

修士論文の和文要旨

研究科・専攻	大学院 情報理工学研究科 情報・ネットワーク工学専攻 博士前期課程		
氏名	西尾 徹朗	学籍番号	2131125
論文題目	学習者の時系列変化する能力を畳み込む Deep-IRT		

要旨

近年、オンライン教育の普及に伴って、大量の学習履歴データが容易に収集できるようになった。人工知能分野、教育工学分野では、これらの教育ビッグデータを分析し、実際の教育現場でどのように有効活用するかが課題となっている。特にオンライン学習システムを用いて学習者個人の特性に合わせて最適な問題提供と学習支援を行うアダプティブラーニングが注目されている。具体的には、学習者の回答履歴から現時点での学習者の習熟度を推定し、未知の項目に対する反応を予測することで、個人に適切な学習支援を行う。学習効率を最大にする学習支援を行うために、高精度に学習者の習熟度と反応の予測を行う Knowledge Tracing (KT) が盛んに研究されている。

KT の手法として深層学習を用いた様々な手法が提案されているが、近年では高い精度での反応予測に加えて項目反応理論 (Item Response Theory; IRT) を用いることで解釈性のある能力パラメータを推定する Deep-IRT が研究されている。しかし、既存の Deep-IRT では現時点での学習者の状態を表す潜在変数のみから能力パラメータを推定するため、過去の能力変化を考慮した能力推定が行われず、パラメータ解釈性と反応予測精度が低下している可能性があった。

そこで本研究では、時点ごとに潜在変数から出力された多次元の能力状態を保存し過去の能力状態を畳み込む Skill Convolution Network を組み込むことによって、学習者の能力変化を反応予測に反映する新たな Deep-IRT を提案する。評価実験では提案手法と既存手法の反応予測精度比較を行い、提案手法の有効性を示した。さらに、時系列 IRT モデルを用いてシミュレーションデータを作成し、提案手法の能力パラメータの推定値と真のパラメータを相関係数を用いて比較することにより提案手法の解釈性を示す。

令和4年度 修士論文

学習者の時系列変化する能力を畳み込む
Deep-IRT

電気通信大学大学院 情報理工学研究科
情報・ネットワーク工学専攻 情報数理プログラム

学籍番号 2131125

西尾 徹朗

主任指導教員 植野 真臣 教授

指導教員 宇都 雅輝 准教授

令和5年1月30日

目次

1	まえがき	3
2	関連研究	6
2.1	Item Response Theory	6
2.2	Attentive Knowledge Tracing	6
2.3	DKVMN	8
2.4	Deep-IRT	10
3	提案手法	13
3.1	Skill Convolution Network	14
3.2	学習者ネットワーク・項目ネットワーク	16
4	評価実験	18
4.1	反応予測精度の評価実験	21
4.2	解釈性の評価実験	21
4.3	能力パラメータの推定値分析	24
5	むすび	27

1 まえがき

近年、オンライン教育の普及に伴って、大量の学習履歴データが容易に収集できるようになった。人工知能分野、教育工学分野では、これらの教育ビッグデータを分析し、実際の教育現場でどのように有効活用するかが課題となっている。特に、オンライン学習システムを用いて学習者個人の特性に合わせて最適な問題提供と学習支援を行うアダプティブラーニングが注目されている [1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11]。具体的には、学習者の回答履歴から現時点での学習者の習熟度を推定し、未知の項目に対する反応を予測することで、個人に適切な学習支援を行う。学習効率を最大にする学習支援を行うために、高精度に学習者の習熟度と反応の予測を行う Knowledge Tracing(KT) が盛んに研究されている [2, 3, 11, 10, 12, 13, 14, 6, 15, 16, 17, 18, 16]。

KT の代表的な手法として、確率モデルを用いた手法 [2, 3, 11, 10, 12, 13] と深層学習を用いた手法 [14, 6, 15, 16, 17, 18] が知られている。確率モデルを用いた手法では、Bayesian Knowledge Tracing(BKT)[2] と項目反応理論 (Item Response Theory;IRT)[19] がある。BKT では学習者が項目に正答するためのスキルを習得しているかで表現し未知の項目への反応を予測する。BKT では隠れマルコフモデルを用いてスキルの習熟度変化を推定するが、習熟度が離散値であるため柔軟に表現できないという問題がある。IRT は学習者の能力値と項目の難易度を独立に推定し、各項目に対する学習者の反応を予測する解釈性の高い数理モデルである。IRT では BKT と異なり学習者の能力値を連続値で推定することができるため、BKT よりも学習者の能力値を柔軟に表現することができる。また、Wilson らが提案した時系列 IRT[20] では、隠れマルコフモデルを用いて時系列変化する能力値を表現し、さらに過去のデータの忘却機能をもたせることで KT への応用を可能にした。しかし、これらの確率モデルで推定される能力値は一次元であり、各スキルに対する能力値は独立していた。

近年では、複数スキルの関係性を考慮した多次元の能力値を推定することにより、高

い精度で反応予測が可能な深層学習を用いた手法が研究されている。深層学習ベースの手法の研究では、一般に自然言語処理の分野で用いられる Attention や Transformer を用いたモデルが研究されている。Transformer を用いた手法としては、Self Attentive Knowledge Tracing(SAKT)[21] が開発されている。SAKT は過去の学習履歴から、スキルと項目の関係性を推定しながら学習者の反応予測を行う。さらに最先端の手法として、SAKT の構造に過去の反応データを忘却する機能を組み込んだ AKT が提案されている。AKT は過去の反応データから、反応予測に必要な反応データを Attention を用いて抽出することで、最も高い反応予測精度を示す手法として知られている。しかし、AKT は学習者の能力変化を表すパラメータをもたず、解釈性が低いという問題があった。

また、Attention を用いた手法としては Dynamic Key-Value Memory Network(DKVMN)[15] が提案されている。DKVMN では時系列変化する学習者の多次元スキルに対する能力状態を保存するための Memory Network をモデルに組み込むことで反応予測精度の向上を達成した。ただし、これらの深層学習手法の反応予測精度は高いものの、解釈性のあるパラメータをもたないため、学習過程における学習者の能力状態変化を表現できない問題があった。

この課題を解決するために、DKVMN と項目反応理論 (Item Response Theory: IRT) を組み合わせた Deep-IRT[6, 18, 22] が提案されている。Yeung らの Deep-IRT[6] では、IRT と同様に学習者の能力パラメータと項目の難易度を表すパラメータを推定することで解釈性を示した。しかし、Yeung らの Deep-IRT では能力値が項目の特性に依存するため、教育的応用としてのパラメータの解釈性には課題があった。そこで、Tsutsumi らは学習者の能力値と項目の困難度パラメータをそれぞれ独立したネットワークを用いて推定することで、パラメータの解釈性を向上させた Deep-IRT を提案した [18, 16, 22]。この手法では多次元のスキルに対する能力変化を能力パラメータに反映しながら反応予測を行い、パラメータ解釈性を向上させた。しかし、Tsutsumi らの Deep-IRT は時点ごとに変化する学習者の潜在能力値 value memory を更新する

際に、最新の反応データのみを用いているために、学習者の過去の反応データや能力値を考慮できず、反応予測精度が低下している可能性があった。そこで、Tsutsumiらは潜在変数 value memory を更新する際に、Hypernetwork 内で最新の反応データと直前の潜在変数の重みを最適化することで反応予測精度を大幅に向上させた [22]。しかし、Tsutsumiらの Deep-IRT では、現時点での value memory のみから能力パラメータを推定するため、過去の能力変化を考慮した能力パラメータの推定が行われず、パラメータ解釈性と反応予測精度が低下している可能性があった。

この問題を解決するために、本研究では毎時点で value memory から出力された多次元の能力状態を保存し、Temporal Convolutional Network(TCN)[23, 24]で過去の能力状態を畳み込むことによって、学習者の能力変化を反応予測に反映する新たな Deep-IRT 手法を提案する。近年、TCNは時系列データを予測する分野で使われているニューラルネットワークモデルであり、LSTM[25]やGRU[26]などのRNNベースのモデルよりも高い精度で特定の時系列データを予測することが知られている [24, 27, 28, 29, 30]。TCNの特徴は、長期間における時系列データや時系列変化する潜在変数を畳み込む点である。LSTMやGRUのように一時点前の状態のみを参照する再帰的なモデルと異なり、複数の時系列を畳み込むTCNではより長期記憶性をもつことが示されている [24]。

本研究では、予測時点以前の各時点で推定された学習者の多次元の潜在能力を表す value memory を全結合層によって低次元の潜在変数にエンコードする。そして、各時点で出力された潜在変数に対して畳み込みを行う。これにより、時系列変化する学習者の能力状態のパターンを畳み込み時に最適化される重みパラメータによって獲得できるようになる。したがって提案手法は、現時点での学習者の能力状態と、解答した項目の特徴量、時系列変化する能力状態の傾向を考慮した反応予測を行う。評価実験では、提案手法と既存手法 (AKT[17], Tsutsumiらの Deep-IRT[18], Deep-IRT+Hypernetwork[22])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、時系列 IRT モデルを用いてシミュレーションデータを作成し、

提案手法の能力パラメータの推定値と真のパラメータを相関係数を用いて比較検証することで提案手法の有効性を示す.

2 関連研究

2.1 Item Response Theory

項目反応理論 (Item Response Theory;IRT) はテストのための測定モデルの一つであり, 異なるテストを受けた学習者の能力を同一尺度上で評価することができる. 近年では, Knowledge Tracing の分野においても時系列変化する学習者の能力値と項目の難易度を推定するために応用されている [20, 6, 13, 31, 22]. 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について説明する. 2 パラメータ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 に関して正答する確率を次のように表す.

$$P_j(\theta_i) = \frac{1}{1 + \exp(-a_j(\theta_i - b_j))} \quad (2.1)$$

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 の難易度パラメータである. IRT では, 時系列変化を仮定しておらず θ は学習時に固定値であることを仮定している. そこで, 学習者の能力値の時系列変化を隠れマルコフモデルで表現した時系列 IRT が複数提案されている [10, 20, 32, 33, 13]. しかし, これらのモデルで推定される能力値は 1 次元であり, 多次元のスキルに対する能力変化を考慮することはできない.

2.2 Attentive Knowledge Tracing

現在最も高精度な学習者の反応予測を行う手法として, Attentive Knowledge Tracing(AKT)[17] が提案されている. AKT は自然言語処理の分野で広く使われ

ている Transformer とラッシュモデルを組み合わせた手法である。モデル内部の attention は、学習者の最新の反応データと過去の反応データの関連を保持しながら指数関数的に過去の反応データを忘却するように推定される忘却パラメータである。さらに、AKT では過去の全反応データから反応予測に必要なデータのみを抽出するように attention を最適化することにより高精度な反応予測を達成している。AKT における attention $\alpha_{t,\tau}$ は以下の式で求める。

$$\alpha_{t,\tau} = \frac{\exp(f_{t,\tau})}{\sum_{\tau'} \exp(f_{t,\tau'})}, \quad (2.2)$$

$$f_{t,\tau} = \frac{\exp(-\eta d(t,\tau)) \cdot \mathbf{q}_t^\top \mathbf{k}_\tau}{\sqrt{D_k}}, \quad (2.3)$$

ここで、 $\mathbf{q}_t \in \mathbb{R}^{D_k}$ は時点 $t = 1$ から t までの、学習者の反応データを表し、 $\mathbf{k}_t \in \mathbb{R}^{D_k}$ は時点 τ でのキー行列、 D_k はキー行列 \mathbf{k}_t の次元を表す。 $\eta > 0$ は過去データの忘却度を定めるハイパーパラメータである。 $d(t,\tau)$ は時点 τ に入力された過去の反応データと時点 t に入力された最新の反応データの関連性を表し、次式で求められる。

$$d(t,\lambda) = |t - \tau| \sum_{t'=\tau+1}^t \frac{\frac{\mathbf{q}_t^\top \mathbf{k}_{t'}}{\sqrt{D_k}}}{\sum_{1 \leq \tau' \leq t'} \frac{\mathbf{q}_t^\top \mathbf{k}_{\tau'}}{\sqrt{D_k}}}, \quad \forall t' \leq t. \quad (2.4)$$

したがって、AKT では学習者の最新の反応データと過去の反応データの関連性を考慮しながら反応予測に必要なデータのみを抽出し、同時に、時点 τ から時点 t までの経過時間 $|t - \tau|$ が大きくなるほど attention $\alpha_{t,\tau}$ が関数にしたがって減少する (忘却する) ように推定される。これらの構造により、AKT は現在最も高い反応予測精度を示す手法として知られている。ただし、AKT は解釈性のあるパラメータをもたないため、学習過程での学習者の能力変化を表現することができない。

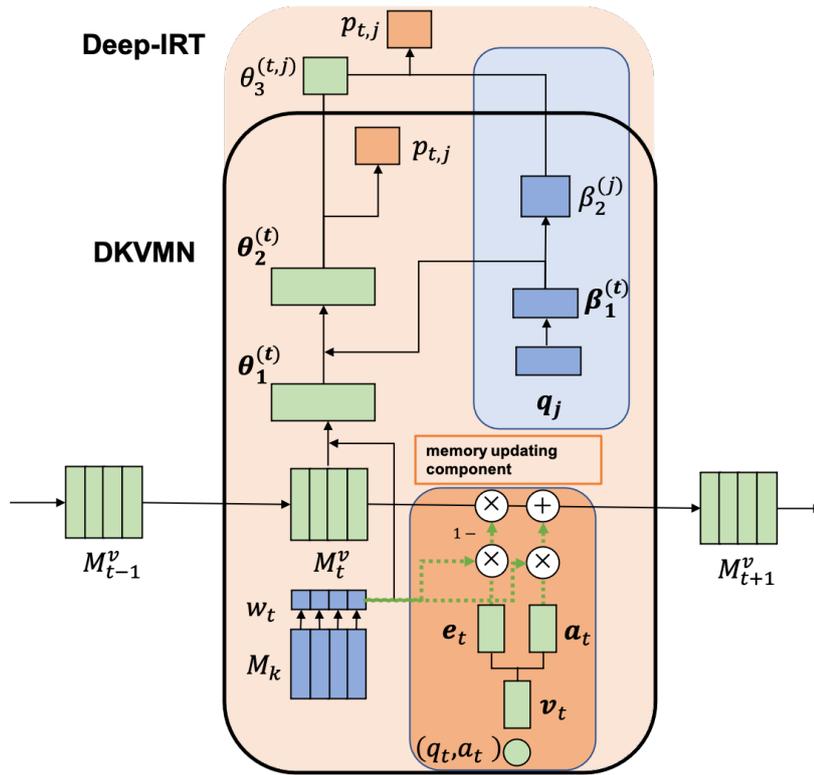


図 1: DKVMN, Yeung らの Deep-IRT の構造

2.3 DKVMN

近年提案されているモデルに、各スキルの習得状態を各時点ごとに更新し、保存する Memory Network を用いた DKVMN[15] が提案されている。DKVMN の構造を図 1 に示す。DKVMN では N 個の潜在スキルを仮定しており各項目とスキルの関係性を 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 $M_t^v \in \mathbb{R}^{N \times d_v}$ に保存する。 d_k と d_v はチューニングパラメータである。ここで、時点 t での j 番目の項目 q_j に対する予測を次のように行う。

はじめに、項目 q_j に対して埋め込み処理をした項目ベクトル $\beta_1^{(j)}$ を用いて、時点 t で解答する項目と l 版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.

$$w_{tl} = \text{Softmax} \left(\mathbf{M}_l^k \beta_1^j \right) \quad (2.5)$$

ここで, \mathbf{M}_l^k は key memory の l 行目を示す.

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.

$$\theta_1^{(t)} = \sum_{l=1}^N w_{tl} (\mathbf{M}_{tl}^v)^\top \quad (2.6)$$

$$\theta_2^{(t)} = \tanh \left(\mathbf{W}^{(\theta_2)} [\theta_1^{(t)}, \beta_1^{(j)}] + \tau^{(\theta_2)} \right) \quad (2.7)$$

$$p_{tj} = \sigma \left(\mathbf{W}^{(y)} \theta_2^{(t)} + \tau^{(y)} \right) \quad (2.8)$$

ここで, \mathbf{M}_{tl}^v は, \mathbf{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.

時系列で変化する潜在能力値 value memory $\mathbf{M}_t^v \in \mathbb{R}^N \times d_v$ は memory updating component において以下のように更新する. はじめに, 時点 t において学習者が回答した項目 j のスキルと項目 j への反応データ u_t から埋め込み処理を行った行列 $\mathbf{v}_t \in \mathbb{R}^{d_v}$ を求める. 次に, \mathbf{v}_t をもとに value memory \mathbf{M}_t^v を以下のように更新する.

$$\mathbf{e}_t = \sigma \left(\mathbf{W}^e \mathbf{v}_t + \tau^e \right) \quad (2.9)$$

$$\mathbf{a}_t = \tanh \left(\mathbf{W}^a \mathbf{v}_t + \tau^a \right) \quad (2.10)$$

$$\tilde{\mathbf{M}}_{t+1,i}^v = \mathbf{M}_{t,i}^v \otimes (1 - w_{ti} \mathbf{e}_t)^\top \quad (2.11)$$

$$\mathbf{M}_{t+1,i}^v = \tilde{\mathbf{M}}_{t+1,i}^v + w_{ti} \mathbf{a}_t^\top \quad (2.12)$$

ここで, \mathbf{W} は重みパラメータ, τ はバイアスパラメータである, w_{tl} は時点 t で回答する項目と 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である. また, \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を調整し, \mathbf{a}_t は時点 t の

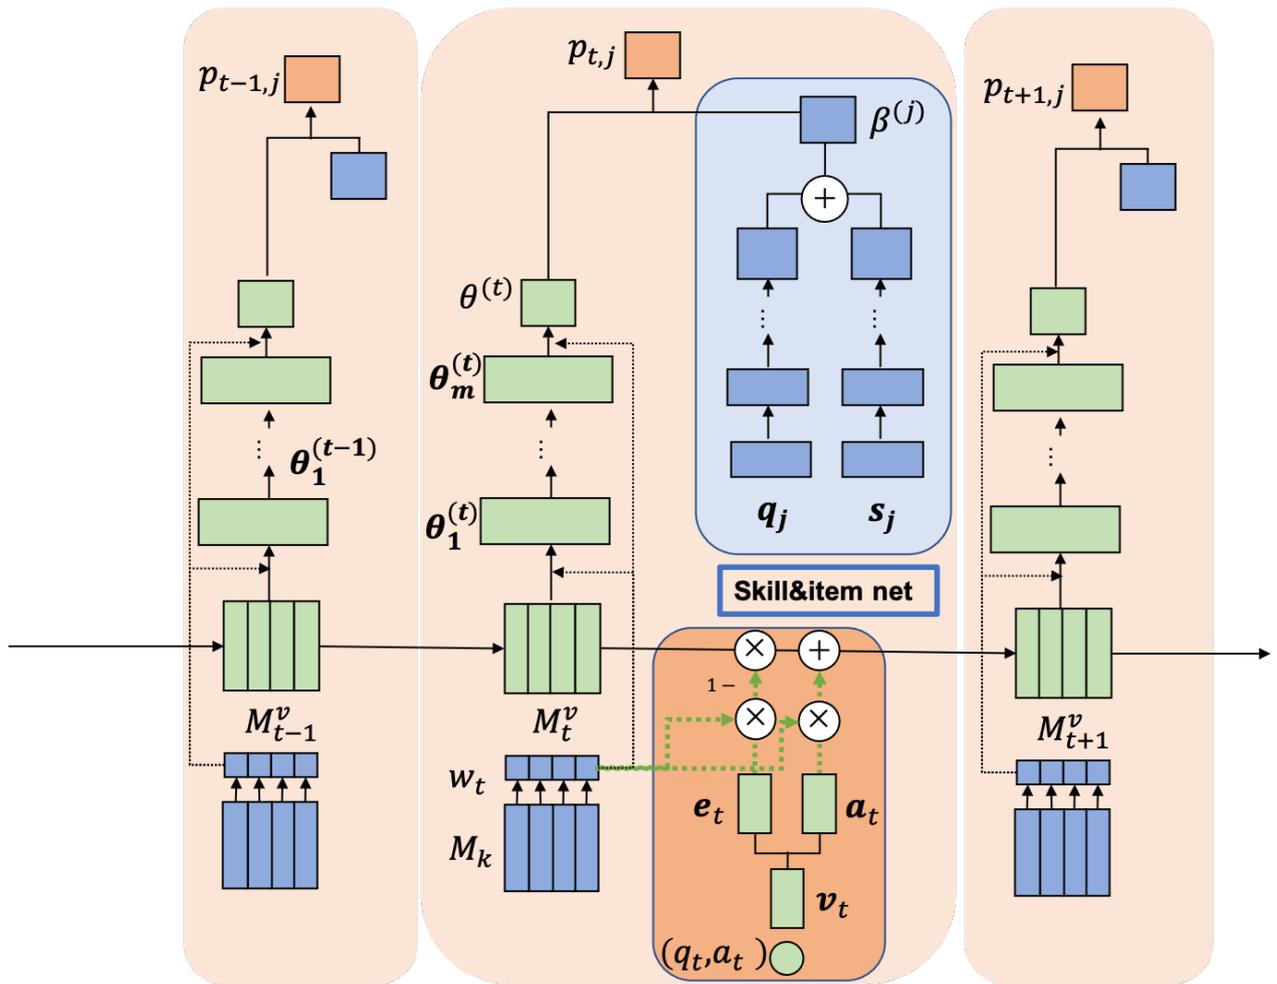


図 2: Tsutsumi らの独立なネットワークをもつ Deep-IRT の構造

反応データをどの程度反映するか調整するパラメータである．このように学習者の能力状態を保持しつつ，潜在変数の更新を行う仕組みによって DKVMN は高い反応予測精度を示す．しかし，DKVMN は解釈可能な能力パラメータや困難度パラメータをもたず，パラメータの解釈性がないという問題があった．

2.4 Deep-IRT

Yeung らは DKVMN のパラメータ解釈性を向上させるための手法として，DKVMN と IRT を組み合わせた Deep-IRT[6] を提案した．Yeung らの Deep-IRT(図 1) は IRT

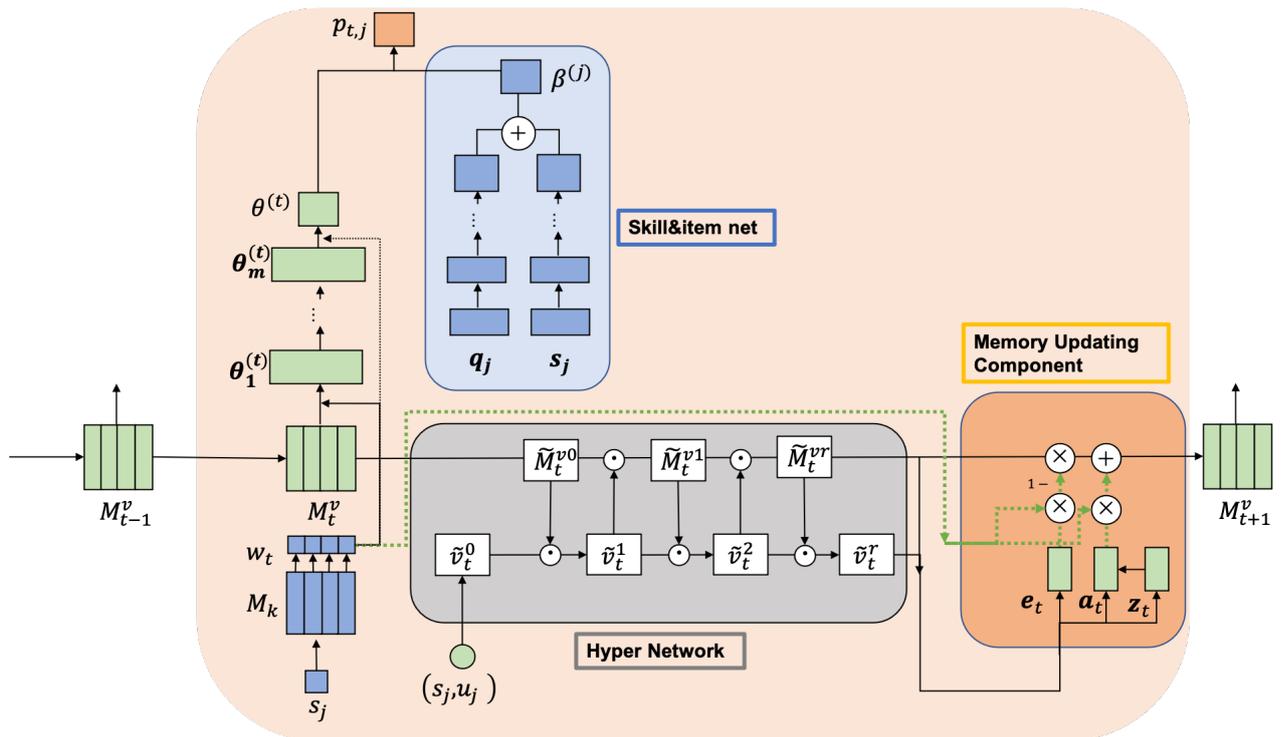


図 3: Hypernetwork を加えた Tsutsumi らの Deep-IRT

と同様に学習者の能力と項目の難易度を表すパラメータを推定させることで DKVMN に解釈性をもたせた。しかし、学習者の能力値が回答項目の特性に依存しており、依然としてパラメータの解釈性には課題があった。

そこで、高精度な反応予測とパラメータ解釈性を両立させるために、Tsutsumi らはそれぞれ独立した学習者ネットワークと項目ネットワークを用いて学習者の能力パラメータと項目の難易度パラメータを推定する新たな Deep-IRT(図 2) を提案している [18, 34]。Tsutsumi らの Deep-IRT では学習者の能力値が項目の特性に依存せず、多次元のスキルに対する能力変化を表現することができ、既存手法と同等の反応予測精度を達成しつつ、能力値に対しても高い推定精度を示した。さらに Tsutsumi らは、時系列変化する潜在能力値を更新・忘却するための仕組みである memory updating component に着目し、Hypernetwork を組み込んだ手法を提案した [22, 31]。Tsutsumi らの Hypernetwork を組み込んだ手法の図を図 3 に示す。

Hypernetwork は以下の式 (2.13) と式 (2.14) を繰り返すことにより、最新の学習者の反応データを埋め込み処理したベクトル \mathbf{v}_t と直前の学習者の潜在能力値 M_t^v のバランスを最適化する.

$$\tilde{\mathbf{v}}_t^r = \delta_1 * \sigma (\mathbf{W}^x \tilde{M}_t^{vr-1} \odot \tilde{\mathbf{v}}_t^{r-2}) \quad (2.13)$$

$$\tilde{M}_t^{vr} = \delta_2 * \sigma (\mathbf{W}^m \tilde{\mathbf{v}}_t^{r-1} \odot \tilde{M}_t^{vr-2}) \quad (2.14)$$

ここで、 $\delta_1 \in \mathbb{R}, \delta_2 \in \mathbb{R}$ と $r = [1, \dots, R]$ はハイパーパラメータであり、 r は繰り返し回数を表す.

memory updating component では最新の学習者の反応データが入力された際に潜在能力値 value memory $M_t^v \in \mathbb{R}^N \times d_v$ を以下のように更新する. はじめに、時点 t において学習者が回答した項目 j のスキルと項目 j への反応データ u_{jt} から埋め込み処理を行った行列 $\mathbf{v}_t \in \mathbb{R}^{d_v}$ を求める. 次に、 \mathbf{v}_t をもとに value memory M_t^v を更新する.

$$\mathbf{e}_t = \sigma (\mathbf{W}^{e1} \tilde{\mathbf{v}}_t^r + \mathbf{W}^{e2} \tilde{M}_{t,l}^{vr} + \tau^e) \quad (2.15)$$

$$\mathbf{z}_t = \sigma (\mathbf{W}^{z1} \tilde{\mathbf{v}}_t^r + \mathbf{W}^{z2} \tilde{M}_{t,l}^{vr} + \tau^z) \quad (2.16)$$

$$\mathbf{a}_t = \tanh (\mathbf{W}^{a1} \mathbf{z}_t + \mathbf{W}^{a2} \tilde{M}_{t,l}^{vr} + \tau^a) \quad (2.17)$$

$$M_{t+1,l}^v = \tilde{M}_{t,l}^{vr} \otimes (1 - w_{tl} \mathbf{e}_t)^\top + w_{tl} \mathbf{a}_t^\top \quad (2.18)$$

ここで、 \mathbf{W} は重みパラメータ、 τ はバイアスパラメータである、 w_{tl} は時点 t で回答する項目と 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である. また、 \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を調整し、 \mathbf{a}_t は時点 t の反応データをどの程度反映するか調整するパラメータである. Tsutsumi ら [31, 22] では、これらの忘却パラメータを最適化することで、能力パラメータの推定精度と反応予測精度向上を達成した. しかし、Tsutsumi らの Deep-IRT では、学習者の能力値を推定する際に、その時点での能力潜在変数のみを用いており、過去の能力状態の情報を考

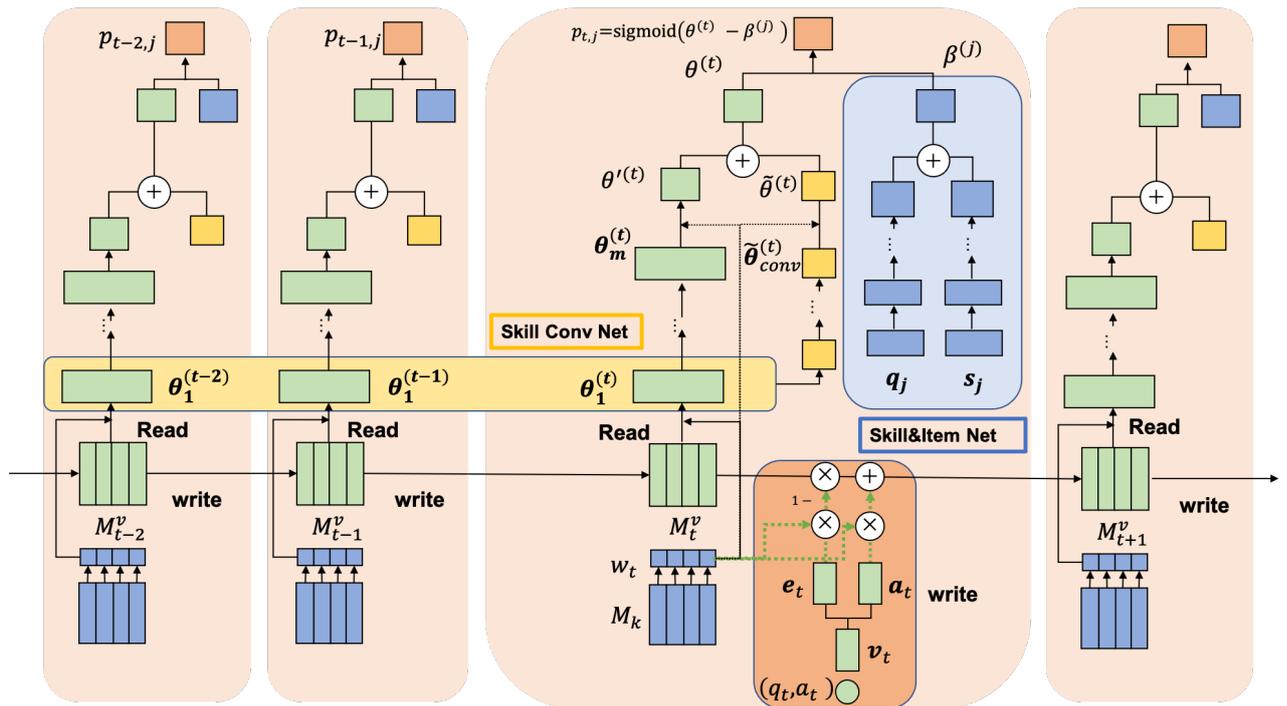


図 4: 提案モデルの全体図

慮していないためにパラメータの推定精度を低下させている可能性があった。

3 提案手法

本研究では、既存の Deep-IRT に学習者の時系列で変化する能力状態のパターンを読み取る Skill Convolution Network を組み込むことで能力パラメータの推定精度を向上させ、高い反応予測精度を達成する Deep-IRT を提案する。提案手法の詳細を図 4 に示す。Skill Convolution Network は、予測時点以前までの学習者の潜在変数を畳み込むことで学習者の時系列変化する能力のパターンを捉えるものである。畳み込みの際には、近年時系列データの予測の分野で用いられている Temporal Convolutional Network(TCN)[23, 24] の構造を応用して畳み込みを行う。

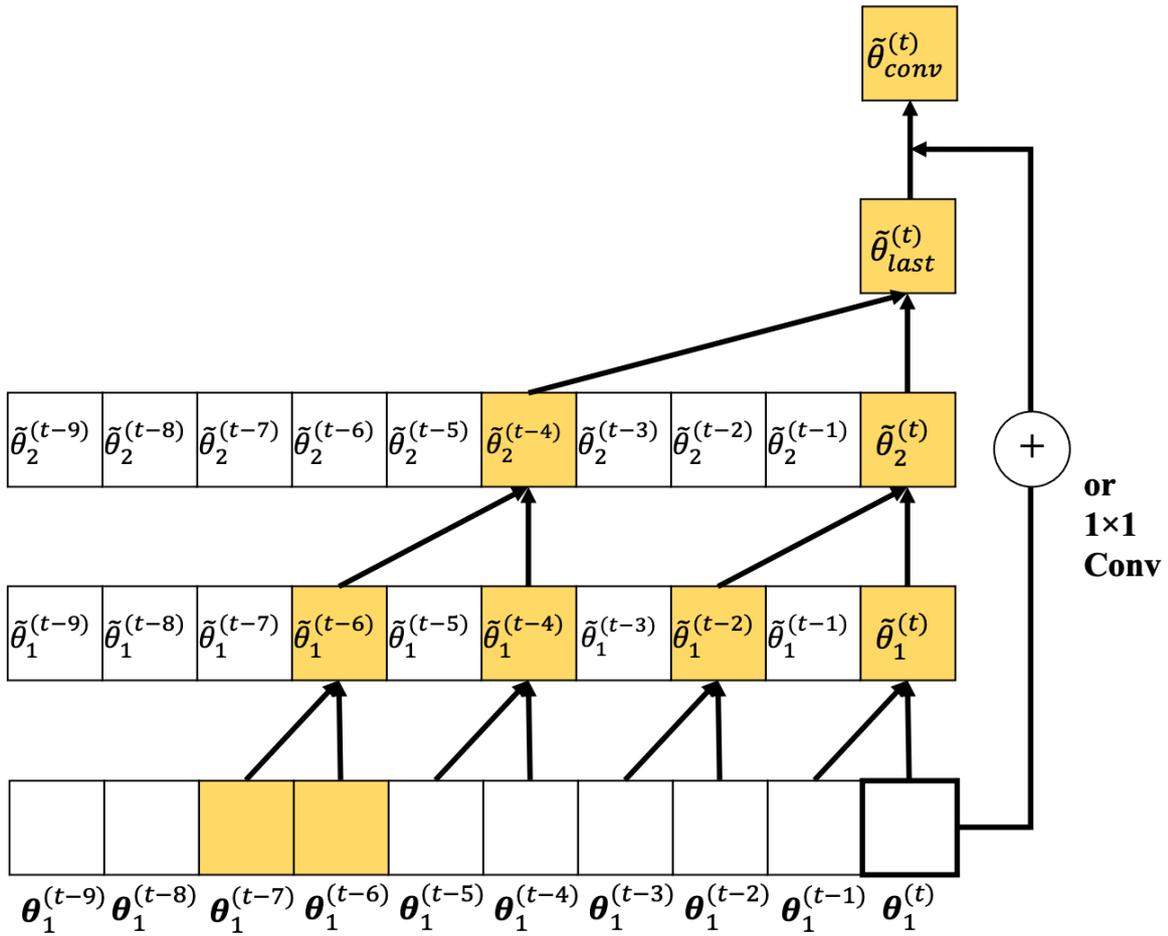


図 5: Skill Convolution Network の構造

3.1 Skill Convolution Network

Skill Convolution Network では、学習者の能力の潜在変数を時系列方向に畳み込むことで、学習者の能力変化を読み取る最適なパラメータを獲得する。畳み込みの構造を図 5 に示す。Skill Convolution Network の入力 は value memory を全結合層でエンコードした値を時系列に並べた列 $\{\theta_1^t, \theta_1^{t-1}, \theta_1^{t-2}, \dots\}$ である。ここで $\theta_1^{(t)}$ は、以下の数式で表される、value memory とアテンションとの重みつき和である。

$$\boldsymbol{\theta}_1^{(t)} = \sum_{l=1}^N w_{tl} (\mathbf{M}_{tl}^v)^\top \quad (3.1)$$

提案手法の Skill Convolution Network は Causal Dilated Convolution と Residual Connection で構成される。Causal Dilated Convolution は入力値の各要素を間隔を空けて畳み込む方法である。また、畳み込む各要素の間隔 (dilation) を各層で指定することができるため、Causal Dilated Convolution を複数層で行うことでカーネルの長さより長い系列の畳み込みを行うことができる。ただし、dilation を 1 にしたときは通常の畳み込みと同様になる。Residual Connection は層の 1 層目を最後の出力に加算することによって、層が深くなった場合に勾配消失を防ぐ効果がある。上記の 2 つの方法を組み合わせて能力の潜在変数に対する畳み込みを複数層にわたって行う。

ある時点 t に関する n 層での一次元畳み込みにおける、ある層の入力ベクトルの列 $\{\boldsymbol{\theta}_1^{(t)}, \boldsymbol{\theta}_1^{(t-1)}, \boldsymbol{\theta}_1^{(t-2)}, \dots\} \in \mathbb{R}^N$ は多次元であるが、簡単のため次のような 1 次元を考える。

$$\text{入力ベクトル: } \{\theta_1^{(t)}, \theta_1^{(t-1)}, \theta_1^{(t-2)}, \dots\} \in \mathbb{R} \quad (3.2)$$

入力ベクトルに対して時点 t での 1 層目の畳み込みは次のように表される。

$$\tilde{\theta}_1^{(t)} = \sum_{i=0}^{k-1} f_i^{(1)} \cdot \theta_1^{(t-d_1 \cdot i)} \quad (3.3)$$

同様に n 層目での畳み込みは

$$\tilde{\theta}_n^{(t)} = \sum_{i=0}^{k-1} f_i^{(n)} \cdot \tilde{\theta}_{n-1}^{(t-d_n \cdot i)} \quad (3.4)$$

と表される。ここで、 $f_i^{(n)}$ は畳み込みに用いる重みであり、 d_n は層ごとに $\{1, 2, 4, \dots, 2^n\}$ と変化させる dilation パラメータである。また k は畳み込みの際の

カーネル f の長さであり、以下のようなパラメータである.

$$k = \begin{cases} k_{last} & (\text{最終層の時}) \\ 2 & (\text{それ以外}) \end{cases} \quad (3.5)$$

最後に、最終層の出力に第一層の能力値 $\theta_t^{(1)}$ を加算する.

$$\tilde{\theta}_{conv}^{(t)} = \theta_t^{(1)} + \tilde{\theta}_{last}^{(t)} \quad (3.6)$$

この Skill Convolution Network によって、学習者の能力変化を考慮した能力推定が可能となる.

3.2 学習者ネットワーク・項目ネットワーク

学習者の能力パラメータと項目に関する難易度パラメータを Deep-IRT[18] と同様の手順で求める.

学習者のネットワークでは、学習者が項目に解答する際の能力値を算出する. 時点 t での value memory から出力した潜在変数を m 層の全結合層に入力した出力 $\theta_m^{(t)} = \{\tilde{\theta}_{m1}^{(t)}, \tilde{\theta}_{m2}^{(t)}, \dots, \tilde{\theta}_{mN}^{(t)}\}$ と Skill Convolution Network からの出力 $\tilde{\theta}_{conv}^{(t)} = \{\tilde{\theta}_{conv1}^{(t)}, \tilde{\theta}_{conv2}^{(t)}, \dots, \tilde{\theta}_{convN}^{(t)}\}$ のそれぞれに対してアテンション w_{tl} を用いて重み付き和を計算する. そして、それぞれの結果を加算することで能力値を求める.

$$\theta'^{(t)} = \sum_{l=1}^N \omega_{tl} \theta_{ml}^{(t)} \quad (3.7)$$

$$\tilde{\theta}^{(t)} = \sum_{l=1}^N \omega_{tl} \tilde{\theta}_{convl}^{(t)} \quad (3.8)$$

$$\theta^{(t)} = \theta'^{(t)} + \tilde{\theta}^{(t)} \quad (3.9)$$

項目ネットワークでは、項目 j に関する難易度パラメータである $\beta^{(j)}$ を求める. 具

体的には、項目 j の ID に対して埋め込み処理を行い、項目に関する難易度パラメータである β_{item}^j を求める。

$$\beta_1^{(j)} = GELU \left(\mathbf{W}^{(\beta_1)} \mathbf{q}_j + \boldsymbol{\tau}^{(\beta_1)} \right). \quad (3.10)$$

$$\beta_2^{(j)} = GELU \left(\mathbf{W}^{(\beta_2)} \beta_1^{(j)} + \boldsymbol{\tau}^{(\beta_2)} \right). \quad (3.11)$$

$$\beta_{item}^{(j)} = \mathbf{W}^{(\beta_n)} \beta_n^{(j)} + \boldsymbol{\tau}^{(\beta_n)}. \quad (3.12)$$

ここでは活性化関数として GELU 関数 [35] を用いる。同様に、項目 j のスキル ID に対して埋め込み処理を行い、スキルに関する難易度パラメータである β_{skill}^j を求める。

$$\gamma_1^{(j)} = GELU \left(\mathbf{W}^{(\gamma_1)} \mathbf{q}_j + \boldsymbol{\tau}^{(\gamma_1)} \right). \quad (3.13)$$

$$\gamma_2^{(j)} = GELU \left(\mathbf{W}^{(\gamma_2)} \gamma_1^{(j)} + \boldsymbol{\tau}^{(\gamma_2)} \right). \quad (3.14)$$

$$\beta_{skill}^{(j)} = \mathbf{W}^{(\gamma_n)} \gamma_n^{(j)} + \boldsymbol{\tau}^{(\gamma_n)}. \quad (3.15)$$

そして推定されたそれぞれの β_{item}^j と β_{skill}^j から以下のように β^j を求める。

$$\beta^{(j)} = \tanh \left(\beta_{item}^j + \beta_{skill}^j \right) \quad (3.16)$$

項目ネットワークの層数は $\{2, 3, \dots, n\}$ の中からデータに基づいて決定するハイパーパラメータである。

最後に、それぞれのネットワークからそれぞれ出力された、能力値と難易度を用いて時点 t での項目 j に対する正答確率を計算する。

$$p_{tj} = \sigma \left(\theta^{(t)} - \beta^{(j)} \right) \quad (3.17)$$

深層学習手法では、一般的に誤差逆伝播法を用いて損失関数 l を最小化することにより、パラメータを学習する。提案手法では、深層学習において一般的な損失関数である

クロスエントロピーを用いる.

$$l = - \sum_i (y_i \log p_{tj} + ((1 - p_{tj}) \log (1 - p_{tj}))) \quad (3.18)$$

4 評価実験

表 1: データセットの概要

Dataset	No. students	No. skills	No. Items	Rate Correct	Learning length
ASSISTments2009	4151	111	26684	63.6%	52.1
ASSISTments2017	1709	102	3162	39.0%	551.0
Statics2011	333	1223	N/A	79.8%	180.9
Junyi	48925	705	N/A	82.78%	345
Eedi	80000	1200	27613	64.25%	177

本章では、深層学習を用いた代表的な KT 手法である AKT[17], Tsutsumi らの Deep-IRT(Tsutsumi-DI)[18], Tsutsumi らの Hypernetwork つき Deep-IRT(DeepIRT-HN)[22], 提案手法を用いて反応予測の比較実験を行う. 具体的には, 5分割交差検証を用いてデータセットを訓練データ, 検証データ, 評価データに分割し, 訓練データと検証データを用いてモデルの訓練とパラメータチューニングを行う. そして, 評価データに対して学習者の未知の項目への反応予測を行い, 実際の反応データとの比較を行う. 予測精度の評価指標としては, Accuracy(正答・誤答の一致割合) と AUC スコアを用いる. 本実験では, データセット Statics2011, ASSISTments2009, ASSISTments2017 を用いる. データセットの詳細を表 1 と以下に示す.

1. ASSISTments dataset(ASSISTments2009, ASSISTments2017)
算数のオンラインデータ学習システムで収集されたデータセット.
2. Statics2011 dataset

大学の工学部に所属する学生の統計学の授業内で収集されたデータセット.

3. Eedi Dataset

小学生から高校生における数学の学習プラットフォーム Eedi で 2018 年から 2020 年の間に収集されたデータセット. Eedi では各項目に対して複数のスキルが含まれている. 本研究では, 複数のスキルタグの組み合わせを一意の数字に変換して使用した.

4. Junyi Dataset

中国の E-Learning システムである Junyi Academy で収集されたデータセット.

表 2: 学習者の反応予測精度

Dataset	metrics	Tsutsumi-DI[18]	AKT[17]	DeepIRT-HN[22]	Proposed
ASSISTments2009	AUC	82.09+/-0.28	82.20+/-0.25	81.98+/-0.54	82.97+/-0.30
	Acc	77.41+/-0.53	77.30+/-0.55	77.15+/-0.55	77.65+/-0.56
ASSISTments2017	AUC	73.56+/-0.27	74.54+/-0.21	75.13+/-0.20	75.69+/-0.36
	Acc	69.78+/-0.41	69.83+/-0.06	70.69+/-0.60	70.68+/-0.50
statics2011	AUC	81.15+/-0.37	82.15+/-0.35	81.57+/-0.50	82.04+/-0.39
	Acc	80.01+/-0.92	80.41+/-0.67	80.11+/-0.92	80.50+/-0.80
Eedi	AUC	78.93+/-0.12	77.58+/-0.21	78.97+/-0.10	79.14 +/-0.11
	Acc	73.38+/-0.17	72.35+/-0.21	73.38+/-0.13	73.55+/-0.13
Junyi	AUC	77.92+/-0.41	78.13+/-0.39	77.91+/-0.37	78.14+/-0.43
	Acc	86.79+/-0.15	86.79+/-0.17	86.65+/-0.15	86.85+/-0.14
Average	AUC	78.73	78.92	79.11	79.60
	Acc	77.47	77.54	77.60	77.81

4.1 反応予測精度の評価実験

学習者の解答した項目に対する反応予測精度を表 2 に示す。表 2 から、全ての指標の平均値で提案手法が最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 DeepIRT-HN[22] を平均的に上回っており、Skill Convolution Network を組み込むことで、学習者の時系列変化する能力状態を考慮したパラメータ推定ができ、反応予測精度が向上したと考えられる。特に ASSISTments2009, ASSISTments2017, Eedi, Junyi では AUC, Accuracy 共に既存手法を上回る精度を達成した。これらのデータセットは学習者が 1000 人以上の大規模なデータセットであり、様々な学習者の能力変化のパターンを学習できたために提案手法の精度が向上したと考えられる。また、Statics2011 のデータに対しても、既存手法とほぼ同じ程度の AUC, Accuracy の精度を達成した。他のデータよりも精度向上が限定的になっているのは、学習者の人数が少ないために多様な能力の変化パターンを学習できず、Skill Convolution Network が有効に働かなかつたためと考えられる。

4.2 解釈性の実験

表 3: 推定された能力値と真の能力値との相関係数

σ	No. items	Pearson			Spearman			Kendall					
		50	100	200	300	50	100	200	300	50	100	200	300
0.1	Tsutsumi-DI	0.732	0.771	0.856	0.815	0.745	0.786	0.882	0.863	0.548	0.595	0.701	0.686
	DeepIRT-HN	0.728	0.765	0.85	0.821	0.739	0.784	0.880	0.867	0.542	0.592	0.698	0.691
	Proposed	0.859	0.896	0.913	0.892	0.866	0.909	0.943	0.939	0.678	0.741	0.789	0.788
0.3	Tsutsumi-DI	0.826	0.843	0.853	0.862	0.849	0.900	0.942	0.951	0.661	0.723	0.787	0.803
	DeepIRT-HN	0.819	0.858	0.855	0.861	0.846	0.913	0.943	0.952	0.657	0.741	0.79	0.804
	Proposed	0.840	0.905	0.900	0.907	0.877	0.932	0.947	0.954	0.689	0.767	0.791	0.804
0.5	Tsutsumi-DI	0.826	0.843	0.853	0.862	0.849	0.900	0.942	0.951	0.661	0.723	0.787	0.803
	DeepIRT-HN	0.849	0.839	0.833	0.818	0.895	0.927	0.939	0.951	0.714	0.759	0.780	0.804
	Proposed	0.846	0.839	0.820	0.810	0.894	0.916	0.917	0.892	0.710	0.732	0.730	0.702
1.0	Tsutsumi-DI	0.826	0.802	0.813	0.795	0.888	0.924	0.940	0.939	0.702	0.753	0.783	0.783
	DeepIRT-HN	0.822	0.805	0.813	0.794	0.887	0.924	0.940	0.938	0.700	0.754	0.786	0.784
	Proposed	0.802	0.793	0.803	0.788	0.876	0.916	0.921	0.927	0.682	0.737	0.748	0.760

本章では、提案手法の能力パラメータの解釈性を評価するために、Tsutsumi ら [31, 22, 18] と同様に、シミュレーションデータを用いて提案手法と既存手法の DeepIRT 手法である Tsutsumi-DI[18], DeepIRT-HN[22] との推定した能力値の比較を行う。シミュレーションデータは時系列 IRT の手法である TIRT を用いて生成する [20]。TIRT では、学習者 i が項目 j に時点 t で正答する確率を計算する。

$$P_{ij}(x_{ij} = 1|\theta_{it}) = \frac{1}{1 + \exp(-\tilde{a}_{\Delta_t}\theta_{it} - b_j)} \quad (4.1)$$

$$\tilde{a}_{\Delta_t} = \frac{a_j}{\sqrt{1 + \sigma a_j^2 \Delta_t}} \quad (4.2)$$

ここで、 $\Delta_t = t - t_j$ であり、現在の時点 t と過去にある項目 j を解いた時点の差分である。 $a_j^2 \in (0, \infty)$ は時点 t での識別力パラメータ、 $b_j \in (-\infty, \infty)$ は項目 j の難易度パラメータである。項目の識別力パラメータ a と難易度パラメータ b の事前分布には、 $a \sim LN(0, 1)$, $b \sim N(0, 1)$ を用いた。また、 $\theta_{it} \in (-\infty, \infty)$ は時点 t での学習者 i の能力値を表す。 θ_{it} の事前分布は $\theta_{i0} \sim N(0, 1)$, $\theta_{it} \sim N(\theta_{it-1}, \sigma)$ の正規分布とした。 σ は θ_{it} の分散であると同時に、過去の学習データの忘却度を決める忘却パラメータである。

本実験では、TIRT を用いて学習者 2000 人の 50, 100, 200, 300 項目への反応データをデータセットとして生成した。はじめに学習者 1800 人分の反応データを用いて項目の識別力パラメータ a と項目パラメータ b を推定し、推定した a, b を所与として残りの 200 人の各時点での能力値を推定する。また、各データセットについて σ の値を $\sigma = \{0.1, 0.3, 0.5, 1.0\}$ に変化させて生成したデータセットを用いて実験を行った。 σ は学習者の能力値の変動を調整するパラメータであり、 σ の値が大きいほど真の能力値は各時点で大きく変動するように推定される。本研究では真のモデル (TIRT) から生成された真の能力値と提案手法、既存手法の Deep-IRT で推定された能力値を比較するために、各時点での能力値について Pearson の積率相関係数、Spearman の順位相関係数、Kendall の順位相関係数を求めた。母集団に分布が仮定されている Pearson の積

率相関係数に対して, Spearman の順位相関係数は母集団に分布を仮定しないノンパラメトリックな指標である. Kendall の順位相関係数は異常値の頑健な推定について評価する指標である. TIRT によって生成した学習過程での能力値 $\theta_t, t \in \{1, 2, \dots, T\}$ と提案手法, 既存手法である Tsutsumi らの Deep-IRT で推定された能力値をそれぞれの相関指標を用いて算出した. 一般に能力値の推定精度評価には二乗平均平方根誤差 (Root Mean Squared Error: RMSE) を用いることが多い. しかし, TIRT の学習者の能力パラメータは事前分布が時点ごとに変動し, 標準正規分布を仮定していない. 提案手法, Deep-IRT 手法においても能力パラメータは分布をもたない. したがって, 本実験では TIRT および提案手法, Deep-IRT 手法では能力値の標準化ができず, RMSE を評価することができないため, 相関係数で評価する.

表 3 に各条件のデータセットについて算出した相関係数を示す. 結果から, 提案手法は能力変化の分散が小さい $\sigma = \{0.1, 0.3\}$ では既存モデルと比較して高精度の結果となった. これは, 分散が小さい場合は現在の能力値が過去の能力変化に大きく依存するため, Skill Convolution Network が効果的に機能し, 推定精度が向上したと考えられる. 一方で, 能力の分散 σ が大きくなるにつれて, 各時点での能力は過去の能力変化に関係なく推定されるため, Skill Convolution Network による効果が低下すると考えられる. ただし, 実際のオンラインラーニングシステムのように, 複数の項目に短期間で解答する学習では能力値の急激な変化は起こりにくいことを留意されたい.

4.3 能力パラメータの推定値分析

本章では, 提案手法を用いて推定した学習者の能力値推移を可視化し, 能力パラメータが解釈性を持つことを示す. 多次元のスキルに対する能力値変化を可視化することは, 指導者が学習者の習熟度や苦手分野を把握し, 適切な支援を行うために重要である. 本章では Tsutsumi[18] らと同様に ASSISTments2009 データセットを用いて, 提案手法を用いて学習者の各スキルの能力推移を推定した. 実データでの評価実験では, 学習者の真の能力値が未知であるため, 推定された能力値が実際の反応データに対し

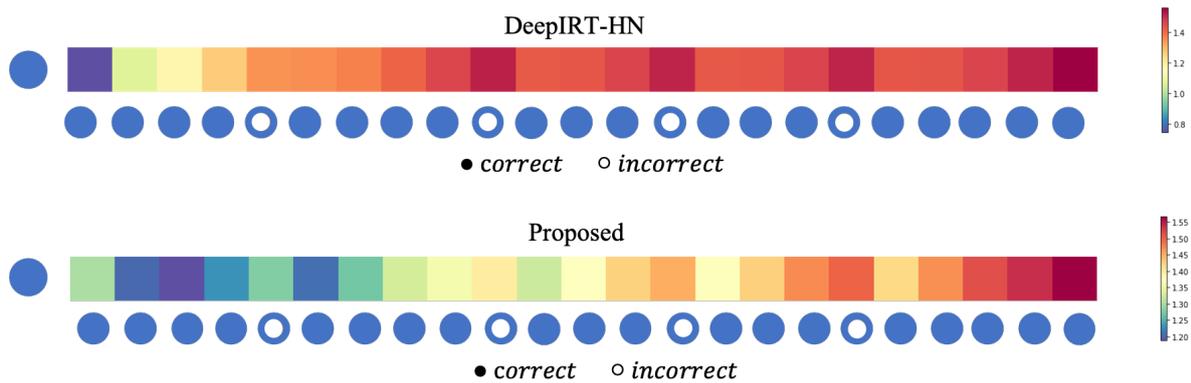


図 6: 単一のスキル項目における能力パラメータの比較

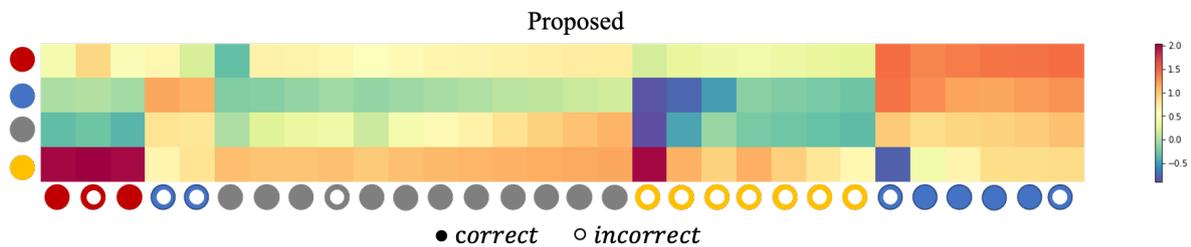


図 7: 提案手法での多次元の能力パラメータの変化

て妥当であるかを評価する。

図 6 に、ある学習者の 23 項目に対する反応データから推定した単一のスキルを解いた際の能力値の変化を Tsutsumi らの手法 [22] と比較した図を示す。縦軸左側がスキル、縦軸右側は学習者の能力値を表し、横軸は学習者の回答項目を表す。また、学習者が項目に正答した場合は"●"に、項目に誤答した場合は"○"で表す。この学習者は数問正答後に誤答するという反応パターンを繰り返す、最終的に 5 問連続で解答する反応データである。既存手法では学習の初期段階で、大幅に推定能力値が向上した後、反応データ通りの上下はあるもののほとんど変化しない。これは既存手法では現時点の状態が一つ前の状態に大きく依存するため、同じ反応パターンを繰り返す系列では推定能力値も周期的な値になると考えられる。一方、提案手法では、正答によって徐々に推定能力値が上昇し、誤答しても能力値は大幅に下がらず最後の 5 問連続で回答した時

点で最も推定能力値が高くなっている。

次に、複数のスキルを解いた際の推定した能力値の変化を ASSISTments2009 データセットの反応データを用いて分析する。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で推定した能力値推移を図 7 に示す。縦軸左側がスキル、縦軸右側は学習者の能力値を表し、横軸は学習者の回答項目を表す。また、学習者が項目に正答した場合は"●"に、項目に誤答した場合は"○"で表す。学習者は 4 つのスキルに回答しており、それぞれのスキルは"ordering fractions"(オレンジ色), "equation solving more than two steps"(青色), "equation solving two or fewer steps"(灰色), "finding percents"(黄色) で示されている。図 7 より、提案手法では、学習者の能力の傾向と共にスキル間の関連性を考慮して能力値推定を行うため、反応データの正誤に伴って該当するスキルだけでなく他のスキルも変化する傾向があることがわかる。また、ある学習者がある項目に正解した場合、その項目に関するスキルが向上するだけでなく、他のスキルも上昇する。特に"equation solving more than two steps"(青色) と"equation solving two or fewer steps"(灰色) は類似のスキルを持っている。そのため、灰色を正解し続けると、類似スキルの青色も共に向上している。一方で項目 15 では項目に正答しているにもかかわらず青色のスキルの能力値が低下しているが、これは提案手法は過去の能力値推移を考慮して能力推定を行うために、学習者の反応が直ちに能力値に反映されないためだと考えられる。

5 むすび

本研究では、高精度の反応予測と解釈性を両立させるために、Skill Convolution Network を組み込むことで時系列変化する学習者の能力を考慮する新たな Deep-IRT を提案した。提案手法では、学習者の時点ごとの能力変化を考慮するために各時点での能力値の潜在変数を畳み込むことで、能力変化のパターンを学習し、学習者の学習傾向を予測に反映することができる。評価実験では、実データを用いて反応予測精度の比較を行い、既存手法と比較して提案手法の精度が向上したことを示した。特に大規模なデータに対する高い予測精度を持つことが明らかとなった。また、能力値に関する評価実験では、シミュレーションデータを用いて時系列 IRT で生成した真の能力値との相関係数を比較し、提案手法が既存の手法と同程度または高い相関を持つことを示した。加えて、能力パラメータの推定値分析を行い既存の Deep-IRT によるパラメータ推定よりも細かな能力変化に対応できることを示唆した。

今後の研究では、本研究においては探索によって決定した層の数や最終層のカーネルの長さを自動で推定するような手法を開発し、より高い精度での反応予測と能力値推定を目指す。また、近年研究されている学習者のレベルにあったヒントを提示する足場がけ学習システム [36, 37] への応用を行っていきたい。

謝辞

本研究の遂行にあたって、終始ご指導、ご助言を賜りました植野真臣教授、宇都雅輝准教授に深く感謝いたします。また、研究に関する議論や論文執筆についてご指摘いただきました先輩方、研究室の皆様にも感謝いたします。

参考文献

- [1] Maomi Ueno. Data mining and text mining technologies for collaborative learning in an ILMS "samurai". In *Proceedings of the IEEE International Conference on Advanced Learning Technologies, ICAALT 2004*, pp. 1052–1053, 2004.
- [2] Albert T. Corbett and John R. Anderson. Knowledge tracing: Modeling the acquisition of procedural knowledge. *User Model. User-Adapt. Interact.*, Vol. 4, No. 4, pp. 253–278, Dec 1995.
- [3] Mohammad M. Khajah, Rowan M. Wing, Robert V. Lindsey, and Michael C. Mozer. Integrating latent-factor and knowledge-tracing models to predict individual differences in learning. In *In submission*, 2014.
- [4] Jung Lee and Emma Brunskill. The impact on individualizing student models on necessary practice opportunities. In *Proceedings of the Fifth International Conference on Educational Data Mining*, pp. 118–125, 01 2012.
- [5] Michael A. Sao Pedro, Ryan Shaun Joazeiro de Baker, and Janice D. Gobert. Incorporating scaffolding and tutor context into bayesian knowledge tracing to predict inquiry skill acquisition. In *EDM*, 2013.
- [6] Chun-Kit Yeung. Deep-irt: Make deep learning based knowledge tracing explainable using item response theory. In *Proceedings of the 12th International Conference on Educational Data Mining, EDM*, 2019.
- [7] Radek Pelánek. Conceptual issues in mastery criteria: Differentiating uncertainty and degrees of knowledge. In *19th International Conference on Artificial Intelligence in Education*, Vol. 1, pp. 450–461, 06 2018.
- [8] Zachary Pardos and Neil Heffernan. 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] Zachary A. Pardos and Neil T. Heffernan. Kt-idem: Introducing item difficulty to the knowledge tracing model. In *Proceedings of 19th International Conference on User Modeling, Adaptation and Personalization (UMAP 2011)*, pp. 243–254, 01 2011.
- [10] Ruby Weng and D. Coad. Real-time bayesian parameter estimation for item response models. *Bayesian Analysis*, Vol. 13, , 12 2016.
- [11] Xiaojing Wang, James Berger, and Donald Burdick. Bayesian analysis of dynamic item response models in educational testing. *The Annals of Applied Statistics*, Vol. 7, No. 1, pp. 126–153, 2013.
- [12] Michael V. Yudelson, Kenneth R. Koedinger, and Geoffrey J. Gordon. Individualized bayesian knowledge tracing models. In *Artificial Intelligence in Education*, pp. 171–180, Berlin, Heidelberg, 2013. Springer Berlin Heidelberg.
- [13] 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. Vol.J102-D, No. No.2, pp. 1L79–1L92, 2018.
- [14] Chris Piech, Jonathan Bassen, Jonathan Huang, Surya Ganguli, Mehran Sahami, Leonidas J Guibas, and Jascha Sohl-Dickstein. Deep knowledge tracing. In C. Cortes, N. D. Lawrence, D. D. Lee, M. Sugiyama, and R. Garnett, editors, *Advances in Neural Information Processing Systems 28*, pp. 505–513. Curran Associates, Inc., 2015.
- [15] Jiani Zhang, Xingjian Shi, Irwin King, and Dit-Yan Yeung. Dynamic key-value memory network for knowledge tracing. In *Proceedings of the 26th International Conference on World Wide Web, WWW '17*, pp. 765–774. International

- World Wide Web Conferences Steering Committee, 2017.
- [16] 堤瑛美子, 郭亦鳴, 植野真臣. 学習データの忘却を最適化する deepirt. 人工知能学会全国大会論文集, Vol. JSAI2022, pp. 2D6GS202–2D6GS202, 2022.
- [17] Aritra Ghosh, Neil Heffernan, and Andrew S Lan. Context-aware attentive knowledge tracing. In *Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, 2020.
- [18] Emiko Tsutsumi, Ryo Kinoshita, and Maomi Ueno. Deep-irt with independent student and item networks. In *Proceedings of the 14th International Conference on Educational Data Mining (EDM)*, 2021.
- [19] 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.
- [20] Kevin H. Wilson, Yan Karklin, Bojian Han, and Chaitanya Ekanadham. Back to the basics: Bayesian extensions of irt outperform neural networks for proficiency estimation. In *9th International Conference on Educational Data Mining*, Vol. 1, pp. 539–544, 06 2016.
- [21] Shalini Pandey and George Karypis. A self-attentive model for knowledge tracing. In *Proceedings of International Conference on Education Data Mining*, 2019.
- [22] Emiko Tsutsumi, Yiming Guo, and Maomi Ueno. Deepirt with a hypernetwork to optimize the degree of forgetting of past data. In *Proceedings of the 15th International Conference on Educational Data Mining (EDM)*, 2022.
- [23] Aaron van den Oord, Sander Dieleman, Heiga Zen, Karen Simonyan, Oriol Vinyals, Alex Graves, Nal Kalchbrenner, Andrew Senior, and Koray Kavukcuoglu. Wavenet: A generative model for raw audio, 2016.
- [24] Shaojie Bai, J. Zico Kolter, and Vladlen Koltun. An empirical evaluation of

- generic convolutional and recurrent networks for sequence modeling, 2018.
- [25] Sepp Hochreiter and Jürgen Schmidhuber. Long short-term memory. *Neural Computation*, Vol. 9, No. 8, pp. 1735–1780, 1997.
- [26] Junyoung Chung, Çağlar Gülçehre, KyungHyun Cho, and Yoshua Bengio. Empirical evaluation of gated recurrent neural networks on sequence modeling. *CoRR*, Vol. abs/1412.3555, , 2014.
- [27] Angjoo Kanazawa, Jason Y. Zhang, Panna Felsen, and Jitendra Malik. Learning 3d human dynamics from video. In *Computer Vision and Pattern Recognition (CVPR)*, 2019.
- [28] Triantafyllos Afouras, Joon Son Chung, Andrew Senior, Oriol Vinyals, and Andrew Zisserman. Deep audio-visual speech recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 44, No. 12, pp. 8717–8727, 2022.
- [29] Colin Lea, Michael D. Flynn, Rene Vidal, Austin Reiter, and Gregory D. Hager. Temporal convolutional networks for action segmentation and detection. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, July 2017.
- [30] Wentian Zhao, Yanyun Gao, Tingxiang Ji, Xili Wan, Feng Ye, and Guangwei Bai. Deep temporal convolutional networks for short-term traffic flow forecasting. *IEEE Access*, Vol. 7, pp. 114496–114507, 2019.
- [31] 堤瑛美子, 郭亦鳴, 植野真臣. 学習データの忘却を最適化する hypernetwork を組み込んだ deepirt. 電子情報通信学会論文誌, Vol. Vol.J106-D, No. No.2, pp. xxx–xxx, 2023.
- [32] Andrew D. Martin and Kevin 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.

- [33] Chaitanya Ekanadham and Yan Karklin. T-skirt: Online estimation of student proficiency in an adaptive learning system. *CoRR*, Vol. abs/1702.04282, , 2017.
- [34] Emiko Tsutsumi, Ryo Kinoshita, and Maomi Ueno. Deep item response theory as a novel test theory based on deep learning. *Electronics*, Vol. 10, No. 9, 2021.
- [35] Dan Hendrycks and Kevin Gimpel. Gaussian error linear units (gelus), 2016.
- [36] Maomi Ueno and Yoshimitsu Miyazawa. Probability based scaffolding system with fading. In *Proceedings of Artificial Intelligence in Education – 17th International Conference, AIED*, pp. 237–246, 2015.
- [37] Maomi Ueno and Yoshimitsu Miyazawa. IRT-based adaptive hints to scaffold learning in programming. *IEEE Transactions on Learning Technologies*, Vol. 11, pp. 415–428, 10 2018.