

4.5.2. モデルによるセグメンテーション (Fig. 8.14)

オリジナルパターン(一番上のパターン)を与えたときのディテクターユニット(左右 2 つのパターン)の活性値を検討

競合学習によるセグメンテーションではセグメンテーションの分離が起きなかった(2 番目に上のパターン)

そこで, ゲシュタルトの法則(近接の要因, 閉塞の要因)を制約としてインプリメントした

- 近接したユニットに活性を伝播 (自己組織化マップ)
- 同じ方位を持ったユニットは活性が共起 (ガボールフィルタ)

連続性・閉塞性に応じたセグメンテーションの分離が起きた (上から 3 番目のパターン)

さらに, 特定のセグメントが診断にとって重要になるカテゴリ化のトレーニングを積んだ後に, セグメンテーションネットワー

クを実行 カテゴリ化のトレーニングに応じたパターンでパターンが分離された(上から4番目のパターン)

5. The unitization of components for categorization [Goldstone, in press]

5.1. 背景

複数の特徴の結合により定義される図形がユニット化されるのどうかを検討

先行研究 [Czerwinski, Lightfoot & Shiffrin, 1992]

- 同一の図形を呈示するトレーニングの繰り返しによって、認識のスピードが上昇

Goldstone (in press)ではカテゴリ化のトレーニングによるユニット化を検討

5.2. 実験 1

5.2.1. 刺激 (Fig. 8.15)

5つのランダムに選ばれたカーブの連結により定義

- 実験に参加する被験者が対応するユニットを持たない刺激
- 各刺激は5つのセグメント(アルファベットによりラベル付け)と下部の半円から構成

5.2.2. 実験条件

All 条件: ABCDE はカテゴリ 1, ABCDZ, ABCYE, ABXDE, AWCDE, VBCDE はカテゴリ 2

- カテゴリ 1 は 5 つのセグメント (A・B・C・D・E) の結合により定義
- カテゴリ化の決め手は単一のセグメントでなく、5つのセグメント全て
- 全ての特徴を認識しなければカテゴリ化ができない

One 条件: ABCDE はカテゴリ 1, ABCDZ, ABCYE, ABXDE, AWCDE, VBCDE のいずれか一つがカテゴリ 2

- カテゴリ 2 に含まれる事例は被験者間でランダムに選択
- ABCDE をカテゴリ化するには、カテゴリ 2 に含まれる事例一つと比較すればよい

Random 条件: 順序は関係無く、A・B・C・D・Eのセグメントから構成されたらカテゴリ 1、それ以外はカテゴリ 2

- 各セグメントの並び順序はランダム
- A・B・C・D・Eのセグメントの全てを含む図形がカテゴリ 1、BCDEA もカテゴリ 1
- 正しいカテゴリ化をするためには、各セグメントが存在するか否かを分析的に判断する必要

5.2.3. 手続き

カテゴリ化の訓練を2時間連続して行う(多分、刺激を一つ呈示 カテゴリ 1 かカテゴリ 2 かを判断 フィードバック 刺激を一つ呈示...)

5.2.4. 結果 (Fig. 8.16)

カテゴリ化トレーニングにおける反応時間の推移

ABCDE を正しくカテゴリ 1 と判断した時間

All 条件でのみ、トレーニングの効果が確認 ABCDE に対応する知覚的ユニットが構成された

5.3. 実験 2

ユニット化と対立する可能として、分析モデルを仮定(一つ一つのセグメントの認識の後にそれぞれの特徴を統合)

一つ一つのセグメントの認識が並列に行われると仮定すれば、分析モデルでもかなり速い反応時間を仮定できる

この対立仮説を否定することを目指した

5.3.1. 方法

- 刺激: 実験 1 と同様
- 実験条件: All 条件, One 条件
- 被験者: リサーチアシスタント 4 名
- 実験手続き: 82 時間のトレーニング課題

5.3.2. 結果 (Fig. 8.17)

最後のセッションで得られた反応時間の確率分布 (縦軸に累積確率, 横軸に反応時間)

○が One 条件, ◻が All 条件, △が分析モデルにしたがった All 条件の予測値

：ランダムに 5 つの One 条件の反応を抽出 5 つのうちで最も反応時間の大きい反応を選択 (並列的に全てのセグメントが処理された後に統合に移る) 上記手続きを多数回実施 反応時間の確率分布を描く [近似解が One 条件の確率を 5 乗した確率分布]

One が最も左, All が 2 番目, One⁵ が最も右

分析モデルの予測を裏切り, All は One⁵ よりも速い反応時間

5.3.3. 考察

結果は特徴の結合を表現するユニット化が促進されるという仮説を支持

だが, All は One よりも遅い

分析モデルとユニット化のインタラクティブなプロセスを考えても良いかもしれない

- 脳内にはユニットのイメージが構成. だが, そのイメージは部分の特徴を曖昧にしか保持していない
- 実環境とやり取りしながら, オブジェクトの認識が進行

6. General remarks on adaptive perceptual vocabularies

6.1. 結果のまとめ

6.1.1. 本稿で示した実験的研究

知覚学習と概念学習の様々なタイプのインタラクションを確認

- 学習された概念が既存の次元 (大きさ・輝度) を感作
- 新規な次元 (顔) を感作
- 新規な次元の特定の領域 (ベジェ曲線) を感作
- 新規な知覚のボキャブラリーを生成 (Segmentation, Unitization)

6.1.2. 本稿の理論的貢献

知覚学習と概念学習のインタラクションに関するメカニズムを提案 ニューラルネットにおける 2 つのリンクの同時的な学習 (学習は系列的ではない. 知覚的特徴の学習に続くコンセプトの学習というプロセスではない)

6.2. Staking out the territory

6.2.1. 著者達の主張

知覚的ボキャブラリーは概念学習に応じて調整される

知覚的ボキャブラリー: オブジェクトを記述するための帰納的特徴の集合

選択的に注意を受けることが可能なオブジェクトのプロパティ

知覚的ボキャブラリーは物理量によって決定されない心理量

Fixed features アプローチでは知覚的ボキャブラリーがどのように獲得されるのかを検討してこなかった

6.2.2. 著者達のアプローチと Dynamical system 論者 (eg., Thelen & Smith, 1994) との区別

Dynamical system 論者の主張

- 経験と合致するオブジェクトのみ認識される
- オブジェクトを部分に分けて認知することはない
- オブジェクトを記述する要素表現は必要ない

著者達はオブジェクトは要素によって表現されると考える

要素が柔軟に作られるかどうか, Fixed set approach との違い

6.2.3. 状況の表象を要素に分解することの利点

命題表現 (述語-論理表現) による明示的な関係の表現, 高次の関係 (システム性) の表現

本稿のアプローチは命題の要素がいかに構成されるかを示したもの

命題の要素は複数の特徴をユニット化したものと捉えられる

6.2.4. 著者達のアプローチの利点

環境や経験による知覚的ボキャブラリーの変化を説明すること

- 同じ環境に住む人は同じようなプリミティブを学習するだろう
- 柔軟に構成されるプリミティブを仮定することの意義は環境や専門性の違いを説明すること

6.3. Constraints on computational models of perceptual and conceptual learning

6.3.1. 有りうる批判

柔軟な特徴を仮定すれば、計算量が爆発。固定された特徴でも組み合わせ爆発をおこす。画像から特徴が生成され、プール値に置きかえられるというメカニズムを仮定すると、カテゴリ学習など起きないと思われるが？

6.3.2. 著者達の一つの回答

2つの制約を考えることで探索空間を制限

心理物理学的制約 = ゲシュタルトの法則

- 近接性、閉塞性の制約が心理学的に妥当なセグメンテーションに不可欠
- 提案したモデルでは、同じ方向と位置を持った特徴のみを抽出
- 一度に熟考できる特徴の数にも制限をかけた

カテゴリカルな制約

- カテゴリユニットからのトップダウンな制約によって探索の幅を制限
- 提案したモデルではカテゴリ間を区別できる特徴を発達させるように方向付けた

2つの制約は並列的に設置するべきで、系列的に制約をかけるべきではない

- 系列的な制約: 精神物理学的制約の適用 カテゴリカルな制約の適用

系列的な制約が問題となる状況

- 分離したピクセルによって表現される特徴が診断において重要であった場合 精神物理学的制約に従わない 十分なトレーニングを受けることができない。
- 並列した制約として捉えれば、どちらか一方の制約に従わなくても、トレーニングが可能になる

6.4. Building perceptual vocabularies: A reprise

認知科学者は状況を表現する少数の特徴を発見するために知恵を絞ってきた

普通の人には研究者と同じくらい賢くて、自分自身の環境に即した特徴集合を調整できる

ここで提案したアプローチの利点は個人差、環境の差、熟達の差を説明できること

領域に特化したカテゴリ化の制約によって、知覚される特徴は変化

まとめると、概念学習は知覚される特徴によって影響を受けるし、知覚学習は概念によって影響を受ける

補足解説

信号検出理論 [認知科学辞典 繁樹 算男]

雑音の中から信号を検出する人間の感覚をモデル化したものであり、現在では、被験者が、知覚し、意思決定をするプロセスに広く応用されている。信号検出理論では、信号と雑音のおおのに確率分布を仮定し、信号ありかなしかという決定に2種類の誤りを想定することによって、知覚と意思決定のプロセスが、数理的にコンパクトに記述できる。

		実際	
		信号	ノイズ
観測者の反応	信号有り	Hit	False alarm (False positive)
	信号無し	Miss (見落とし)	Correct rejection

$d' = M_{sn} - M_n / \sigma_n$: SN 分布と N 分布の平均値の差を N 分布の標準偏差で割ったもの

ROC 曲線: 縦軸に hit 率, 横軸に False positive を取ったときの曲線。ROC 曲線下面積が広ければ、信号検出力が優れていることになる。

競合学習 [認知科学辞典 倉田 耕治]

神経回路モデルに用いられる学習法の一つ。1つの入力信号に対し、複数の神経細胞が競合し、1つだけが勝ち残って興奮する。従って入力信号の集合は各細胞の縄張り領域に分割される。これを勝者テイクオール (winner-take-all) 型競合と呼ぶ。勝ち残った細胞にヘブ学習などの教師なし学習をさせるのが競合学習である。ある入力を学習した細胞は、それに類似した入力が再び与えられたとき、より勝ち残りやすくなる。学習則によっては細胞の勝率を平均化する仕組みが必要。いろいろな特性の細胞を育てる効果があり、自己組織化マップとの関係が深い。

自己組織化マップ [認知科学辞典 倉田 耕治]

頭文字をとって SOM (self-organizing map) ともいう。現在、この言葉は Kohonen, T.の提案したモデルを指す。細胞層に入力が与えられると、競合に勝ち残った細胞と、その近傍の細胞が同時に学習する。これは競合学習の改良版である。ランダムに選んだ入力によって学習を繰り返すと、入力情報の類似関係が、入力に対応する勝者の、細胞層上での遠近関係に反映するようになる。自己組織化マップは、大脳皮質の特徴マップのモデルとして提案され研究されてきたが、クラスタ分類やノンパラメトリック回帰分析のための応用も多い。