

AI・ビッグデータによるアダプティブ・ラーニング

Adaptive Learning using AI and Big data

植野真臣
Maomi Ueno

電気通信大学大学院 情報理工学研究科
Graduate School of Informatics and Engineering, The University of Electro Communications
ueno@ai.lab.uec.ac.jp, <http://www.ai.lab.uec.ac.jp/>

Keywords: big data, knowledge tracing, generation AI, 深層ニューラルネットワーク, automatic essay scoring, deep-IRT

1. はじめに

アダプティブ・ラーニング(Adaptive Learning, 本文中は以降 AL と書く)とは, 人工知能を用いて生徒に適応した学習支援を行う学習支援システムの総称である. 近年の AL は過去の学習履歴ビッグデータを機械学習し, 生徒がどのような知識を習得しているかを学習中に推論して適切な学習内容を提示するアプローチが主になっている. 大規模学習履歴データをあらかじめ機械学習して生徒の知識状態を推論するための手法は(1)確率アプローチの IRT(Item Response Theory; 項目反応理論) [Wilson16] [van der Linden 18] [堤 19, 20]や隠れマルコフモデルによる Knowledge Tracing[Corbett 95]と 2)深層ニューラルネットワークによる Knowledge Tracing [Piech 15]に大別できる. 前者は後者より推論結果や能力値の教育的解釈性は高いが未知の知識状態の予測精度では劣るという特性を持つ. このように従来手法は一長一短があるが, 近年, IRT の解釈性の高さと深層ニューラルネットワークの予測精度の高さを兼ね備えた, 以下の利点を持つ Deep-IRT が注目されている[Tsutsumi 21,22]. パラメータの高い解釈性を持ったままスキル測定精度の高さ, 未知の知識状態予測精度の高さを持つ.

1. IRT の仮定である問題の局所独立性や受検者ランダムサンプリングの仮定が必要ない.
2. 正誤データのみでなく様々な解答データも予測できるだけでなく, 所要時間や解答履歴データを補助データとして加えることが容易にできる.
3. 学習によるスキル能力の時系列変化も表現で

きる.

4. ChatGPT や BERT などの大規模言語モデルによる生成 AI を容易に組み込むことも容易であり, 記述式解答の自動採点だけでなく, 所望の領域・難度の問題やヒント, 解説などを自動生成することも可能となっている.

教育ビッグデータの機械学習手法を AL に如何に有効活用するかが重要な課題となる. 従来 AL への機械学習の活用法として, 学習者の未習熟な知識やスキルを同定し, それらに対応した教材を順次教授していくことが良く知られている. しかし, このように知識を順次教授していく方法は学習者の基礎知識構築には適しているが, より深い思考力を育てるには限界がある. 本論では基礎知識の構築のための従来型 AL を「フェーズ 1」と呼び, より発展した思考力を育てるための AL を「フェーズ 2」と呼び区別する. 「フェーズ 2」についての教育方法は教育学において古くから研究されてきた. 特にヴィゴツキーに代表される社会的構成主義 [Vygotsky 62, 87]はフェーズ 2 を対象にしてきた. 社会的構成主義では, 「教育における難しさとして教師が生徒に教えすぎても教えなさすぎても生徒の発達を十分に促すことができないこと」を指摘してきた. しかし, 従来の教育学研究では生徒に最適な学習支援がどの程度か科学的な知見は明らかにしていない. この問題を解決するために植野らは「確率的足場かけ (Probabilistic Scaffolding)」のフレームワークを提案している[Ueno 15, 18]. この理論では学習効果を最大にする学習支援には, 支援を行うことで生徒が到達する最適な予測正答確率があるという仮説に基づいている. 従来フェーズ 1 の支援は生徒が確率 1.0 で正答できるような支援を行ってきたが, それ

は「教えすぎ」(over-instruction)となることが多いことも指摘している。実験の結果、予測正答確率が 0.35 以上 0.4 以下の問題・問題を適応的に提示し正答確率が 0.5 になるように各生徒にヒントを与える場合が最も生徒の能力が伸びることが示された。つまりフェーズ 2 の学習では、生徒が独力で解けないような問題を与えて予測正答確率が 0.5(できるかできないかの最小限のレベルの支援)となるようなヒントを与えることが最も学習効果が高いことを示した。本システムでは、生徒の能力が向上するのに従ってシステムからのヒントや支援の数が徐々に減っていく「フェーディング(Fading)」の現象も観測されている。Pea は「フェーディング」が学習支援成功の最重要要件と主張している[Pea 04]。さらに本システムは、最小限の支援のみを提示するので、その時点で誤答や長考に入った場合にも予測正答確率が 0.5 に近い場合は追加のヒントは与えずに「励まし」を与えて生徒の「深い思考」と「一つ上のレベルへの乗り越え」を誘発させる。つまり「なるべく教えないアダプティブ・ラーニング」であり、生徒が最小限の支援を受けて自力で最後まで解き「一つ上のレベルの問題への乗り越え」の成功経験を得ることを支援する。実際の学校現場での実践では、フェーズ 2 で独力では解けない問題を最小限のヒントだけで最後まで解こうとした生徒の能力が有意に伸びていることが示された。このようにフェーズ 2 では基礎知識を用いてより難易度の高い問題を解ける思考力、応用力の習得のみだけでなく「乗り越えの経験」を体験させることが重要である。また、植野らは、実験で比較した従来の AL システムのほとんど(従来 AL の教えすぎを批判して開発された足場がけのための段階ヒントシステムを含む)が「教えすぎ」の傾向にあると報告していることも興味深い[Ueno 15, 18]。

以下、2 章では過去の学習履歴ビッグデータを機械学習し、フェーズ 1 の反応予測や知識・スキル予測手法として IRT (Item Response Theory) と深層ニューラルネットワーク手法を紹介する。ただし IRT と深層ニューラルネットワークは互いに長所・短所があるので、お互いの長所を組み合わせた現在最高予測精度を持ち解釈性も持つ Deep-IRT を紹介する。3 章では大規模言語モデルによる記述式解答の自動採点や所望の難易度を持つ問題やヒントの自動生成について述べる。4 章ではフェーズ 2 における思考力を育てるための「なるべく教えないでチャレンジし自力で乗り越える力」を育てるアダプティブ・ラーニング」を紹介する。

2. AL のための教育ビッグデータの機械学習

前述のように近年のフェーズ 1 の AL は、過去の生徒のオンライン・ラーニング環境での学習履歴ビッグデー

タを機械学習し、新たな生徒がどのような知識をその程度習得しているかを学習中に追跡して適切な学習内容を提示する。ここでは CBT(Computer Based Testing)の国際標準でも採用され一般的に知られている IRT(Item Response Theory;項目反応理論)[van der Linden 18]と深層ニューラルネットワークを用いた Deep Knowledge Tracing [Piech 15]、最後にそれらの利点をすべて持つ Deep-IRT[Tsutsumi 21, 22]を紹介する。

2.1. IRT (Item Response Theory)

IRT は CBT で標準的に用いられており、今後国内の教育界のキーツールになる可能性が高い[植野 23a]。IRT 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、最近では過去の学習データから生徒の能力値と問題の特性パラメータを推定し、未知の問題への反応を予測して AL にも用いられている[Wilson 16][堤 19, 20]。IRT では問題 j に生徒 i が正答する確率が以下のロジスティック関数によって表現される。

$$P(x_j = 1 | a_j, b_j, \theta_i) = \frac{1}{1 + \exp(-1.7a_j\theta_i + b_j)} \quad (1)$$

ここで a_j は問題 j の識別力パラメータ、 b_j は問題 j の難易度パラメータ、 θ_i は生徒 i の能力値潜在変数を示す。ただし、各問題への反応が能力値を所与として条件付独立であるという局所独立性の仮定がある。この仮定では、同一の生徒の各問題への反応は独立でないといけない。しかし、この仮定を満たす限り、各生徒が異なる問題を解答していても能力推定値が高い精度で得られ解釈性も高いという利点がある。最近のモデル[Wilson 16][堤 19, 20]では、隠れマルコフモデルを IRT に組み入れて学習による生徒の能力の変動も推定できる。

2.2. Deep Knowledge Tracing

AL システムのための知識状態の予測およびスキル予測のために、人工知能分野では Knowledge Tracing という手法が提案されている。特に注目されたのは深層ニューラルネットワークによる Deep Knowledge Tracing (DKT) [Piech 15] が提案されたことによる。DKT は Long-short term memory (LSTM) を用いて生徒のスキルの習得状態を表現し、生徒の各問題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す。その後、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。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、過学習に陥りにくいことが報告されている。しかし、DKVMN では生徒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、問題の困難度を表すパラメータが存在しないなど、問題特性の解釈性が低いといった短所もある。これらの欠点を解決するために、

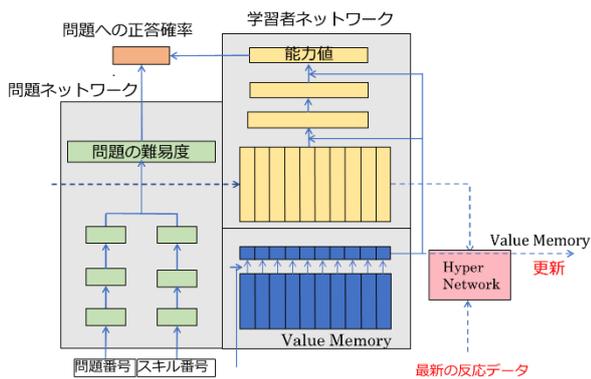


図1 Deep-IRTの構成図

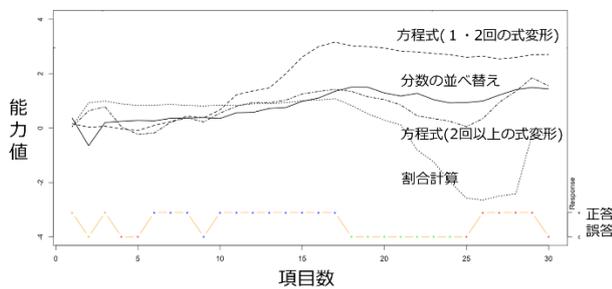


図2 Deep-IRTによる4次元スキル能力推定値の例

[Tsutsumi 21, 22, 24]はIRTと深層ニューラルネットワークの利点を持ち合わせるDeep-IRTを提案している、Deep-IRTは、図1のように生徒の能力パラメータに対応する学習者ネットワークと問題の難易度パラメータに対応する問題ネットワークを独立に組み合わせ、各問題への正誤を予測する。Deep-IRTはパラメータの解釈性を向上させるだけでなく最高の予測精度を持つ手法を提案している。またDeep-IRTでは、従来のIRTのような局所独立性の仮定や生徒の無作為抽出の仮定も必要ない。さらにこのDeep-IRTでは、多次元のスキルの能力値の時系列変化を推定することもできる。

DKVMNでは、能力値を保存するvalue memoryを更新する際に最新の生徒の反応データのみを用いて最適化される。しかし、Deep-IRTではHyper networkを用いて過去のすべてのデータを反映してvalue memoryの更新を最適化でき、生徒の能力値変化もより正確に反映できる。図2は生徒の反応データからDeep-IRTが各スキルの能力値の変化を推定している例である。1つの問題が複数のスキルによって構成されている場合もDeep-IRTは自動的に各スキル能力に分離して推定することも特徴である。フェーズ1のアダプティブ・ラーニングでは習熟度の低いスキルを同定し、そのスキルを基礎から学習できる環境を提示することに用いられる。また、実際には解いていない問題への正誤反応も予測することができ、問題に対応する知識マップの未習得状況から生徒に最適な教材順序を再設計して提示することにももち

いられる。詳細は後述するが、フェーズ2では様々なヒントや励ましなどの学習支援をした後の正答確率を予測し、最適な支援を提供することに用いられる。

さらに重要なDeep-IRTの利点は、ChatGPTやBERTなどの大規模言語モデルによる生成AIを容易に組み込むことも容易であり、記述式解答の自動採点だけでなく、所望の領域・難度の問題やヒント、解説などを自動生成することも可能となっていることである。

3. 大規模言語モデルによる機械学習

3.1. 記述式解答のニューラル自動採点

近年、ChatGPTに代表される大規模言語生成モデルが実用化され、記述式解答の自動採点や学生からの質問への回答、問題や教材、ヒントなどの自動生成が可能となっている。しかし、ChatGPTに代表される大規模言語生成モデルのように内部構造の詳細が公開されないケースでは信頼性の観点では適切とはいえない。AIの説明性を最適化する代わりに乱数により出力に多様性を与えるような固有の仕組みも存在する。また、そのモデル規模の大きさから、個々の研究者や組織が手元の教師ありデータでモデルを追加学習して、独自の自動採点モデルを構築するアプローチも年々難しくなっている。我々のアプローチは、文章の意味情報を詳細に反映させた高次元の特徴表現ベクトルを内部で計算する。そのような内部表現は将来的にモデルがさらに高度化し、事前学習用のデータが増加すると、ますます品質が向上していくと期待される。自動採点のように信頼性が重要なタスクにおける有望な方法論の一つとしては、大規模言語モデルを特徴抽出機として利用し、図3のようにその特徴ベクトルを入力とする一般的な教師あり学習モデルを訓練して自動採点モデルを得る方法が現実的と考える[Uto 20]。

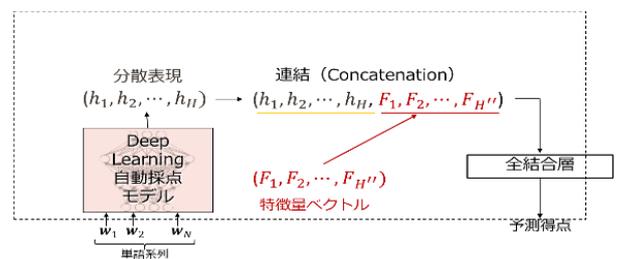


図3 特徴量を組み込んだ深層学習自動採点モデル

本手法は2020年に記述式解答の自動採点の世界最高精度を記録している。青見らや宇都らは様々な記述式解答の自動採点機を評価者付きIRTの評価者とみなして統合する手法を開発している[Aomi 21] [Uto 23]。この手法は、複数の自動採点機の特徴性を考慮しつつ、人間の評価尺度でスコア推定が可能となり、現在、記述式解答の自動採点の最高精度を持つ。これらの手法を用いて、一つ

の問題への解答から多くの生徒の情報を取り出し、より適応的な学習環境を提供することができる。

3.2. 所望の難易度を持つ問題・ヒントの自動生成

ALでは問題や教材、ヒントを開発する労力が最もコストが高い。特に所望の難易度を持つ問題やヒントの作成は非常に難しい。Deep-IRTにChatGPTなどの生成AIを組み込んで再学習すると所望の難易度を持つ問題やヒントの生成が可能となる。図4は、その手法により所望の難易度を持つように自動生成された短冊式プログラミング問題、図5は生徒の能力推定値を所与としてある問題への正答確率を所望の値にできるヒントを自動生成している。これらは人間が問題チェックを必要とするが作問やヒント作成にはかなりの労力が削減される。さらにこの手法を用いれば、ALにおいて生徒の能力推定値もしくは知識状態に応じてリアルタイムにその場で適応的な問題生成やヒント生成が可能になり、生徒へのより適応的な学習環境を提供できる。

```

問題
ある郵便局には、複数の荷物があります。各荷物には特定の重さがあり、トラックは特定の最大積載量を持っています。以下の短冊から適切に並べ替えて、荷物の重さをすべて載せるために必要なトラックの最小数を計算するプログラムを完成させてください。

短冊
1. def min_trucks(n, packages, max_load):
2.     truck_count += 1
3.     packages.remove(pkg)
4.     current_load = 0
5.     return truck_count
6.     current_load += pkg
7.     if current_load + pkg <= max_load:
8.     while len(packages) > 0:
9.     for pkg in packages[:]:
10.    packages.sort(reverse=True)
11.    truck_count = 0
12.    packages.append(pkg)
13.    if current_load < max_load:
14.    for weight in packages:
15.    truck_count += 1

```

図4 所望の難易度を持つ短冊式プログラミング問題の自動生成

```

ヒント1
* まず、関数を定義するための短冊を探して配置しましょう。

ヒント2
* トラックの数や現在の積載量を初期化する短冊は、ループの前に配置することを考えましょう。

ヒント3
* ダミーの短冊の中には、この問題文には存在しないような操作を示唆するものがあります。それらを避けるため、問題文と照らし合わせながら考えてみましょう。

ヒント4
* トラックの現在の積載量を更新する際、どの短冊を使用する必要がありますでしょうか？

ヒント5
* 'while'や'for'の短冊の下には、ループ内の処理を示す短冊が配置されるはずですが、適切な短冊を選んで、その下に配置してみましょう。

```

図5 所望の難易度にするヒントの自動生成

4. 確率的足場がけシステム

4.1. フェーズ2のための教育学

教育学の最近の主な興味は、知識注入主義からヴィゴツキーに代表される社会的構成主義 [Vygotsky 62, 87]に移行しつつある。社会的構成主義は前述のフェーズ2の学習を対象としているといつてよい。ヴィゴツキーの「最近接発達領域」(ZPD; Zone of Proximal Development)の理論によれば、生徒の高次の問題解決に教師が適度に助言することにより、生徒の発達を促すことができる。Brown and FerraraやCampioneは生徒のZPDを評価することが重要であると考え、ダイナミック・アセスメントを提唱している[Brown 85][Campione 89]。ダイナミック・アセスメントではZPDに基づく支援支援により生徒の伸びる力を評価し、段階ヒント(Graded hints)(後になるほどヒントの具体性が強くなるヒントの集合)を正答するまで順に見せていく手法を提案している。最小限のヒントで正答に至っている生徒の伸びが最も大きいことが報告されている。段階ヒントは、その後、多くの学習支援システムに搭載されている。以上のZPDに基づく支援を定式化したのが「足場がけ」(Scaffolding)の概念である[Wood 76][Bruner 78][Bruner 96]。「足場がけ」は、生徒がひとりで解決できないような高次の問題解決を生徒の能力に応じて支援することである。その後、「足場がけ」は認知的徒弟性の枠組みの中にも取り入れられ、重要な役割を果たしてきた[Collins 89]。認知的徒弟制は、モデリング、コーチング、足場がけ、フェーディング(Fading)などのフェーズを通じて、熟達者の高度な知識や思考プロセスを生徒に獲得させる[Collins 89]。従来の徒弟制が徒弟を独り立ちさせることが目的であるように、認知的徒弟制においても、徐々に支援を減少させること(フェーディング)で生徒の自立を最終的な目標とする。また「足場がけ」の具体的な手法についても研究されている。ヴィゴツキーによれば、生徒に提示される問題は能力より高いことが望ましい。更に、生徒がなんとか解決できる程度に最小限の支援をすることにより生徒の自立を促し、一方的に教え込まれた場合に比較し、より高度な発達が期待されると考えられている[Vygotsky 87]。Collonsらは足場がけの提示に不可欠な要素として、(1)生徒の現状の理解度や能力、または問題の難易度を正確に診断すること、(2)診断した能力や問題の難しさに応じて適切な支援が行われること、を挙げている[Collins 89]。また、学習支援システムの分野でも、生徒に過度に教えてしまう「教えすぎ」が最適な学習を阻害してしまう「学習支援のジレンマ」という現象があることも報告されている[Koedinger 07]。

Peaはフェーディングの生起が学習支援成功の最重要

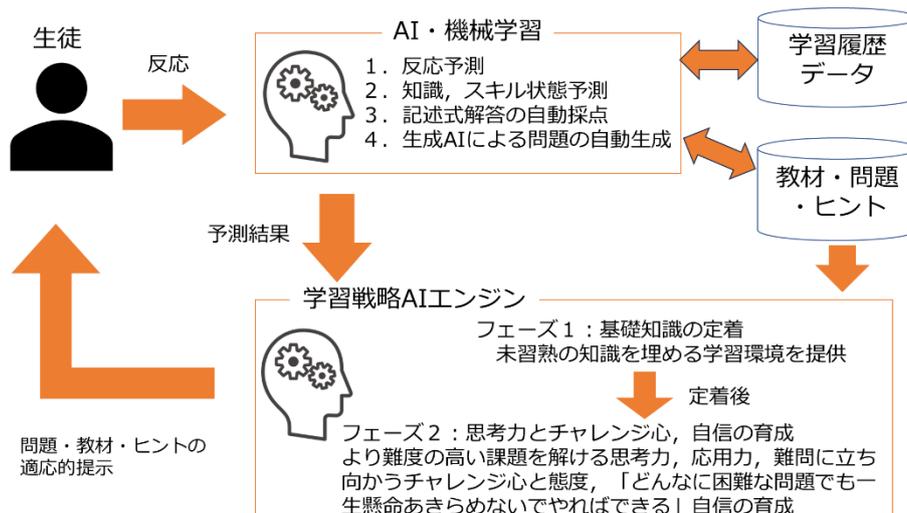


図6 AI・ビッグデータによるALシステム

ファクターであると主張している。その意味で、Peaは従来のアダプティブ・ラーニング・システムは「フェーディング」が一切働いておらず、適応的な「足場かけ」とはいえず単なる知識の教授主義（本論のフェーズ1）と同じであると批判している[Pea 04].

4.2. なるべく教えないAL

前述のように生徒が基礎知識を構築するにはフェーズ1は有効であるが、さらに発展して思考力を身につけるためには十分でないことが示唆されている。フェーズ2では生徒に適応的に最小限の支援のみを行うことが望ましいと主張されてきた。しかし、生徒に最適な最小限の学習支援がどのようなものか、についてこれまで明らかにされていない。このような疑問を解決するためにUenoらは「確率的足場かけ (Probabilistic Scaffolding)」のフレームワークを提案した[Ueno 15, 18]。この理論では、学習効果を最大にする学習支援には、支援を行うことで生徒が到達する最適な予測正答確率があるという仮説に基づいている。従来のフェーズ1の支援は生徒が確率1.0で正答できるような教え込みを行ってきたが、それは従来研究でも「教えすぎ」と指摘されてきた。フェーズ2について、Uenoらはプログラミング問題においてIRTを用いて各支援後の問題への正答確率を予測して、最適な正答確率になるような学習支援（プログラミングのためのヒント）を提供する実験を行った[Ueno 15]。ただし、この実験では問題の予測正答率と最適な予測正答率の設定を様々に変えて繰り返し実験した。その結果、予測正答確率が0.35以上0.4以下の問題をアダプティブ・テストング[Ueno 19, 22]を用いて適応的に提示し、正答確率が0.5になるように生徒にヒントを与える支援が最も能力が伸びることが示された。つまり、フェーズ2の学習では、生徒が自力で解けないような問題を与えて予測正答確率が0.5(できるかできないかの最小限のレベル)となるようなヒントを与

えることが最も学習効果が高いことを示した。さらにUenoらは、実験で比較した従来のALシステムのほとんどが「教えすぎ」の傾向にあることを報告している[Ueno 15, 18]。例えば、教えすぎを批判して提案された「段階ヒント」も生徒がヒントを十分な思考を経ずに開示してしまい、結果として「教えすぎ」と同じく高い予測正答確率になるような支援を行っていた。さらにUenoは生徒が誤答してもすぐにはヒントや解説を与えない方が学習効果が高いことを報告している[Ueno 18]。生徒の予測正答確率が0.5に近い間は新たにヒントは与えずに「システムはあなたがじっくり考えれば正答できると高い確率で予想しています。じっくり考えてみましょう。」などの励ましを与えて自力で乗り越えさせるようにしていくことがフェーズ2では効果的であることを報告している。生徒の能力に従って生徒が自力では解けないような問題を与え、ぎりぎり正答できるかどうかのヒントを与え、できる限り自分で考えさせ一つ上のレベルを乗り越えさせることが能力を発達させるのに効果的であることがわかった。生徒の能力が発達にしたがってシステムからのヒントや支援の数が徐々に減っていく「フェーディング」の現象が観測され、Peaの有効な適応的学習支援の要件[Pea 04]にも合致していることもわかった。

著者らのシステムの概要を示すために、植野らのALのフレームワークを図6に示す。「AI・機械学習」により過去の大規模学習履歴データを学習し、生徒の知識状態の同定、未知の問題への反応予測、これから行う学習支援の効果予測、自然言語処理を用いた記述式解答や論述式解答の自動採点、ChatGPTなどの生成AIを組み込んだニューラルネットワークによる所望の領域の難易度を持つ問題やヒントの自動生成、などを行う。学習戦略AIエンジンは二つのモードを持つ。フェーズ1では、基礎知識の定着のために「AI・機械学習」で同定された生徒の未習熟のスキルや知識の学習支援を提供する。フェーズ1で基礎知識が定着したことが確認されると、

フェーズ2に移行し、難易度の高い問題を解ける思考力、応用力の習得を支援するためのより複雑な教授戦略に移行する。具体的には「AI・機械学習」で生徒の正答率が0.4程度になる問題を選択し提示する。誤答するとちょうど正答確率が0.5になるようなヒントを「AI・機械学習」により予測し提示する。その後、生徒が誤答しても更新して推定された予測正答確率がヒントを与えなくても0.5付近であれば、新たにヒントは与えずに「システムはあなたがじっくり考えれば正答できると高い確率で予想しています。じっくり考えてみましょう。」などの励ましを提示する。ただし、さらに新たなヒントを与えて、予測正答確率がより0.5に近づく場合にはそのヒントを提示する。この手法では、生徒が必要最小限の支援を受けて自力で最後まで解ききって「一つ上のレベルの問題への乗り越え」の成功経験を得ることを目標としている。この手法により生徒の難問に立ち向かうチャレンジ心と態度、「どんなに困難な問題でも一生懸命あきらめないでやればできる」自信を育成できるとアンケートの結果より報告されている[Ueno 18].

駿台予備校では、植野らの確率的足場がけシステム([Ueno 15, 18])を用いた数学、物理、化学のアダプティブ・ラーニング・システム「S-LME」を開発し実践している[駿台 21]。フェーズ1では基礎知識を学ぶためのALシステムで学ばせ、基礎知識が身につくとフェーズ2のS-LMEに移行する仕組みである。数年間の実践の結果、利用している生徒の偏差値が利用していない生徒に比較して有意に伸びており、特に学習中の問題への正答率よりも難問に最後まであきらめずに解ききるかどうかが生徒の偏差値向上の最重要要因になっていることを報告している。アンケートの結果から、生徒が最小限の支援を受けて自力で最後まで解ききって「一つ上のレベルの問題への乗り越え」の成功経験を得ることが自信につながる大きな経験であったことが報告されている[植野 23b]。さらにフェーズ2では難問に立ち向かうチャレンジ心と態度、「どんなに困難な問題でも一生懸命あきらめないでやればできる」自信を育成できることも報告され、それが生徒の将来にとって非常に重要であることもわかった[植野 23b].

5. おわりに

教育学では、適切な学習支援のために教師は(1)生徒の現状の理解度や能力または問題の難易度を正確に診断すること、(2)診断した能力や問題の難しさに応じて適切な支援を行うことが重要と教えてきた。しかし、実際、ベテラン教師でさえ生徒の能力を正確に把握し、将来の効果を予測しながら各生徒に適応的に学習を支援することは難しい。一方、AIは人間に比べて過去データを用いて正確に予測することを得意とする。本論ではAI・ビッグデータを用いて学習効果を逐次予想しながら適応

的に学習を支援するアダプティブ・ラーニング・システムを紹介した。フェーズ1における技術的特徴は、1. IRTや深層ニューラルネットワークが用いられる傾向にあり、最近ではDeep-IRTが最も性能が高い、2. Deep-IRTではChatGPTなどの大規模言語モデルを組み込んで問題生成や学習支援内容自体を適応的に生成できるようになってきている、などが挙げられる。

さらに著者らが開発してきたフェーズ2のためのアダプティブ・ラーニング・システムに関する主な発見は以下の通りであった。

- ①多くの従来型アダプティブ・ラーニング・システムは教えすぎの傾向にある。
- ②各生徒が独力で解けないレベルの問題（正答確率が0.35~0.4程度）を適応的に提示し、生徒ができるかできないか最小限の支援として、予測正答確率が0.5になるようにヒントを出すと最も学習効果が高い。
- ③学習途中の問題への正答率よりも、難問でも最後までヒントを見ながら考えてやりきる人の成績の伸びが大きい。システムは、たとえ生徒が間違えてもすぐに解き方を教えるのではなく、じっくり考えて最後までやり遂げるように励ますことが重要であることがわかった。
- ④効果的な学習では、ある領域における生徒の能力が発達するにしたがって、システムからのヒントや支援の数が徐々に減っていく、[Pea 04]が学習支援成功の最重要要件と主張する「フェーディング」の現象が観測された。
- ⑤難問に立ち向かうチャレンジ心と態度、「どんなに困難な問題でも一生懸命あきらめないでやればできる」自信を育成することが生徒の将来にとって非常に重要であることがわかった。

今後の問題として、1. 「確率的足場がけ」のための教育ビッグデータからの確率推定を最適化する機械学習手法として、真の確率予測を漸近的に保証する最新手法ベイジアン・ネットワーク分類機[Sugahara 24]の導入、2. 近年、学校現場で導入が進んでいる大規模CBTとアダプティブ・ラーニング・システムの連携、などが挙げられる。

[謝辞]

本研究は科学研究費問題番号50262316, 19H05663, 22K19825の支援を受けた。

◇ 参考文献 ◇

- [Aomi 21] Aomi,I., Tsutsumi,E., Uto,M. and Ueno,M.: Integration of Automated Essay Scoring Models using Item Response Theory, Proc. of 22th International Conference on Artificial Intelligence in Education (AIED2021), pp.54-59 (2021)
- [Brown 85] Brown, A. and Ferrara, R.: Diagnosing zones of proximal development, Culture, Communication, and Cognition: Vygotskian Perspectives, J. Wertsch, Ed. Cambridge, U.K.: Cambridge Univ. Press, pp. 273–305 (1985)
- [Bruner 78] Bruner, J. S.: The role of dialogue in language acquisition, Sinclair, A., Jarvelle, R. J. and Levelt, W. J. M. (eds.) , The Child's Concept of Language, New York: Springer-Verlag (1978)
- [Bruner 96] Bruner,J.S.: The Culture of Education, Harvard University Press (1996)
- [Campion 89] Campione, J. C.: Assisted assessment: A taxonomy of approaches and an outline of strengths and weaknesses, Journal of learning disabilities, Vol. 22, No. 3, pp. 151-165 (1989)
- [Collins 89] Collins, A., Brown,J.S. and Newman, S.E.: Cognitive apprenticeship: Teaching the craft of reading, writing and mathematics, Resnick, LB Knowing, Learning and Instruction, pp.453-494 (1989)
- [Corbett 95] Corbett, A. T. and Anderson, J. R.: Knowledge tracing: Modeling the acquisition of procedural knowledge, User Modeling and User-Adapted Interaction, Vol. 4, No. 4, pp. 253-278 (1995)
- [Koedinger 07] Koedinger, K. R. and Aleven, V.: Exploring the assistance dilemma in experiments with cognitive tutors, Educational Psychology Review, Vol. 19, pp. 239-264 (2007)
- [Pea 04] Pea, R.: The social and technological dimensions of scaffolding and related theoretical concepts for learning, education, and human activity. The Journal of the Learning Science, Vol. 13, No. 3, pp. 423-451 (2004)
- [Piech 15] Piech,C., Bassen, J. Huang, J. , Ganguli, S., Sahami, M. , Guibas, L. J. and Sohl-Dickstein, J. :Deep knowledge tracing, in Advances in Neural Information Processing Systems Vol. 28, C. Cortes, N. D. Lawrence, D. D.Lee, M. Sugiyama, and R. Garnett, Eds. Curran Associates, Inc., pp. 505-513 (2015)
- [Sugahara 24] Sugahara, S., Kato, K., and Ueno,M.: Learning Bayesian Network Classifiers to Minimize Class Variable Parameters. In the 38th AAAI Conference on Artificial Intelligence (AAAI) (Accepted 2024)
- [駿台 21] 学校法人駿河台学園: 難関国公立大入試・個別試験対策 ICT 教材, <https://www.sundai.ac.jp/press/2021/2021-0312-01.pdf> (2021)
- [堤 19] 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 (2019)
- [堤 20] 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 (2020)
- [Tsutsumi 21] Tsutsumi,E., Kinoshita,R. and Ueno, M.: Deep-IRT with independent student and item networks, Proc. of the 14th International Conference on Educational Data Mining (EDM2021), pp. 510-517 (2021)
- [Tsutsumi 22] Tsutsumi,E., Guo,Y. and Ueno, M.: Deep knowledge tracing incorporating a hypernetwork with independent student and item networks, Proc. of the 15th International Conference on Educational Data Mining (EDM2022) (2022)
- [Tsutsumi 24] Tsutsumi,E., Guo,Y. and Ueno, M.: Deep knowledge tracing incorporating a hypernetwork with independent student and item networks, IEEE Transaction on Learning Technology (Accepted 2024)
- [Ueno 15] Ueno, M. and Miyazawa, Y.: Probability based scaffolding system with fading, Proc. of 17th International Conference on Artificial Intelligence in Education (AIED2015), pp. 237-246 (2015)
- [Ueno 18] Ueno, M. and Miyazawa, Y.: IRT-Based Adaptive Hints to Scaffold Learning in Programming, IEEE Transactions on Learning Technologies, IEEE computer Society, Vol.11, No. 4, pp. 415-428 (2018)
- [Ueno 19] Ueno, M. and Miyazawa, Y.: Uniform adaptive testing using maximum clique algorithm, 20th International Conference on Artificial Intelligence in Education (AIED2019) , pp. 482-493 (2019)
- [Ueno 22] Ueno, M. and Miyazawa, Y.: Two-Stage uniform adaptive testing to balance measurement accuracy and item exposure, Proc. of 23rd International Conference on Artificial Intelligence in Education (AIED2022), pp. 626-632 (2022)
- [植野 23a] 植野真臣 : CBT の最前線, 情報処理 Vol.64, No.5,pp.e1-e6 (2023)
- [植野 23b] 植野真臣 : AI・ビッグデータによるアダプティブ・ラーニングとその未来, オンライン・ラーニング・フォーラム (2023)
- [Uto 20] Uto,M., Xie,Y. and Ueno, M.: Neural Automated Essay Scoring Incorporating Handcrafted Features, Proc. of 28th International Conference on Computational Linguistics (COLING2020), pp, 6077-6088 (2020)
- [Uto 23] Uto,M., Aomi,I., Tsutsumi,E. and Ueno,M. : Integration of Prediction Scores from Various Automated Essay Scoring Models Using Item Response Theory, IEEE Transactions on Learning Technologies, pp. 1-18 (2023)
- [van der Linden 18] van der Linden,W. J.: Handbook of Item Response Theory: Three Volume Set (Chapman & Hall/CRC Statistics in the Social and Behavioral Sciences) (2018)
- [Vygotsky 62] Vygotsky, L. S.: Thought and Language, Cambridge, MA: MIT Press (1962)
- [Vygotsky 87] Vygotsky, L. S.:Mind in society: The development of higher mental processes, Harvard University Press,Cambridge, MA (1987)
- [Wilson 16] Wilson, K.H., Karklin, Y., Han, B. and Ekanadham, C.: Back to the basics: Bayesian extensions of IRT outperform neural networks for proficiency estimation, Proc. of 9th International Conference on Educational Data Mining, Vol.1, pp.539-544 (2016)
- [Wood 76] Wood,D., Bruner,J.S. and Ross,G.: The role of tutoring in problem solving, Journal of Child Psychology and Psychiatry, and Allied Disciplines, pp. 89-100 (1976)

2023年12月24日 受理

著者紹介

**植野 真臣** (正会員)

1992 神戸大学大学院教育学研究科修士課程修了, 1994 東京工業大学大学院総合理工学研究科博士課程修了, 博士 (工学). 2006 より電気通信大学助教授, 准教授を経て 2013 教授, 現在に至る. ベイズ人工知能, アダプティブ・ラーニング, CBT, 教育ビッグデータ解析, の研究に従事. 2008 The 20th IEEE International Conference on Tools with Artificial Intelligence (ICTAI 2008) Best Paper Award, 2015 17th International Conference on Artificial Intelligence in Education (AIED2015) Best Paper nominee, 2017 電子情報通信学会論文賞.