

局所的変分法による非補償型ナレッジトレーシング

玉野 浩嗣

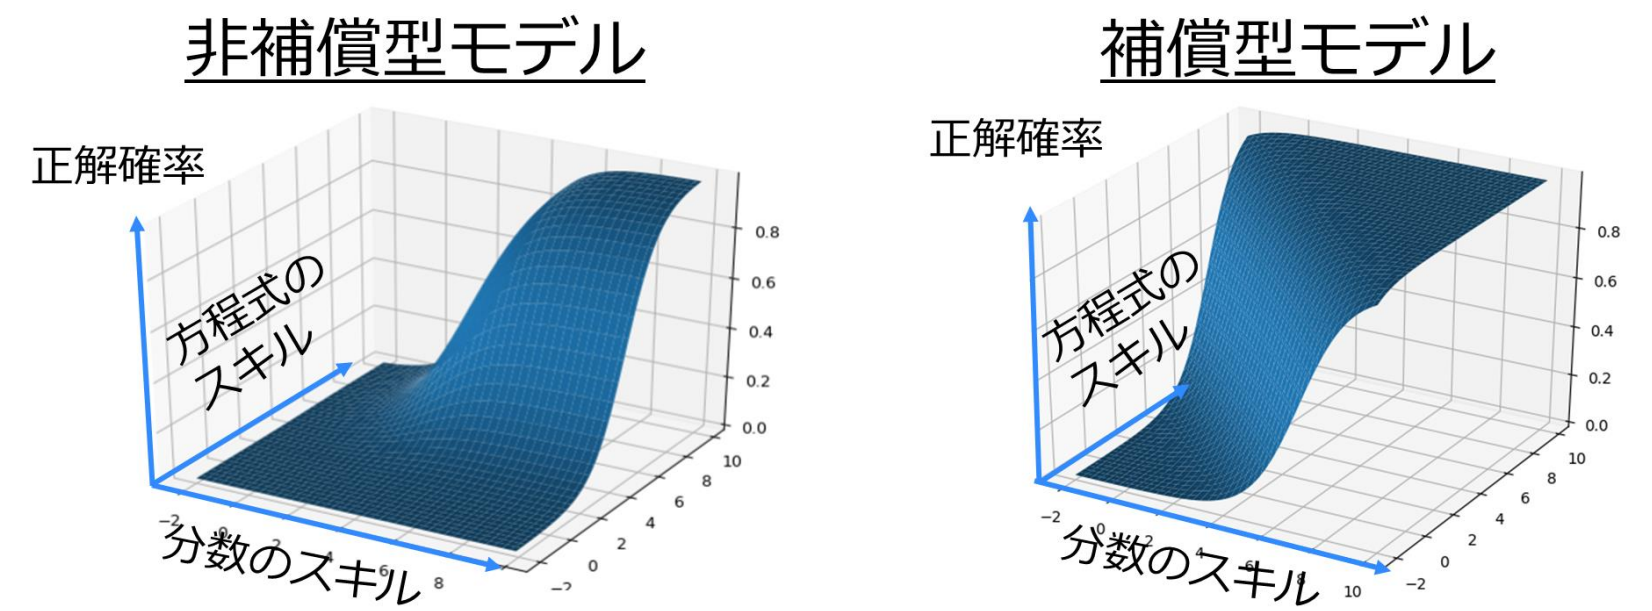
総合研究大学院大学 統計科学専攻 D5

背景

- 「ナレッジトレーシング」とは、学習者が問題を解いた時系列ログから学習者の潜在的なスキルの変化を追跡し、今後の問題に対する正誤を予測する手法のことで、IRT（項目応答理論）の時間発展版に相当する
- 人間が結果を理解するためには問題と潜在スキルの対応が必要で、必要なスキルはAND条件となることが多い
 - 例）方程式 $\frac{1}{5}x + \frac{3}{10} = 2x$ は、①分数のスキルと②方程式のスキルが満たされれば解くことができる
- IRT（項目応答理論）の**非補償型モデル**に対応
- 学習者へのリアルタイムフィードバックや、推定の不確実性も学習者の判断にとって重要となる
 - **解析的な推定方法**、**分散も含めた推定**

目的

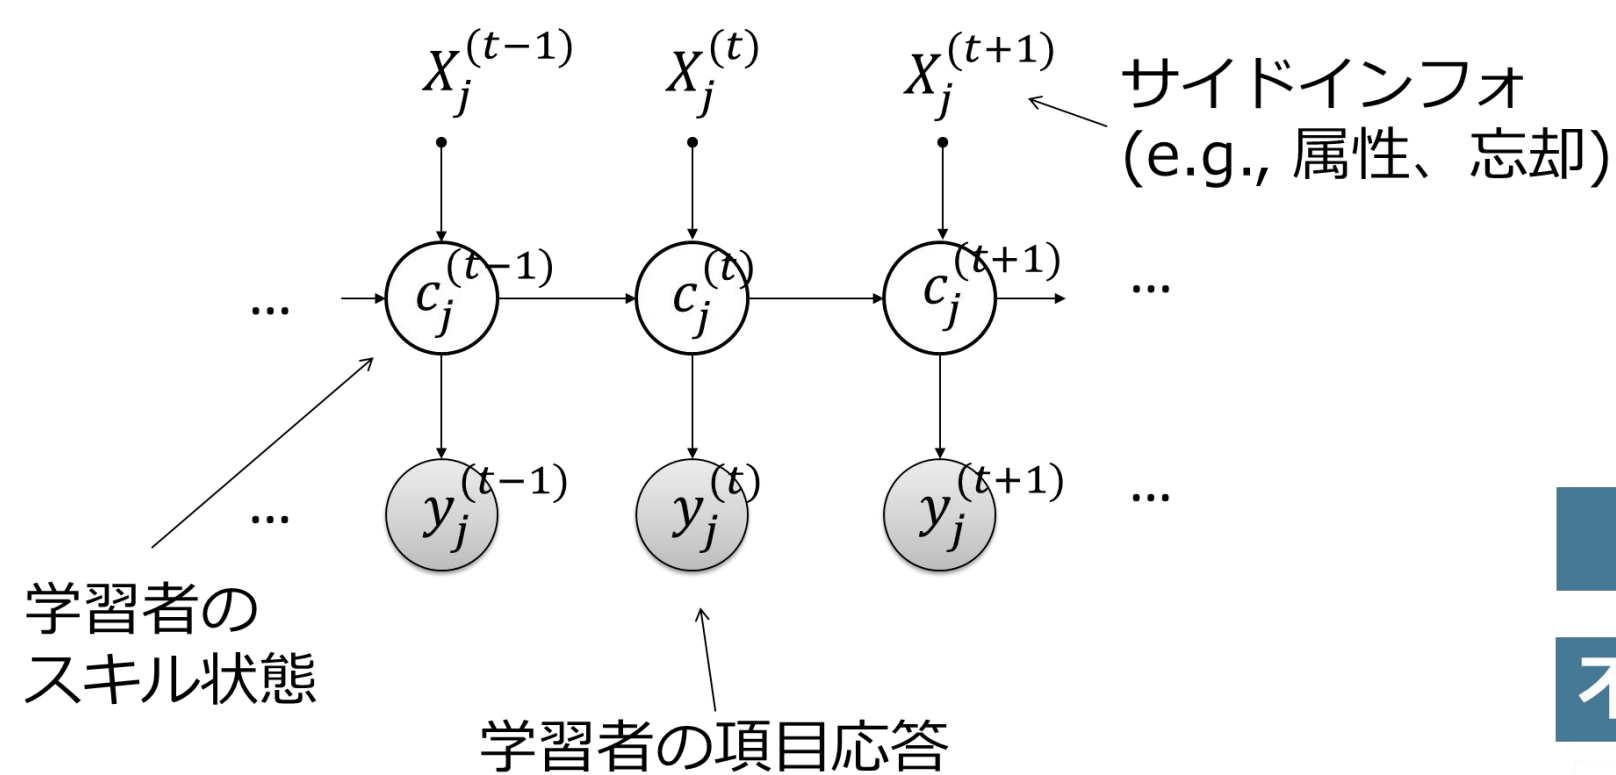
- 非補償型モデル**で、学習者のスキルの時系列変化を**分散も含め**、**解析的に推定**できる方法を実現する



提案方法

【生成モデル】

≡ カルマンフィルタ + 非補償型項目応答モデル



項目応答モデル

$$P(y_j^{(t)} = 1 | c_j^{(t)}) = \prod_k \sigma(a_{i,k}(c_{j,k}^{(t)} - b_{i,k}))$$

状態遷移モデル

$$P(c_j^{(t+1)} | c_j^{(t)}) = N\left(c_j^{(t+1)} \middle| D_{i(j,t)} c_j^{(t)} + \begin{bmatrix} \vdots \\ \beta_k^T x_{j,k}^{(t+1)} \\ \vdots \end{bmatrix}, \Gamma_{i(j,t+1)}\right)$$

初期状態モデル

$$P(c_j^{(1)}) = N(c_j^{(1)} | \mu_0, P_0)$$

【推定方法】

方針： α メッセージをガウス近似して、EMアルゴリズムにより推定する

$$\hat{\alpha}(c_j^{(t)}) = P(c_j^{(t)} | y_j^{(1)}, \dots, y_j^{(t)}) \propto \underbrace{P(y_j^{(t)} | c_j^{(t)})}_{\text{尤度 (非補償モデル)}} \underbrace{P(c_j^{(t)} | y_j^{(1)}, \dots, y_j^{(t-1)})}_{\text{事後分布 (事前分布 (ガウス))}}$$

→ 非補償型尤度の2次下界を求め、ガウス近似する

正解側尤度の2次下界

Jaakkola&Jordan 2000で容易に2次近似可能


不正解側尤度の2次下界

事前分布の近くで局所ガウス近似する


$$P(y_j^{(t)} = 0 | c_j^{(t)}) = 1 - \prod_k \sigma(a_{i,k}(c_{j,k}^{(t)} - b_{i,k}))$$

STEP1: 事前分布の中心における尤度の勾配方向に1次元化して下界を求める (Jaakkola&Jordan下界1 + Jensen下界2)


STEP2: 尤度関数の等高線は凸関数となる。他の次元の共分散は任意で下界となるため、事前分布の共分散を用いる



STEP1




STEP2



評価


① 局所ガウス近似

尤度に対して事前分布を移動、回転等させて近似と真の事後分布を比較



② 予測性能

- ニューラル手法DKT[1], DKVMN[2]と比較
- ASSISTment Data (Skill Builder)[3]
 - ユーザ数 4,106; 問題数 9151; スキル数 106
 - 最低でも10名が解いた問題に限る
- 8割を学習用、2割をテスト用 (各ユーザの最初の応答は評価対象外)



まとめ・課題

- 非補償型モデルで、学習者のスキルの時系列変化を分散も含め、解析的に推定できる方法をカルマンフィルタをベースに局所ガウス近似を用いて実現
- ASSISTment Skill Builderデータにより、ニューラル手法と同等以上の性能を確認
- 状態遷移モデルの複雑化
- M-stepの項目応答モデルの最適化の効率化 (現状、勾配法による繰り返し最適化)

Reference

- [1] Chris Piech, Jonathan Spencer, Jonathan Huang, Surya Ganguli, Mehran Sahami, Leonidas Guibas, & Jascha Sohl-Dickstein. (2015) Deep Knowledge Tracing
- [2] Zhang, J., Shi, X., King, I., & Yeung, D. Y. (2017). Dynamic key-value memory networks for knowledge tracing
- [3] Feng, M., Heffernan, N.T., & Koedinger, K.R. (2009). Addressing the assessment challenge in an Intelligent Tutoring System that tutors as it assesses