

THE IEICE TRANSACTIONS ON INFORMATION AND SYSTEMS (JAPANESE EDITION)

IEICE | **電子情報通信学会**
D | **論文誌** 情報・システム

DOI:10.14923/transinfj.2020JDP7061

早期公開日:2021/04/02

本PDFは、早期公開版である。本論文を引用する場合には、電子情報通信学会和文論文誌投稿のしおり(情報・システムソサイエティ)の「8.早期公開」を参照すること。

情報・システムソサイエティ

一般社団法人 **電子情報通信学会**

THE INFORMATION AND SYSTEMS SOCIETY

THE INSTITUTE OF ELECTRONICS, INFORMATION AND COMMUNICATION ENGINEERS

独立な学習者・項目ネットワークをもつ Deep-IRT

堤 瑛美子^{†a)} 木下 涼^{†b)} 植野 真臣^{†c)}

Deep-IRT with independent student and item networks

Emiko TSUTSUMI^{†a)}, Ryo KINOSHITA^{†b)}, and Maomi UENO^{†c)}

あらまし 近年、人工知能分野では大規模な学習履歴データに基づき、学習過程における学習者のスキルの習得状態を自動的に把握し、未知の項目への反応予測を行う Knowledge Tracing (KT) が注目されている。最先端の KT 手法である Deep-IRT は、学習者の能力値や項目困難度といった解釈可能なパラメータをもち、高精度な反応予測を行うことが報告されている。しかし、Deep-IRT は同一スキル内の項目を等質と仮定しており、能力推定値が項目の特性に依存するという問題がある。このため、項目特性が異なる場合には能力値や項目困難度の解釈が困難である。本論文では、Deep-IRT におけるパラメータの解釈性を高め、より高精度な反応予測を可能とする新たな Deep-IRT を提案する。具体的には、学習者の項目への反応を二つの独立な学習者ネットワークと項目ネットワークで表現し、項目特性に依存せずに能力値を推定するモデルを提案する。さらに提案手法では項目とスキルの双方の特徴を考慮した反応予測を行う。評価実験ではこれまで KT に用いられてきた既存手法と提案手法の反応予測精度比較を行い、提案手法の有効性と高い解釈性を示す。

キーワード Knowledge Tracing, Deep Knowledge Tracing, 深層学習, 項目反応理論, 教育工学

1. ま え が き

近年、オンライン教育の普及に伴い、大量の学習履歴データが容易に入手できるようになった。教育現場では学習者の発達を促すため、これらのデータに基づいて個々の学習者の理解度を把握し、適切な支援を与えることが課題となっている。人工知能分野では、機械学習手法を用いて過去の学習履歴から学習者の知識の習得状態を推定し、学習者の未知の項目への反応予測を行う Knowledge Tracing (KT) が注目を集めている [1]~[22]。Knowledge tracing の重要な役割は、学習者の項目への反応予測を行うだけでなく、知識の習得状態を学習者にフィードバックすることで学習者が自らの苦手分野を把握したり、教師が項目の難易度を把握し改善することにある。したがって、より正確な反応予測と学習者の能力値や項目の困難度などの解釈可能なパラメータをもつ手法の開発が進められて

いる。

KT の代表的な手法として、Bayesian Knowledge Tracing (BKT) が知られている [1]。BKT は隠れマルコフモデルに基づいて、学習者が課題解決に必要な知識 (スキル) を習得しているかを 2 値で推定し、未知の項目への反応予測を行う。BKT 手法は様々な拡張手法が開発されているが、スキルの習得状態が 2 値で表されるためにスキルの習熟度変化を柔軟に表現することができない [8]~[11], [13], [23], [24]。また、各スキルの独立性を仮定しているためスキル間の関係性を考慮した習熟度推定を行うことができない問題があった。この問題を解決するため、深層学習を用いた KT 手法として Deep Knowledge Tracing (DKT) が提案されている [7]。DKT は Long-short term memory (LSTM) [25] を用いて学習者のスキルの習得状態を表現し、学習者の各項目への反応を予測するモデルである。DKT では LSTM の隠れ層に全てのスキルの習得状態が圧縮されているとみなしており、BKT 手法と比較して反応予測精度が高いことが報告されている。

一方で、その後の研究では、一般に学習者の能力測定モデルとして利用される項目反応理論 (Item Response Theory; IRT) [26] が KT 手法として用いられるようになった。IRT は学習者の能力パラメータと項目の困

[†] 電気通信大学大学院情報理工学研究所, 調布市

Graduate school of Informatics and Engineering, The University of Electro-Communications, 1-5-1 Chofugaoka, Chofu-shi, 182-8585, Japan

a) E-mail: tsutsumi@ai.lab.uec.ac.jp

b) E-mail: kinoshita@ai.lab.uec.ac.jp

c) E-mail: ueno@ai.is.uec.ac.jp

難度パラメータを独立に推定し、各項目に対する学習者の正答確率を予測する解釈可能性の高いモデルである。IRT の能力パラメータは連続量で表されるため BKT よりも表現力が高い。また、Wilson らは IRT の反応予測精度が DKT を上回ることを示している [27]。さらに、時系列学習履歴データへの適用のため、学習過程における学習者の能力値を隠れマルコフ過程に従って時系列変化させた隠れマルコフ IRT が複数提案されている [2], [27]~[31]。これらの手法は IRT と BKT の一般化手法であり、KT 手法として用いることで、深層学習を用いた KT 手法より高精度な反応予測を行うことが示されている [27], [31]。しかし、IRT 手法では項目の局所独立性を仮定しているため、同じ項目に繰り返し取り組む学習には適応できない。さらに BKT と同様に複数のスキルの関係性を考慮した能力推定を行うことはできない。

近年では、深層学習を用いた新たな KT 手法として、アテンションとメモリネットワークを用いた Dynamic Key-Value Memory Network (DKVMN) が提案されている [4]。DKVMN は外部に情報を保存するための Memory Network をモデルに組み込むことにより、DKT より反応予測精度が高く、過学習に陥りにくくことが報告されている。しかし、DKVMN では学習者の能力が隠れ変数行列に圧縮されており、各スキルにおける能力変化を解釈することが難しい。また、項目の困難度を表すパラメータが存在しないなど、項目特性の解釈性が低いといった問題がある。

DKVMN におけるパラメータの解釈性を向上させた手法として DKVMN と IRT を組み合わせた Deep-IRT が提案されている [5]。Deep-IRT は学習者の能力パラメータや項目困難度を計算するために DKVMN に隠れ層を追加することで、予測精度を落とすことなく、モデルの解釈性を向上させることが報告されている。しかし、Deep-IRT で推定される能力値は項目の特性に依存しており、同一スキル内の全ての項目が等質であると仮定しているために、異なる困難度をもつ項目からの能力推定値は同一尺度上で比較することが難しい。従って、能力パラメータや困難度パラメータの解釈性は従来の IRT に比較して制約がある。

一方、木下らは深層学習と IRT を用いた測定モデル Item Deep Response Theory (IDRT) を提案している [32]。IDRT は独立した学習者ネットワークと項目ネットワークによって構成され、項目特性に依存せずに学習者の能力値を推定できる。評価実験では能力

推定値の信頼性と反応予測精度が高いことが示されている。しかし、IDRT は能力の時系列変化を考慮していないため、学習過程での能力変化を表現できない。

これらの問題を解決するために、本論文では能力の時系列変化を表現する学習者ネットワークと独立な項目ネットワークにより学習者の項目への反応を予測する新たなモデルを提案する。提案手法は学習者の能力が解答する項目の特性に依存せず、複数のスキルに関する多次元の能力を表現できる。また、能力測定モデルである多次元 IRT モデルの能力パラメータベクトルと同様の解釈が可能となる [33]。すなわち、提案モデルは、IRT と同等の解釈性と Deep-IRT と同等の高精度な反応予測を実現できる。

さらに、既存の Deep-KT 手法 (DKT, DKVMN, Deep-IRT) では同じスキルを必要とする項目は全て等質とみなしており、各項目の特性の違いを反映していないことが反応予測を劣化させる原因となっている。そこで、提案手法では項目とその項目に必要なスキルの双方の特徴を考慮した反応予測を行う。

本研究では、提案手法と既存手法 (IRT, IDRT, DKT, DKVMN, Deep-IRT) を用いて学習者の反応予測精度の比較を行い、提案手法の有効性を示す。さらに、提案手法の能力パラメータ、困難度パラメータが高い解釈性をもつことを示す。

2. 関連手法

2.1 Item Response Theory

項目反応理論 (Item Response Theory; IRT) [26] は本来、テストデータのための測定モデルの一つであるが、近年では過去の学習データから学習者の能力値と項目の特性パラメータを推定し、未知の項目への反応を予測する KT 手法として用いられるようになって [27], [30], [31]。

ここでは最も一般的な 2 パラメータロジスティックモデル (2-Parameter Logistic Model; 2PLM) について説明する。2 母数ロジスティックモデルでは、能力値 $\theta_i \in (-\infty, \infty)$ の学習者 i が項目 j に正答する確率を次式で表す。

$$P_j(\theta_i) = \frac{1}{1 + \exp(-a_j(\theta_i - b_j))} \quad (1)$$

ここで、 $a_j \in [0, \infty)$ は項目 j の識別力パラメータ、 $b_j \in (-\infty, \infty)$ は項目 j の困難度パラメータと呼ばれる項目パラメータである。標準的な IRT では学習過

程での学習者の能力は固定値であるため、能力の時系列変化は反映されていない。

2.2 Deep Knowledge Tracing

DKT は過去の学習データと特徴量を利用し、Long short-term memory (LSTM) [25] を用いて項目への反応を予測する [7]。DKT ではスキル間の独立性が仮定されていないため、学習者のスキルの習得状態を多次元かつ連続量で表現できる。しかし、DKT は全てのスキルに対する習得状態を単一の隠れ変数ベクトルで表現するため、各スキルをどの程度習得したかを表現することはできない。

2.3 Dynamic Key-Value Memory Network

近年、新たな KT 手法として各スキルの習得状態を保存する Memory Network を用いた DKVMN が提案されている [4]。DKVMN では N 個の潜在スキルを仮定しており、各項目と潜在スキルの関係を key memory $M^k \in \mathbb{R}^{N \times d_k}$ に保存し、時点 t の各潜在スキルに対する能力を value memory $M_t^v \in \mathbb{R}^{N \times d_t}$ に保存する (図 1)。ここで、 d_k 、 d_t はチューニングパラメータである。また、 j 番目の項目は j 番目の要素のみが 1、他の要素が 0 の one-hot vector $q_j \in \mathbb{R}^J$ で表現し、時点 t の入力 q_j に対する反応予測を次のように行う。

はじめに、式 (2) で入力 q_j から生成される項目ベクトル $\beta_1^{(j)}$ を用いて、時点 t で解答する項目と l 番目の潜在スキルの関係性の強さを表すアテンション w_{tl} を計算する。

$$\beta_1^{(j)} = \mathbf{W}^{(\beta_1)} q_j + \tau^{(\beta_1)}, \quad (2)$$

$$w_{tl} = \text{Softmax} \left(M_t^l \beta_1^{(j)} \right) \quad (3)$$

ここで、 M_t^l は key memory の l 行目を示す。なお、本論文では \mathbf{W} 、 τ はそれぞれニューラルネットワークの重みパラメータ、バイアスパラメータとする。

次に、アテンションを用いた value memory の重み付き和から学習者ベクトル $\theta_1^{(t)}$ を計算し、 $\beta_1^{(j)}$ と組み合わせることで時点 t の項目 j への正答確率 p_{tj} を計算する。

$$\theta_1^{(t)} = \sum_{l=1}^N w_{tl} (M_t^l)^{\top} \quad (4)$$

$$\theta_2^{(t)} = \tanh \left(\mathbf{W}^{(\theta_2)} \left[\theta_1^{(t)}, \beta_1^{(j)} \right] + \tau^{(\theta_2)} \right) \quad (5)$$

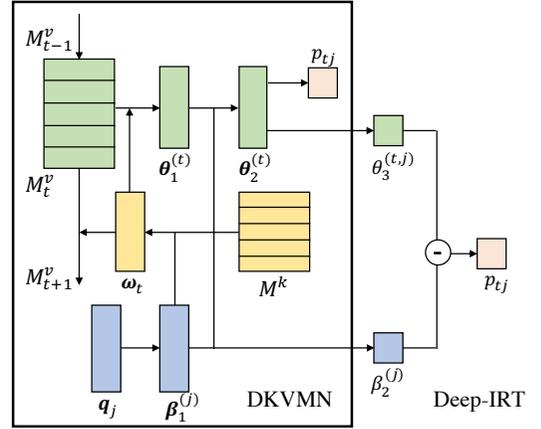


図 1 DKVMN, Deep-IRT 手法

$$p_{tj} = \sigma \left(\mathbf{W}^{(y)} \theta_2^{(t)} + \tau^{(y)} \right) \quad (6)$$

ここで、 M_{tl}^v は、 M_t^v の l 行目を示し、 $[\cdot]$ はベクトルの結合を表す。また、 $\sigma(\cdot)$ はシグモイド関数を示す。DKVMN は高い反応予測精度を示すことが知られているが、DKT と同様に学習者の能力パラメータや項目困難度パラメータをもたないため、解釈可能性が低いという問題が指摘されている [5]。

2.4 Deep-IRT

最新の KT 手法では、DKT や DKVMN のパラメータの解釈可能性を向上させた手法として、DKVMN と IRT を組み合わせた Deep-IRT が提案されている [5]。Deep-IRT は DKVMN に隠れ層を追加し、解釈可能な能力パラメータと項目困難度パラメータが得られるように設計されたモデルである (図 1)。具体的には、以下のように時点 t で項目 j を解答するときの能力値 $\theta_3^{(t,j)}$ と項目 j の困難度 $\beta_2^{(j)}$ を DKVMN の式 (2) と (5) を用いて算出する。

$$\theta_3^{(t,j)} = \tanh \left(\mathbf{W}^{(\theta_3)} \theta_2^{(t)} + \tau^{(\theta_3)} \right), \quad (7)$$

$$\beta_2^{(j)} = \tanh \left(\mathbf{W}^{(\beta_2)} \beta_1^{(j)} + \tau^{(\beta_2)} \right), \quad (8)$$

これを用いて、次のように正答確率を求める。

$$p_{tj} = \sigma \left(3.0 * \theta_3^{(t,j)} - \beta_2^{(j)} \right) \quad (9)$$

学習者の能力は M_t^v に圧縮されていると考えられるが、Deep-IRT では項目固有のアテンション w_t をもとに M_t^v の重み付き和から $\theta_3^{(t,j)}$ を計算しているため、得られる能力値が項目の特性に依存している。また、 $\theta_2^{(t)}$ を計算する際に、学習者ベクトルと項目ベク

トルの両方を用いており、能力値と困難度を分離することができていない。そのため、Deep-IRT は解釈可能なパラメータを持つ一方で、その解釈性は十分でないといえる。

2.5 Item Deep Response Theory

木下ら (2020) は深層学習と IRT を用いたテスト理論として Item Deep Response Theory (IDRT) を提案している [32]。IDRT は独立した項目ネットワークと学習者ネットワークを用いることで高い能力推定の信頼性と反応予測精度を示している。しかし、IDRT は能力の時系列変化を考慮していないため、学習過程での能力変化を表現できない。また、IRT と同様に複数のスキルの関係性を考慮した能力推定を行うことはできない。

3. 提案手法

前章では、学習過程での学習者の反応予測を行う KT 手法として IRT と深層学習手法を紹介した。本研究ではパラメータの解釈性と高精度な反応予測を両立するために、Deep-IRT と IDRT の特徴を組み合わせ、能力の時系列変化を表現する学習者ネットワークと独立な項目ネットワークにより学習者の項目への反応を予測する新たな Deep-IRT を提案する。提案モデルは学習者の能力推定値が項目の特性に依存せず、複数のスキルに関する多次元の能力を表現することが可能である。さらに、既存の深層学習手法では同じスキルを必要とする項目を全て同質とみなしているため、各項目の特性の違いが反映されておらず、反応予測を劣化させる原因となっている。そこで、提案モデルでは解答する項目とその項目が必要とするスキルの情報を入力とし、双方の特徴を考慮することで反応予測精度の向上を目指す。

提案モデルの概要図を図 2 に示す。提案モデルは学習者ネットワーク、項目ネットワークの 2 つの独立したニューラルネットワークから構成される。学習者ネットワークには DKVMN と同様のメモリネットワーク構造を用いており、項目ネットワークでは解答する項目とその項目が必要とするスキルの双方を入力とし、項目の困難度を出力する。

提案モデルでは、学習者 i の時点 t における項目 j への正答確率を次の手順で求める。なお、以下では可読性のため学習者 i の表記は省略する。学習者ネットワークでは IDRT に基づき、以下のように深層ニューラルネットワークを計算し、項目 j に解答する際の能

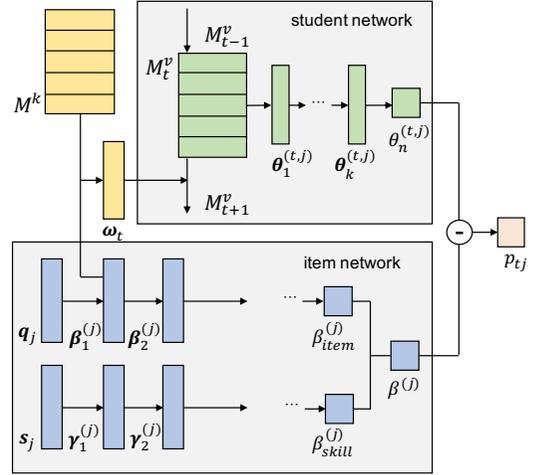


図 2 提案モデル

力値 $\theta^{(t,j)}$ を算出する。

$$\theta_1^{(t,j)} = \sum_{l=1}^N M_{tl}^v, \quad (10)$$

$$\theta_k^{(t,j)} = \tanh \left(W^{(\theta_k)} \theta_{k-1}^{(t,j)} + \tau^{(\theta_k)} \right) \quad (11)$$

ここで、 k は $k = \{2, 3, \dots, n\}$ である。学習者ネットワークの層数 n は実データに基づいて最適値を決定する。IDRT では $\theta_1^{(t)}$ もニューラルネットワークを用いて算出しているが、提案モデルでは時系列データに対応するため value memory の値に基づいて算出する。さらに、提案モデルでは Deep-IRT と異なり、式 (3) で求められるアテンション ω_t を $\theta_1^{(t,j)}$ の計算に用いないことで、能力パラメータ $\theta_n^{(t,j)}$ を解答する項目 j と独立に求めることができる。したがって、本研究では $\theta_n^{(t,j)}$ を学習者の能力ベクトルとみなす。これは測定モデルである多次元 IRT [33] における能力値と同様に解釈可能である。

次に、項目ネットワークで項目 j の困難度 β_{item}^j とその項目に必要なスキルの困難度 β_{skill}^j を求め、これらの和を解答する際の困難度とする。 β_{item}^j は n 層のニューラルネットワークで以下のように推定する。

$$\beta_1^{(j)} = W^{(\beta_1)} q_j + \tau^{(\beta_1)} \quad (12)$$

$$\beta_k^{(j)} = \tanh \left(W^{(\beta_k)} \beta_{k-1}^{(j)} + \tau^{(\beta_k)} \right) \quad (13)$$

$$\beta_{item}^{(j)} = W^{(\beta_n)} \beta_n^{(j)} + \tau^{(\beta_n)} \quad (14)$$

同様に、項目 j に必要なスキルに該当する要素のみが 1、他の要素は 0 のベクトル $s_j \in \mathbb{R}^S$ から β_{skill}^j を計

算する.

$$\gamma_1^{(j)} = \mathbf{W}^{(\gamma_1)} \mathbf{s}_j + \tau^{(\gamma_1)} \quad (15)$$

$$\gamma_k^{(j)} = \tanh\left(\mathbf{W}^{(\gamma_k)} \gamma_{k-1}^{(j)} + \tau^{(\gamma_k)}\right) \quad (16)$$

$$\beta_{skill}^{(j)} = \mathbf{W}^{(\gamma_m)} \gamma_n^{(j)} + \tau^{(\gamma_m)} \quad (17)$$

項目ネットワークの層数は学習者ネットワークと同様に $k = \{2, 3, \dots, n\}$ から実データに基づいて最適値を決定する. 提案モデルと Deep-IRT の相違点は, 学習者の能力パラメータと困難度パラメータが完全に分離されていることである. これにより学習者の能力推定値が項目の特性に依存せず, 能力値と困難度の解釈性が向上することが期待される.

最後に, 能力値と困難度の差から正答確率を予測する.

$$p_{tj} = \sigma\left(\theta_n^{(t,j)} - (\beta_{item}^{(j)} + \beta_{skill}^{(j)})\right) \quad (18)$$

提案モデルでは全ての重みパラメータ, バイアスパラメータと key memory, value memory の各要素をすべて同時に学習する. 具体的には, 学習者の実際の反応 y_t (正答=1, 誤答=0) を用いて以下のクロスエントロピー ℓ を最小化するように全てのパラメータを更新する.

$$\ell = - \sum_t (y_t \log p_{tj} + (1 - y_t) \log(1 - p_{tj})) \quad (19)$$

提案モデルは全てのパラメータについて微分可能に設計されており, 確率的勾配法を用いて容易にパラメータを推定することができる. パラメータ更新のために時点 t の入力 q_j と実際の反応 y_j をもとに埋め込みベクトル \mathbf{c}_j を計算する.

$$\mathbf{c}_j = \begin{cases} [\mathbf{0}, \mathbf{q}_j] & y_j = 1 \\ [\mathbf{q}_j, \mathbf{0}] & y_j = 0 \end{cases} \quad (20)$$

ここで, $\mathbf{0}$ は項目数だけ 0 を並べたベクトルである. 最後に, \mathbf{c}_j とアテンション \mathbf{w}_t (式 (3)) をもとに value memory \mathbf{M}_t^v を更新する.

$$\mathbf{v}_t = \mathbf{W}^v \mathbf{c}_j + \tau^v \quad (21)$$

$$\mathbf{e}_t = \sigma(\mathbf{W}^e \mathbf{v}_t + \tau^e) \quad (22)$$

$$\mathbf{a}_t = \tanh(\mathbf{W}^a \mathbf{v}_t + \tau^a) \quad (23)$$

$$\tilde{\mathbf{M}}_{(t+1)l}^v = \mathbf{M}_{tl}^v \otimes (1 - \mathbf{w}_{tl} \mathbf{e}_t) \quad (24)$$

$$\mathbf{M}_{(t+1)l}^v = \tilde{\mathbf{M}}_{(t+1)l}^v + \mathbf{w}_{tl} \mathbf{a}_t^T \quad (25)$$

\mathbf{e}_t はそれまでの value memory の値をどの程度保存しておくか制御し, \mathbf{a}_t は時点 t の結果をどの程度反映するか制御しているとみなせる.

4. 予測精度評価

本章では, これまで Knowledge Tracing に用いられてきた代表的な手法 (IRT, IDRT, DKT, DKVMN, Deep-IRT) と提案手法を用いて学習者の反応予測を行う. 具体的には, 10 分割交差検証を用いて学習履歴データを訓練データ, 検証データ, 評価データに分割し, 訓練データ, 検証データから推定したパラメータを利用して評価データの反応予測を行う. 予測精度の評価指標として Accuracy (一致割合), AUC スコア, F 値を算出する.

本実験では, オンライン学習システムで収集された公開データセット ASSIST2009^(注1), ASSIST2015^(注2), Statics2011^(注3), KDDcup^(注4) を用いる. 学習データの概要を表 1 に示す. 各学習データには学習者の反応 $y_j = \{1, 0\}$, 解答した項目番号とスキルタグが付与されている. 学習データは学習者ごとに解答数が大きく異なることが報告されている [5]. 本研究ではデータの偏りを避けるために, 先行研究 [5] で行われた実験条件と同様に, 入力する学習データの上限を学習者 1 人につき 200 項目とした. 表中の平均解答数は入力データの上限を 200 項目とした場合に学習者が解答した全項目数の平均値を示す. スパース率は 10 人以下の学習者が解答した項目の割合を示し, 項目パラメータが少数データから推定された割合を示す. ただし, ASSIST2015 データにはスキルの情報しか含まれておらず, 項目が区別できないため表 1 の項目数と結果を示した表 2 では N/A と表記する.

本研究における Deep-KT 手法 (DKT, DKVMN, Deep-IRT, 提案手法) では, IRT 手法と同様に項目への反応を入力値とする場合と, Piech ら [7] と同様に各スキルへの反応を入力とする場合の両方の予測精度を算出する. スキル入力では同じスキルのすべての項目を等価とみなし, 共通の困難度パラメータをもつ. ただし,

(注1): <https://sites.google.com/site/assistmentsdata/home/assistance-2009-2010-data>

(注2): <https://sites.google.com/site/assistmentsdata/home/2015-assistments-skill-builder-data>

(注3): <https://pslcdatashop.web.cmu.edu/DatasetInfo?datasetId=507>

(注4): <https://pslcdatashop.web.cmu.edu/KDDCup/downloads.jsp>

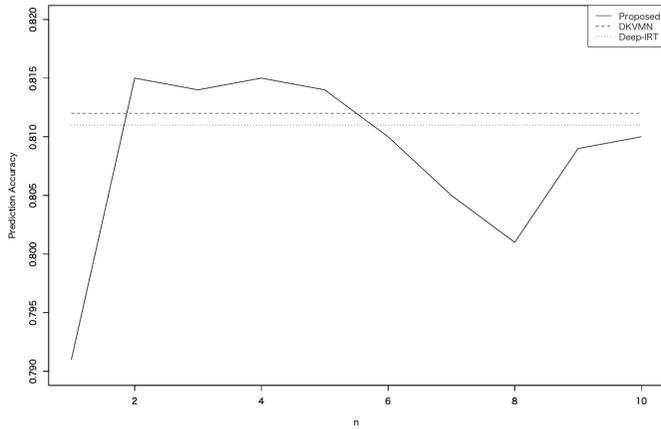


図 3 層数の変化による予測精度の変化

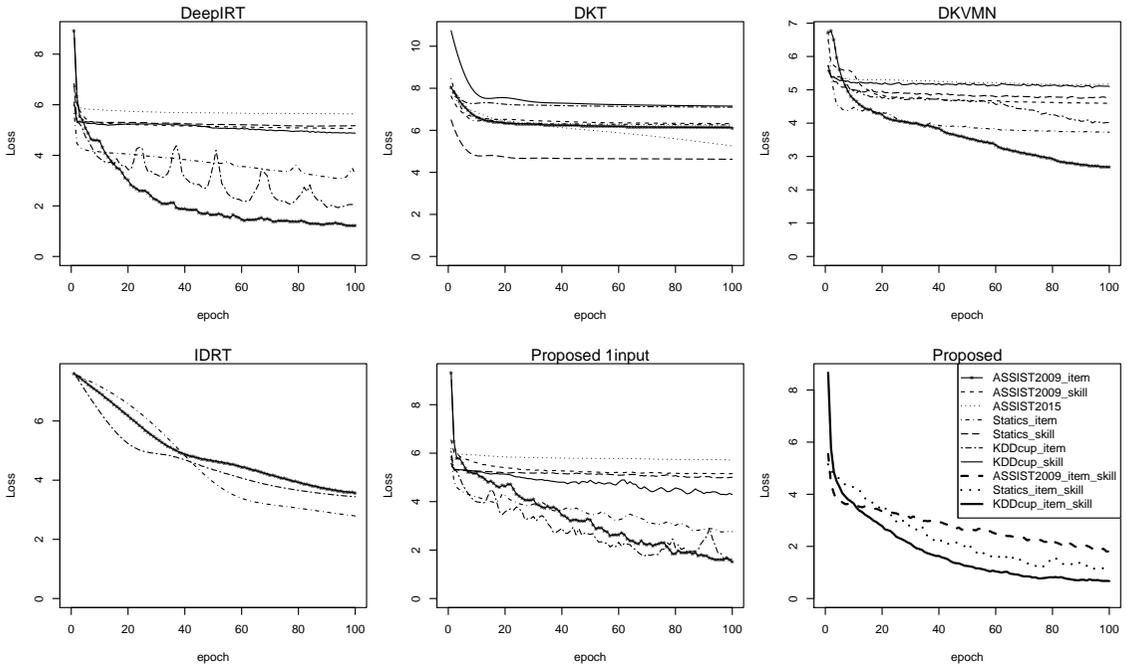


図 4 クロスエントロピーの収束状態

IDRT は項目への反応予測を前提に開発されたモデルであり、スキルへの反応予測を想定していないため項目のみを入力とし、提案手法は解答した項目とその項目に付与されたスキルの双方の情報を入力とする。また、ASSIST2015 データにはスキルの情報しか含まれておらず、項目が区別できないため Deep-KT 手法のみに適用した。

ここで、提案手法において学習者・項目ネットワークの層数を変化させた場合の ASSIST2009 での反応予測精度を図 3 に示す。図 3 より $n = 2$ のときに最大の予測精度を持つため、以下の実験では全て $n = 2$ とした。隠れ層の次元数と DKVMN, DeepIRT, 提案手法のメモリの次元数 N は先行研究と同様に $\{5, 10, 20, 50, 100\}$ から交差検証を用いて最適値を

表 1 データセットの詳細

Dataset	学習者数	スキル数	項目数	正答率	平均解答数	スパース率
ASSIST2009	3,776	111	26,587	68.0%	70.8	55.2%
ASSIST2015	19,840	100	N/A	73.2%	34.2	12.6%
Statics2011	229	41	1,095	77.7%	180.9	2.6%
KDDcup	820	43	476	78.3%	11.9	57.8%

表 2 学習者の反応予測精度

		IRT		DKT		DKVMN		Deep-IRT		IDRT			提案手法		
		item	skill	item	skill	item	skill	item	skill	item	item	skill	item&skill		
ASSIST2009	Acc	0.72	0.765	0.759	0.637	0.763	0.683	0.768	0.71	0.711	0.768	0.765			
	AUC	0.785	0.8	0.781	0.659	0.807	0.71	0.806	0.77	0.75	0.818	0.810			
	F1	0.636	0.713	0.697	0.602	0.714	0.647	0.718	0.613	0.651	0.725	0.722			
ASSIST2015	Acc	N/A	N/A	0.754	N/A	0.732	N/A	0.727	N/A	N/A	0.752	0.752			
	AUC	N/A	N/A	0.73	N/A	0.749	N/A	0.747	N/A	N/A	0.751	0.751			
	F1	N/A	N/A	0.433	N/A	0.541	N/A	0.54	N/A	N/A	0.543	0.543			
Statics2011	Acc	0.816	0.769	0.777	0.805	0.78	0.817	0.787	0.81	0.819	0.789	0.822			
	AUC	0.819	0.666	0.652	0.819	0.721	0.822	0.722	0.823	0.821	0.721	0.821			
	F1	0.581	0.483	0.461	0.679	0.521	0.681	0.526	0.585	0.679	0.522	0.69			
KDDcup	Acc	0.733	0.777	0.784	0.76	0.773	0.779	0.792	0.72	0.78	0.786	0.802			
	AUC	0.614	0.549	0.538	0.565	0.594	0.561	0.588	0.61	0.57	0.588	0.601			
	F1	0.522	0.439	0.439	0.464	0.439	0.447	0.455	0.501	0.455	0.469	0.478			
Average_item	Acc	0.768	0.771	N/A	0.745	N/A	0.765	N/A	0.760	0.773	N/A	0.793			
	AUC	0.760	0.707	N/A	0.713	N/A	0.727	N/A	0.753	0.739	N/A	0.761			
	F1	0.636	0.598	N/A	0.631	N/A	0.639	N/A	0.625	0.641	N/A	0.668			
Average_skill	Acc	N/A	N/A	0.769	N/A	0.762	N/A	0.769	N/A	N/A	0.774	0.785			
	AUC	N/A	N/A	0.675	N/A	0.718	N/A	0.716	N/A	N/A	0.720	0.746			
	F1	N/A	N/A	0.508	N/A	0.554	N/A	0.560	N/A	N/A	0.565	0.608			

決定した [5]. メモリの次元数以外の調整すべきチューニングパラメータは先行研究 [4], [5] で最適化された値を用いた.

図 4 に各手法を用いて訓練データでパラメータを推定した際のクロスエントロピー (式 (19)) を示す. IDRT は各学習データにおいて項目のみを入力としたため, 他の手法よりデータ数が少ないことに注意されたい. Proposed input は提案手法のうち項目またはスキルのみの情報を入力とし, Proposed は項目とスキルの情報を入力とした場合を表す. 縦軸の Loss はクロスエントロピー, 横軸の epoch は学習回数を表す. グラフ線の形式と学習データは全ての手法で Proposed 内で定義されている対応に統一した.

図 4 より, 項目またはスキルのみを入力とした提案手法は DeepIRT とほぼ同様の収束の早さを示し, 項目とスキルを入力とした提案手法は他手法より小さいクロスエントロピーに早く収束していることがわかる. これらより, 項目とスキルを入力とすることによりパラメータ推定効率が向上していることがわかる.

次に, 100 回の学習のうち, 検証データにおける AUC スコアが最も高い時点のパラメータを用いて評価データの反応予測を行う. 予測精度の実験結果を表 2 に示す. 表中の Average_item は項目入力可能なデータセットにおける予測精度の平均値であり,

Average_skill はスキル入力可能なデータセットにおける予測精度の平均値である. 表 2 よりいずれの平均値においてもすべての指標で項目とスキルの双方の情報を入力とした提案手法がもっとも高い反応予測精度を示した. 提案手法は既存手法である IDRT の予測精度を上回っており, 時系列モデルに拡張することで反応予測を向上できたと考えられる.

ASSIST2009, Statics2011, KDDcup においては, Deep-KT 手法はスキル入力と項目入力の予測精度に差があり, DKT, DKVMN, Deep-IRT, 提案手法のいずれも同様の特徴を示している. スキルのみの入力ではスキル内のすべての項目を等価とみなしているため, 項目の特性が異なる場合は困難度パラメータを正しく推定できず, 予測精度が低下している可能性がある. 一方, 項目入力は項目ごとに困難度パラメータを推定するため, 項目の特性が異なる場合に高い予測精度を示すと考えられる. 従って, スキル入力と項目入力のどちらかのみでは各項目の特性によって反応予測精度が安定しない可能性が高い. つまり, 提案手法は項目とスキルの双方の特性を考慮することで, 反応予測精度に差がある場合でも様々なデータに頑健な反応予測が可能であると言える.

項目入力の結果に注目すると, 提案手法では Acc

と F1 の平均値で最も高い精度を示したが、AUC は IRT が高い精度を示した。特に KDDcup では IRT が AUC や F1 値について高い精度を示している。KDDcup は正答率が高く、反応に偏りのあるデータであり、さらに学習者の平均解答数が極端に少ない。このことから、Deep-KT 手法は IRT に比べて反応の偏りと少数データに脆弱である可能性がある。スキル入力の提案手法ではすべての指標において既存の Deep-KT 手法より高い予測精度を示した。本モデルは、二つの独立な深層ネットワークを導入したために、従来の Deep-IRT に比べてパラメータ数が大幅に増加している。オッカムの剃刀のルールに従えば、予測精度が向上することは奇異かもしれないが、近年、深層学習で冗長なネットワークを構成することで予測精度を向上できることが理論的に解明されてきている [34], [35]。提案手法はこれらの性質によって予測精度を向上できたと解釈できる。

5. 解釈性の評価実験

5.1 能力パラメータの評価実験

5.1.1 能力パラメータの推定値比較

前節では、提案手法は既存手法と比較して予測精度が高いことを示した。本節では、実データを用いて提案手法で推定した多次元の能力パラメータが高い解釈性をもつことを示す。Yeung [5] では Deep-IRT を用いて推定した各スキルにおける能力値推移を分析し、その解釈性の高さを主張している。しかし、彼らによって公開された Deep-IRT のプログラムコードでは一次元の能力値推移しか出力できず、論文で示された複数スキルに対応した結果を再現できない。このため、本実験では、式 (7) で得られる $\theta_3^{(t,j)}$ を多次元で出力した値を Deep-IRT における多次元のスキルの能力値推移とする。一方、提案手法では項目とスキルの両方を入力データとすることで、各項目に解答したときの多次元のスキルの能力値推移を容易に推定することができる。

実データにおける評価実験では、学習者の真の能力値が分からないため、各モデルで推定した能力値推移を可視化して比較する。本実験では、ASSIST2009 のデータから先行研究 [5] で考察されている 4 つのスキルに関する項目のみを抽出した学習履歴データを作成し、4 次元の能力パラメータベクトルをもつモデルを学習した。ある学習者の 30 項目に対する反応データを用いて提案手法と Deep-IRT で推定した能力値推移

をそれぞれ図 5, 図 6 に示す。縦軸は左側が正規化した学習者の能力値、右側が学習者の項目への反応、横軸は項目を表し、右に進むほど学習が進むことを表している。図 5, 図 6 の $\theta_1 \sim \theta_4$ はそれぞれ同じスキルの能力値を表す。

図 5 より、提案手法の能力パラメータは以下のように解釈できる。

(1) 1~3 項目は "ordering fractions" のスキルに対応する項目が出題されており、学習者が正答すると能力値が向上し、誤答すると降下することから、 θ_1 は "ordering fractions" に対する能力値を表す。

(2) 6~17 項目は "equation solving two or few steps" のスキルに対応する項目が出題されている。学習者が正答すると能力値が向上し、誤答すると降下することから、 θ_2 は "equation solving two or few steps" のスキルに対する能力値を表す。

(3) 18~24 項目は "finding percents" のスキルに対応する項目が出題され、学習者はすべての項目に誤答している。それらの項目に対して θ_3 の値が最も大きく低下していることから、 θ_3 は "finding percents" のスキルに対する能力値を表す。

(4) 4, 5 項目と 25~30 項目は "equation solving two or few steps" のスキルに対応する項目が出題されている。 θ_4 は学習者が誤答した 4, 5 項目で低下し、連続で正答した 26~39 項目で上昇しているため、"equation solving two or few steps" のスキルに対する能力値を表す。

以上のように、提案手法は多次元スキルにおける能力値推移を同時に計算でき、高い解釈性を有する。提案手法は各スキル間の独立性を仮定していないため、 θ_2 が上昇している項目 6~17 については θ_1 , θ_3 , θ_4 も上昇している。つまり、他のスキルに対応した項目に解答した場合でも能力値の変化が生じていることがわかる。一方、図 6 より、Deep-IRT では "ordering fractions" のスキルに対する能力値 θ_1 が項目 18~24 の間で上昇しているが、実際には "finding percents" の項目に連続で誤答しており、 θ_1 のスキルが上昇する可能性は低い。さらに項目 26~29 の間では正答が続いているにもかかわらず、 θ_2 以外の能力値が低下している。この結果から、Deep-IRT の能力値は学習者の反応データを正確に反映できず、解釈可能性が低いことがわかる。また、急激な能力値変動が多いため安定した能力値推定が行えておらず、これも解釈を難しくしている。

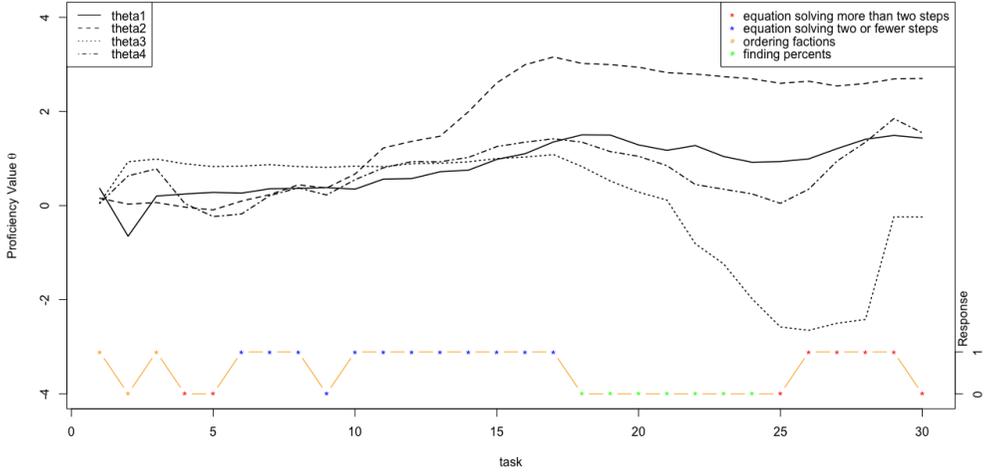


図 5 提案手法における多次元の能力パラメータ

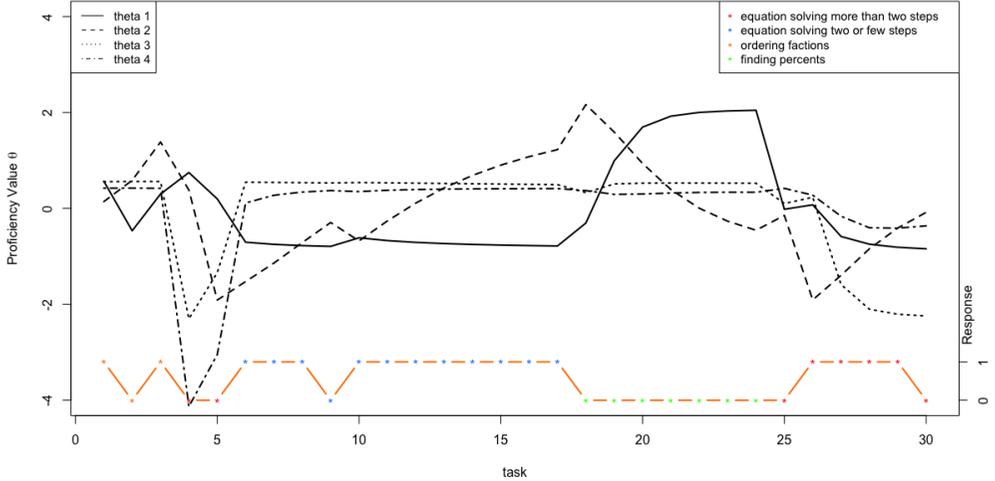


図 6 Deep-IRT における多次元の能力パラメータ

5.1.2 能力パラメータの特性比較

本章では 5.1.1 章と同様に ASSIST2009 のデータを用いて推定した能力パラメータの特性について考察する。提案手法と Deep-IRT における能力パラメータ特性を比較するため、以下の指標を算出した。全学習者数を I 、学習者 i の学習過程を時点 $t \in \{1, \dots, T_i\}$ 、時点 t での学習者 i の能力値 $\theta_n^{(t,j)}$ を θ_i^t と表記する。

(1) 反応データとの相関：学習者 i の各時点 t での反応データ y_{it} (正答=1・誤答=0) と能力推定値 θ_i^t の相関係数 R_i と全学習者の平均値 R 。 \bar{y}_i は学習者 i の反応データの平均値、 $\bar{\theta}_i$ は学習過程で推定された能

力値の平均値を表す。

$$\bar{y}_i = \frac{1}{T_i} \sum_{t=1}^{T_i} y_{it}, \quad \bar{\theta}_i = \frac{1}{T_i} \sum_{t=1}^{T_i} \theta_i^t \quad (26)$$

$$R_i = \frac{\frac{1}{T_i} \sum_{t=1}^{T_i} (\theta_i^t - \bar{\theta}_i)(y_{it} - \bar{y}_i)}{\sqrt{\frac{1}{T_i} \sum_{t=1}^{T_i} (\theta_i^t - \bar{\theta}_i)^2} \sqrt{\frac{1}{T_i} \sum_{t=1}^{T_i} (y_{it} - \bar{y}_i)^2}} \quad (27)$$

$$R = \frac{1}{I} \sum_{i=1}^I R_i \quad (28)$$

(2) 能力値変動：学習者 i の時点 $t-1$ から t への能力変動幅の平均値 H_i と全学習者の平均値 H .

$$H_i = \frac{1}{T_i - 1} \sum_{t=2}^{T_i} |\theta_i^t - \theta_i^{t-1}| \quad (29)$$

$$H = \frac{1}{I} \sum_{i=1}^I H_i \quad (30)$$

(3) 個人内分散：学習過程で推定された学習者 i の能力値の分散 S_i と全学習者の平均値 S .

$$S_i = \frac{1}{T_i} \sum_{t=1}^{T_i} (\theta_i^t - \bar{\theta}_i)^2 \quad (31)$$

$$S = \frac{1}{I} \sum_{i=1}^I S_i \quad (32)$$

(4) 個人間分散：時点 t で推定された全学習者の能力値の個人間分散 S'_t と全時点での平均値 S' . 50 項目以上学習した学習者の時点 $t \in \{1, \dots, 50\}$ での能力値のみを対象とする.

$$\bar{\theta}^t = \frac{1}{I} \sum_{i=1}^I \theta_i^t \quad (33)$$

$$S'_t = \frac{1}{I} \sum_{i=1}^I (\theta_i^t - \bar{\theta}^t)^2 \quad (34)$$

$$S' = \frac{1}{50} \sum_{t=1}^{50} S'_t \quad (35)$$

(5) 平均値：全学習者の能力値の平均値 $\bar{\theta}$.

$$\bar{\theta} = \frac{1}{I} \sum_{i=1}^I \bar{\theta}_i \quad (36)$$

これらの指標を表 3 に示した.

表 3 能力パラメータの特性比較

モデル	Deep-IRT	提案手法
相関係数 R	0.390	0.613
能力値変動 H	0.298	0.190
個人内分散 S	0.108	0.133
個人間分散 S'	0.140	0.208
平均値 $\bar{\theta}$	0.299	0.027

表 3 より, 提案手法は反応データと能力値推移の相関係数 R が Deep-IRT に比較して高いことから 5.1.1 章で述べたように Deep-IRT より能力推定値の解釈可能性が高い.

また, 提案手法は Deep-IRT と比較して能力値変動

H が小さく, 個人内分散 S が大きい. 各時点での能力値変動 H が小さいことは能力値が緩やかに推移することを表している. 個人内分散 S は各学習者の学習過程での能力値分散を表しており, 値が大きいほど能力値推移の範囲が広いことを意味する. つまり, 提案手法の能力値は Deep-IRT に比べて穏やかであるが大きく変動する表現力の高いモデルであるといえる. さらに, 提案手法は個人間分散 S' が大きいことから学習者間の能力値をよく識別していることがわかる.

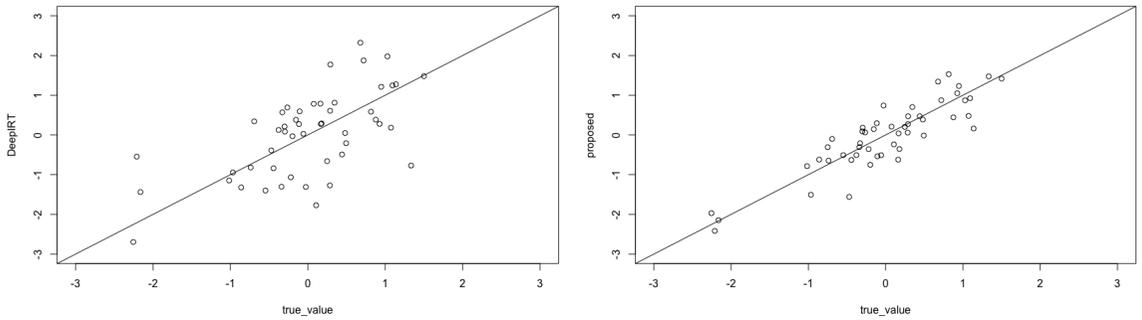
一方, Deep-IRT では能力値変動 H が大きく, 個人内分散 S は大きくないことから限定された範囲で急激な能力変動が起きやすいことがわかる. また, 個人間分散 S' が小さいことから学習者間の能力値の識別力が低く, 各学習者が類似の能力値で推定されていると解釈できる. さらに, 能力推定値の平均値 $\bar{\theta}$ では Deep-IRT が提案手法より高い値を示した. このことは, これまで分析してきたように Deep-IRT の能力推定値は提案手法に比較して不安定であることが影響しているのかもしれない.

5.2 困難度パラメータの評価実験

次に, 提案手法と Deep-IRT において困難度パラメータの推定精度の比較を行う. 本研究では提案手法が IRT と同等の困難度パラメータの解釈性をもつことを目指しているため, IRT の中でも一般的な 2PLM(式 (1)) に基づいて以下の分布から発生させたシミュレーションデータを用いて分析する.

$$\theta \sim N(0, 1), \quad a \sim LN(0, 1), \quad b \sim N(0, 1)$$

各項目の真の困難度と推定した困難度パラメータ値の誤差を算出することにより, 困難度パラメータの推定精度を比較する. 真の困難度と Deep-IRT を用いて推定した困難度パラメータの散布図を図 7(a) に, 真の困難度と提案手法を用いて推定した困難度パラメータの散布図を図 7(b) に示す. 図 7 より, 提案手法は Deep-IRT と比較して真の困難度に近い値で困難度パラメータを推定していることがわかる. 実際に関 7(a) の相関係数は 0.611 であるのに対し, 関 7(b) の相関係数は 0.886 と大きく上回った. Deep-IRT の困難度パラメータの相関係数が低いのは, 能力パラメータと困難度パラメータを完全に分離できていないことが原因だと考えられる. すなわち, 提案手法は学習者と項目を完全に分離することで, 解釈性の高い困難度パラメータの推定が可能になったことを意味する. したがって, 提案手法は IRT と同等の解釈性の高い測定モ



(a)Deep-IRT による困難度推定値

(b) 提案手法による困難度推定値

図 7 推定困難度パラメータと真の値の散布図

デルであることが示された。

6. むすび

本研究では、Deep-IRT と IDRT の特徴を組み合わせ、能力の時系列変化を表現する学習者ネットワークと独立な項目ネットワークにより学習者の項目への反応を予測するモデルを提案した。提案手法は学習者の能力が解答する項目の特性に依存せず、複数のスキルに関する多次元の能力を表現できる。さらに、既存の Deep-KT 手法では同じスキルを必要とする項目は全て同質とみなしており、各項目の特性の違いが反映されていなかったが、提案手法では項目とスキルの双方の特徴を考慮した反応予測を行うことで、反応予測精度が向上することを示した。

提案手法は二つの独立な深層ネットワークを導入したために従来の Deep-IRT に比べてパラメータ数が大幅に増加している。一般にパラメータ数の増加は予測精度を低下させる可能性が高いと考えられるが、近年の研究では冗長なネットワークを構成することでより予測精度が向上することが理論的に解明されてきている [34], [35]。提案手法はパラメータ数が増加しているものの、独立な学習者・項目ネットワークを利用し、反応予測に重要な項目とスキルの双方の特徴を考慮することで、予測精度が向上したと考えられる。また、提案手法は能力パラメータと困難度パラメータについて IRT と同等の高い解釈性を持ち、Deep-IRT より高精度な推定が可能であることを示した。

最新の研究では、Deep-KT 手法に項目の内容を組み込んで学習することにより、スキルタグを付与しなくても各項目のクラスタリングを自動で行う手法が開

発されている [36]。また、項目の内容を考慮することで各スキルと項目の依存関係や特徴量をより高精度に推定できる [37]。これらの機能を提案手法に組み込むことにより、表現力の高いモデルに拡張することが可能である。さらに、Ueno and Miyazawa(2015, 2018) はヒントを含む学習において、従来の IRT を用いて学習者にヒントを提示した場合の正答確率を予測し、学習者が誤答した場合に学習効率が最大となる予測正答確率 50% の量のヒントを提示するアダプティブラーニングシステムを開発している [38], [39]。提案手法はヒントの予測モデルに簡単に拡張できるため、今後は提案手法を [38], [39] のシステムに搭載し、学習者の反応予測精度を向上させたアダプティブラーニングシステムを実現していきたい。

謝辞 本研究は JSPS 科研費 JP19H05663, JP19K21751 の助成を受けたものです。

文 献

- [1] A.T. Corbett and J.R. Anderson, “Knowledge tracing: Modeling the acquisition of procedural knowledge,” *User Modeling and User-Adapted Interaction*, vol.4, no.4, pp.253–278, Dec. 1994.
- [2] R. Weng and D. Coad, “Real-time bayesian parameter estimation for item response models,” *Bayesian Analysis*, vol.13, pp.115–137, 2017.
- [3] W. Xiaojing, J.O. Berger, and D.S. Burdick, “Bayesian analysis of dynamic item response models in educational testing,” *The Annals of Applied Statistics*, vol.7, no.1, pp.126–153, 2013.
- [4] J. Zhang, X. Shi, I. King, and D.-Y. Yeung, “Dynamic key-value memory network for knowledge tracing,” *Proceedings of the 26th International Conference on World Wide Web*, pp.765–774, WWW ’17, International World Wide Web Conferences Steering Committee, Republic and Canton of Geneva, CHE,

- 2017.
- [5] C. Yeung, "Deep-irt: Make deep learning based knowledge tracing explainable using item response theory," Proceedings of the 12th International Conference on Educational Data Mining, EDM, 2019.
- [6] M. Khajah, R.V. Lindsey, and M.C. Mozer, "How deep is knowledge tracing?," ArXiv, vol.abs/1604.02416, 2016.
- [7] C. Piech, J. Bassen, J. Huang, S. Ganguli, M. Sahami, L.J. Guibas, and J. Sohl-Dickstein, "Deep knowledge tracing," Advances in Neural Information Processing Systems 28, eds. by C. Cortes, N.D. Lawrence, D.D. Lee, M. Sugiyama, and R. Garnett, pp.505–513, Curran Associates, Inc., 2015.
- [8] Z. Pardos and N. Heffernan, "N.t. modeling individualization in a bayesian networks implementation of knowledge tracing," In Proceedings of the 18th International Conference on User Modeling, Adaption, and Personalization, pp.255–266, 06 2010.
- [9] Z. Pardos and N. Heffernan, "Kt-idem: Introducing item difficulty to the knowledge tracing model," Proceedings of 19th International Conference on User Modeling, Adaptation and Personalization (UMAP 2011), pp.243–254, 01 2011.
- [10] J. Lee and E. Brunskill, "The impact on individualizing student models on necessary practice opportunities," Proceedings of the Fifth International Conference on Educational Data Mining, pp.118–125, 01 2012.
- [11] M.V. Yudelson, K.R. Koedinger, and G.J. Gordon, "Individualized bayesian knowledge tracing models," Artificial Intelligence in Education, pp.171–180, Springer Berlin Heidelberg, Berlin, Heidelberg, 2013.
- [12] M. Khajah, Y. Huang, J. Gonzalez-Brenes, M. Mozer, and P. Brusilovsky, "Integrating knowledge tracing and item response theory: A tale of two frameworks," Personalization Approaches in Learning Environments, vol.1181, 2014.
- [13] M.M. Khajah, R.M. Wing, R.V. Lindsey, and M.C. Mozer, "Integrating latent-factor and knowledge-tracing models to predict individual differences in learning," In submission, 2014.
- [14] Y. Gong, J. Beck, and N. Heffernan, "Comparing knowledge tracing and performance factor analysis by using multiple model fitting procedures," Intelligent Tutoring Systems, pp.35–44, Springer Berlin Heidelberg, 2010.
- [15] R. Baker, A. Corbett, and V. Aleven, "More accurate student modeling through contextual estimation of slip and guess probabilities in bayesian knowledge tracing," Intelligent Tutoring Systems, pp.406–415, Springer Berlin Heidelberg, 2008.
- [16] R.S. Baker and P.S. Inventado, "Educational data mining and learning analytics," Springer New York, vol.14, pp.61–75, 2014.
- [17] M. Yudelson, O. Medvedeva, and R. Crowley, "A multifactor approach to student model evaluation," User Model. User-Adapt. Interact., vol.18, pp.349–382, 09 2008.
- [18] M. Ueno and K. Nagaoka, "Learning log database and data mining system for e-learning," On-line statistical outlier detection of irregular learning processes," Proceedings of the International Conference on Advanced Learning, 2002.
- [19] M. Ueno, "Data mining and text mining technologies for collaborative learning in an ilms" samurai", IEEE International Conference on Advanced Learning Technology, 2004.
- [20] M. Ueno, "Animated agent to maintain learner's attention in e-learning," E-Learn: World Conference on E-Learning in Corporate, Government, Healthcare, pp.194–201, 2004.
- [21] M. Ueno, "Online outlier detection system for learning time data in e-learning and its evaluation," proceedings of the 7th IASTED International Conference on Computers and Advanced Technology in Education, pp.248–253, 2004.
- [22] M. Ueno, "Animated pedagogical agent based on decision tree for e-learning," Advanced Learning Technologies, 2005. ICALT 2005. Fifth IEEE International Conference, pp.188–192, 2005.
- [23] R. Baker, A. Corbett, S. Gowda, A. Wagner, B. MacLaren, L. Kauffman, A. Mitchell, and S. Giguere, "Contextual slip and prediction of student performance after use of an intelligent tutor," Proceedings of the 18th Annual Conference on User Modeling, Adaptation and Personalization, vol.6075, pp.52–63, 2010.
- [24] R. Pelánek, "Conceptual issues in mastery criteria: Differentiating uncertainty and degrees of knowledge," 19th International Conference on Artificial Intelligence in Education, vol.1, pp.450–461, 06 2018.
- [25] H. Sepp and S. Jurgen, "Long short-term memory," Neural Computation, vol.14, pp.1735–1780, 1997.
- [26] F.B. Baker and S.H. Kim, Item Response Theory: Parameter Estimation Techniques, Second Edition, Statistics: A Series of Textbooks and Monographs, Taylor & Francis, 2004.
- [27] K.H. Wilson, Y. Karklin, B. Han, and C. Ekanadham, "Back to the basics: Bayesian extensions of irt outperform neural networks for proficiency estimation," 9th International Conference on Educational Data Mining, vol.1, pp.539–544, 06 2016.
- [28] A.D. Martin and K.M. Quinn, "Dynamic ideal point estimation via markov chain monte carlo for the u.s. supreme court, 1953–1999," Political Analysis, vol.10, pp.134–153, 2002.
- [29] C. Ekanadham and Y. Karklin, "T-skirt: Online estimation of student proficiency in an adaptive learning system," CoRR, vol.abs/1702.04282, 2017.

- [30] 堤瑛美子, 宇都雅輝, 植野真臣, “ダイナミックアセスメントのための隠れマルコフ irt モデル,” 電子情報通信学会論文誌, vol.J102-D, pp.79–92, 02 2019.
- [31] 堤瑛美子, 植野真臣, “Knowledge tracing のための sliding window 隠れマルコフ irt,” 電子情報通信学会論文誌, vol.J103-D, pp.894–905, Dec. 2020.
- [32] 木下 涼, 植野真臣, “深層学習によるテスト理論: item deep response theory,” 電子情報通信学会論文誌, vol.J103-D, pp.314–329, 2020.
- [33] T. Ackerman, “Unidimensional irt calibration of compensatory and noncompensatory multidimensional items,” Applied Psychological Measurement, vol.13, pp.113–127, 06 1989.
- [34] J. Lee, L. Xiao, S. Schoenholz, Y. Bahri, J. Sohl-Dickstein, and J. Pennington, “Wide neural networks of any depth evolve as linear models under gradient descent,” ArXiv, vol.abs/1902.06720, 2019.
- [35] S. Goldt, M.S. Advani, A.M. Saxe, F. Krzakala, and L. Zdeborová, “Dynamics of stochastic gradient descent for two-layer neural networks in the teacher-student setup,” NeurIPS 2019, 2019.
- [36] H. Tong, Y. Zhou, and Z. Wang, “Exercise hierarchical feature enhanced knowledge tracing,” Artificial Intelligence in Education – 21th International Conference, AIED., pp.324–328, 2020.
- [37] S. Yu, L. Qingwen, L. Qi, H. Zhenya, Y. Yu, C. Enhong, D. Chris, W. Si, and H. Guoping, “Exercise-enhanced sequential modeling for student performance prediction,” Proceedings of 32nd AAAI Conference on Artificial Intelligence, pp.2435–2443, 2018.
- [38] M. Ueno and Y. Miyazawa, “Probability based scaffolding system with fading,” Artificial Intelligence in Education – 17th International Conference, AIED., pp.237–246, 2015.
- [39] M. Ueno and Y. Miyazawa, “Irt-based adaptive hints to scaffold learning in programming,” IEEE Transactions on Learning Technologies, vol.11, pp.415–428, Oct. 2018.

(xxxx 年 xx 月 xx 日受付)



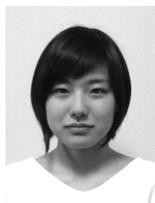
木下 涼

2018 年電気通信大学大学院情報理工学研究科博士前期課程修了, 同年, 電気通信大学大学院情報理工学研究科博士後期課程入学, 在学中.



植野 真臣 (正員)

1992 年神戸大学大学院教育学研究科修了, 1994 年東京工業大学大学院総合理工学研究科修了. 博士 (工学). 東京工業大学, 千葉大学, 長岡技術科学大学を経て 2006 年より電気通信大学助教授, 2013 年より教授, 現在に至る.



堤 瑛美子

2020 年電気通信大学大学院情報理工学研究科博士前期課程終了. 同年, 電気通信大学大学院情報理工学研究科博士後期課程入学, 在学中.

Abstract Knowledge tracing, the task of tracking the knowledge state of each student over time, has been assessed actively by artificial intelligence researchers. Recent reports describe that Deep-IRT provides superior performance. Deep-IRT can express each student's ability and the difficulty of each item. However, its interpretability and applicability remain limited because it assumes that different items for the same skill have the equivalent difficulty. To overcome those difficulties, this study proposes a novel Deep-IRT model, which has two independent networks: a student network and an item network. Experiments demonstrate that the proposed model outperforms the previous methods.

Key words Knowledge Tracing, Deep Knowledge Tracing, Deep Learning, Item Response Theory