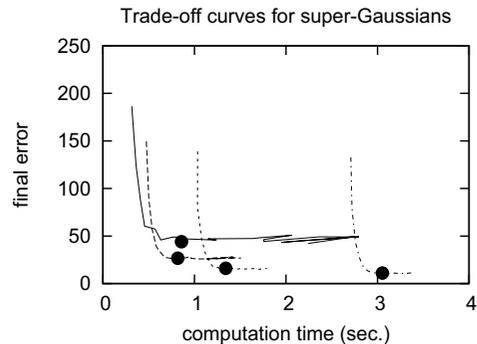


D-1: 高次統計量推定における 誤差分布を利用した独立成分分析

松田 源立 (青山学院大学)

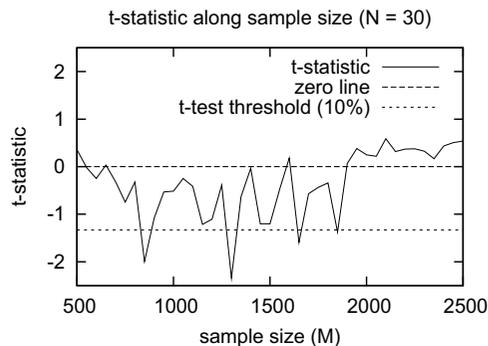
- 独立成分分析 (ICA) の解法である Joint Approximate Diagonalization (JAD) の改良
- $C_{pq} = (\kappa_{ijpq})$: 4 次統計量行列
JAD: $AC_{pq}A'$ を対角化する A を推定
- 提案手法: 高次統計量 κ_{ijpq} 推定時の誤差分布を理論的に評価し JAD を改良

1. 情報量基準による収束条件の最適化 [1]



最適な時点での打ち切り

2. 尤度に基づくロバストな目的関数 [2]



統計的に有意な精度向上

[1]. Y. Matsuda, K. Yamaguchi, Neurocomputing, vol. 74, pp. 1994-2001, 2011.

[2]. Y. Matsuda, K. Yamaguchi, LNCS 7553, pp. 205-212, Springer-Verlag, 2012.

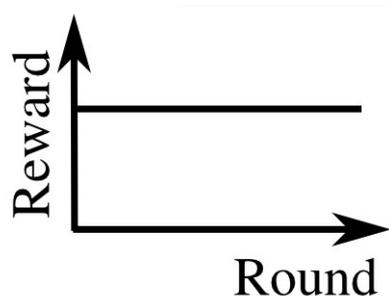
D-2 バンディット問題の非定常状態への拡張

小宮山純平, 佐藤一誠, 中川裕志 (東京大学)

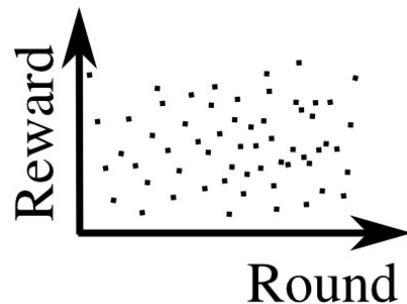
バンディット問題:

- ・ 毎ラウンド、複数のオプションの中から最も良いものを探す問題 (最善のオプションとの差 = Regret の最小化問題)
- ・ オプションの報酬は確率的
- ・ 選んだオプションの情報しか得られない (部分フィードバック)
- ・ ニュースのカテゴリ選択、広告推薦などのモデル

従来モデルとの比較:



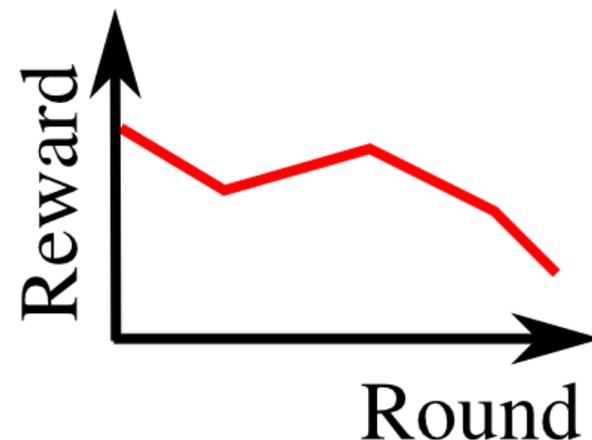
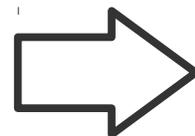
確率分布が定常 (Stochastic)



分布仮定なし (Adversarial)

従来のモデル

より
現実的な
モデル



Drift 速度 d の範囲で、
確率分布が移動する

今回の提案モデル

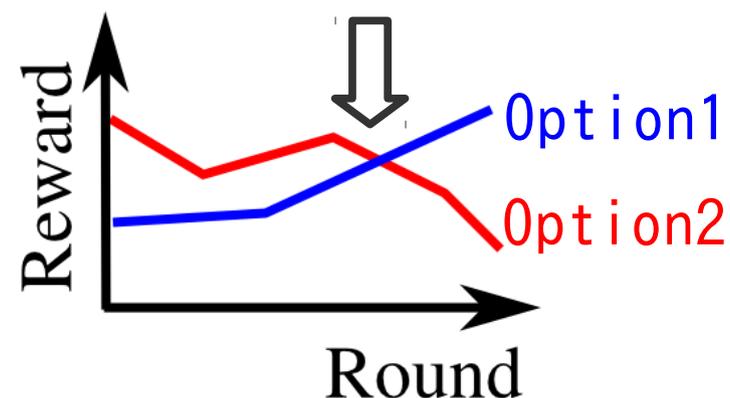
D-2 バンディット問題の非定常状態への拡張

非定常のバンディット問題は難しい

確率ノイズ+最適オプションの
交代+部分フィードバック

→ **トレードオフ問題を解決
するアルゴリズム**

最適オプションの交代



提案アルゴリズム (DSW-UCB)

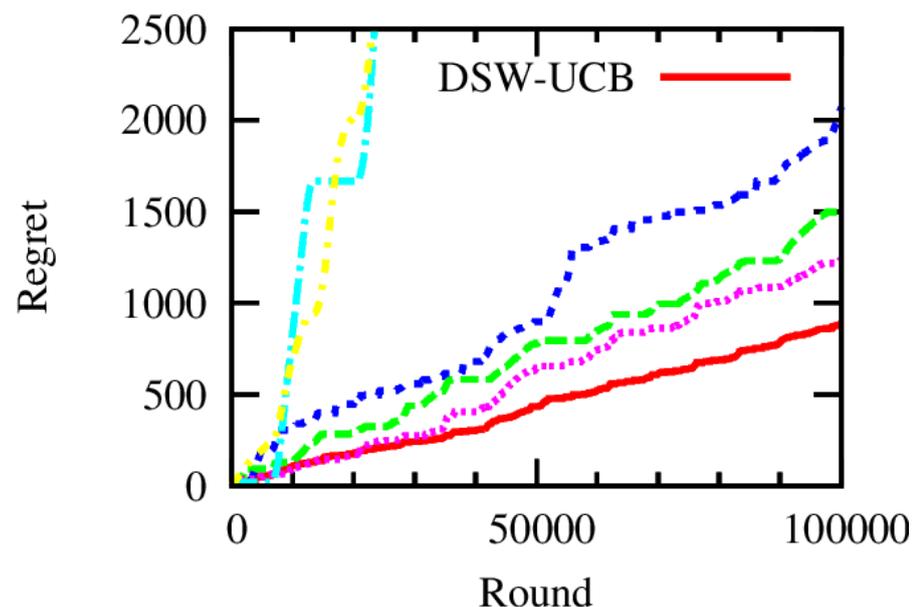
Sliding Window (古いデータ忘却)
+ Drift 項の追加 (速度を考慮)

$$B_{i,t} \stackrel{\text{def}}{=} \hat{X}_i^w(t) + \sqrt{\frac{\log \delta^{-1}}{2T_i^w(t)}} + d(t - \tau_i^w(t))$$

- Regret の上限を導出

$$R_n \leq O(\ln n)$$

実験 (従来手法と比較)

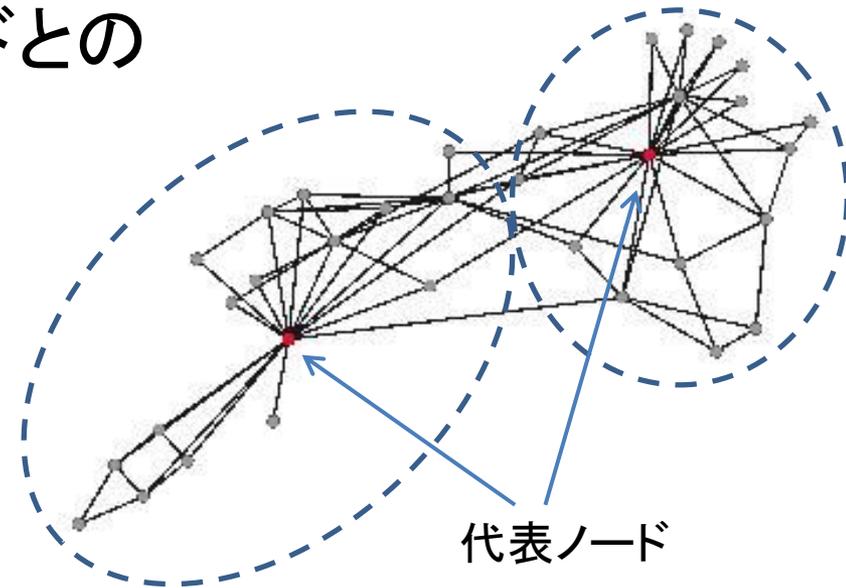


D-3

凸最適化を用いた ネットワーククラスタリング

荒野 俊平, 鹿島久嗣(東京大学)

- 目的: ネットワーク中のコミュニティ構造を見つける
- 定式化:
 - コミュニティ内の代表ノードとの非類似度を最小化
 - 凸計画になるように緩和
- 利点:
 - 局所解がない
 - 代表ノードを発見できる
 - 有向グラフにも適用可能



D-3

凸最適化を用いた ネットワーククラスタリング

荒野 俊平, 鹿島久嗣(東京大学)

- 凸最適化問題としての定式化:
 - 各コミュニティ = 1つの代表ノードとそれに帰属するノード集合
 - 所属に要する非類似度 d_{ij} の和を最小化
 - 代表ノードの数を抑えるグループ正則化項

$$\left\{ \begin{array}{l} \min \sum_{i,j} a_{ij} d_{ij} + c \sum_j \| \mathbf{a}_j \|_0 \\ \text{s.t. } a_{ij} = \begin{cases} 1 & (i \text{ が } j \text{ に所属}) \\ 0 & (\text{otherwise}) \end{cases} \end{array} \right. \xrightarrow{\text{緩和}} \left\{ \begin{array}{l} \min \sum_{i,j} a_{ij} d_{ij} + c \sum_j \| \mathbf{a}_j \|_2 \\ \text{s.t. } a_{ij} \geq 0 \\ \sum_j a_{ij} = 1 \end{array} \right.$$

D-4: エピソード時系列データ分析のための 強化学習ツール RLearn

麻生英樹, 城真範, 神嶋敏弘, 赤穂昭太郎 (産総研), 興梠貴英 (東大)
製作協力 (株) 数理システム

◆ R の強化学習パッケージを作りました

◆ できること

✓ MDP上の強化学習

- 状態空間：離散多次元
- 報酬値：連続多次元

✓ オンライン強化学習

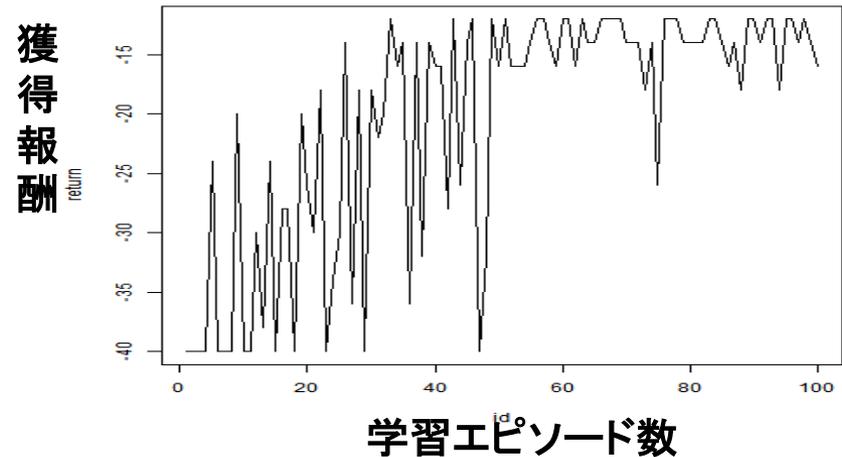
✓ オフライン強化学習

(エピソードデータからの MDPモデルや方策の推定)

✓ 方策最適化 (DP解, Actor-Critic, Q学習など)

✓ 方策シミュレーション

✓ 結果の可視化 (報酬分布, 学習曲線, 方策など)

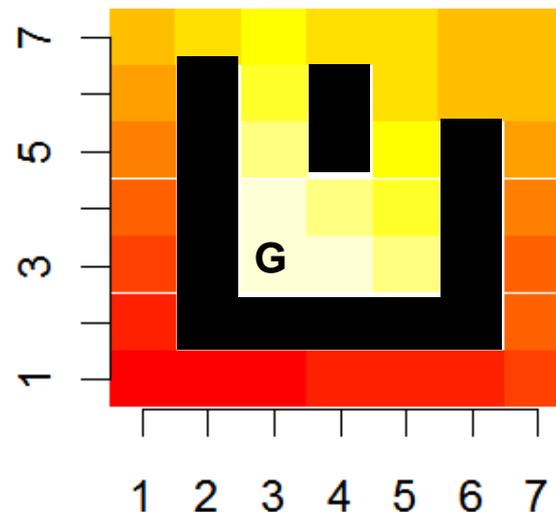


◆ 利用例

- > `MDPenv=estimate.mdp(MDPepi)` #エピソードから MDP環境を推定
- > `MDPpol=estimate.policy(MDPepi)` #エピソードから行動方を推定
- > `summary(MDPenv)` #MDP環境の統計的サマリを出力
- > `barplot(MDPenv)` #MDP環境の遷移確率などの棒グラフ表示
- > `MDPvalue=mdp.evaluate(MDPenv, MDPpol, method="policy-evaluation", gamma=0.9, maxiteration=100, delta=0.01)` #価値関数などの計算
- > `MDPresult=mdp.learn(MDPenv, method="on-q", numepisodes=100, episodelength=40, alpha=0.5, gamma=0.9, policy.method="greedy", eps=0.1)` #推定したMDP環境でのオンラインQ学習の実行
- > `image(MDPresult, x.index="state1", y.index="state2", image.type="value")` #学習した行動方策, 状態価値関数, 行動価値関数のヒートマップ表示

◆ 今後の拡張予定

- ✓ POMDP対応
- ✓ 逆強化学習, 徒弟学習



2次元迷路の
状態価値表示

D-5: 情報理論に基づく超解像可能条件

九州大学 川喜田 雅則, 山口 耕太郎, 高橋 規一, 竹内 純一

背景と動機

超解像を理論的に解析している研究はほとんどない。我々は「超解像が通信路符号化の問題としての構造が似ている」という事実を用いて超解像の理論的境界を探る。

シングルフレーム超解像

一枚の低解像度画像から一枚の高解像度画像を復元する問題



図 1: 入力画像

図 2: 復元画像

研究内容

超解像と通信路符号化

問題の対応

超解像問題

通信路符号化

アルゴリズムの対応

Yang の超解像

スパース重ね合わせ符号

成果 ある統計モデルのもとで

- 超解像の通信路容量 C と伝送レート R を導出した
- 通信路符号化定理より超解像可能条件 $R < C$ を導出した
- Yang の超解像がこの限界を達成するか数値実験により調査した。結果は**否定的**であり、より良いアルゴリズムの存在が示唆された。

D-6 ワーカーのグループ構造を取り入れたクラウドソーシングを用いた教師付き学習

梶野 洸 (東大), 坪井 祐太 (IBM東京基礎研), 鹿島 久嗣 (東大)

- クラウドソーシングを用いた教師データ作成

不特定多数の人に仕事を依頼できるシステム

 安価に教師データ作成可能

 データの質がワーカーの能力に依存

 ワーカーの能力を考慮した学習手法が必要

- 既存手法の問題点

 ワーカーの独立性の仮定

実データではワーカーのグループ構造が指摘されている

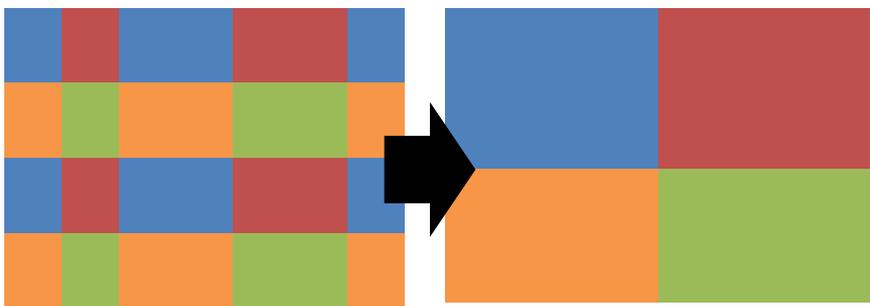
- 提案手法

- ワーカーのグループ構造の推定と学習を同時に実現
- 凸最適化問題として定式化

テーマ

関係データのクラスタ数推定問題

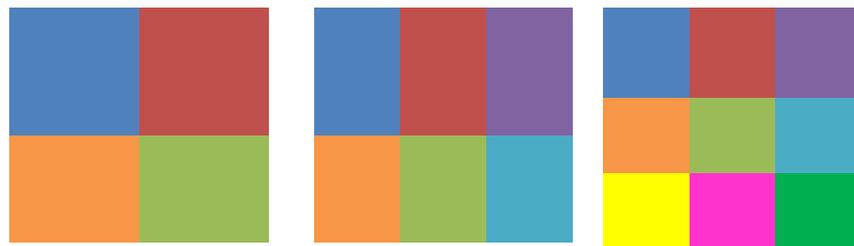
関係データ・クラスタリング



行・列の並べ替えによりパターン抽出
=オブジェクト・関係のクラスタリング

クラスタ数推定問題

Q. どの構造が最適か？



既存手法: IRM [Kemp+ 06] など

提案

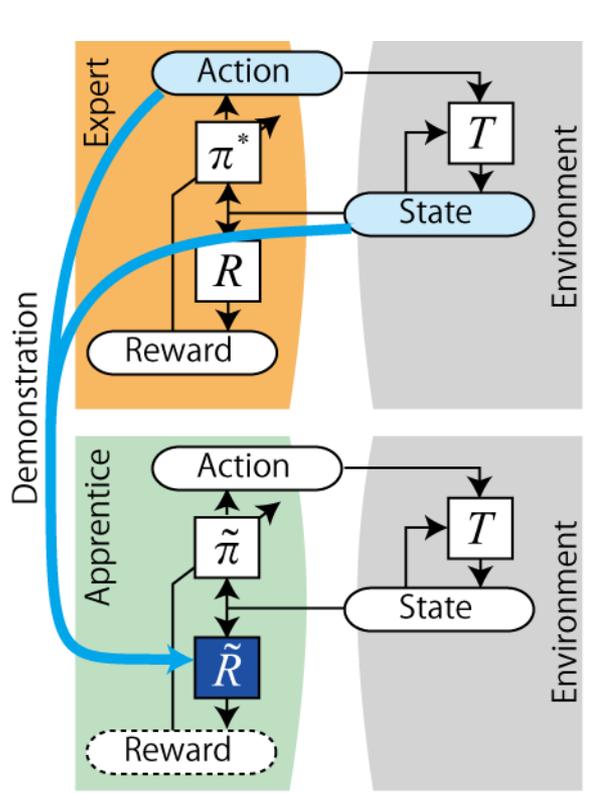
情報論的アプローチ: 正規化最尤符号長に基づくモデル選択

- Latent Stochastic Blockmodels [Snijders & Nowicki 97]に対する正規化最尤符号長の導出
 - 尤度関数さえ与えられれば計算可能 = 事前の知識が不要
 - ただし計算コストが大きい
- Factorized NML 符号長 [Roos+ 08] の応用による効率的な計算
 - データを「潜在変数 → 観測変数」の順に多段的に符号化
 - オブジェクト数に対して線形時間で計算可能

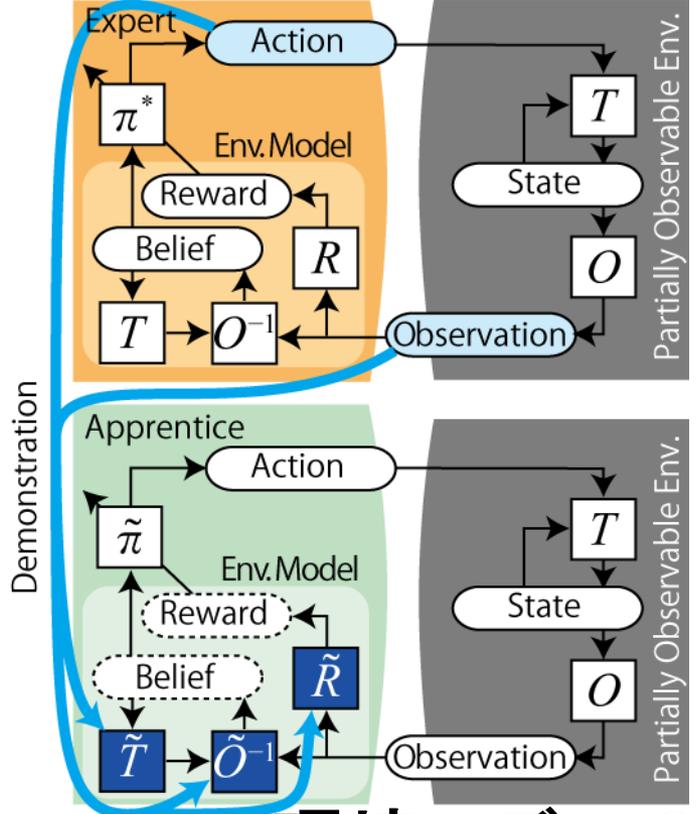
D-8 POMDP ポリシーの高速再計算法と勾配計算法

牧野貴樹, 小田也寸志, 合原一幸(東京大学)

□ やりたいこと: 環境モデル徒弟学習の高速化



逆強化学習 (Abbeel+, 2004)
(報酬関数の徒弟学習)



POMDP 環境モデルの
徒弟学習 (Makino+, 2012)

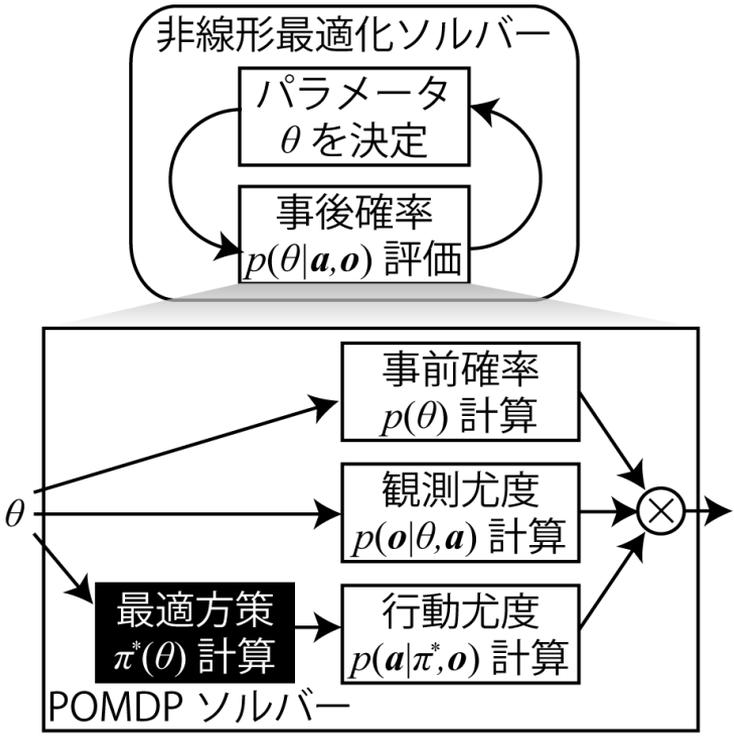
D-8 POMDP ポリシーの高速再計算法と勾配計算法

牧野貴樹, 小田也寸志, 合原一幸(東京大学)

- 現状では、計算時間がかかるため、非常に小規模な対象にしか対応できない → 実用化に障害
- 計算がもっとも遅い部分はPOMDPソルバー

→ 高速化する手法を検討

- 環境パラメータ θ が小さく変化した場合に、前回の解を利用して高速に解を求める方法
- 尤度値の θ 勾配を計算することで、最適化ソルバの関数評価回数を削減する方法



D-9 : 大規模問題のためのオンライン転移学習

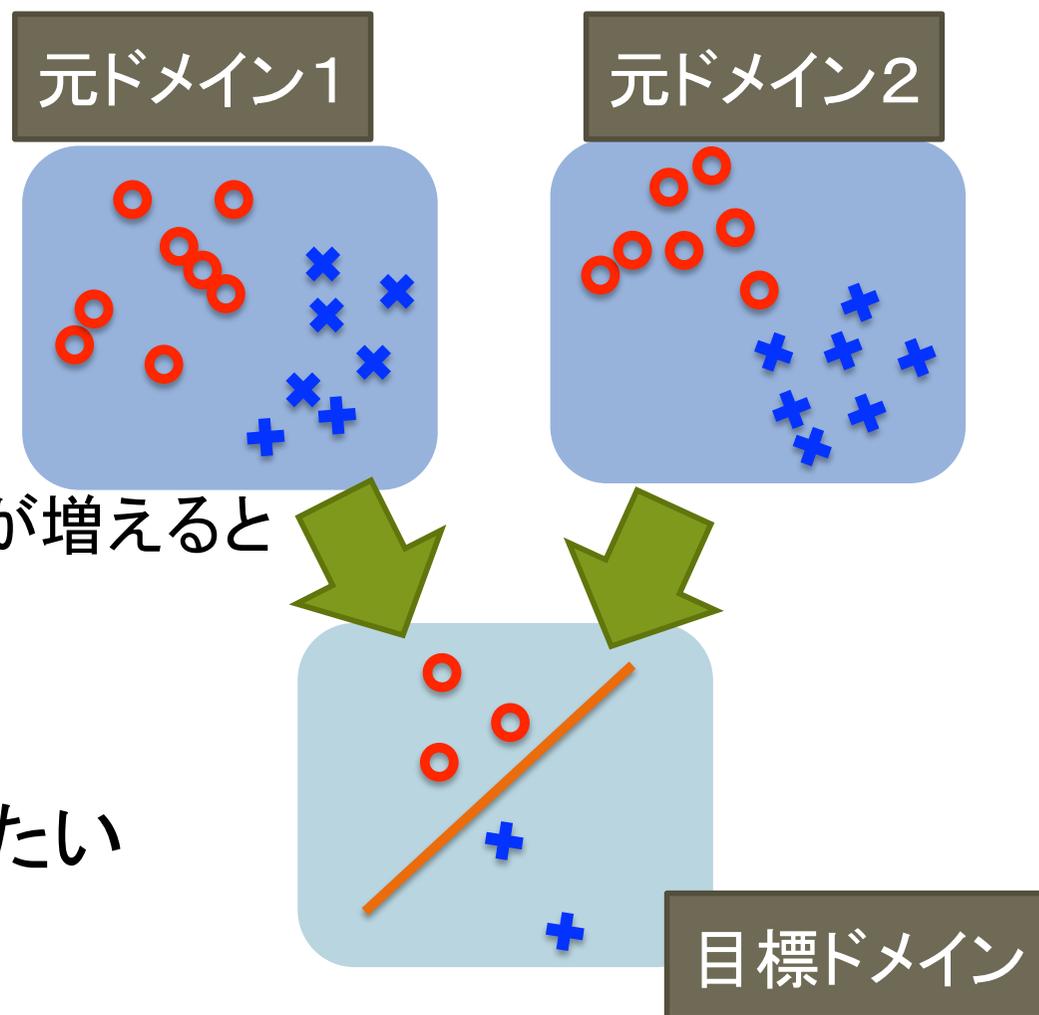
○成田敦博・佐藤一誠・中川裕志(東京大)

- 元タスクのデータをすべて使って目標タスクを学習する

— **重い**

- ドメインの数/データの数が増えると困る

- オンラインで転移学習したい
 - コールドスタート問題



- 元ドメインのデータを使わない転移学習(軽い)

- 各ドメインでの予測関数のみ利用

元ドメイン f_{S_i} for $i = 1 \dots N$

目標ドメイン f_T

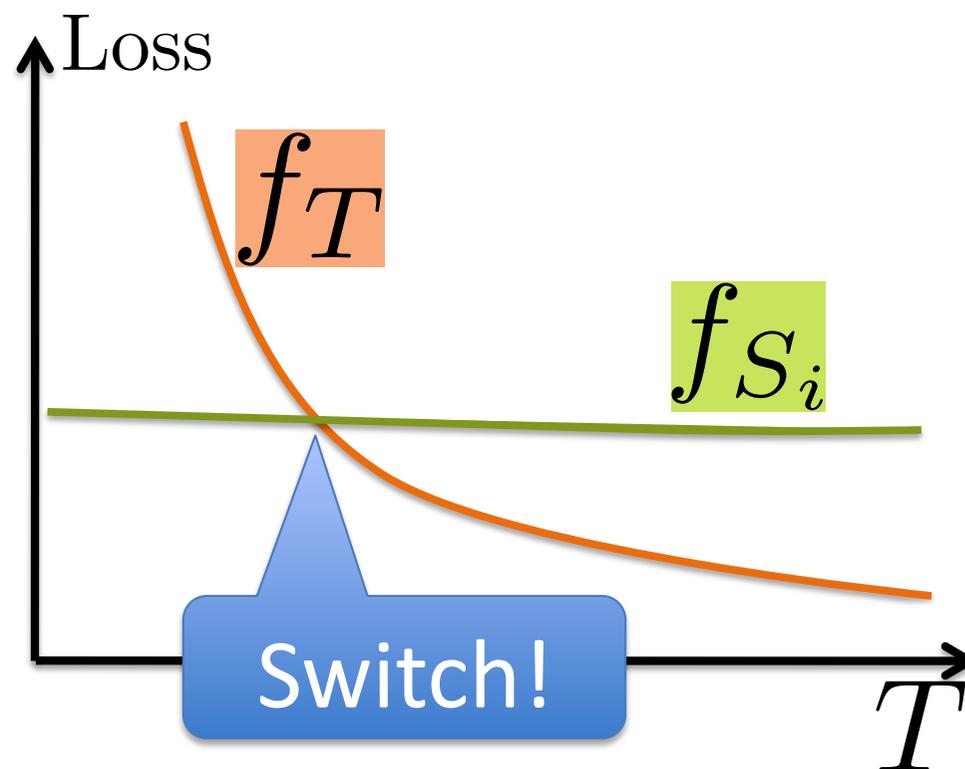
- f_T をオンライン学習しながら
予測関数を組み合わせる

- コンセプトドリフト
を応用

- 従来手法よりも精度向上

- 小さいRegret、小さい汎化誤差

- 「負の転移」をおこさない



転移学習しても
絶対損をしない

マルコフ決定過程での統計的推測のための 混合時間正則化

森村哲郎 (IBM)*, 恐神貴行 (IBM), 白井朋之 (九州大学)

*tetsuro@jp.ibm.com

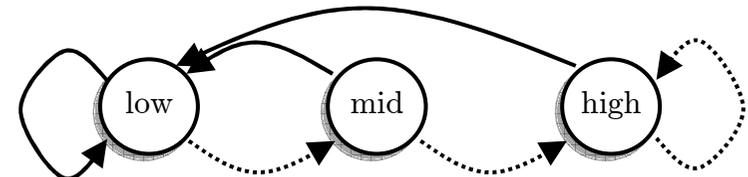
概要

- 混合時間とマルコフ決定過程での推定量の偏り・分散の関係性を解析
⇒ 混合時間が大きいほど、推定が難しくなる
- 混合時間を抑えた強化学習法 (混合時間正則化) を提案

背景

■ マルコフ決定過程 (MDP)

- ✓ 逐次的な意思決定問題の定式化に用いられる標準的なモデル
- 😊 近年、ビジネスプロセス最適化や自然言語処理などの実問題への応用が盛ん
- 😞 多くの場合、システムが未知のため、方策の学習に膨大な時間がかかる



■ Cesaro混合時間

- ✓ システムが定常分布に近づくのにかかる時間

$$m_{\theta}(\varepsilon) \triangleq \min_{t \in \mathbb{N}_0} \left\{ t \mid \max_{s_0 \in \mathcal{S}} \| \mathbf{v}_{\theta}(s_0, t) - \boldsymbol{\pi}_{\theta} \|_1 \leq 2\varepsilon \right\}$$

θ : MDPのパラメータ

各要素は、初期状態 s_0 の時、各状態にいる確率の時刻 $[0, t-1]$ における平均値

定常分布ベクトル

マルコフ決定過程での統計的推測のための 混合時間正則化

森村哲郎 (IBM)*, 恐神貴行 (IBM), 白井朋之 (九州大学)

*tetsuro@jp.  .com

➤ 理論解析

- Cesaro混合時間は、MDPでの推定量の偏りや分散を抑えるのに必要な反復回数 t の上限になる

⇒ 混合時間が大きいほど厄介

$$\left\{ \begin{array}{l} m_{\theta}(\varepsilon) \geq \min_{t \in \mathbb{N}_0} \{t \mid \text{bias}_{\theta}(t) \leq 2C\varepsilon\} \\ m_{\theta}(\varepsilon) \geq \min_{t \in \mathbb{N}_0} \{t \mid \text{Var}_{\theta}(t) \leq 4C^2\varepsilon^2\} \end{array} \right.$$

➤ 提案手法 (混合時間正則化)

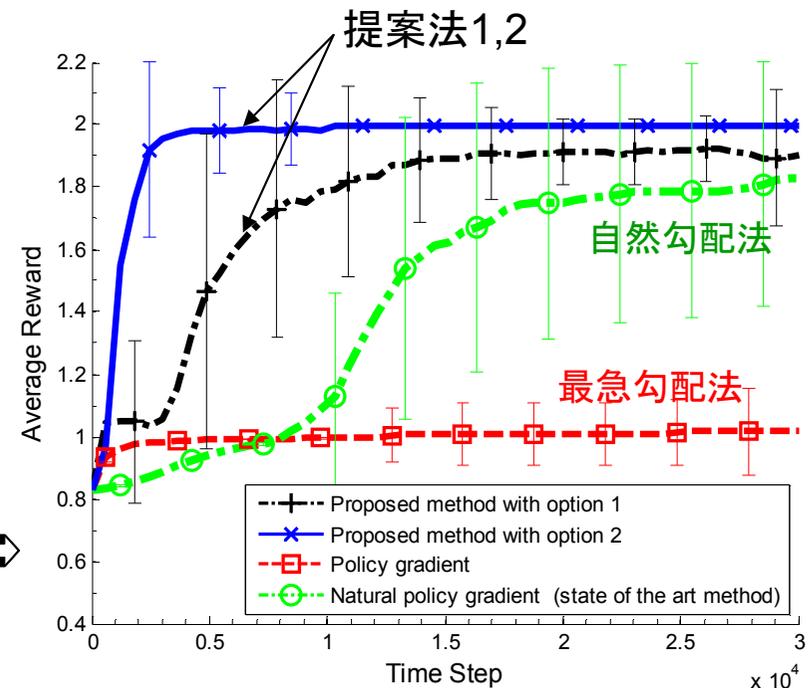
- Cesaro混合時間の上限 h を正則化する勾配法に基づく方策最適化法

✓ θ は方策パラメータ

$$\max_{\theta \in \mathbb{R}^d} : E[r|\theta] - \lambda h(\theta)$$

➤ 数値実験

- 強化学習のベンチマーク課題で検証 ⇒



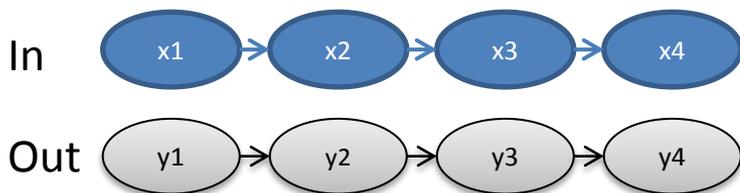
D-11 クラウドソーシングを用いた 系列ラベリング学習

村下 瑛（東京大学）， 坪井 祐太（日本IBM）， 鹿島 久嗣（東京大学）

非専門家による不正確な教師データからの系列ラベリング学習法を提案

■ 系列ラベリング問題

- 入力系列⇒出力系列のマッピング



- 系列データ解析の基本的なタスク

- 例： 固有表現抽出
文章から人や組織の名前を抽出

出力	○	○	○	B	I	I	I	○	○	○	○	
入力	今	年	の	西	東	京	市	は	暑	い	で	す

- 実用上の課題：

教師データの作成にコストがかかる

■ クラウドソーシングの利用

- インターネットを経由した不特定多数へのタスク発注

○ 高速に大量のデータを安価に入手可

× 品質が大きくばらつく

○ データ作成者（ラベラー）をIDで識別できる

エコノミストのAPPLE分析記事



正解



エコノミストを一般名詞と
思っている



ずるしている
(スパマー)

- 教師データ作成者の特性を考慮した学習方法が課題

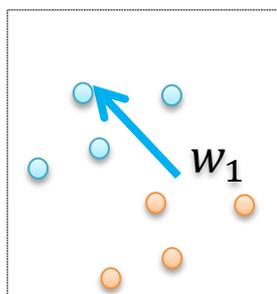
D-11 クラウドソーシングを用いた 系列ラベリング学習

村下 瑛（東京大学），坪井 祐太（日本IBM），鹿島 久嗣（東京大学）

非専門家による不正確な教師データからの系列ラベリング学習法を提案

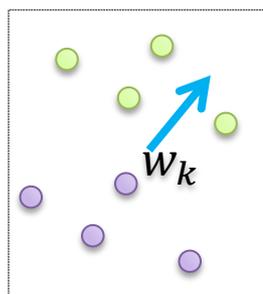
■ 提案モデル：識別器統合モデル [Kajino+, AACL 2012] の系列ラベリング問題への拡張

- ラベラーの一人一人が別々の系列ラベリングモデル（CRF）に従って正解ラベルを生成すると仮定
- 各々のモデルは、真のモデルを中心に分布すると仮定

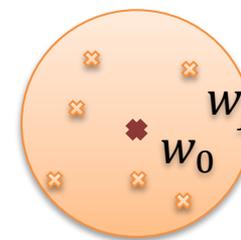
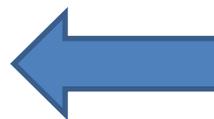


ラベラー1のモデル

...



ラベラーkのモデル



各ラベラーのモデルの事前分布

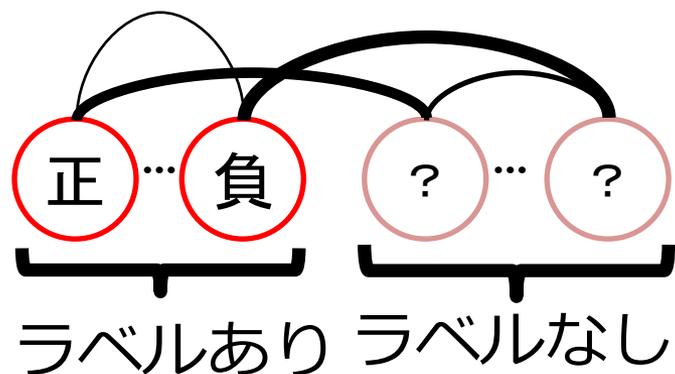
- 結果：ラベラーの個性を考慮しないモデルと比較して高精度

グラフ上のラベル伝搬法による 半教師あり学習・能動学習の大規模化

[江原遥](#), 佐藤一誠, 大岩秀和, 中川裕志 (東京大学)

ラベル伝搬法 :

重み付きグラフ (隣接行列 W) 上の少数のノードにラベルを与え, ラベルをエッジの重みに従って周囲のノードに分散させることにより, ラベルなしノードのラベルを判別する, 半教師あり (弱教師あり) ノード分類手法の一種.



主な手法 :

- [Gaussian Random Field \(GRF\)](#) [Zhu+, ICML 2003]
- [Learning with Local and Global Consistency \(LLGC\)](#) [Zhou+, NIPS 2004]

主な応用先 :

- 情報検索, 情報抽出, 類似画像検索, 自然言語処理の様々なタスク (語義曖昧性解消など), etc...

グラフ上の能動学習：

グラフ上のノードの集合から，ラベル伝搬法でラベル付けすると判別に有用と思われるラベルなしノードを l 個選ぶタスク。

従来研究：

GRFとLLGC，それぞれを用いた時の誤差を利用して能動学習を実現する手法が，今年，相次いで提案されている。（誤差の種類は両論文で異なる）

GRF: [\[Ji and Han, AISTATS 2012\]](#)

LLGC: [\[Gu and Han, ICDM 2012 short \(to appear\)\]](#)

問題点：

両手法とも， W から作るラプラシアン行列の固有値分解が必要．ノード数を n として，空間計算量 $O(n^2)$ ，時間計算量 $O(n^3)$ ．ノード数が大規模な時に実行困難．情報抽出をはじめ，応用先には大規模化へのニーズがある．

提案手法：

疎なノード（データ）-特徴行列 X を用いて， $W=(D^{-1/2}X)(D^{-1/2}X)^T$ とかけるグラフに限定（ $D=\text{diag}(XX^T\mathbf{1})$ ）． $D^{-1/2}X$ に乱択化特異値分解[\[Halko+, arXiv 2010\]](#)，[\[岡野原, NLP2011\]](#)を適用し，ラプラシアン行列を低ランク近似することによって大規模化の実現を目指す．

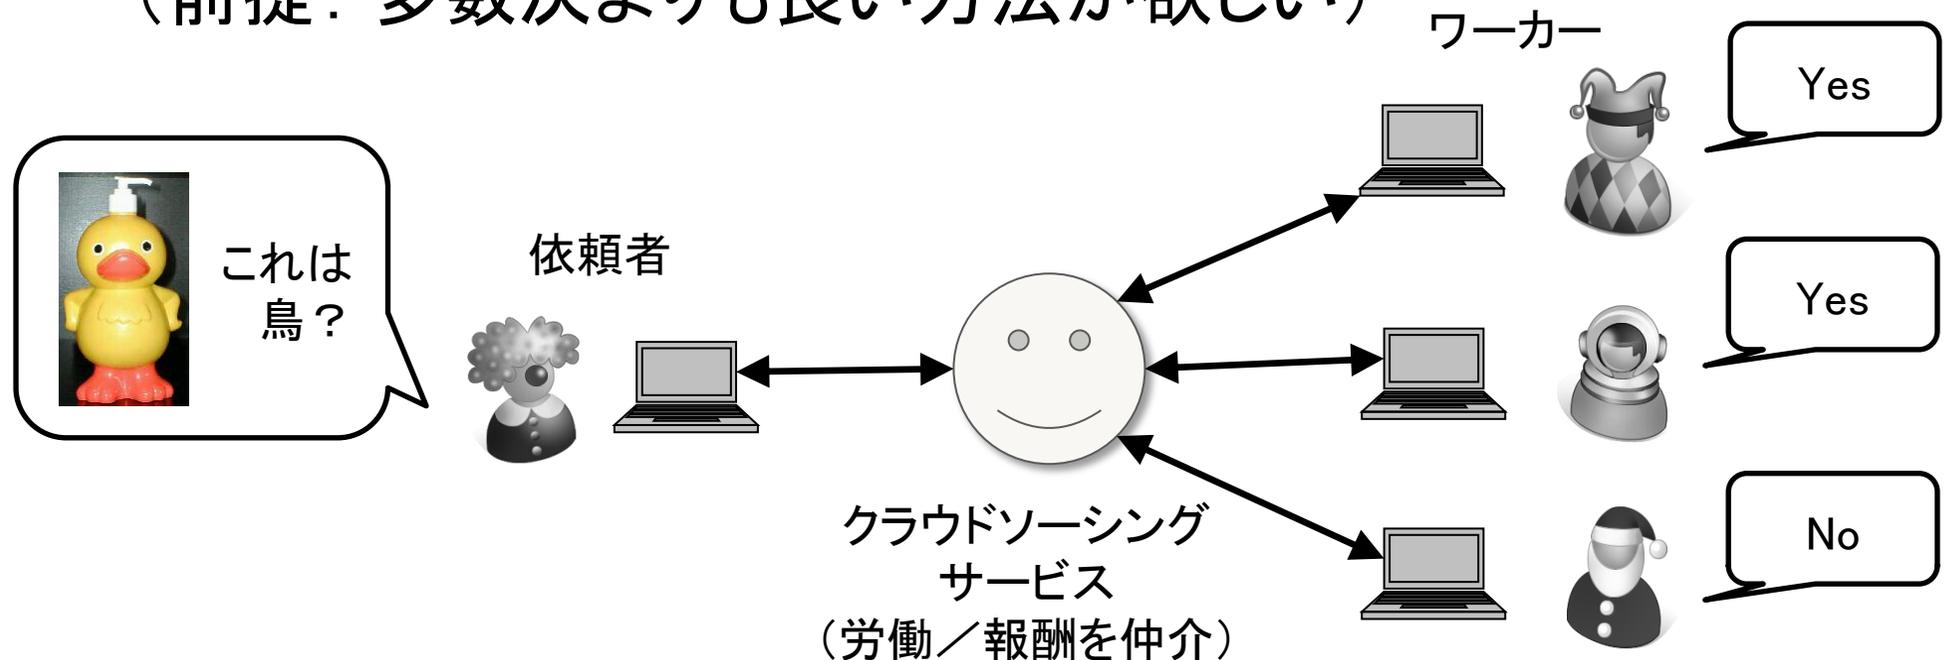
評価：

数値実験を予定．理論的評価は今後の課題．

ワーカーの確信度を用いた クラウドソーシングにおけるラベル統合

小山 聡(北大), 馬場雪乃(東大), 櫻井祐子(九大), 鹿島久嗣(東大)

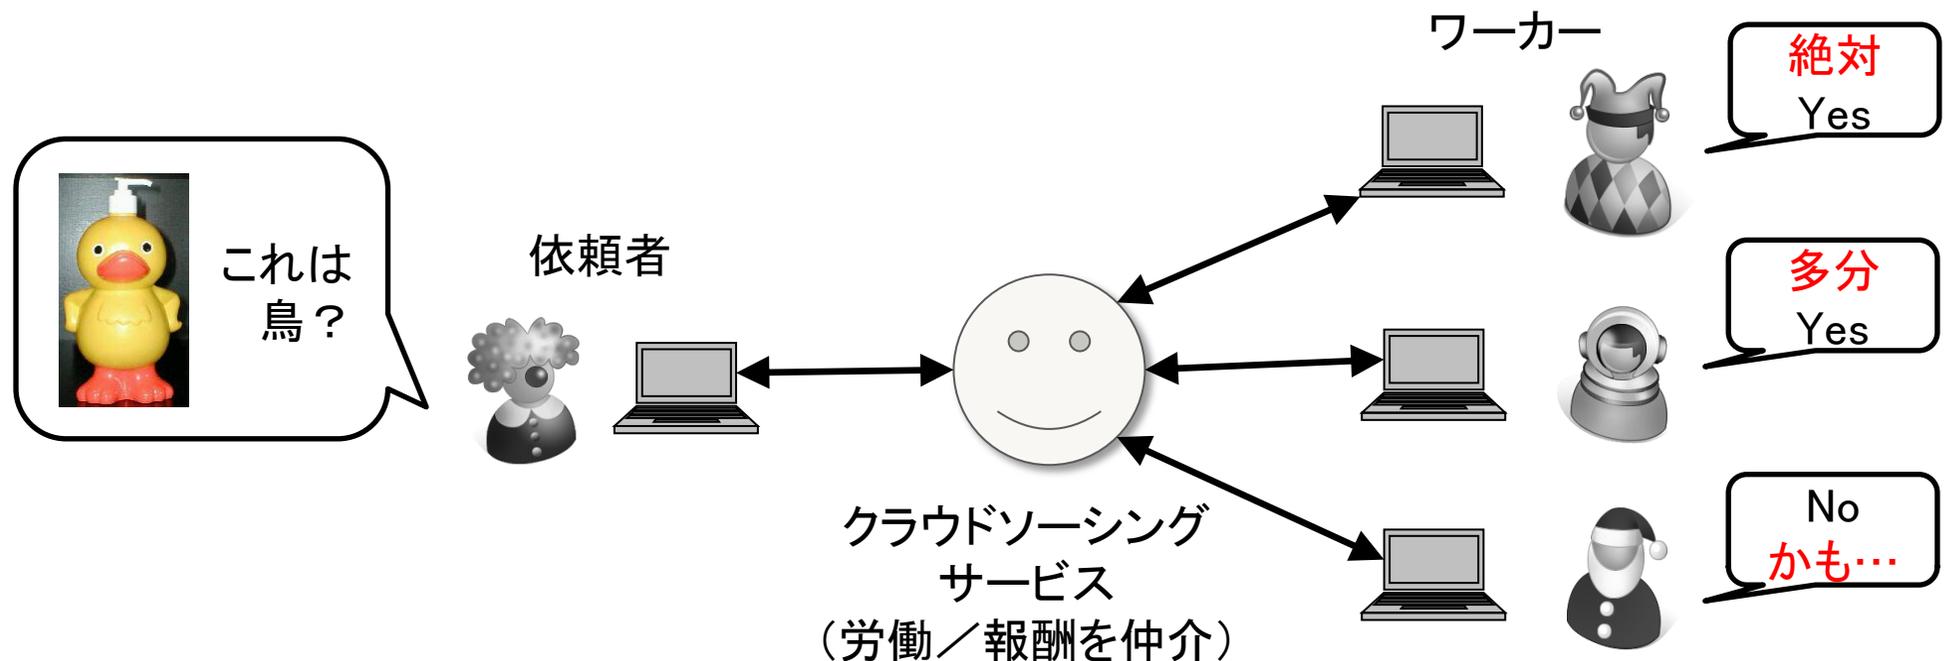
- ヒューマンコンピューテーション: クラウドソーシングを利用して「機械には困難、人間には易しい」タスクを解く
- 課題: 品質の確保 (ワーカー毎の能力 / やる気のばらつき)
- アプローチ: 冗長なデータ収集と統計的な統合
(前提: 多数決よりも良い方法が欲しい)



ワーカーの確信度を用いた クラウドソーシングにおけるラベル統合

小山 聡(北大), 馬場雪乃(東大), 櫻井祐子(九大), 鹿島久嗣(東大)

- 本研究の提案: 回答に加え、その確信度も報告させる
- アプローチ: ラベル統合のモデルに確信度を利用
 - Dawid&Skene (1979) の生成モデルを拡張
- 結果: 確信度情報を用いない場合よりも推定精度が向上

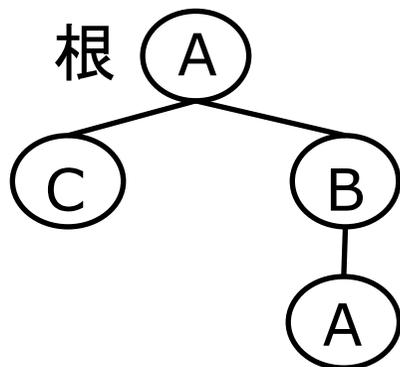


XBWを用いた大規模かつ 省メモリな木カーネルのSVM学習

木村大翼, 鹿島久嗣(東京大学)

部分パス木カーネル [kimura & kashima, '2012]

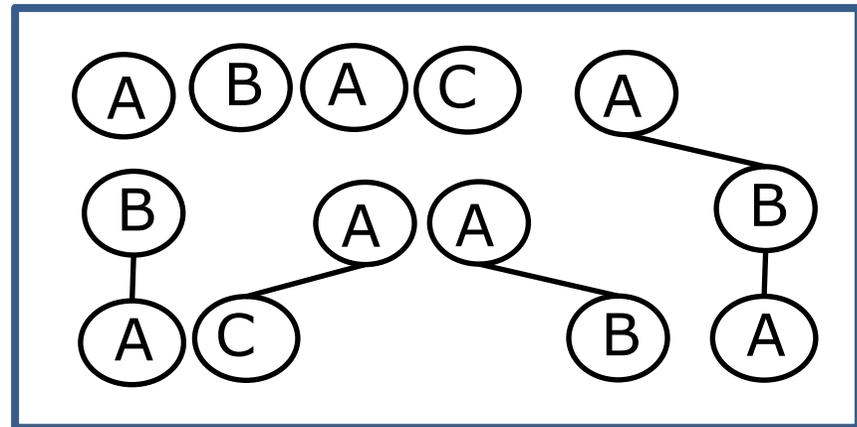
- 特徴: 木の垂直方向の縦パス
- 高速かつ他と同等の予測精度



特徴抽出



部分パス

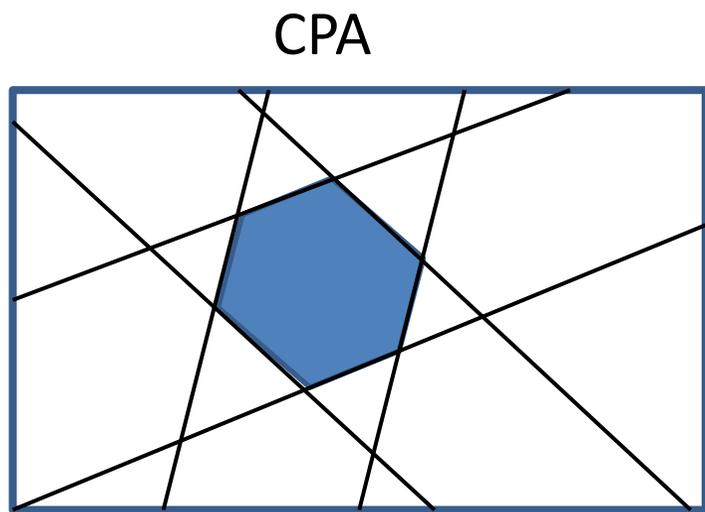


SVM学習の問題点: 計算が重い

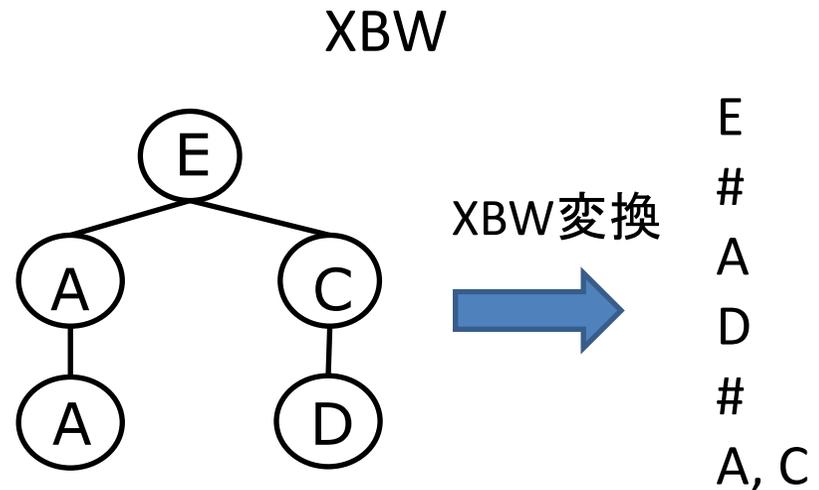
計算量: $O(n^2)$ n : データ数

提案手法: CPA + XBW で高速かつ省メモリな学習を実現

- 高速化: [Severyn & Moschitti, '2011]らのCutting plane algorithm(CPA) を利用
- 省メモリ化: 簡潔データ構造XBWで木構造をコンパクトに保持



最も制約を破っている制約式を
順次追加して最適化



データサイズは情報論的下限
+ 高速なクエリ操作

計算量

$O(n\hat{T}^2)$ n : データ数 \hat{T} : 木の平均ノード数

➡ データ数について線形時間かつ省メモリ!

スパースな線形ガウス状態空間モデルとその解法

大岩秀和, 佐藤一誠, 中川裕志 (東京大学)

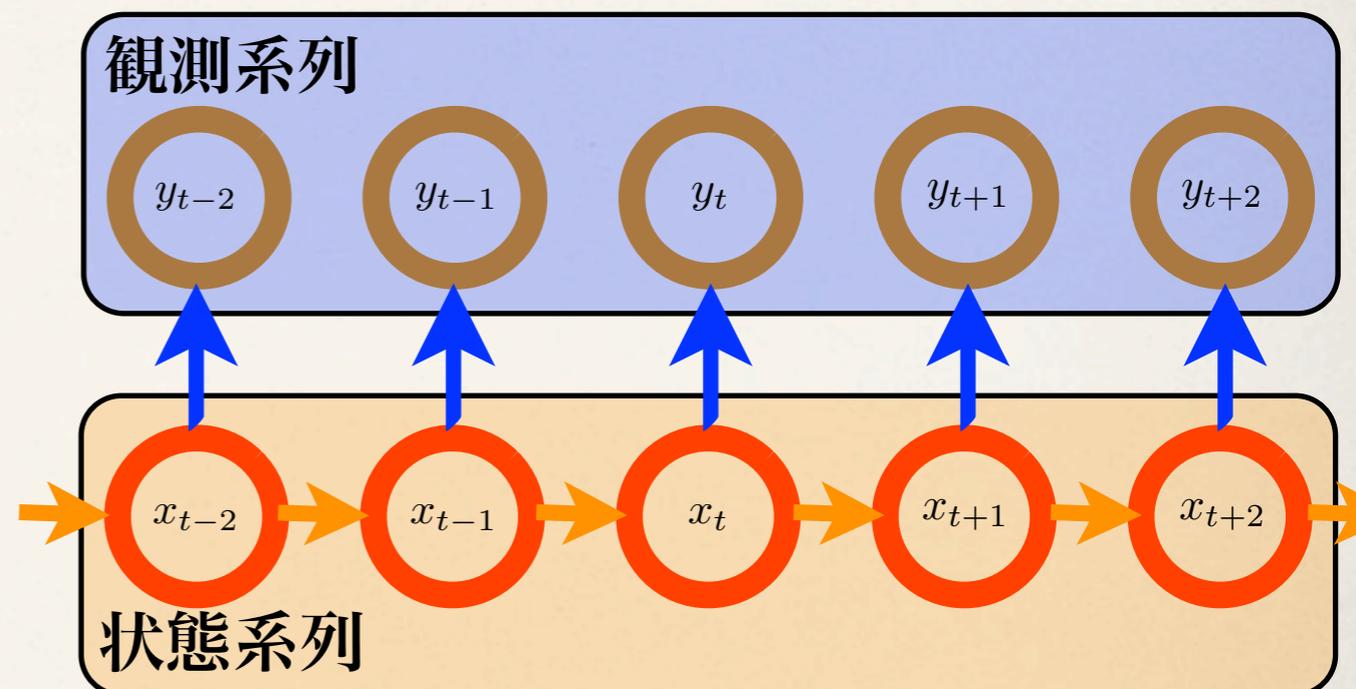
❖ 線形ガウス状態空間モデル

❖ 時系列データのモデリング手法

❖ 経済現象の推定

❖ ソーシャルメディア解析

❖ 物体追跡



❖ 状態ベクトルの設計は非常に重要な課題

❖ Ex: ARモデルの次数設計

$$x_t = (0, 1, 0, 0, -1)$$

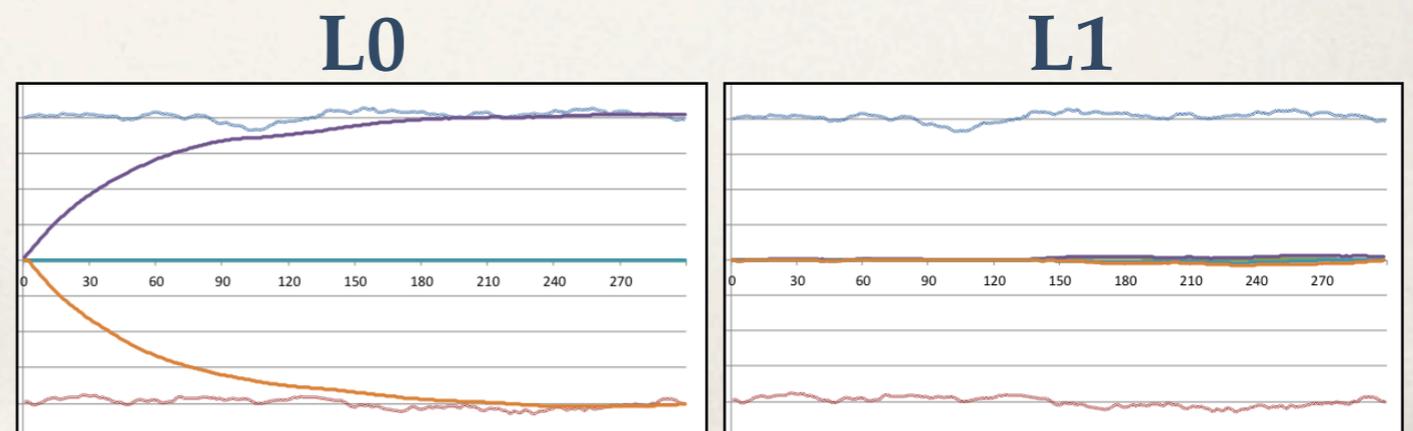
❖ 状態ベクトルのスパース化によって, 有効特徴の自動決定を図る

❖ 設計の自動化 / 計算量の削減 / 解釈の容易化 / ノイズ除去

スパースな線形ガウス状態空間モデルとその解法

大岩秀和, 佐藤一誠, 中川裕志 (東京大学)

- ❖ L0-regularization に基づいたスパースカルマンフィルタを提案
 - ❖ 特徴選択とパラメータ最適化を同時最適化可能な定式化
- ❖ 高速解法のための双対問題への変換
 - ❖ 双対分解を用いた高速ソルバーの提案
 - ❖ 解くべき最適化問題を変形することなく, 最適化可能
- ❖ 既存手法との比較
 - ❖ L1-regularization では冗長な解が導出される場合にも, 本手法で適切なスパース化が可能になる例を紹介



サポートベクトルマシンのための Safe Shrinking ルール

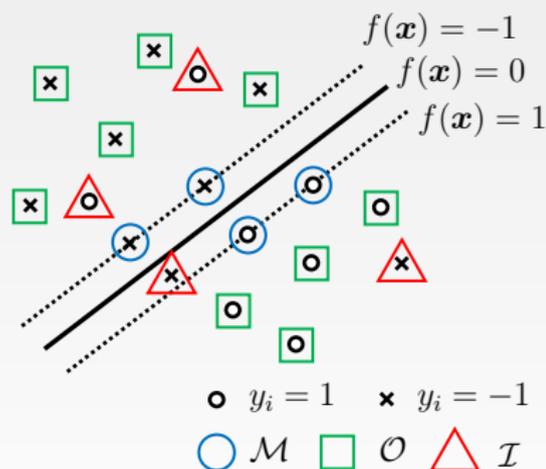
小川 晃平, 鈴木 良規, 新村 祐紀, 竹内 一郎 (名古屋工業大学)

研究目的

- ▶ SVM マージン外 (\circ) に存在するインスタンスは判別器に影響しない

$$y_i f^*(\mathbf{x}_i) > 1 \Rightarrow \alpha_i = 0$$

- ▶ 学習前にそれらを削除することで計算コストを削減



サポートベクトルマシンのための Safe Shrinking ルール

小川 晃平, 鈴木 良規, 新村 祐紀, 竹内 一郎 (名古屋工業大学)

提案手法

- ▶ LASSO screening (Ghaoui et al., 2010)
- ▶ 最適解 f^* が含まれる領域 Θ を構築する

$$\min_{f \in \Theta} y_i f(\mathbf{x}_i) > 1 \Rightarrow y_i f^*(\mathbf{x}_i) > 1 \Rightarrow \alpha_i = 0$$

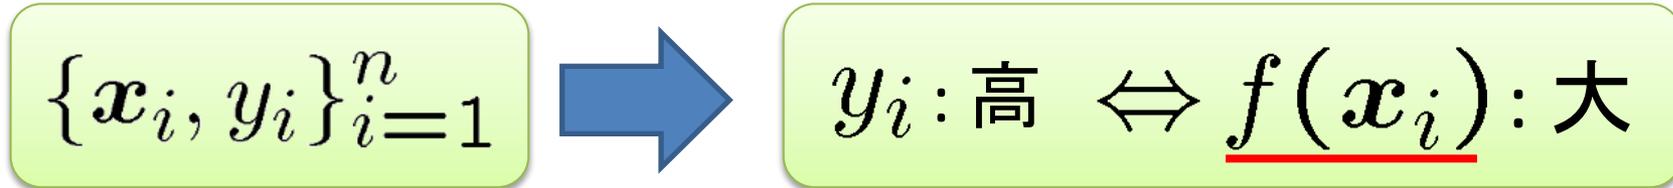
→ Θ によって削除可能なインスタンス数が変化

D-17 ランキング上位の整合性に特化した 効率的なランキング学習法

松野 司, 石原 直樹, 竹内 一郎

(名古屋工業大学大学院)

◆ ランキング学習とは



$x_i := \{ \text{構文解析, ドメイン信頼度, リンク送受信数, etc...} \}$

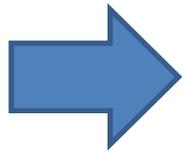
$y_i := \{ \text{ユーザーの主観的な評価値(多段値)} \}$

◆ 従来法(ランキングSVM)の欠点

- 学習データサイズが $O(\text{ドキュメント数}^2)$ の2クラス分類問題
- (参照頻度の高い)上位ドキュメントを重視せず

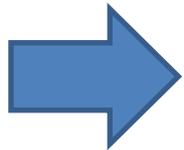
◆ 提案法

- $f(x_i)$ の値が小さくなる程, 学習への影響度を下げる



ランキング上位の影響度を上げる

- $f(x_i)$ の値が閾値より小さい物を学習から削除



計算コストの減少

◆ 貢献

- 非凸最適化問題への定式化
- 局所解へ収束するアルゴリズムの提案

D-18 Density Power Divergenceを利用したノイジーオラクル下における能動学習

十河 泰弘¹, 植野 剛², 河原 吉伸¹, 鷲尾 隆¹(1: 大阪大学, 2: JST ERATO)

□ 能動学習

- ラベル有り小事例集合 L , ラベル無し大事例集合 U



□ 問題

- 従来手法はオラクルが常に真のラベルリング分布に基づいてラベル付けを行うと仮定.
- 現実的には, ノイズラベルを含む.
⇒結果, 能動学習の精度が悪化する.

□ 目的

- ノイズラベルに対してロバストな能動学習手法の提案.

D-18 Density Power Divergenceを利用したノイジーオラクル下における能動学習

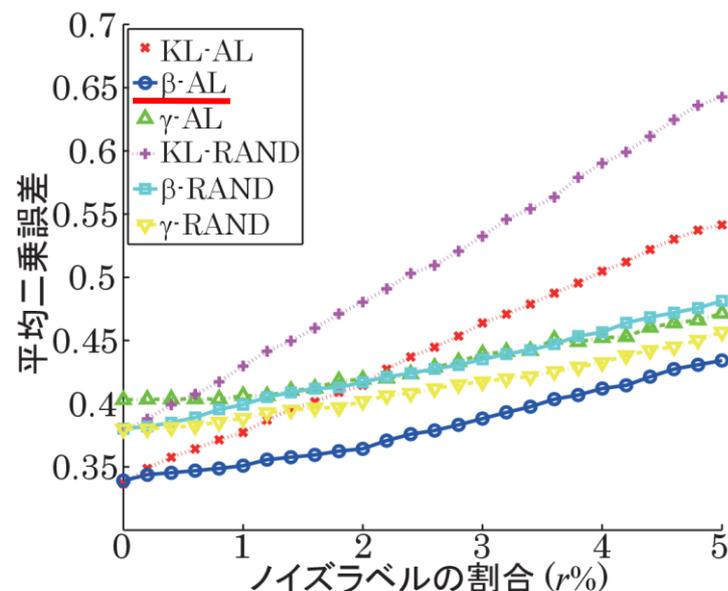
十河 泰弘¹, 植野 剛², 河原 吉伸¹, 鷲尾 隆¹(1: 大阪大学, 2: JST ERATO)

□ 提案

- Density Power Divergenceの導入
 - KLに比べ, ロバスト推定が可能
- パラメータ漸近分散に基づくクエリ選択基準の拡張
 - 真のパラメータに最も近づくクエリを選択

□ 数値実験

- 線形回帰モデルへ導入
- 平均二乗誤差を評価
- KLベース, ランダムサンプリングと比較



□ まとめ

- ノイジーオラクル下における, 提案手法(β -AL)のモデル推定精度の向上を確認.

19 バイズ推定による顕微鏡画像の三次元再構成

井本 康宏 前田 新一 石井 信

(京都大学大学院 情報学研究科 システム科学専攻)

• 目的

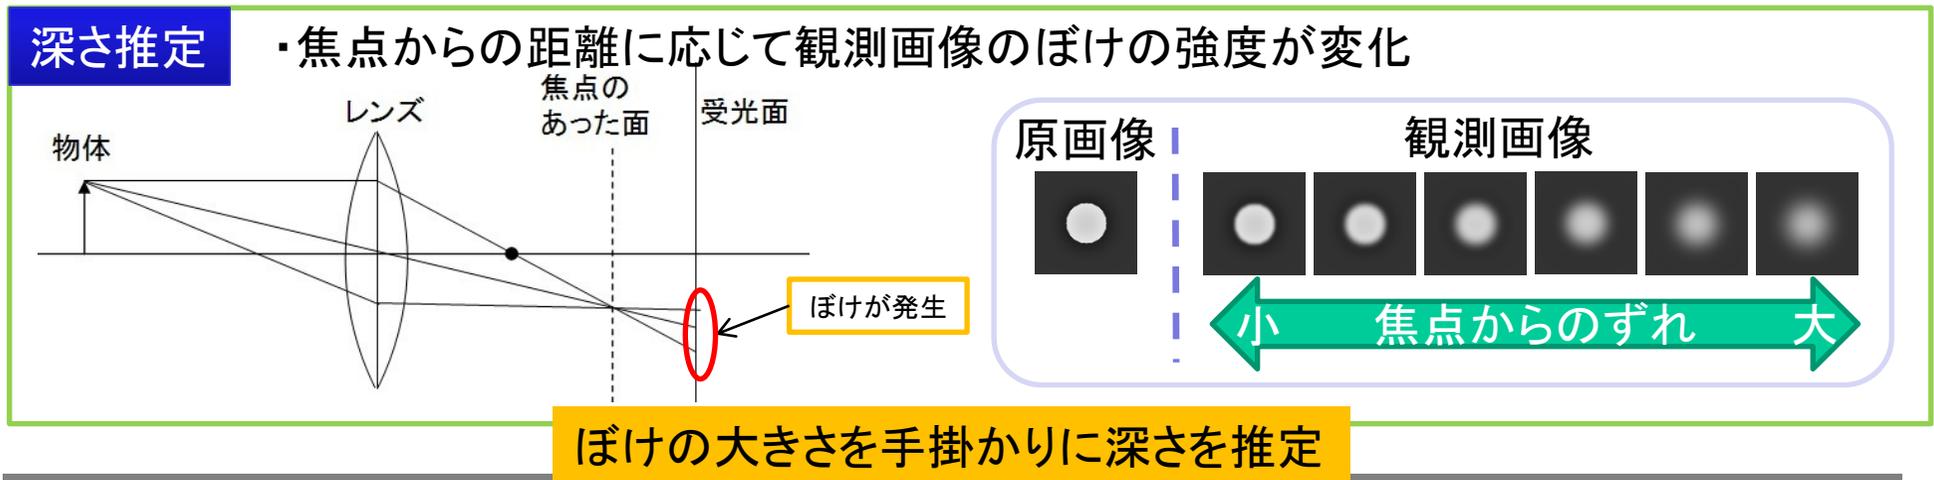
– ぼけのある複数枚の顕微鏡画像から細胞の立体的な形状を推定する

• 手法

– ぼけの大きさから深さを推定

– 統計モデルを利用して複数の観測画像に対して矛盾のない深さと輝度値を推定

– 各ピクセルが属するクラス(細胞クラス、背景クラス)を考え、領域の境界を保存した滑らかさ制約など複雑な制約を表現



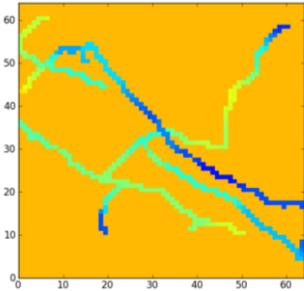
19 ベイズ推定による顕微鏡画像の三次元再構成

井本 康宏 前田 新一 石井 信
(京都大学大学院 情報学研究科 システム科学専攻)

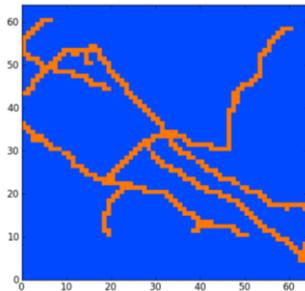
• 実験および結果

- 人工的に作り出した観測画像から輝度値マップと深さマップを推定する

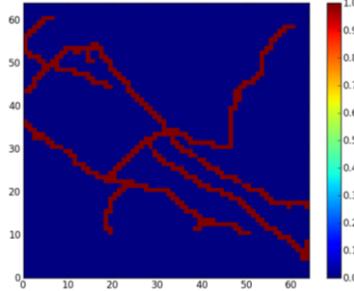
原画像



深さマップ

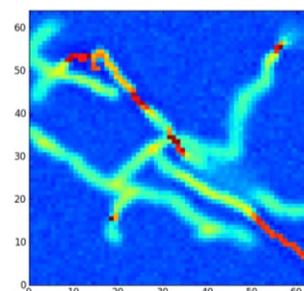
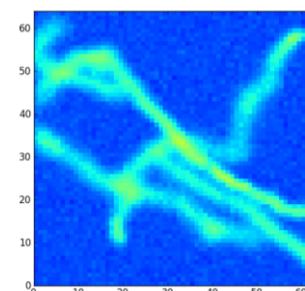


輝度値マップ



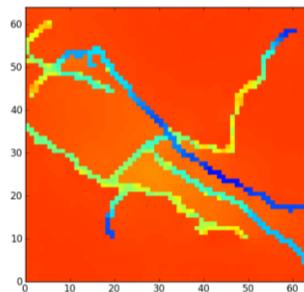
クラスマップ
(1:細胞、0:背景)

観測画像(5枚のうち2枚)

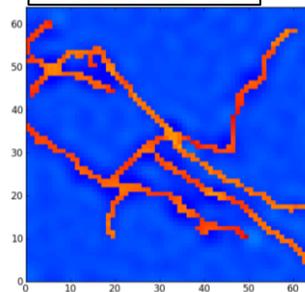


焦点位置が異なり、それぞれで異なったぼけの観測画像

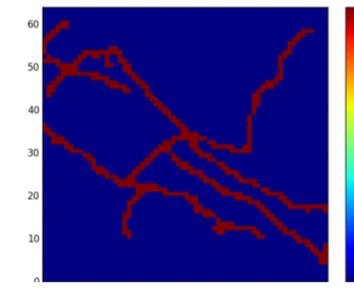
推定結果



深さマップ



輝度値マップ



クラスマップ
(1:細胞、0:背景)

• まとめ

- 細胞が上下に交差している場合(画像中央)でも深さを正しく推定できている
- 背景領域は深さに関する情報が少ないので事前分布に精度に影響される
- ピクセルの属するクラスを考えることで、細胞領域のみを抽出可能

D-20 低画質な定点画像からの教師なし車両台数推定

勝木孝行, 森村哲郎, 井手剛 / Takayuki Katsuki, Tetsuro Morimura, and Tsuyoshi Idé

IBM東京基礎研究所 / IBM Research – Tokyo

画像内のある注目領域の**車両台数**を計測する



[ポイント]

- 世界各地の既存のweb cameraから交通情報を取得できれば,**安価に広範**な交通情報を得ることが可能になる
- web camera等の交通計測専用ではない機器から得られる画像は,通常以下のような不都合な性質を抱えている



重なり



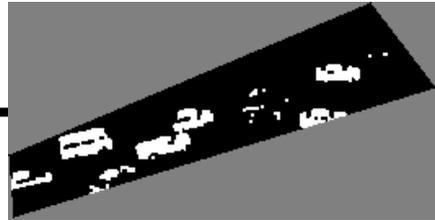
解像度不足

- 教師データは作成コストが高い

□教師なしBayes車両台数推定を提案する



左図赤の領域の車両領域を特徴量として抽出

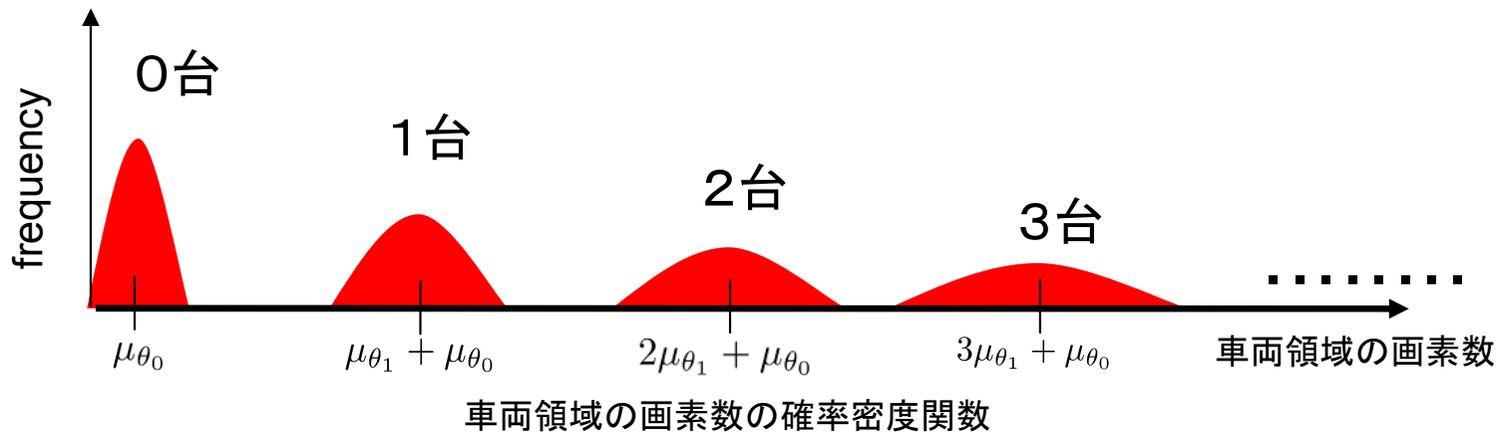


車両台数
推定関数

車両台数

この関数をBayes的密度関数推定によって求める

- 重なりや解像度に対して頑健な**車両領域の画素数**を特徴量に用いる
- **台数の増加に対して車両領域画素数は線形に増加する**という直感的な性質を利用した、下図のような無限混合Gaussモデルによって車両領域画素数の密度関数を表現し、そのパラメータの推定問題として問題を定式化する



□実画像を用いた実験において、**教師あり手法と同等程度の性能を持つことを確認した**

D-21 Soft-projection method for incremental learning on a budget

中部大学工学部 情報工学科 山内康一郎

目的：

組み込み機器で利用可能な学習アルゴリズムの実現を目指す。

- 限られた資源以内で追記学習を継続できる。
- 少ない計算量で実用的スピードで実行できる。
- 非独立分布から生成される学習サンプルであっても忘却を起すことなく one-pass 学習できる

同様の能力を目指したものとしてカーネルパーセプトロンによる手法が多く研究されている。例えば projectron[2], forgetron[3], PDM[1] など。しかし過去の学習サンプルの分布を陽には考慮しないため、忘却の発生を抑制できない場合がある。

筆者は既に Limited General Regression Neural Network (LGRNN)[1] でこれをおある程度解決する手法を開発したが、本研究ではこれをさらに改善する Soft-projection 法を提案する。

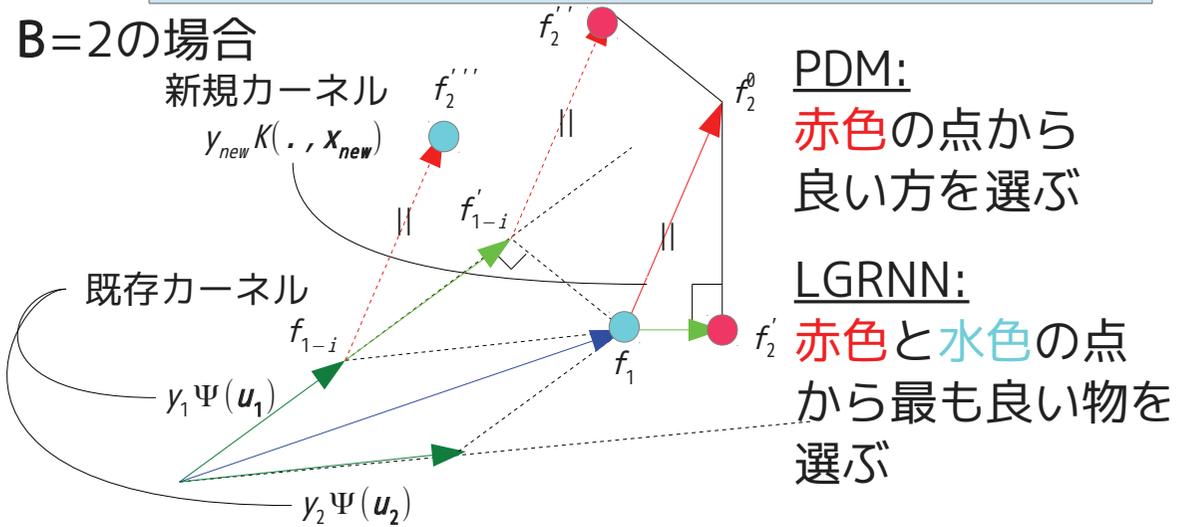
既存手法の例：LGRNN(2011)[1], PDM(2011)[2]

```

LGRNN, PDM を併せた 擬似コード
for each (x_new, y_new)
  f_t[x_new] = sum_{alpha in B} y_alpha K(x_new, u_alpha)
  B はカーネル集合を表し、
  B はその上限を表す。
  P はプロジェクションを表す
  if (y_new - f[x_new])^2 > theta then
    f_{t+1}^0 = f_t + y_new K(. , x_new)
    if |B| < B then f_{t+1} = f_{t+1}^0
  else
    新規カーネルを射影し削除 -> f'_{t+1} = f_t + y_new P K(. , x_new)
    冗長カーネル射影し削除 -> f''_{t+1} = f'_{t+1} + P y_i K(. , u_i) + y_new K(. , x_new)
    新規カーネル追加 -> f'''_{t+1} = f'_{t+1} + y_new P K(. , x_new)
    冗長カーネルを削除 -> f_{t+1} = f_t, f'_{t+1}, f''_{t+1}, f'''_{t+1} の中で最も良い物
    新規カーネル追加
  endif
endif {if error > theta}
t = t + 1
end for {for each}
    
```



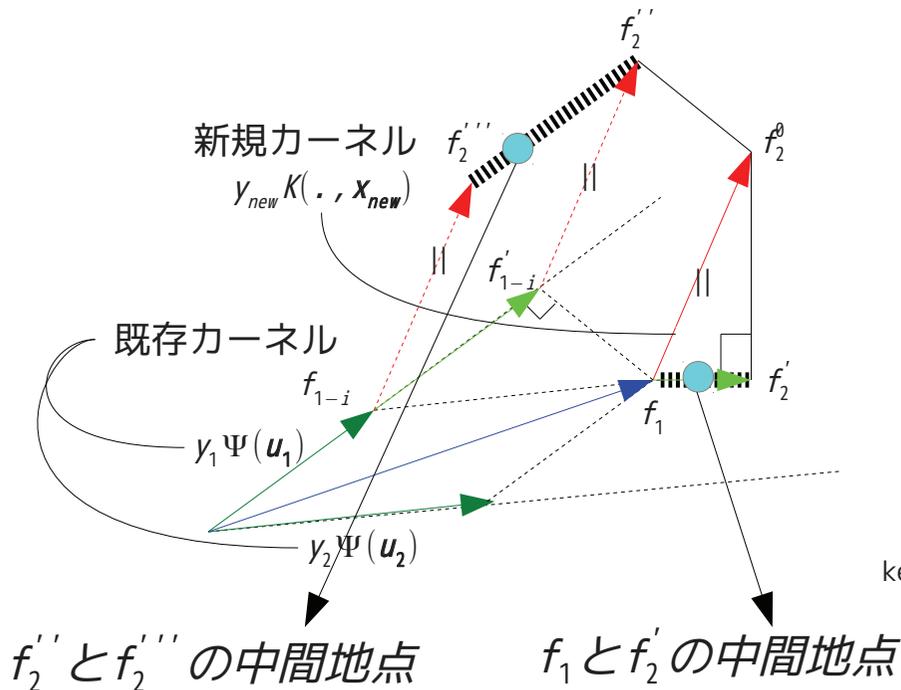
本研究で想定する応用例：
組み込みカーネルマシンを使用した最大電力点高速追従コンバータ
(JST-Astep AS231Z00475B)



D-21 Soft-projection method for incremental learning on a budget

提案法:Soft Projection法

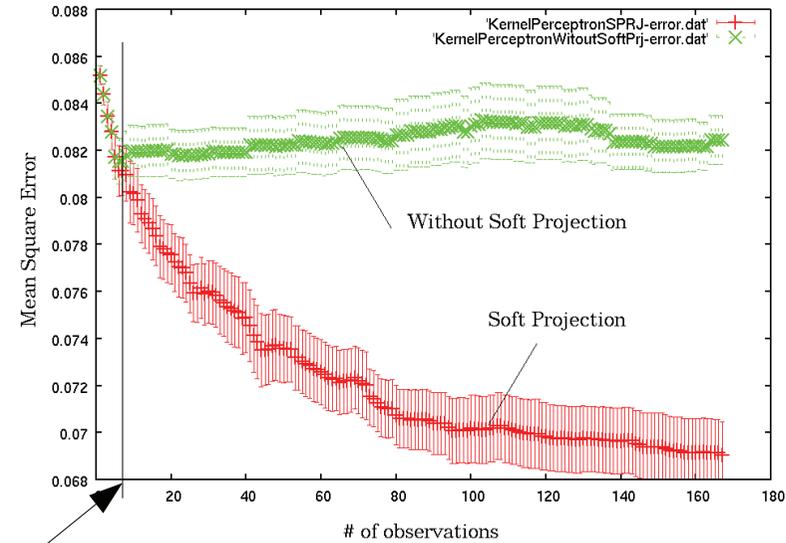
ベンチマークテスト(preliminary)



のどちらかを選択する。中間地点の決定方法および選択方法についてはポスターにて説明する。

参考文献

- [1] Koichiro Yamauchi . "Pruning with Replacement and Automatic Distance Metric Detection in Limited General Regression Neural Networks", IJCNN2011, IEEE, pp. 899--906, July, (2011).
- [2] Wenwu He, Si Wu . "A kernel-based Perceptron with dynamic memory", Neural Networks, vol.25, pp. 105--113, (2011).
- [3] Ofer Dekel, Shai Shalev-Shwartz, Yoram Singer . "The Forgetron: A Kernel-Based Perceptron on a Budget", SIAM Journal on Computing (SIAMP), vol.37, No.5, pp. 1342--1372, January, (2008).
- [4] Francesco Orabona, Joseph Keshet, Barbara Caputo . "The Projectron: a Bounded Kernel-Based Perceptron", in ICML2008, pp. 720--727, (2008).



kernel数の上限: 5

Servo data を使った比較実験結果
エラーバーは95%信頼区間(50試行)
(kernel Perceptronを使用)

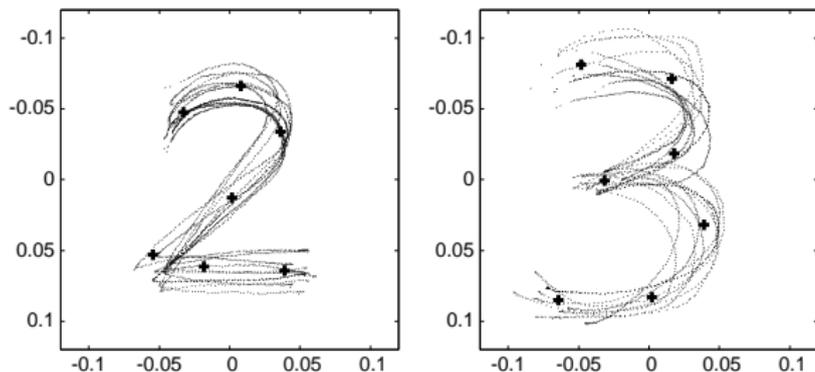
Soft Projection法を使うことでサンプルの分布を勘案した学習が可能となる。サンプル数がカーネル数の上限を超えても誤差が減少するのみならず、Soft Projectionを使用しない場合に比べ、大きく誤差が減少することが分かる。

D-22: 同種類の形状にランドマークを自動的に配置する方法

岩田 一貴 (広島市立大学)

- ランドマークとは ...
 - 形状解析のベースとなる輪郭線上に配置された有限個の点
 - 同種類の形状との対応がついていなくてはならない
- 研究の要約
 - 輪郭線上に自動的にランドマークを配置する手法を提案
 - ランドマークの配置はある最適化問題の解に帰着される

実験結果の一部



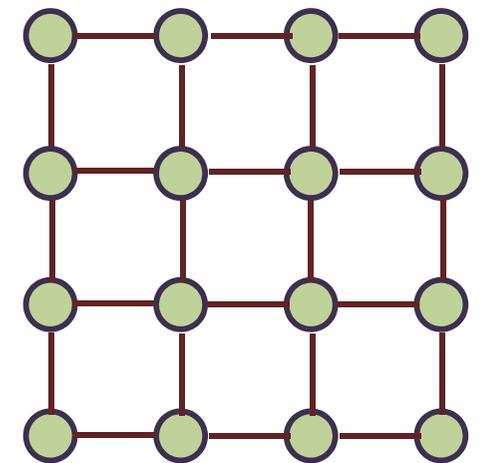
◀ この手法で配置されたランドマーク (+ 印) は“2”と“3”の形状をうまく表現できている

背景と目的

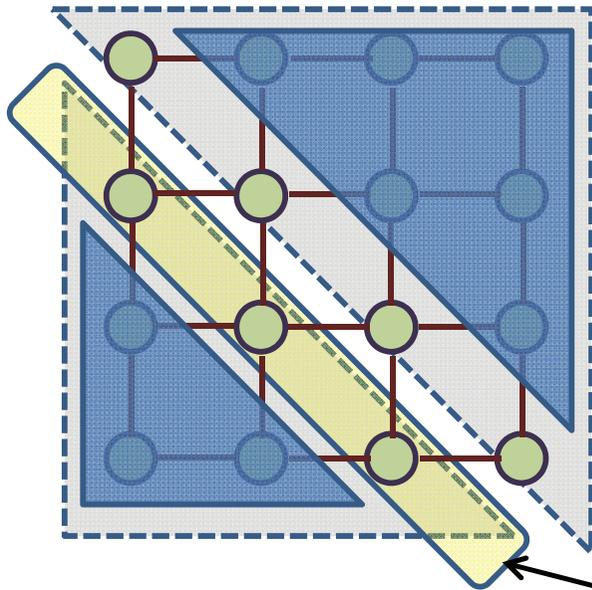
時間的、空間的に局所的な相関を表現するのに
格子状のグラフで表現される確率モデルがしばしば用いられる。

格子状グラフに特化した手法で良いから
格子状グラフの推論(周辺化,統計量推定)を精度よく行いたい!

	一般のグラフ	...	格子状	...	特殊なグラフ
ループ	有りえる		有り		無し
相関	様々		局所的		局所的
手法	naïve Bayes, TRW, ベータ近似		提案法		sum-product algorithm



二次元格子の例



足し算が正確に行なえれば、周辺分布が求まる

同時分布 $p(\mathbf{x}) \propto \exp\left(\sum_{i \sim j} \phi(x_i, x_j)\right)$

周辺分布 $p(x_i) \propto \sum_{\mathbf{x}_{\setminus i}} \exp\left(\sum_{i \sim j} \phi(x_i, x_j)\right)$ $\mathbf{x}_{\setminus i}$ は \mathbf{x} から x_i を除いた変数

$p(x_i, x_j) \propto \sum_{\mathbf{x}_{\setminus \{i,j\}}} \exp\left(\sum_{i \sim j} \phi(x_i, x_j)\right)$ $\mathbf{x}_{\setminus \{i,j\}}$ は \mathbf{x} から x_i と x_j を除いた変数

$\mathbf{x}^{(d)}$ (左下を1番目としてd番目の斜めの列に位置するx)

提案法

$$S(\mathbf{x}^{(d)}) = \sum_{\mathbf{x} \text{ in } \triangleleft} \exp\left(\sum_{i \sim j \text{ in } \triangleleft} \phi(x_i, x_j)\right) \doteq \tilde{S}(\mathbf{x}^{(d)}) = \exp\left(\sum_{i \sim j \text{ in } \square} \psi(x_i, x_j) + \sum_{i \text{ in } \square} \psi(x_i)\right)$$

となる関数 ψ を逐次的に求める。提案法では ψ はsum-product algorithmで高速に求められる。

逐次的とは $\tilde{S}(\mathbf{x}^{(d)}) \approx S(\mathbf{x}^{(d)})$ をもとに $\tilde{S}(\mathbf{x}^{(d+1)}) \approx S(\mathbf{x}^{(d+1)})$ を推定すること。

これが得られれば、sum-product algorithm (Forward-Backward algorithm)で周辺化可能。

ポイント: 使えるところはsum-product algorithmで厳密計算

結果 ポスター会場。。