

電気通信大学情報理工学域
I 類 (情報系) 情報数理工学プログラム卒業論文

アダプティブラーニングのための
Deep-IRT を用いた最適ヒント予測

2025 年 1 月 28 日

情報数理工学プログラム

学生番号 2010311

佐々木 極昇

指導教員 植野 真臣

1 まえがき

近年、教育の現場では、教師は学習者に教えすぎても、教えなさすぎても学習者の十分な発達は見えないという問題が注目されている。Vygotsky [1, 2] は、学習者が自力で課題解決できない場合でも教師の支援によって学習者の発達を促すことができる「最近発達領域」(ZPD; Zone of Proximal Development) を提案した。ZPD の考え方に従い、Bruner [3] や Wood et al. [4], Collins [5] は、学習者が高次の課題に取り組む際に、個々の能力に応じた適度な支援「足場がけ」を行えば能力の発達を促せることを示した。

適切な足場がけを提供するには、学習者の能力を正確に予測すること、足場がけ後の学習者のパフォーマンスを予測することが重要な課題である。そこで、Brown and Ferrara [6] や Collins [5] は、学習者の学習履歴データを用いて ZPD における学習者の能力を客観的に測定するダイナミックアセスメントと呼ばれる新たな評価手法を開発した。ダイナミックアセスメントは、学習者支援に段階的なヒントを使用し、課題を解くのに利用したヒント数から学習者を評価する手法である。彼らが行った実験では、少数のヒントで課題に正答した学習者ほど学習効率が高いことが示された。その後、Wood [7] は、学習効率の高い支援を行うには、それまでの課題を解くのに利用したヒント数を評価するのが重要であると示した。しかし、ダイナミックアセスメントには以下の問題がある。1) 難易度の異なる課題の特性を評価に使用していないため、能力評価としての信頼性が低い。2) 課題ごとの異なるヒントの特性を評価に使用していないため、能力評価としての信頼性が低い。

この問題を解決するために、植野・松尾 [8], Ueno and Miyazawa [9, 10] は、学習者の課題に対するヒント提示後の反応を予測する項目反応理論 (Item Response Theory, IRT) を提案した。更に、彼らは提案した項目反応理論を用いて、ヒントを提示した後の学習者の課題へのパフォーマンス (正答確率) を予測し、最も学習効果が高くなるように適応的にヒントを与えるアダプティブ・ラーニング・システムを開発した。この手法では、ヒント提示後の学習効果が最大になる正答確率 p が存在すると仮定し、学習者の課題への予測正答確率が p に近いヒントを提示する。Ueno and Miyazawa [10] では、いくつかの p の候補を設定し、各々の p に近いヒントを提示する学習者グループのプレテストとポストテストの差異を比較した。実験の結果から、 $p = 0.5$ に設定したグループの学習効果が最大となった。このことから、学習効果を最大化する足場がけのためには、ヒント提示後の課題に対する高精度な正答確率予測が重要であることが示唆される。

しかし、Ueno and Miyazawa [9, 10] が用いた IRT モデルは学習過程での能力値の時系

列変化を考慮できないために長期の学習過程に対して予測正答確率の誤差が増加する問題があった。そこで、堤らは学習者の能力変化の度合いと、ある時点での能力値が継続する時間(課題数)を考慮するために、学習者の能力が学習過程において変化するプロセスを項目反応理論に組み込んだ隠れマルコフ IRT モデルを提案した [11]。隠れマルコフ IRT はある時点での能力値が影響する時間(課題数)を表すウィンドウサイズと学習者の能力の変動の程度を反映する変動パラメータをもち、これらの最適値をデータから推定することで学習者のヒント提示後のパフォーマンスの予測精度が向上することを示した。その他にも学習者の能力成長を追跡するために、潜在能力値が隠れマルコフ過程に従う確率モデルが複数提案されている [12-14]

しかし、これらの確率モデルには以下の問題がある。

1. 課題の局所独立性を仮定しているため、課題間の関係性を推定できない
2. 複数のスキル間の関係性を元にした能力値推定や困難度推定ができない

近年では e-ラーニングシステムで収集した学習者の課題への反応データを機械学習を用いて分析し、未知の項目に対する学習者の反応予測を行う knowledge Tracing が注目を集めている。[12, 15-27]。深層学習を用いた手法では学習者の時系列変化する多次元の潜在能力を推定し、複数のスキル・課題間の関係性を考慮した反応予測を行い、確率モデルを用いた手法より高い汎化性能を示すことが知られている。最新の研究において堤らは、高い反応予測精度とパラメータの教育的解釈性を実現するために、深層学習手法と項目反応理論の枠組みを組み合わせた Deep-IRT を開発した。堤らの Deep-IRT 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を用いることで、未知の項目に対する高い反応予測精度と IRT と同等の高いパラメータ解釈性をもつことを報告している [26, 27]。しかし、このモデルでは各ヒントの困難度推定が出来ないために、ヒントを与えた時の課題に対する正答確率予測ができない。

本研究では、学習効果を最大化する足場かけを実現するために、深層学習を用いて学習者の時系列変化する多次元の能力値と、各ヒントを提示した際の課題の困難度を推定し、ヒント提示後の課題への正答確率を予測するあらたな Deep-IRT を提案する。提案手法は、Deep-IRT に各ヒントの困難度を推定するネットワークを追加することで、各ヒントの難易度を推定可能にしたモデルである。これにより、提案手法は学習過程での能力値の時系列変化を考慮でき、さらに複数の潜在スキルを用いた能力値推定と困難度推定が行える。実験では、提案手法と既存手法を用いて、学習者が使用した予測精度の比較を行う。

2 ダイナミックアセスメント・システム

Ueno and Miyazawa [10] は、段階反応モデルを用いてヒント提示後の学習者の項目への正答確率を予測し、最も学習効果が高くなるヒント数を予測することで個々の学習者に適応的に支援を行うシステムを開発した。システムの内容はプログラミング学習におけるトレース問題であり、学習者は初めにプログラミングの基礎知識を学習後、プログラムコードを読み、指定された変数に格納される最後の値を答える課題を数問解答する。学習者が課題に誤答した場合は、学習者が正答するまで図1のようにプログラミングの文法の説明やコードの意味などがヒントとして段階的に提示される。学習者が課題に正答するか最後のヒント提示後に誤答をすると、課題の解答と解説を提示する。




図1 ダイナミックアセスメント・システム

Ueno and Miyazawa [9,10] では、このシステムの運用にあたり予測正答確率が 0.5 に近いヒントを提示する支援が最も学習効率が高いことが示されており、ヒント提示後の正答確率を正確に予測することが重要であることが報告されている。

3 項目反応理論

ここでは、学習者の項目への反応履歴データから学習者の能力値と未知の課題への正答確率を予測する手法の1つとして、項目反応理論 [28, 29] の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。学習者 i が項目 j に正答した時の反応を $u_{(i,j)} = 1$, 誤答した時の反応を $u_{(i,j)} = 0$ とすると、学習者 i の項目 j に対して正答する確率は次式で表される。

$$p(u_{(i,j)} = 1 | \theta_i) = \frac{1}{1 + \exp(-1.7\alpha_j(-\theta_i - \beta_j))} \quad (1)$$

ここで、 α_j は項目 j の識別力パラメータ、 β_j は項目 j の困難度、 θ_i は学習者 i の能力パラメータをそれぞれ表す。

適切な足場がけを決定するには、正確な能力値推定と各ヒント提示後の学習者のパフォーマンス予測が必要である。そこで Ueno and Miyazawa [9, 10] は項目反応理論の段階反応モデル [9, 10, 30] で能力値評価と各ヒント提示後の学習者のパフォーマンス予測を行った。段階反応モデルは学習者 i が項目 j にヒント $k = \{k = 1, \dots, s(j)\}$ で正答する確率 $P_i^{(j,k)}$ を次式で求める。ここで、学習者の反応 $u_{(i,j)} = 0$ はヒントなしで正解した場合、 $u_{(i,j)} = s(j)$ は項目 j のすべてヒントを利用して正解した場合、 $u_{(i,j)} = s(j) + 1$ はすべてのヒントを利用しても誤答した場合をそれぞれ表す。

$$p(u_{(i,j)} = k | \theta_i) = p_i^{(j,k)} - p_i^{(j,k-1)} \quad (2)$$

$$p_i^{(j,k)} = \frac{1}{1 + \exp(-\alpha_j(-\theta_i - \beta_{(j,k)}))} \quad (3)$$

ただし、 $p_i^{(j,s(j)+1)} = 1$, $p_i^{(j,0)} = 0$ である。ここで、 $\beta_{(j,k)}$ は項目 j にヒント k までを使用して解いた場合の困難度を表す。ただし、 $\beta_{(j,0)} > \beta_{(j,k)} > \beta_{(j,s(j))}$ である。

しかし、Ueno and Miyazawa [10] が用いた段階反応モデルでは、学習者の真の能力値が時点ごとに変化せず、学習過程で固定値であることが仮定されている。これにより能力値の時系列変化を考慮できず、長期の学習過程に対して予測正答確率の誤差が増加する問題があった。

4 隠れマルコフ IRT モデル

従来の項目反応理論の問題を解決するために、堤らは、学習者の能力が時点ごとに変化するプロセスを項目反応理論に組み込んだ隠れマルコフ IRT モデルを提案した [11]。段

階反応モデル [9, 10, 30] と隠れマルコフ IRT モデル [11] のグラフィカルモデルを図 2, 3 示す.




図 2 段階反応モデル




図 3 隠れマルコフ IRT モデル

前述したとおり段階反応モデルでは、学習者 i の能力値が固定されているため時間による能力値変化を考慮出来ない．一方で、隠れマルコフ IRT モデルでは学習者 i の時点 t における能力値 $\theta_{(i,t)}$ が時点 $t-1$ における能力値 $\theta_{(i,t-1)}$ に依存して確率的に変化するモデルである [11]．また、隠れマルコフ IRT モデルでは能力値 $\theta_{(i,t)}$ の変動モデルにスライディングウィンドウ方式 [31, 32] を用いている．スライディングウィンドウ方式は、設定したデータ区間を一定の幅でスライドしながら隠れ変数が影響する変数領域を決定する方法である．隠れマルコフ IRT モデルではある時点での学習者の能力値が影響を及ぼす課

題数 (ウィンドウサイズ) を L と設定し、 L 個以上の項目に解答した場合には以降の能力値推定に使用する項目の範囲を 1 題ずつずらして能力値の時系列変化を推定する。これにより、学習者が解答した直近 L 個の項目以前の反応データを忘却した能力値推定が可能となる。時点 t において学習者 i が項目 j にヒント k で正答する確率 $q_t^{(j,k)}$ を次式で求める。

$$p(u_{(i,j)} = k | \theta_{(i,t)}) = p_{(i,t)}^{(j,k)} - p_{(i,t)}^{(j,k-1)} \quad (4)$$

$$p_{(i,t)}^{(j,k)} = \frac{1}{1 + \exp(-\alpha_j (-\theta_{(i,t)} - \beta_{(j,k)}))} \quad (5)$$

ここで、 $\theta_{(i,t)}$ は時点 t での学習者 i の能力パラメータをそれぞれ表す。ただし、

$$\theta_{(i,t)} \sim N(\theta_{(i,t-1)}, \delta) \quad (6)$$

$$\theta_{(i,0)} \sim N(0, 1) \quad (7)$$

ここで、 $N(\mu, \sigma)$ は平均 μ 、標準偏差 σ の正規分布を表し、 δ は能力値の変動パラメータである。

しかし、従来の IRT モデルや隠れマルコフ IRT モデルは課題の局所独立性を仮定しているために、項目間の関係性を推定できず、複数のスキル間の関係性を元にした能力値推定や困難度推定ができないために、課題への予測正答確率が正確に推定されていない可能性がある。

5 Deep-IRT

近年、e-ラーニングシステムで収集した学習者の解答履歴データから、学習者の習熟度と未知の項目に対する学習者の反応を予測する knowledge Tracing が盛んに研究されている [12, 15–27]。その中でも深層学習を用いた手法は、学習者の時系列変化する多次元の潜在能力推定と複数のスキル・課題間の関係性を考慮した反応予測を行うことで、確率モデルを用いた手法より高精度な予測精度を示すことが知られている [19–27]。最新の研究において堤らは、高い反応予測精度とパラメータの教育的解釈性を実現するために、深層学習手法と項目反応理論を組み合わせた Deep-IRT を提案した [26, 27]。堤らの Deep-IRT [26, 27] では、時点ごとの学習者の能力値を推定する学習者ネットワークと項目の難易度を推定する項目ネットワークを用いることで、未知の項目に対する学習者の反応予測を行う。




図4 Deep-IRT の構造

堤らの Deep-IRT の構造を図4に示す．堤らの Deep-IRT [26, 27] では L 個の潜在スキルを仮定しており，各項目と潜在スキルとの関係を key memory $\mathbf{M}^k \in \mathbb{R}^{N \times d_k}$ へ保存し，時点 t の各潜在スキルに対する能力値を value memory $\mathbf{M}_t^v \in \mathbb{R}^{N \times d_v}$ に保存する．ここで， d_k, d_v はチューニングパラメータである．学習者ネットワークでは， N 層のニューラルネットワークを用いて $\mathbf{M}_t^v$ から時点 t で学習者 i が項目 j に解答する際の能力値 $\theta^{(t,j)}$ を推定する．

$$\mathbf{w}_t = \mathbf{M}_t^v \quad (8)$$

$$\theta_1^{(t,j)} = \sum_{l=1}^L \mathbf{M}_t^v{}^\top \quad (9)$$

$$\theta_n^{(t,j)} = \tanh \left(\mathbf{W}^{(\theta_n)} \theta_{n-1}^{(t,j)} + \tau^{(\theta_n)} \right) \quad (10)$$

$$\theta^{(t,j)} = \mathbf{w}_t{}^\top \theta_N^{(t,j)} \quad (11)$$

ここで， $n = \{n \in \mathbb{R} | 2 \leq n \leq N\}$ ， $\mathbf{w}_t$ は項目のスキルと潜在スキルの関係性の強さを表す attention である．項目ネットワークでは，項目 j の困難度 β_{item}^j と項目 j を解答する際に必要なスキルの困難度 β_{skill}^j を推定する． β_{item}^j は項目 j から計算された埋め込みベクトル $\mathbf{q}_j \in \mathbb{R}^{d_k}$ を用いて 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．

$$\mathbf{q}_1^j = \tanh \left(\mathbf{W}^{(q_1)} \mathbf{q}_j + \tau^{(q_1)} \right) \quad (12)$$

$$\mathbf{q}_n^j = \tanh \left(\mathbf{W}^{(q_n)} \mathbf{q}_{n-1}^j + \tau^{(q_n)} \right) \quad (13)$$

$$\beta_q^j = \mathbf{W}^{(\beta_q)} \mathbf{q}_N^j + \boldsymbol{\tau}^{(\beta_q)} \quad (14)$$

β_s^j は項目 j のスキルから計算された埋め込みベクトル $\mathbf{s}_j \in \mathbb{R}^{d_k}$ を用いて 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.

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

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

$$\beta_s^j = \mathbf{W}^{(\beta_s)} \gamma_N^{(j)} + \boldsymbol{\tau}^{(\beta_s)} \quad (17)$$

学習者 i が時点 t で項目 j に正答できる確率は以下の方式で計算される.

$$p_t^j = \sigma \left(\theta^{(i,t)} - (\beta_q^j + \beta_s^j) \right) \quad (18)$$

ここで, σ はシグモイド関数を表す.

堤らの Deep-IRT [26, 27] では, Memory updating component と呼ばれる機構で学習者の最新の反応を用いて, value memory $\mathbf{M}_t^v$ を更新する. 始めに, 項目 j に対する学習者 i の反応を $y_{i,j}$ (1 : 正答, 0 : 誤答) として, 埋め込みベクトル $\mathbf{c}_j$ を以下の方法で計算する.

$$\mathbf{c}_j = \begin{cases} [\mathbf{0}, \mathbf{q}_j] & y_j = 1 \\ [\mathbf{q}_j, \mathbf{0}] & y_j = 0 \end{cases} \quad (19)$$

次に, 以下のように value memory $\mathbf{M}_t^v$ を更新する.

$$\mathbf{v}_t = \mathbf{W}^v \mathbf{c}_j + \boldsymbol{\tau}^v \quad (20)$$

$$\mathbf{e}_t = \sigma (\mathbf{W}^e \mathbf{v}_t + \boldsymbol{\tau}^e) \quad (21)$$

$$\mathbf{a}_t = \tanh (\mathbf{W}^a \mathbf{v}_t + \boldsymbol{\tau}^a) \quad (22)$$

$$\tilde{\mathbf{M}}_{(t+1)}^v = \mathbf{M}_t^v \otimes (1 - \mathbf{w}_t \mathbf{e}_t) \quad (23)$$

$$\mathbf{M}_{(t+1)}^v = \tilde{\mathbf{M}}_{(t+1)}^v + \mathbf{w}_t \mathbf{a}_t^\top \quad (24)$$

ここで, $\mathbf{W}$ は重みパラメータ, $\boldsymbol{\tau}$ はバイアスパラメータ, $\otimes$ はアダマール積を表す. また, $\mathbf{e}_t$ は $\mathbf{M}_t^v$ の値をどの程度保存するかを決定し, $\mathbf{a}_t$ は時点 t の反応データをどの程度更新に反映するかを決定するパラメータである.

堤らの Deep-IRT [26, 27] では Deep-IRT が未知の項目に対する高い反応予測精度と IRT と同等の高いパラメータ解釈性をもつことを報告している. しかし, 各ヒントの困

難度を推定するネットワークが存在しないため、各ヒント提示後の課題に対する正答確率予測ができず、段階的ヒントを用いた足場がけ支援に適応していない。また、能力値更新にヒントの情報を用いないために、学習者が使用したヒントを考慮して能力値を更新出来ない。

6 提案手法

本研究では、学習効果を最大化する足場がけを実現するために、深層学習を用いて学習者の時系列変化する多次元の能力値と、各ヒントを提示した際の課題の困難度を推定し、ヒント提示後の課題への正答確率を予測する新たな Deep-IRT を提案する。提案手法は、堤らの Deep-IRT [26, 27] に、各ヒントの困難度を推定するネットワークを追加し、ヒントを考慮した多次元の能力値更新と項目間の関係性を考慮した反応予測を行う。また、Memory updating component では学習者が利用したヒントに応じて時点ごとに value memory M_t^v の更新を行う。




図5 提案手法の構造

提案手法の構造を図5に示す。提案手法は学習者ネットワーク、項目ネットワーク、ヒントネットワークの3種類の独立なニューラルネットワークから構成される。ヒントネットワークは項目 j が持つヒントから埋め込み処理を行った $\mathbf{h}_{(j)} = [h_{(j,0)}, \dots, h_{(j,k)}, \dots, h_{(j,s(j))}]$ を入力とし、段階ヒントを提示した際の困難度の差分 $\beta_h^{(j,k)}$

を推定する．まず，提案手法における項目 j の困難度 β_q^j を以下で求める．

$$\mathbf{q}_1^j = \tanh \left(\mathbf{W}^{(q_1)} \mathbf{q}_j + \boldsymbol{\tau}^{(q_1)} \right) \quad (25)$$

$$\mathbf{q}_n^j = \mathbf{W}^{(q_n)} \mathbf{q}_{n-1}^j + \boldsymbol{\tau}^{(q_n)} \quad (26)$$

$$\beta_q^j = \mathbf{W}^{(\beta_q)} \mathbf{q}_N^j + \boldsymbol{\tau}^{(\beta_q)} \quad (27)$$

次に，各ヒントを提示した場合の困難度の差分を以下で求める．

$$\mathbf{h}_1^{(j,k)} = \tanh \left(\mathbf{W}^{(h_1)} \mathbf{h}_{(j,k)} + \boldsymbol{\tau}^{(h_1)} \right) \quad (28)$$

$$\mathbf{h}_n^{(j,k)} = \mathbf{W}^{(h_n)} \mathbf{h}_{n-1}^{(j,k)} + \boldsymbol{\tau}^{(h_n)} \quad (29)$$

$$\begin{aligned} \beta_h^{(j,k)} &= \text{softplus} \left(\mathbf{W}^{(\beta_h)} \mathbf{h}_N^{(j,k)} + \boldsymbol{\tau}^{(\beta_h)} \right) \\ &= \log \left(\exp \left(\mathbf{W}^{(\beta_h)} \mathbf{h}_N^{(j,k)} + \boldsymbol{\tau}^{(\beta_h)} \right) + 1 \right) \end{aligned} \quad (30)$$

項目 j でヒント 1 から k まで提示した後の困難度 $\beta^{(j,k)}$ は次式で求める．

$$\beta^{(j,k)} = \begin{cases} \beta_q^j - \beta_h^{(j,k)} & k = 0 \\ \beta^{(j,k-1)} - \beta_h^{(j,k)} & 1 \leq k \end{cases} \quad (31)$$

学習者ネットワークでは既存手法と同様に式 (8) – (11) を用いて能力値を求める．各ネットワークの出力から学習者 i が時点 t で項目 j にヒント 1 から k までを用いて正答できる確率は以下で求める．

$$p_t^{(j,k)} = \sigma \left(\theta^{(i,t)} - \beta^{(j,k)} \right) \quad (32)$$

次に，提案手法における能力値更新の方法について説明する．提案手法では学習者が項目 j に対して正答するまで使用したヒント数から埋め込みベクトルを作成する．具体的には，学習者が項目 j に対しヒント y で正解した場合，埋め込みベクトル $\mathbf{c}_{j,k}$ を以下のようにする．

$$\mathbf{c}_{j,k} = \begin{cases} 1 & \text{項目 } j \text{ に対しヒント } y \text{ で正答} \\ 0 & \text{それ以外} \end{cases} \quad (33)$$

$$\mathbf{c} = [\mathbf{c}_{1,0}, \dots, \mathbf{c}_{1,k}, \dots, \mathbf{c}_{1,K}, \dots, \mathbf{c}_{j,0}, \dots, \mathbf{c}_{j,k}, \dots, \mathbf{c}_{j,K}, \dots, \mathbf{c}_{J,0}, \dots, \mathbf{c}_{J,k}, \dots, \mathbf{c}_{J,K}] \quad (34)$$

ここで， J は項目の合計数を表し， $K = \max\{s(1), \dots, s(j), \dots, s(J)\}$ である．埋め込みベクトル $\mathbf{c}$ を用いて，堤らの Deep-IRT [26, 27] と同様の方法で能力値を更新する．

$$\mathbf{v}_t = \mathbf{W}^v \mathbf{c} + \boldsymbol{\tau}^v \quad (35)$$

$$\mathbf{e}_t = \sigma(\mathbf{W}^e \mathbf{v}_t + \boldsymbol{\tau}^e) \quad (36)$$

$$\mathbf{a}_t = \tanh(\mathbf{W}^a \mathbf{v}_t + \boldsymbol{\tau}^a) \quad (37)$$

$$\tilde{\mathbf{M}}_{(t+1)}^v = \mathbf{M}_t^v \otimes (1 - w_t \mathbf{e}_t) \quad (38)$$

$$\mathbf{M}_{(t+1)}^v = \tilde{\mathbf{M}}_{(t+1)}^v + w_t \mathbf{a}_t^\top \quad (39)$$

7 実験結果

7.1 利用ヒント数予測実験

本節では、提案手法と既存手法である IRT, 隠れマルコフ IRT モデル (HMIRT) [11] を用いて、実データにおいて学習者が課題に正解するまでに利用したヒント数の予測精度比較を行う。具体的には、学習者が正答するまでに必要なヒント数を予測し、実際に利用したヒント数との Acc(一致割合: Accuracy), AUC スコア (macro-AUC, micro-AUC), 2 次の重み付きカッパ係数 (quartic weighted kappa: QWK) を評価する。

本節ではデータセットはプログラミング、物理、離散数学の 3 種類の反応データを用いた。上記のデータセットを 10 分割交差検証で訓練データ、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でモデルのパラメータを調整した後に評価データで予測精度を算出する。データセットの詳細は表 1 に示す。表中の各ヒントの利用率とは項目が持つ各ヒントを使用した学習者の割合の平均を表し、(40) 式で算出した。

表 1 データセットの詳細

データセット名	学習者数	項目数	欠損率	ヒント数 (平均)	各ヒントの利用率 (平均)
プログラミング	75	18	1.19%	9.55	3.42%
物理	99	64	50.63%	2.18	13.30%
離散数学	436	123	18.78%	5.07	6.40%

$$\text{項目 } j \text{ のヒント利用率} = \frac{\text{項目 } j \text{ でヒントを使用して正答した解答数}}{\text{項目 } j \text{ の解答数} \times \text{項目 } j \text{ のヒント数}} \quad (40)$$

また、必要なヒント $\hat{k}$ の算出には以下の式を使用する。ここで、 $\hat{k} = s(j) + 1$ とは課題 j

が持つ全てのヒントを使用しても誤答した場合を表す.

$$\hat{k} = \underset{k}{\operatorname{argmax}} \begin{cases} 1 - p_t^{(j,k)} & \text{if } k = s(j) + 1 \\ p_t^{(j,k)} & \text{if } k = 0 \\ p_t^{(j,k)} - p_t^{(j,k-1)} & \text{others.} \end{cases} \quad (41)$$

IRT と HMIRT の訓練方法は先行研究 [11] と同様の方法で行った. このとき, HMIRT モデルの能力値の変動パラメータ δ とウィンドウサイズ L の最適値は $\{0.1, 0.2, 0.3, 0.5\} \times \{1, 2, \dots, 10\}$ から交差検証で最も予測精度が高い組み合わせを選択した. また, 提案手法のネットワークの層数 N の最適値を $\{2, 3, 4, 5, 6, 7, 8, 9, 10\}$ から同様の方法で選択した. 実験の結果, プログラミングでは $(\delta, L) = (0.1, 2)$, 物理では $(\delta, L) = (0.1, 6)$, 離散数学では $(\delta, L) = (0.1, 9)$ を選択した. また, N の値を表 2 に示す. 以降, Deep-IRT に hint network を加えた手法を提案手法 1, 提案手法 1 に新たな hint embedding を追加した手法を提案手法 2 と呼ぶ.

表 2 N の設定値

データセット名	提案手法 1	提案手法 2	提案手法 3
プログラミング	3	7	7
物理	2	7	6
離散数学	2	6	3

なお IRT の段階反応モデルの事前分布は以下の通りである.

$$\log \alpha_j \sim N(0.0, 0.2)$$

$$\theta_i \sim N(0.0, 1.0)$$

$$\{\mu_{(j,0)}, \dots, \mu_{(j,k)}, \dots, \mu_{(j,s(j))}\} = \{-2, \dots, -2 + \frac{4k}{s(j)}, \dots, 2\}$$

$$\beta_{(j,k)} \sim N(\mu_{(j,k)}, 0.16)$$

表 3 利用ヒント数予測実験の結果

データセット名	評価手法	IRT	HMIRT	提案手法 1	提案手法 2
プログラミング	Acc	0.605 $\pm$ 0.004	0.664 $\pm$ 0.001	0.658 $\pm$ 0.001	0.651 $\pm$ 0.002
	Macro-F1	0.307 $\pm$ 0.005	0.351 $\pm$ 0.004	0.348 $\pm$ 0.002	0.343 $\pm$ 0.003
	macro-AUC	0.492 $\pm$ 0.003	0.443 $\pm$ 0.007	0.632 $\pm$ 0.007	0.690 $\pm$ 0.005
	micro-AUC	0.837 $\pm$ 0.001	0.848 $\pm$ 0.001	0.874 $\pm$ 0.001	0.885 $\pm$ 0.001
	RMSE	0.234 $\pm$ 0.008	0.125 $\pm$ 0.007	0.142 $\pm$ 0.004	0.195 $\pm$ 0.007
	QWK	0.274 $\pm$ 0.009	0.136 $\pm$ 0.018	0.093 $\pm$ 0.010	0.186 $\pm$ 0.013
物理	Acc	0.497 $\pm$ 0.001	0.583 $\pm$ 0.003	0.584 $\pm$ 0.002	0.591 $\pm$ 0.004
	Macro-F1	0.379 $\pm$ 0.001	0.421 $\pm$ 0.005	0.416 $\pm$ 0.002	0.423 $\pm$ 0.005
	macro-AUC	0.515 $\pm$ 0.003	0.493 $\pm$ 0.008	0.526 $\pm$ 0.004	0.523 $\pm$ 0.008
	micro-AUC	0.643 $\pm$ 0.002	0.754 $\pm$ 0.003	0.754 $\pm$ 0.000	0.748 $\pm$ 0.005
	RMSE	0.656 $\pm$ 0.001	0.559 $\pm$ 0.004	0.586 $\pm$ 0.002	0.580 $\pm$ 0.002
	QWK	0.172 $\pm$ 0.002	0.428 $\pm$ 0.009	0.416 $\pm$ 0.005	0.433 $\pm$ 0.009
離散数学	Acc	0.634 $\pm$ 0.000	0.679 $\pm$ 0.000	0.663 $\pm$ 0.001	0.675 $\pm$ 0.001
	Macro-F1	0.308 $\pm$ 0.001	0.326 $\pm$ 0.001	0.287 $\pm$ 0.004	0.331 $\pm$ 0.001
	macro-AUC	0.586 $\pm$ 0.001	0.684 $\pm$ 0.001	0.666 $\pm$ 0.002	0.725 $\pm$ 0.001
	micro-AUC	0.862 $\pm$ 0.000	0.903 $\pm$ 0.000	0.894 $\pm$ 0.000	0.903 $\pm$ 0.000
	RMSE	0.333 $\pm$ 0.001	0.260 $\pm$ 0.000	0.268 $\pm$ 0.000	0.257 $\pm$ 0.001
	QWK	0.459 $\pm$ 0.001	0.558 $\pm$ 0.003	0.518 $\pm$ 0.002	0.601 $\pm$ 0.003
Average	Acc	0.579	0.642	0.635	0.639
	Macro-F1	0.331	0.366	0.350	0.366
	macro-AUC	0.531	0.540	0.608	0.646
	micro-AUC	0.781	0.835	0.840	0.845
	RMSE	0.408	0.315	0.332	0.344
	QWK	0.302	0.374	0.342	0.406

実験結果を表 3 に示す. 表 3 より, 提案手法 2, 3 は既存手法 (IRT, HMIRT) に対し AUC スコア, QWK で平均的に上回ることを示した.

8 まとめ

本研究では, 学習効果を最大化する足場がけを実現するために, 深層学習を用いて学習者の時系列変化する多次元の能力値と, 各ヒントを提示した際の課題の困難度を推定し,

ヒント提示後の課題への正答確率を予測するあらたな Deep-IRT を提案した。評価実験では、提案手法は IRT に近い解釈性をもつパラメータ推定が可能であることを示したが、利用ヒント数の予測精度については既存手法を平均的に下回った。今後は実データのようにデータ数が比較的少なく、欠損がある場合にも高精度なヒント数予測ができるように改良していきたい。

参考文献

- [1] L. S. Vygotsky. Thought and language. *Cambridge, MA: MIT Press*, 1962.
- [2] L. S. Vygotsky. Mind in society. *Cambridge, MA: MIT Press*, 1978.
- [3] J. S. Bruner. The culture of education. *The Culture of Education. Harvard University Press*, 1997.
- [4] David J. Wood, J. S. Bruner, and Gail Ross. The role of tutoring in problem solving. *Journal of Child Psychology and Psychiatry*, Vol. 17, pp. 89–100, 2006.
- [5] Collins, Allan, John Seely Brown, and Susan E. Newman. Cognitive apprenticeship: Teaching the craft of reading, writing and mathematics. *Thinking: The journal of philosophy for children* 8.1, pp. 2–10, 1988.
- [6] A. Brown and R. Ferrara. Diagnosing zones of proximal development. *Culture, communication, and cognition: Vygotskian perspectives*, pp. 273–305, 1985.
- [7] David J. Wood. Scaffolding, contingent tutoring, and computer-supported learning. *International Journal of Artificial Intelligence in Education* 12.3, pp. 280–293, 2001.
- [8] 植野真臣, 松尾淳哉. 項目反応理論を用いて適応的のヒントを提示する足場かけシステム. 電子情報通信学会論文誌 D, Vol. J98-D, pp. 17–29, 1 2015.
- [9] 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.
- [10] 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.
- [11] 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 D, Vol. J102-D, pp. 79–92, 02 2019.
- [12] Michael V. Yudelson, Kenneth R. Koedinger, and Geoffrey J. Gordon. Individu-

- alized bayesian knowledge tracing models. In *Artificial Intelligence in Education*, pp. 171–180, Berlin, Heidelberg, 2013. Springer Berlin Heidelberg.
- [13] 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.
 - [14] Chaitanya Ekanadham and Yan Karklin. T-SKIRT: Online estimation of student proficiency in an adaptive learning system. *CoRR*, Vol. abs/1702.04282, , 2017.
 - [15] 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.
 - [16] 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.
 - [17] 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.
 - [18] 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.
 - [19] 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.
 - [20] 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.
 - [21] 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.
- [22] Qi Liu, Zhenya Huang, Yu Yin, Enhong Chen, Hui Xiong, Yu Su, and Guoping Hu. EKT: Exercise-aware knowledge tracing for student performance prediction. *IEEE Transactions on Knowledge and Data Engineering*, Vol. 33, pp. 100–115, 06 2019.
 - [23] Hiromi Nakagawa, Yusuke Iwasawa, and Yutaka Matsuo. Graph-based knowledge tracing: Modeling student proficiency using graph neural network. In *2019 IEEE/WIC/ACM International Conference on Web Intelligence (WI)*, pp. 156–163, 2019.
 - [24] Shalini Pandey and Jaideep Srivastava. RKT: Relation-aware self-attention for knowledge tracing. In *Proceedings of the 29th ACM International Conference on Information & Knowledge Management*, pp. 1205–1214, 2020.
 - [25] 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.
 - [26] 堤瑛美子, 木下涼, 植野真臣. 独立な学習者・項目ネットワークをもつ deep-irt. 電子情報通信学会論文誌 D, Vol. J104-D, pp. 596–608, 7 2021.
 - [27] 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.
 - [28] F.M. Lord and M.R. Novick. *Statistical Theories of Mental Test Scores*. Addison-Wesley, 1968.
 - [29] 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.
 - [30] Fumiko Samejima. Estimation of latent ability using a response pattern of graded scores. *Psychometrika monograph supplement*, 1969.
 - [31] Ortiz Laguna, Javier, Angel García Olaya, and Daniel Borrajo. A dynamic sliding window approach for activity recognition. *User Modeling, Adaption and Personalization: 19th International Conference, UMAP 2011, Girona, Spain, July 11-15, 2011. Proceedings 19. Springer Berlin Heidelberg*, 2011.
 - [32] Impedovo Sebastiano, Anna Ferrante, and Raffaele Modugno. Hmm based handwritten word recognition system by using singularities. *2009 10th International*

Conference on Document Analysis and Recognition. IEEE, 2009.