

# Online Learning Multi Deep-IRT による予測所要時間を考慮した適応型テスト Adaptive Testing using Online Learning Multi Deep-IRT with prediction of item response time

岡田 幸征<sup>\*1</sup>, 湊本 吉真<sup>\*1</sup>, 石川 文弥<sup>\*1</sup>, 植野 真臣<sup>\*1</sup>

<sup>\*1</sup> 電気通信大学

<sup>\*1</sup>The University of Electro-Communications

okada@ai.lab.uec.ac.jp

あらまし：適応型テストは受検者の能力を効率的に測定できるが，所要時間を考慮しておらず，制限時間下で測定精度が低下する．本研究では逐次的な回答データから未知の項目への正誤と所要時間を予測可能な Online Learning Multi-Task Deep-IRT を提案する．提案手法では出題時に予測所要時間を用いて制限時間を考慮した最適な項目を出題する．この結果，提案手法は制限時間下で測定精度を向上した

キーワード：適応型テスト, 深層学習, マルチタスク学習, 項目反応理論

## 1. はじめに

適応型テストは，受検者の能力を効率的に測定できる利点を持つが，従来の形式では所要時間を考慮しないため，能力推定精度が低下する可能性がある．制限時間内に出題した項目が解き終わることができない場合，未回答の項目が生じ，能力の推定誤差の増加につながる．

この課題に対処するため，シャドウテストアプローチを用いた制限時間の制約のある適応型テストが提案されている<sup>(1)</sup>．このアプローチでは，各項目に対する解答時間を予測し，制限時間内で受検者が解答可能と見込まれる項目群を適切に提示することにより，能力推定精度を向上させることができた．

所要時間予測には，確率モデル<sup>(2)</sup>が利用されているが，近年では深層学習モデルがその予測精度を上回ることが報告されている．特に，Multi-Task Deep-IRT は，受検者の正誤反応と項目への所要時間を同時に学習できる深層学習モデルとして高い予測精度が知られている<sup>(3)</sup>．Multi-Task Deep-IRT は，Multi-gate Mixture-of-Experts<sup>(4)</sup> というマルチタスク学習の手法を基盤としており，正誤反応と所要時間の依存関係を学習することで，所要時間の予測精度を向上させた．Multi-Task Deep-IRT では，入力ベクトルから受検者と項目のパラメータを予測し，これらのパラメータを用いて正誤反応と所要時間の予測値を算出する．

本研究では，この Multi-Task Deep-IRT を適応型テストに用いるために，逐次的に得られる応答情報を学習することで受検者のパラメータを更新するように拡張した Online learning Multi-Task Deep-IRT を提案する．これにより，未知の受検者に対しても，逐次回答が得られるたびに，予測精度の向上が期待される．この手法を用い，予測した所要時間を用いて出題時に制限時間を考慮した最適な項目を出題する．本研究では，実データを用いた数値実験により，提案手法の有効性を示した．

## 2. Online Learning Multi-Task Deep-IRT

Multi-Task Deep-IRT は，受検者の正誤反応と項目への所要時間を同時に予測できる高精度な深層学習モデル

である．しかし，各受検者の応答の予測には，その受検者の全応答履歴を事前にモデルへ入力する必要があった．そのため，まだ応答履歴のない新しい受検者や，テストを受検途中の受検者については，応答を予測することが不可能だった．そこで本研究では，逐次的に得られる応答から未知受検者の応答予測を可能にする適応型テストのための Online Learning Multi-Task Deep-IRT を提案する．図 1 は，提案手法の概要図である．

項目  $j$  のワンホットベクトル  $q_j$  の入力，エキスパートネットワーク，ゲート付きネットワークに与えられる．エキスパートネットワークでは，複数のエキスパートがそれぞれ異なる特徴を抽出し，ゲート付きネットワークにより，これらのエキスパートに各応答予測タスク（正誤反応，所要時間）に応じた重みづけられる．これにより，特徴ベクトル  $h_j^{(k)}$  が抽出される．次に，各項目に固有の項目パラメータと逐次的な回答データにより更新される受検者パラメータを予測する．

項目難易度  $\beta_j$  と項目時間量  $\lambda_j$  は，タスクごとに抽出された特徴ベクトル  $h_j^{(k)}$  に基づいて FNN（多層 Feed-forward neural network）により推定される．

$$\beta_j = \text{FNN}_\beta(h_j^{(1)}), \lambda_j = \text{FNN}_\lambda(h_j^{(2)})$$

$t$  問回答後に推定される受検者の能力  $\theta_t$  と回答速度  $\zeta_t$  は，直前の応答情報により逐次更新される能力メモリによって推定される．メモリの更新は，項目のワンホットベクトル  $q_t$  と，それに対する応答情報（正誤反応  $v_t^{(1)}$ ，所要時間  $v_t^{(2)}$ ）を結合した入力に基づいて行われる．メモリの add 信号  $a_t^{(k)}$  を用いて更新が行われる．

$$a_t^{(k)} = \tanh(W_a \cdot [q_t, v_t^{(k)}])$$

各メモリ要素  $M_{t+1,j}^{v(k)}$  は，既存の値を，読み出しにおける重み  $w_{t,j}^{(k)}$  と add 信号  $a_t^{(k)}$  を用いて更新される．

$$M_{t+1,j}^{v(k)} = M_{t,j}^{v(k)} + w_{t,j}^{(k)} \cdot a_t^{(k)}$$

次に，予測のため，メモリからの読み出しベクトル  $v_t^{(k)}$  が計算される．これは  $h_j^{(k)}$  とメモリキー  $M^k$  の類似度

から重み  $w_j^{(k)}$  を計算し、メモリ値  $M^v$  を集約する形式で表現される。

$$w_t^{(k)} = \text{softmax}(h_j^{(k)} (M^k)^T)$$

$$v_t^{(k)} = \sum_{j=1}^M w_j^{(k)} \cdot M_{t,j}^v$$

$$\theta_t = \text{FNN}_\theta(v_t^{(1)}), \zeta_t = \text{FNN}_\zeta(v_t^{(2)})$$

受検者パラメータは、逐次的に得られる応答情報からメモリを学習するため、未知の受検者に対しても予測精度の向上が期待される。最終的に、これらの予測したパラメータを用いて、以下のように回答が予測される。ここで、 $\sigma(\cdot)$  はシグモイド関数である。

$$\text{正誤反応} : \hat{y}_1 = \sigma(W_{\hat{y}_1}(\hat{\theta}_i - \hat{\beta}_j) + b_{\hat{y}_1})$$

$$\text{所要時間} : \hat{y}_2 = W_{\hat{y}_2}(-\hat{\zeta}_i + \hat{\lambda}_j) + b_{\hat{y}_2}$$

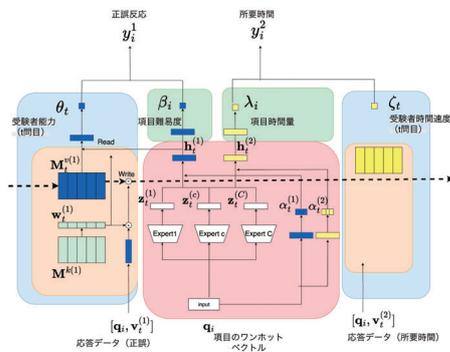


図 1: Online Learning MTDIRT

### 3. Online Learning Multi-Task Deep-IRT による所要時間を考慮した適応型テスト

本研究では、Online Learning Multi-Task Deep-IRT により、各項目への所要時間を予測する。予測した所要時間を用いて、制限時間内で回答可能であるという制約のもと、情報量を最大化するシャドウテストアプローチを用いて、項目の出題を行う。Online Learning Multi-Task Deep-IRT は、受検者から得られる応答情報（正誤反応、所要時間）をメモリに与えてオンライン学習を行うことで、受検者の能力や回答速度を逐次更新する。これにより、未知の受検者に対して、応答情報が得られるたび所要時間の予測精度が向上し、適応型テストにおける能力推定精度も向上が期待される。

### 4. 評価実験

本研究では、電気通信大学における入学時 CBT 学力調査試験結果（UEC 検定）を用いて、提案手法の有効性を示すため評価実験を行った。比較手法は、古典的な適応型テスト（CAT）と従来手法であるシャドウテストアプローチを用いた適応型テスト（STA）とする。試験は 100 項目で構成され、受検者数 666 人である。各手法で出題した項目に対する受検者の実データの正誤反応と所要時間を用いて回答をシミュレーションした。データは 10 分割交差検証により、事前データとシミュレ

ーションデータに分割した。事前データを用いて項目パラメータの推定と Online Learning Multi-Task Deep-IRT の学習を行い、シミュレーションデータを用いて評価を行った。評価指標として、予測所要時間の誤差（RMSE）、テストの所要時間の平均（Avg.time）、出題項目数の平均（Avg.count）、テスト情報量の平均（Avg.info）を用いた。テスト終了条件には、制限時間（30 分、60 分）を設定した。結果を表 1 に示す。

表 1: テスト結果

制限時間	評価指標	CAT	STA	提案手法
30 分	RMSE	230.47 (243.17)	67.33 (4.14)	<b>64.56</b> (4.09)
	Avg.time (s)	1630.69 (82.17)	1684.03 (25.43)	<b>1763.65</b> (12.95)
	Avg.count	11.44 (3.07)	16.16 (2.52)	<b>18.03</b> (3.07)
	Avg.info	0.56 (0.32)	0.76 (0.33)	<b>0.81</b> (0.34)
60 分	RMSE	276.03 (291.27)	68.96 (4.57)	<b>65.61</b> (5.38)
	Avg.time (s)	3461.00 (46.51)	3476.79 (17.35)	<b>3560.09</b> (15.85)
	Avg.count	21.37 (3.15)	25.89 (2.44)	<b>27.61</b> (2.87)
	Avg.info	0.94 (0.38)	1.11 (0.44)	<b>1.19</b> (0.50)

それぞれの表の括弧には標準偏差の値を記した。表 1 より提案手法は、STA よりテスト所要時間の予測精度が高い。また、提案手法は最もテスト情報量を大きくすることができた。平均テスト所要時間は、提案手法が最も長くなっており、平均出題項目数は最も多くなっている。これは、制限時間内で十分に時間を活用し、出題項目数を多くすることができたと推測できる。このことから、提案手法は従来の手法と比較して、制限時間内でより多くの項目を出題し、能力推定精度を向上できた。

### 5. むすび

本研究では、適応型テストのための所要時間予測手法として Online Learning Multi-Task Deep-IRT を提案した。実データを用いたシミュレーション実験により、制限時間下において、提案手法は従来手法よりも多くの項目を出題し、能力推定精度を向上させることができた。

### 参考文献

- (1) Wim J. van der Linden and Xinhui Xiong. Speededness and adaptive testing. *Journal of Educational and Behavioral Statistics*, Vol. 38, No. 4, pp. 418–438, 2013.
- (2) Wim J Van der Linden. A hierarchical framework for modeling speed and accuracy on test items. *Psychometrika*, Vol. 72, No. 3, pp. 287–308, 2007.
- (3) 石川文弥, 瀧本壱真, 植野真臣. 問題項目への所要時間を予測する multi-task deep gaussian process. 人工知能学会研究会資料 先進的学習科学と工学研究会, Vol. 101, pp. 01–06, 2024.
- (4) Jiaqi Ma, Zhe Zhao, Xinyang Yi, Jilin Chen, Lichan Hong, and Ed H. Chi. Modeling task relationships in multi-task learning with multi-gate mixture-of-experts. *KDD '18*, pp. 1930–1939, New York, NY, USA, 2018. Association for Computing Machinery.