

## 「順序例からの学習」の提案

### Learning from Order Examples; LOE)

#### 順序を対象とした学習問題

- ・ 順序：何かの基準の順に整列したもの

例：a, b, c の順に好きである  $a \succ b \succ c$

bよりaが好きだが、どれくらい好きかは分からない

- ・ 順序付けされたアイテム集合が訓練事例
- 未整列アイテム集合の順序を推定する規則の学習
- ・ この学習タスクの解法を幾つか示し，人工データへの適用実験により，各解法の特徴を解析

# 順序を用いることの利点

例：ものの嗜好に関する調査

SD(Semantic Differential)法：一般的な方法

被験者に「好き」から「嫌い」までを、例えば5段階で評価してもらう方法

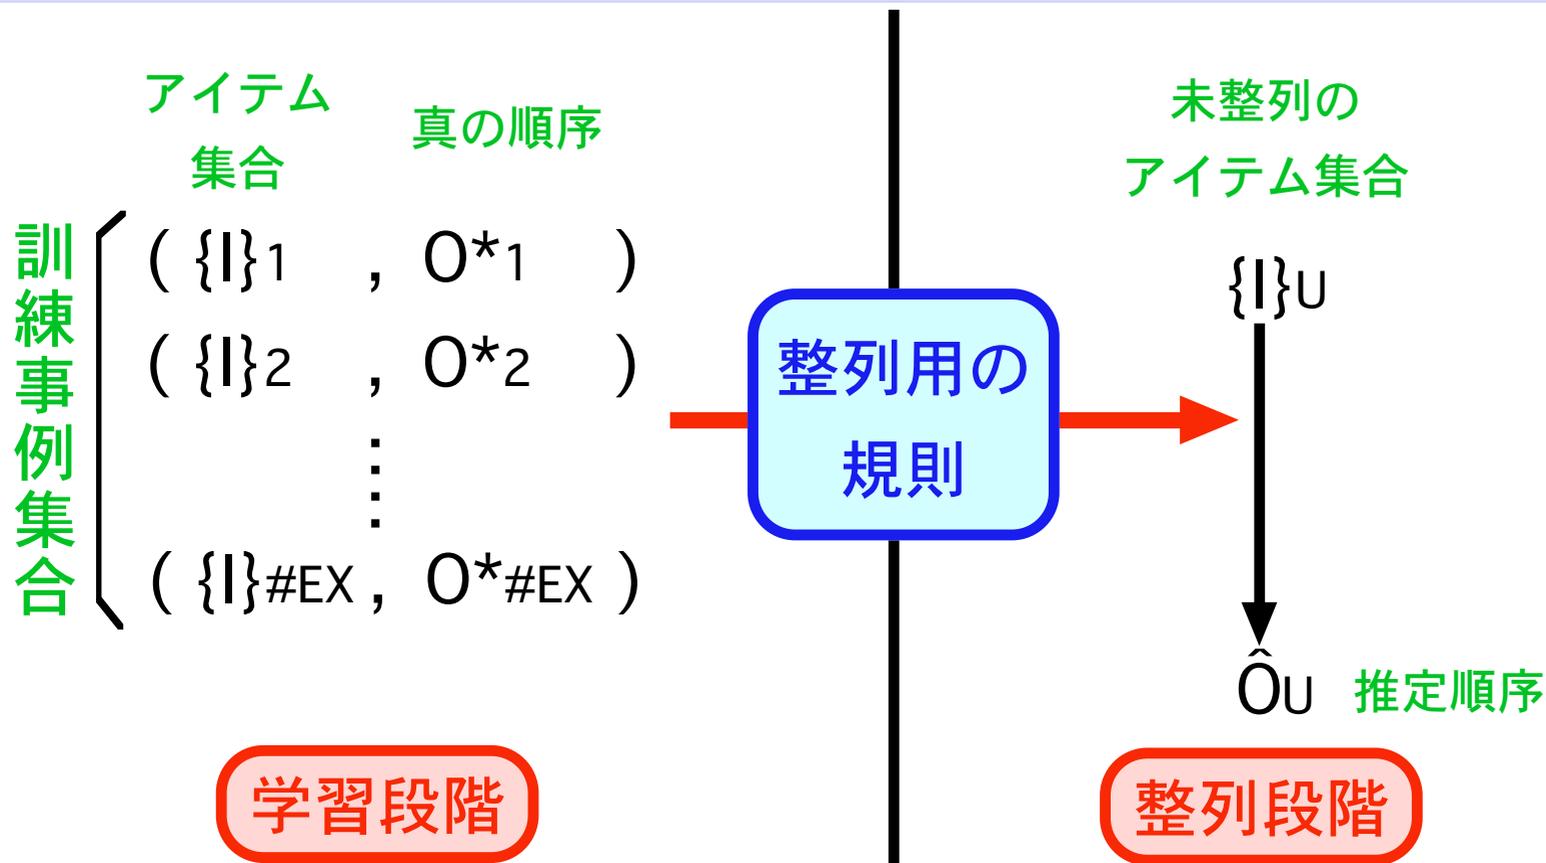
- ・3と4のどちらが適切か、被験者が迷う

順位法

被験者に「好き」な方から順にアイテムを並べてもらう方法

- ・絶対的な評価が困難な場合でも、相対的評価なら可能なことも

# 順序例からの学習



各アイテムは属性ベクトルで記述

➡ 訓練事例にないアイテムも整列可能

# 順序例からの学習の仮定と順位相関係数

仮定：真の順序(学習事例中の順序) =

絶対順序(一般的な部分) + ノイズ(個性の部分)

絶対順序：アイテムの全集合にある全順序

※ アイテムの全集合は学習事例中に現れないアイテムも含む

絶対順序に対するエラーが小さくなるような推定順序を求める

スピアマンの順位相関係数(RCI)：順序エラー尺度

二つの順序の間の、全体的な類似性を示す

0なら無関係，1なら一致，-1なら逆順

- ◇ [流郷01] [佐藤 95] 比較やマッチングに順位相関係数を利用. 順序の予測はしない
- ◇ [Cohen 99]
  - ・ 前提 : アイテムの集合が与えられる
  - ・ 教師信号 : 二つのアイテムのどちらが前にあるかの関係を示した情報
  - ・ 出力 : 教師信号で示された, 二つのアイテム間の関係情報を, できるだけ保存した順序

# [Cohen 99]の研究との相違点

## ◇ エラーの評価

関数  $\text{PREF}(I^x, I^y)$  : 2アイテム間の順序関係の  
確信度

Cohenらは、関数  $\text{PREF}$  のエラーについては議論しているが、最終的な順序のエラーについては議論していない

- ・ 関数  $\text{PREF}$ のエラーをいくら小さくしても、  
順序が正しくなるかは保証されない
- ・ 教師信号が2個のアイテムの関係だけなので、  
順序全体の評価は本質的に不可能

# 手法SC: クラス分類手法を用いた解法1

SumClass(SC)法 : Cohenの問題に変換して解く

- ・ **学習段階** : 学習事例中の順序  $O_i$  を, アイテム対の順序関係に分解
- ・ 分解した順序関係から関数 PREF を推定
- ・ **整列段階** : 次式を最大にする順序の獲得が目標

$$\sum_{x,y:I^x \succ I^y} \text{PREF}(I^x, I^y)$$

- ・ PREF の和に基づき, 一番前にあるアイテムを推定し, それを一つずつ取り出して順序に追加

# 手法PC: クラス分類手法を用いた解法2

## ProdotClass(PC)法 : SC法の派生手法

- ・関数 PREF の総和ではなく、次式を最大にする順序の獲得が目標

$$\prod_{x,y:I^x \succ I^y} \text{PREF}(I^x, I^y)$$

- ・Cohenが用いた総和は完全なヒューリスティックス
- ・この関数 PREF の積は、二つのアイテムの順序関係が独立とした場合の尤度

# 手法R: 回帰分析手法を用いた解法

## Regression(R)法：回帰分析を用いた手法

- ・ **学習段階**：学習事例中のアイテムを，真の順序となるべく矛盾しないような全順序に整列
- ・ アイテムの属性から，この全順序中の順位を推定する関数  $f(A(I^x))$  を回帰分析で求める
- ・ **整列段階**：関数  $f(A(I^x))$  の値に従って，アイテムを整列

# 実験手法

- ・ アイテムの全集合 = 9種

属性値数 = 3, 5, 7      属性数 = 3, 4, 5

- ・ 絶対順序と全集合の対 = 90種

各アイテム全集合に10種類の絶対順序を，ランダムに重みを決めた線形関数に従い決定

- ・ 事例集合 810種

アイテム集合の大きさ = 3, 5, 10

事例数 = 10, 30, 50

※ 予稿では属性値数=7の場合を含まないので，以後の実験の数値は予稿と異なる

# ノイズのない場合の実験結果

ノイズのない場合：絶対順序と真の順序は無矛盾

- ・絶対順序と推定順序の間のRCIの平均
- ・アイテム集合の大きさごとにまとめた結果と全体の結果

	全体	3	5	10
SC法	0.808	0.667	0.825	0.932
PC法	0.808	0.667	0.825	0.932
R法	0.802	0.617	0.837	0.950

- ・アイテム集合の大きさが大きいほど結果は精度が向上
- ・大きさ10では、危険率1%でも有意な相関が平均的に観測される

# 三種類の手法の比較

## 3手法の比較：RCIの差を対応のあるt検定で調査

	全体	3	5	10
SC—PC	- 0.1472	- 0.2709	+0.3806	- 1.5912
SC—R	+1.4430 > t0.90	+4.4143 > t0.99	- 2.2272 < t0.03	- 8.5784 < t0.01
PC—R	+1.4626 > t0.90	+4.4254 > t0.99	- 2.3547 < t0.01	- 8.5023 < t0.01

黒字=差なし 青字=前者優位 赤字=後者優位

>t0.99は99-パーセントイル以上， <t0.01は1-パーセントイル以下

- ・ 手法SCとPCには差がない
- ・ 手法Rは，アイテム集合の大きさが小さいときは他の手法に劣るが，大きくなると逆に優位になる

# ノイズがある場合

## 隣接したアイテムが入れ替わるノイズ

- ・ 3手法とも，10%の対が入れ替わった場合，RCIの低下は3%程度
- ・ ノイズの影響は，どの手法も差はない

## 属性値が変化するノイズ

- ・ 3手法とも，属性の値が10%で変化した場合，RCIの低下は4～5%程度
- ・ ノイズのレベルが低い場合に，他の手法と比べて，R法は性能の低下が若干小さい

# SC法とPC法での最適解との比較

評価関数を最大にする順序を欲張り法で探索

➡ 最適解に対する性能低下の度合いは？

〈最適解のRCI〉 - 〈欲張り法のRCI〉 の  $t$ -値

SC法: - 2.7915      PC法: - 2.9306

順序のRCIは、評価関数を最適にする手法の方が、危険率1%でも有意に低い、すなわち、精度が劣る

違う！ { アイテム対の順序関係を保存する順序  
全体として、よく整列された順序

➡ Cohenの研究とLOEの差が明確に

# 計算量に関する考察

## 学習段階

- ・ SC法とPC法 :  $O(\sum_i^{\#EX} (\# I_i)^2)$
- ・ R法 :  $O((\# I_C)^3)$

SC法やPC法の方が高速

## 整列段階

- ・ SC法とPC法 :  $O((\# I_U)^3)$
- ・ R法 :  $O(\# I_U \log(\# I_U))$

R法の方が高速

# まとめと今後の予定

## まとめ

- ・新しい学習問題「順序例からの学習」を提案
- ・3種類の解法を提案し，人工データに適用
- ・3手法とも適切な順序を推定することが可能
- ・アイテム数が少ない場合はSC・PC法が有利，多い場合はR法が有利
- ・ノイズの影響は，手法間であまり差がなかった

## 今後の予定

- ・間接的ではなく，RCIを直接的に最小化する順序を推定する規則の学習方法の開発