

電気通信大学大学院博士前期課程

令和3年度 情報理工学研究科修士論文

アダプティブラーニングのための深層 学習によるヒント予測モデル

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 情報数理工学プログラム

学籍番号 1931059

蔡睿

主任指導教員 植野真臣 教授

指導教員 川野秀一 准教授

2021年1月24日

目次

第 1 章	はじめに	3
1.1	本論文の構成	5
第 2 章	アダプティブラーニング	6
2.1	アダプティブラーニングシステム	6
2.2	段階的ヒント	7
2.3	アダプティブラーニングのための項目反応理論	8
2.4	リンケージ	9
第 3 章	IDRT モデル	10
3.1	IDRT モデルの概要図	10
3.2	学習者ネットワーク	11
3.3	項目ネットワーク	12
3.4	IDRT モデルの出力	13
第 4 章	提案モデル	14
4.1	提案モデルの概要図	14
4.2	ヒントネットワーク	15
4.2.1	ヒントの one-hot vector データ	15
4.2.2	ネットワーク	15
4.2.3	モデルの出力	16
4.3	パラメータ学習	16
第 5 章	実験設定	18
5.1	実データ	18
5.2	実験条件	19
5.3	実験手法	21
5.4	未知の課題への反応予測精度比較	22
5.5	予測利用ヒント数の誤差分析	24
第 6 章	まとめ	27

第1章 はじめに

近年,教育の現場では,個々の学習者の理解度や苦手分野を把握し,学習すべき項目や適応的ヒントを提供するアダプティブラーニングが注目を集めている[1].

Wood ら[2]は,学習者の発達を促すためには,学習者が高次の項目に直面した際に教師が学習者の能力に応じて適度に支援をする「足場がけ」が重要であることを示している.足場がけでは,学習過程における学習者の能力値を推定し,教師が支援した後の学習者のパフォーマンスを予測する必要がある.問題解決において支援後の学習者のパフォーマンスを予測し,最小限の支援となる足場がけを与えることが優秀な教師であると考えられている.しかし,従来行われてきた能力評価や学習者への支援は教師の経験や勘によるものであり,学習者ごとに正確な支援を行うことは非常に困難であった.

近年,人工知能分野では,コンピュータやタブレット端末を利用したe-ラーニングシステムを用いて,学習者の項目へのパフォーマンス(正答・誤答)を収集・分析することで,学習過程における学習者の能力値や未知の項目への正答確率を予測する手法が開発されている.植野・松尾 [3],Ueno and Miyazawa [4], [5] は,項目解決における学習効率を最適化する項目への予測正答確率があると仮定し,項目反応理論を用いて特定の予測正答確率になるように適応的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た.この手法の特徴は,ヒントを与えたとき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ていることである.つまり,学習者の項目への予測正答確率が設定された正答確率 P に近づくようにシステムがヒントを提供し,学習者に提示することにより,学習効率が向上す

る.Ueno and Miyazawa [5] では,正答確率 P を様々に変化させてヒント提示した学習者グループの事前テスト・事後テストの成績を比較した結果,正答確率 P を 50%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,ヒント提示後の学習者の正答確率を高精度に予測することが重要であることがわかる.

しかし,Ueno and Miyazawa [5] で用いられている IRT モデルは,学習過程での能力の時系列変化が考慮されていないために,支援後の予測正答確率が正しく推定されていない可能性が高いことが指摘されている[6].この問題を解決するために,堤ら[6] は IRT モデルに隠れマルコフモデルを組み込み,学習過程において能力値が時系列変化する隠れマルコフ IRT モデルを提案している.このモデルは,学習者の能力値推定を行う際に過去の学習データを忘却するパラメータをもち,ヒント提示後のパフォーマンス予測が最大になるように推定できるため,IRT モデルと比較して学習者が正解までに利用するヒント数の予測精度が向上することが示されている.これらの IRT 手法の利点には以下が挙げられる.

- 1) 推定精度の低い異質項目の影響を最小限に抑えて能力推定を行うことができる.
- 2) 異なる項目への学習者の反応を同一尺度上で評価できる.
- 3) 学習者グループに対して不変の項目パラメータをもち,項目データベース構築などに有効である.

しかし,従来の IRT 手法では,大規模な項目データベースを構築することや異なる学習項目に取り組んだ学習者を同一尺度上で評価することができない.このためには,学習者の同一母集団からの独立ランダムサンプリングを仮定し,リンケージと呼ばれる処理が必要である.

しかし,一般に,独立ランダムサンプリングを仮定しない母数確率モデルは複

雑であり,実用化は困難である.そこで,リンケージ処理を避けるために,木下涼,植野真臣 [7]は,深層学習に基づいて学習者の能力と項目の困難度を推定する IDRT(Item Deep Response Theory)モデルを提案している.IDRT では,学習者が等質でない場合やテスト間に共通する項目がない場合にも能力推定精度の低下が抑えられることが示された.しかし,IDRT モデルはヒント付きの項目に対応しておらず,学習支援への応用可能性は限られている.アダプティブラーニングでは,学習履歴データから学習者の理解度を正しく把握することによって,適切な支援を提供することが目的である.そのため,学習者は短時間で効率的学習を実現することができる.同時に,個々の学習者の理解度によって効果的な学習指導上のサポートを行い,教師の負担を軽減することも重要である.近年,アダプティブラーニングは Edtech(Education Technology)の一分野として注目を集めている.

本研究では,IDRT モデルをアダプティブラーニングに用いるため,段階的ヒントを含む学習データに適応し,学習者が項目に正答するまでに必要とするヒント数を予測する新たなモデルを提案し,学習者のヒント提示後のパフォーマンス予測精度の向上を目指す.

1.1 本論文の構成

本論文は,本章を含めて 6 章から構成される.第 2 章では,提案モデルに関連する段階的ヒントモデルについて説明する.第 3 章では,学習者の母集団と独立性を仮定しないテスト理論 IDRT について説明する.第 4 章では,IDRT を拡張しているヒントを予測できるアダプティブラーニングモデルについて説明する.第 5 章では,本実験で行う実験の設定と実験結果を述べる.最後に第 6 章では,本論文で記述する研究内容およびその結果を総括する.

第2章 アダプティブラーニング

学力向上のためには,学習者の理解度(能力値)を正しく把握し,適切な学習支援を提供することが重要である.適切な支援を提供するためには,学習者の能力値とヒントを与えた後の学習者のパフォーマンス予測を正確に行う必要がある.このための能力評価の精度の高さが学力向上支援に有効と考えられる.あるいは,学習者が誤答した際に段階的にヒントを提示することによってその学習過程を評価する.

2.1 アダプティブラーニングシステム

Ueno and Miyazawa[4][5]は,IRT(Item Response Theory) モデルを用いて学習者にヒントを与えた後の課題への正答確率を予測し,適応的に支援を行うアダプティブラーニングシステムを開発した.

システムでは,初めに学習者がプログラミングの基礎的な知識を勉強し,その後,学習状況を把握するために,プログラミング課題を数問出題する.課題では,学習者が誤答した際には,段階的にヒントを提示する.課題の解説と解答がフィードバックとして与えられる.プログラミング課題の例を図 2.1 に示す.学習者はプログラミングのコードを読み,変数 (a,b) の最後の値を回答する.誤答した際には,ヒントとしてプログラミング文法に関する説明やコードの意味などが段階的に提示され,学習者が課題を達成するまでヒントをより具体的な内容にしていく.Ueno and Miyazawa[4][5] では,ダイナミックアセスメント・システムシステム

を用いてヒントなしで正解した場合,ヒントありで誤答した場合でも,前述のフィードバックにより能力値が向上することが報告されている。

Programming Test

プログラムコード
解答欄

下のコードを実行した時の最終的な変数a,b,cの値を答えよ.

a

1 ▼

b

1 ▼

解答する

```

1 public class Question2_2 {
2   public static void
3     main(String args[]){
4     int a = 0;
5     int b = 0;
6     while(a < 3){
7       a++;
8       if(b > a){
9         continue;
10      a++;
11      b++;
12     }
13     b += 3;
14   }
15   System.out.println(a);
16   System.out.println(b);
17 }

```

ヒント1

Variable

= Assignment Statement

Operator

++ Increment

+= Addition assignment operator

if

if-else

conditional expression

while

++ Increment

++ : Increment
a ++; ⇒ a = a + 1;

Code

```

a = a + 1;
a = 5 + 1;
a = 6;

```

図 2.1:段階的ヒントの例

2.2 段階的ヒント

ここで,Ueno and Miyazawa[4][5]システムで得られるデータを整理しておく.このシステムでは,各課題 i に対して $K - 1$ 個の段階的ヒント $\{k\}$, ($k = 1, \dots, K - 1$) が用意されている.初めはヒントを表示しない状態で学習者 j に課題 i を提示する.学習者が課題 i に誤答した場合はヒント $k = 1$ を提示し,更に誤答するごとにヒント $k = K - 1$ までを順次提示する.正答するか,最後のヒントが提示さ

れても誤答した場合は、フィードバックを提示し、次の課題 $i + 1$ を提示する。課題数 I に達するまでこの操作を繰り返し行う。学習者数を J , 課題数を I とすると、学習者 j が課題 i にヒント k を表示した段階で正答した反応データは式 (2.1)(2.2) ように表せる。

$$x_{ji} = \begin{cases} k: \text{ヒント}k\text{を与えられた時に正答} \\ K: \text{全てのヒントを提示しても誤答} \\ 0: \text{ヒントなしで正答} \end{cases} \quad (2.1)$$

$$X = \{x_{ji}\}, (j = 1, \dots, J, i = 1, \dots, I) \quad (2.2)$$

2.3 アダプティブラーニングのための項目反応理論

各段階的ヒントを提示した後、学習者の能力値を正確に推定し、学習者のパフォーマンスを予測しなければならない。予測結果によって学習支援を続けるかどうか判断する。

本章では、Ueno and Miyazawa[5]システムで学習者の能力とヒントごとの学習者のパフォーマンスを予測するための項目反応モデルとして段階反応モデル IRT(Item Response Theory)を説明する [8]~[12]。

IRT モデルでは学習者 j が課題 i に対してヒント $k, (k = 1, \dots, K - 1)$ で正答する確率 P_{ijk} を式(2.3)(2.4)で与える。

$$P_{ijk} = P_{ijk-1}^* - P_{ijk}^* \quad (2.3)$$

$$P_{ijk}^* = \frac{1}{1 + \exp(-a_i(\theta_j - b_{ik}))} \quad (2.4)$$

ただし、 $P_{ij0}^* = 1, P_{ijK}^* = 0$ である。ここで、 a_i は課題 i の識別力を表すパラメー

タ, b_{ik} は課題 i でヒント k が提示されたときの難易度を表すヒントパラメータ, θ_j は学習者 j の能力値パラメータを表す.実験より,ヒント提示後の学習者の正答確率を高精度に予測することが効果的な学習のために有効であることが報告されている.

しかし,従来のIRT手法では,大規模な項目データベースを構築することや異なる学習項目に取り組んだ学習者を同一尺度上で評価することができない.このためには,学習者の同一母集団からの独立ランダムサンプリングを仮定し,リンケージと呼ばれる処理が必要である[13][14].

2.4 リンケージ

リンケージ処理は以下の方法が有する.

- 1) 特定のテストの尺度に他のテストの尺度を変換 (等化係数推定法)
- 2) 全てのテストデータに対して同時にパラメータを推定 (同時尺度推定法)

リンケージの実施には綿密な等化計画と莫大なコストが必要になることが多い [15],厳密にリンケージを行うことは理論的に困難であることが知られている.さらに,同時確率分布を完全に表現できるIRTのリンケージは存在しないことが知られており,リンケージ精度は保証されない [16]~[18]特に,現実には学習者の能力分布は多母集団かつ独立サンプリングができないことが多く,このような場合には大きく能力推定値の精度が損なわれてしまう.

第3章 IDRT モデル

木下,植野 [7]では,受検者に母集団とランダムサンプリングを仮定しない深層学習を用いたテスト理論である IDRT(Item Deep Response Theory) を提案した.IDRT モデルには以下の利点がある[8].

- 1) テスト間に共通する項目がなくとも能力を高精度に推定することができる.
- 2) 受検者にランダムサンプリングが仮定できない場合にも能力を高精度に推定することができる.
- 3) 受検者の母集団が単一でない場合にも能力を高精度に推定することができる.
- 4) 過去の反応履歴から未知の項目への反応予測をする際に提案モデルが最も高精度な予測が可能である.

本章は IDRT モデルについて説明する.

3.1 IDRT モデルの概要図

IDRT モデルの概要図を図 3.1 に示す.

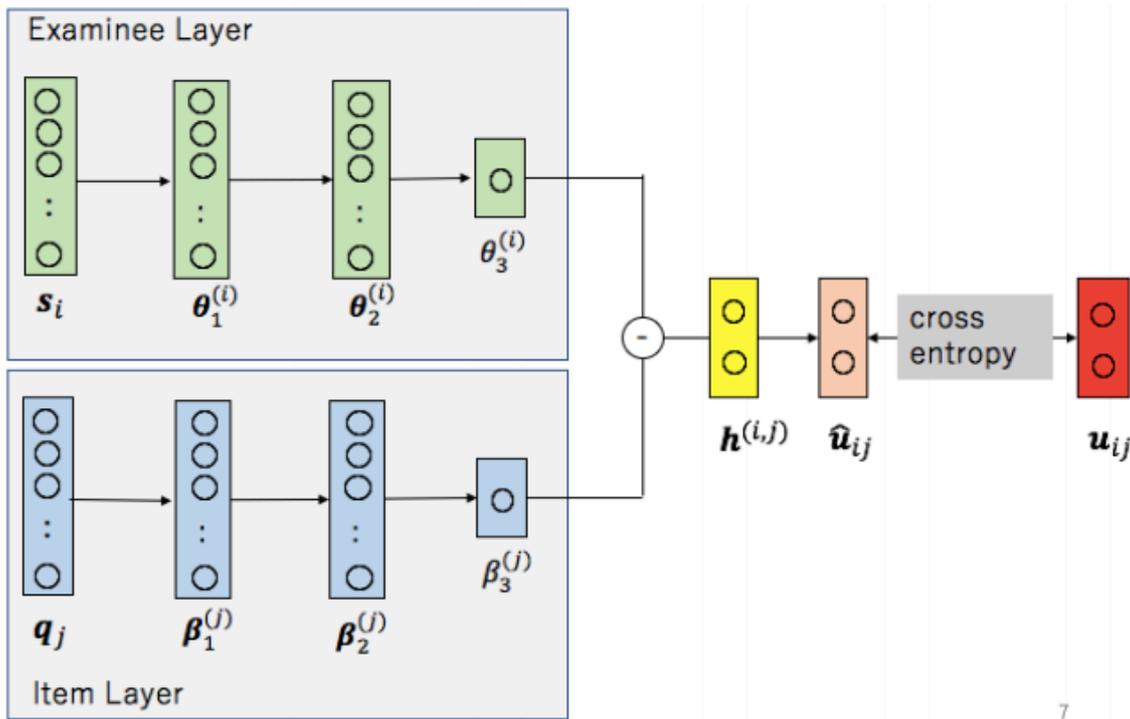


図 3.1:IDRT モデルの概要図

IDRT モデルでは、三層の学習者ネットワーク (Examinee Network) と三層の項目ネットワーク (Item Network) の二つの独立したニューラルネットワークの出力を組み合わせる。

3.2 学習者ネットワーク

学習者ネットワークでは i 番目の学習者を表現するため、 i 番目の要素のみが 1、他の要素が 0 の one-hot-vector \mathbf{s}_i を入力として、層ごとの出力は式 (3.1) (3.2) (3.3) ように計算する。

$$\boldsymbol{\theta}_1^{(i)} = \tanh(\mathbf{W}^{(\theta_1)} \mathbf{s}_i + \boldsymbol{\tau}^{(\theta_1)}) \quad (3.1)$$

$$\theta_2^{(i)} = \tanh(\mathbf{W}^{(\theta_2)}\theta_1^{(i)} + \boldsymbol{\tau}^{(\theta_2)}) \quad (3.2)$$

$$\theta_3^{(i)} = \mathbf{W}^{(\theta_3)}\theta_2^{(i)} + \tau^{(\theta_3)} \quad (3.3)$$

ここで, \tanh は活性化関数として, 以下のように計算する.

$$\tanh(x) = \frac{\exp(x) - \exp(-x)}{\exp(x) + \exp(-x)} \quad (3.4)$$

$\mathbf{W}^{(\theta_1)}, \mathbf{W}^{(\theta_2)}, \mathbf{W}^{(\theta_3)}$ は重みパラメータ行列を表し, $\boldsymbol{\tau}^{(\theta_1)}, \boldsymbol{\tau}^{(\theta_2)}$ はバイアスパラメータベクトルを表す. 得られた反応データの予測を最大にするよう重みパラメータ $\mathbf{W}_{\theta_1}, \mathbf{W}_{\theta_2}, \mathbf{W}_{\theta_3}, \mathbf{W}_y$ を更新し, 学習者ネットワークの出力 $\theta_3^{(i)}$ を学習者 i の能力パラメータとみなす. IDRT モデルでは, 新たな反応データが得られたとき, 全ての重みパラメータを更新するため, 学習者パラメータ間の独立性が存在しないことがわかる.

3.3 項目ネットワーク

項目ネットワークでは j 番目の項目を表現するため, j 番目の要素のみが 1, 他の要素は 0 の one-hot vector \mathbf{q}_j を入力として, 層ごとの出力は式(3.5)(3.6)(3.7)のように計算する.

$$\boldsymbol{\beta}_1^{(j)} = \tanh(\mathbf{W}^{(\beta_1)}\mathbf{q}_j + \boldsymbol{\tau}^{(\beta_1)}) \quad (3.5)$$

$$\boldsymbol{\beta}_2^{(j)} = \tanh(\mathbf{W}^{(\beta_2)}\boldsymbol{\beta}_1^{(j)} + \boldsymbol{\tau}^{(\beta_2)}) \quad (3.6)$$

$$\boldsymbol{\beta}_3^{(j)} = \mathbf{W}^{(\beta_3)}\boldsymbol{\beta}_2^{(j)} + \boldsymbol{\tau}^{(\beta_3)} \quad (3.7)$$

$\mathbf{W}^{(\beta_1)}, \mathbf{W}^{(\beta_2)}, \mathbf{W}^{(\beta_3)}$ は重みパラメータ行列, $\boldsymbol{\tau}^{(\beta_1)}, \boldsymbol{\tau}^{(\beta_2)}$ はバイアスパラメータベクトルを表す.得られた反応データの予測を最大にするよう重みパラメータ $\mathbf{W}_{\beta_1}, \mathbf{W}_{\beta_2}, \mathbf{W}_{\beta_3}, \mathbf{W}_y$ を更新し,重みパラメータを介して $\beta_3^{(j)}$ だけで項目ネットワークの出力 $\beta_3^{(j)}$ を項目 j の難易度パラメータとみなす.IDRT モデルでは,能力値と同様に項目難易度パラメータ間の独立性が存在しないことがわかる.

3.4 IDRT モデルの出力

学習者の能力パラメータと項目の難易度パラメータの差を用いて学習者の項目への反応をモデル化する.具体的には,学習者 i の項目 j への反応 $h^{(i,j)}$ を以下のように求める.

$$h^{(i,j)} = (\mathbf{W}^{(y)})^T (\theta_3^{(i)} - \beta_3^{(j)}) + \boldsymbol{\tau}^{(y)} \quad (3.8)$$

学習者 i の項目 j への反応確率を以下のように求める.

$$\hat{u}_{i,j} = \text{softmax}(\mathbf{h}^{(i,j)}) = \frac{\exp(h_1^{(i,j)})}{\exp(h_0^{(i,j)}) + \exp(h_1^{(i,j)})} \quad (3.9)$$

第4章 提案モデル

4.1 提案モデルの概要図

本研究では IDRT をアダプティブラーニングへ応用するため,独立なヒントネットワークを追加し,学習者が課題解決までに必要とするヒントを予測する新たな IDRT モデルを提案する.

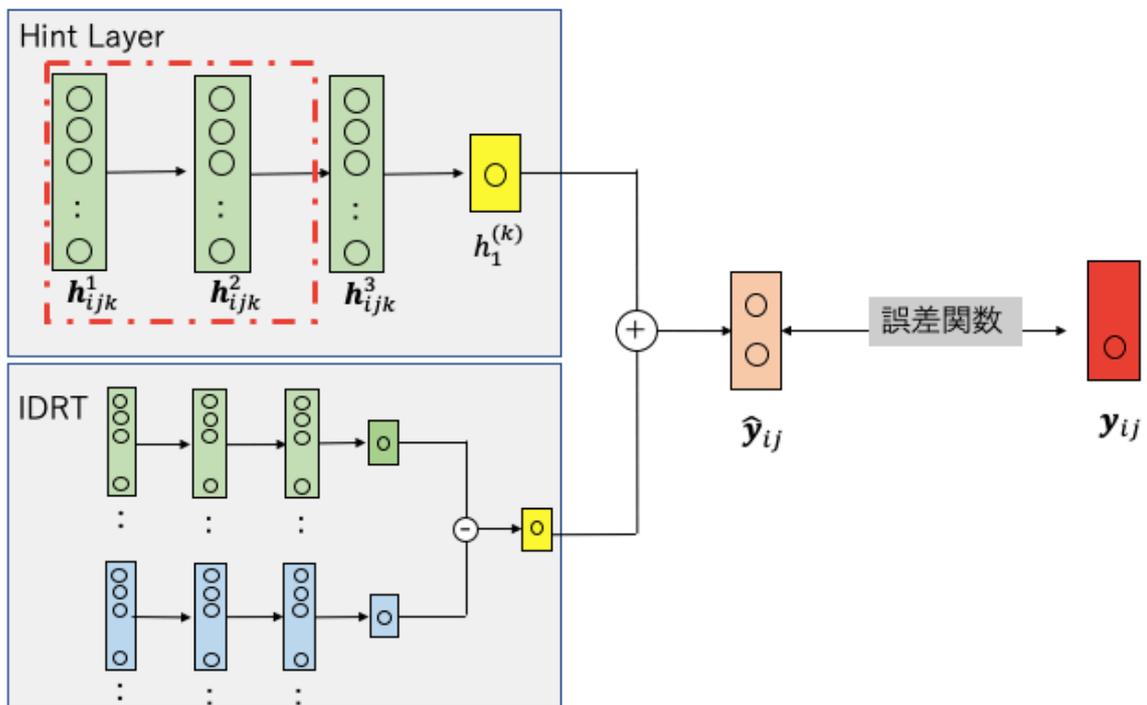


図 4.1:提案モデルの概要図

4.2 ヒントネットワーク

4.2.1 ヒントの one-hot vector データ

一般的に、項目ごとに設定されているヒント数は異なるため、ヒントの one-hot vector は全ての項目に含まれているヒントの総数とする。ヒントネットワークでは i 番目の学習者の j 番目が項目に正答するまでに用いたヒントの個数 h_{ijk} を表現するため、ヒント $0 \sim k$ までのヒントを用いて正答した場合には、 $h_{ij0} \dots h_{ijk}$ 番目の要素のみが 1、他の要素は 0 の one-hot vector \mathbf{h}_{ijk} を入力とする。

4.2.2 ネットワーク

ヒントネットワークでは ヒントの one-hot vector を入力として、層ごとの出力は式(4.1)(4.2)(4.3)のように計算する。

$$\alpha_1^{(k)} = \tanh(\mathbf{W}^{(\alpha_1)} \mathbf{h}_{ijk} + \boldsymbol{\tau}^{(\alpha_1)}) \quad (4.1)$$

$$\alpha_2^{(k)} = \tanh(\mathbf{W}^{(\alpha_2)} \alpha_1^{(k)} + \boldsymbol{\tau}^{(\alpha_2)}) \quad (4.2)$$

$$\alpha_3^{(k)} = \text{relu}(\mathbf{W}^{(\alpha_3)} \alpha_2^{(k)} + \boldsymbol{\tau}^{(\alpha_3)}) \quad (4.3)$$

$\mathbf{W}^{(\alpha_1)}, \mathbf{W}^{(\alpha_2)}, \mathbf{W}^{(\alpha_3)}$ は重みパラメータ行列、 $\boldsymbol{\tau}^{(\alpha_1)}, \boldsymbol{\tau}^{(\alpha_2)}$ はバイアスパラメータベクトルを表す。得られた反応データの予測を最大にするよう重みパラメータ $\mathbf{W}_{\alpha_1}, \mathbf{W}_{\alpha_2}, \mathbf{W}_{\alpha_3}, \mathbf{W}_y$ を更新し、ヒントネットワークの出力 $\delta_3^{(k)}$ を学習者 i の項目 j に k 番目ヒントの難易度パラメータとみなす。IDRT モデルでは、ヒントパラメータ間の独立性が存在しないことがわかる。

4.2.3 モデルの出力

学習者の能力パラメータ,項目の難易度パラメータの差,ヒントの難易度パラメータを用いてヒントを提示した時の,学習者の項目への反応をモデル化する.具体的には,ヒント k での学習者 i の項目 j への予測正答確率 $\mathbf{p}^{(i,j,k)}$ を以下のように求める.

$$\mathbf{p}^{(i,j,k)} = (\mathbf{W}^{(y)})^T \left(\theta_3^{(i)} - \beta_3^{(j)} + \alpha_3^{(k)} \right) + \mathbf{b}^{(y)} \quad (4.4)$$

ヒント k での学習者 i の項目 j への反応を以下のように求める.

$$\hat{y}_{i,j}^{(c)} = \text{softmax}(\mathbf{p}^{(i,j)}) = \frac{\exp(p_c^{(i,j)})}{\sum_c \exp(p_c^{(i,j)})} \quad (4.5)$$

4.3 パラメータ学習

一般に,深層学習では誤差逆伝播法によりパラメータを学習する.しかし,実データでは受検者や項目の反応に偏りがあることが多い.この問題を避けるため,本研究で式(4.6) Lossclass [19]によりパラメータを学習する.

$$\begin{aligned} \text{Loss}_{\text{class}} = & \sum_i \sum_j \ell(u_{ij}, \hat{u}_{ij}) + \gamma_1 \sum_{i \in L\text{-examinee}} \sum_{j \in (u_{ij}=1)} \ell(u_{ij}, \hat{u}_{ij}) \\ & + \gamma_2 \sum_{i \in H\text{-examinee}} \sum_{j \in (u_{ij}=0)} \ell(u_{ij}, \hat{u}_{ij}) + \gamma_3 \sum_{j \in L\text{-item}} \sum_{i \in (u_{ij}=1)} \ell(u_{ij}, \hat{u}_{ij}) \\ & + \gamma_4 \sum_{j \in H\text{-item}} \sum_{i \in (u_{ij}=0)} \ell(u_{ij}, \hat{u}_{ij}) \end{aligned} \quad (4.6)$$

ここで,L-examinee は正答率が $\alpha_{L-examinee}$ 以下の受検者集合 ,H-examinee は正答率が $\alpha_{H-examinee}$ 以上の受検者集合,L-item は正答率が α_{L-item} 以下の項目集合,H-item は正答率が α_{H-item} 以上の項目集合である. また, $\gamma_1, \gamma_2, \gamma_3, \gamma_4$ と $\alpha_{L-examinee}, \alpha_{H-examinee}, \alpha_{L-item}, \alpha_{H-item}$ はチューニングパラメータであり,任意の値に設定する.

第 5 章 実験設定

5.1 実データ

本研究では既存手法 IRT と提案モデルを用いて学習データから学習者のヒント使用状態および能力値を推定し,学習者の課題への反応予測を行う.評価実験では,大学習者 81 人を対象に講義の確認テストにおける 22 課題について,植野 [20]~[23] が開発した e-ラーニングシステム SAMURAI を用いて収集した離散数学の学習データを用いて実験を行い,反応予測精度から各手法の問題点を示す.また,課題ごとのヒント数と各課題におけるヒントなしでの正答率を表 5.1 に示す.

表 5.1：各課題におけるヒント数とヒントなしでの正答率

課題	1	2	3	4	5	6
ヒント数	5	4	8	6	6	8
正答割合 (%)	49.38%	79.01%	25.93%	16.05%	28.40%	45.68%
課題	7	8	9	10	11	12
ヒント数	5	7	7	1	5	7
正答割合 (%)	46.91%	37.04%	46.91%	48.15%	18.52%	22.22%
課題	13	14	15	16	17	18
ヒント数	5	6	6	6	6	6
正答割合 (%)	77.78%	28.40%	30.86%	14.81%	13.58%	8.64%
課題	19	20	21	22		
ヒント数	15	8	7	11		
正答割合 (%)	55.56%	17.28%	70.37%	34.57%		

5.2 実験条件

本研究では提案モデルの実装にニューラルネットワークのフレームワークの一つである Chainer^(注1)を用い,10 分割交差検証で予測実験を行なった.

全ての実験に共通するパラメータの値を表 5.2 に示す.これらのパラメータのうち, $\epsilon, \alpha 1, \alpha 2$ には先行研究 [24],[25]で提案されている値を用いた.

表 5.2:共通するチューニングパラメータの値

パラメータ	値	パラメータ	値
$\theta_1^{(i)}$ のノード数	100	$\gamma 1$	0.1
$\theta_2^{(i)}$ のノード数	100	$\gamma 2$	0.1
$\beta_1^{(j)}$ のノード数	100	$\gamma 3$	0.1
$\beta_2^{(j)}$ のノード数	100	$\gamma 4$	0.1
$\delta_1^{(k)}$ のノード数	100	αL -examinee	0.2
$\delta_2^{(k)}$ のノード数	100	αH -examinee	0.8
エポック数	500	αL -item	0.2
μ	0.01	αH -item	0.8
ϵ	10^{-8}		
$\alpha 1$	0.9		
$\alpha 2$	0.999		

IRT のモデルには式(2.4)を採用し,パラメータ推定は MCMC 法を用いた EAP 推定で行なった[26],[27].ここでリンクージュには同時尺度推定法を用い,すべての

パラメータを同時に推定した.また,各パラメータの事前分布には次の分布を用いた.

$$\theta \sim N(0, 1), a \sim LN(0, 1), b \sim N(1, 0.4) \quad (5.1)$$

$N(\mu, \sigma)$, $LN(\mu, \sigma)$ は平均 μ ,標準偏差 σ の正規分布と対数正規分布を表す.

5.3 実験手法

本研究では,10 分割交差検証で実験を行う.以下の手順で,次の課題で学習者が必要とするヒントを予測し,実際に学習者が正答するまでに利用したヒントとの一致率を計算する.

1. 学習者 j の項目 i における実際のヒント利用数 x_{ij} と予測利用ヒント数 \hat{x}_{ij} を用いて,各項目 i における一致率 c_i を次式で求める.

$$c_i = \frac{1}{J} \sum_{j=1}^J \psi(\hat{x}_{ij}, x_{ij}) \quad (5.2)$$

ここで, $\psi(\hat{x}_{ij}, x_{ij})$ は \hat{x}_{ij} と x_{ij} が一致するときに 1,そうでないときに 0 をとる関数とする[28].

2. 手順 (1) で求めた一致割合を全ての課題について平均し,提案モデルの予測精度 c として式(5.3)を求める.

$$c = \frac{1}{M-1} \sum_{m=2}^M c_m \quad (5.3)$$

(注 1):<https://chainer.org/>

また,予測した課題 j へのヒント数 \hat{k} と実際に使用のヒント数 k と比較し,学習者全員 I に対する式(5.4)(5.5)によって過大予測率と過少予測率を計算する.

$$e_j = \frac{1}{I} \sum_{i=1}^I \nabla(\hat{k}_{ij}, k_{ij}) \quad (5.4)$$

ここで, $\nabla(\hat{k}_{ij}, k_{ij})$ は \hat{k}_{ij} より k_{ij} が大きいときに 1,そうでないときに 0 をとる関数とする.

$$m_j = \frac{1}{I} \sum_{i=1}^I \Delta(\hat{k}_{ij}, k_{ij}) \quad (5.5)$$

ここで, $\Delta(\hat{k}_{ij}, k_{ij})$ は \hat{k}_{ij} より k_{ij} が少ないときに 1,そうでないときに 0 をとる関数とする.

5.4 未知の課題への反応予測精度比較

本節では,学習データに提案モデルと既存手法 IRT モデルについて反応予測精度 c を分析する.実験結果を表 5.3 に示す.

表 5.3:課題ごとの予測利用ヒント数の予測精度

	課題 1	課題 2	課題 3	課題 4	課題 5	課題 6	課題 7	課題 8
提案モデル	37.5%	75.00%	25.00%	6.25%	37.50%	37.50%	31.25%	31.25%
IRT モデル	37.50%	56.25%	43.75%	18.75%	25.00%	37.50%	18.75%	31.25%
	課題 9	課題 10	課題 11	課題 12	課題 13	課題 14	課題 15	課題 16
提案モデル	56.25%	50.00%	25.00%	75.00%	75.00%	25.00%	37.50%	50.00%
IRT モデル	56.25%	50.00%	31.25%	18.75%	68.75%	18.75%	25.00%	31.25%
	課題 17	課題 18	課題 19	課題 20	課題 21	課題 22	平均	
提案モデル	68.75%	62.50%	43.75%	56.25%	56.25%	12.50%	43.18%	
IRT モデル	37.50%	25.00%	56.25%	31.25%	56.25%	43.75%	37.22%	

予測精度 (Accuracy) は前節の手順で求めた反応予測精度 c を表す。また、各学習データでの学習者全体の正解率を示した。表 5.3 より、提案モデルは大半の課題において IRT モデルより、高精度に予測していることがわかる。すなわち、提案モデルが従来の IRT モデルと比較して学習者のパフォーマンスを正確に予測できることを示した。ただし、若干の課題において IRT モデルの予測精度のほうが

高いことがわかる.その理由について,次節において二つ方法で予測利用ヒント数を分析する.

5.5 予測利用ヒント数の誤差分析

ここでは,提案モデルと従来の IRT モデルによる予測利用ヒント数の誤差を分析するために,5.3 節の方法で各モデルによる予測利用ヒント数が実際の利用ヒント数より多い学習者の割合と少ない学習者の割合を求めた.

表 5.4: 予測利用ヒント数の過大予測率と過少予測率

		課題 1	課題 2	課題 3	課題 4	課題 5	課題 6	課題 7	課題 8
提案モデル	extra	37.50%	18.75%	56.25%	62.5%	25.00%	37.50%	50.00%	18.75%
	missing	25.00%	6.25%	18.75%	25.00%	37.50%	37.50%	18.75%	43.75%
IRT モデル	extra	12.50%	6.25%	25.00%	56.25%	25.00%	50.00%	43.75%	25.00%
	missing	50.00%	37.50%	31.25%	25.00%	50.00%	12.50%	37.50%	43.75%
		課題 9	課題 10	課題 11	課題 12	課題 13	課題 14	課題 15	課題 16
提案モデル	extra	37.50%	37.50%	50.00%	6.25%	18.75%	37.50%	37.50%	37.50%
	missing	6.25%	12.50%	18.75%	12.50%	6.25%	31.25%	18.75%	6.25%
IRT モデル	extra	43.75%	50.00%	68.75%	75.00%	25.00%	75.00%	68.75%	68.75%
	missing	0.00%	0.00%	0.00%	6.25%	6.25%	6.25%	6.25%	0.00%
		課題 17	課題 18	課題 19	課題 20	課題 21	課題 22	平均	
提案モデル	extra	12.50%	12.50%	31.25%	37.50%	37.50%	50.00%	34.09%	
	missing	12.50%	18.75%	25.00%	25.00%	6.25%	37.50%	19.89%	
IRT モデル	extra	62.50%	75.00%	37.50%	68.75%	43.75%	50.00%	49.43%	
	missing	0.00%	0.00%	6.25%	0.00%	0.00%	6.25%	13.35%	

「extra」は各項目で予測利用ヒント数が実際の利用ヒント数より多かった割合を表し、「missing」は予測利用ヒント数が実際の利用ヒント数より少なかった割合を表す。

表 5.3 より,提案モデルは大半の課題において IRT モデルより,高精度にヒント数を予測していることがわかる.ただし,課題 3,4,22 においては IRT モデルの予測精度の方が提案モデルより高い.その理由は,表 5.4 より,課題 3,4,22 では RT モデルの missing(過少予測率)が提案モデルのものより低いからと考えられる.ただし,IRT モデルと比較し,その他の大半の課題に対して提案モデルの extra (過大評価予測率)が低く,精度も高いことがわかる.つまり,IRT モデルより少ないヒント数で正答するように予測する傾向がある.Ueno and Miyazawa [5] はヒントの支援が過剰な場合と過小な場合とでは,過小な方が学習効率(事前テストと事後テストの差異)が良いことを報告している.従ってアダプティブラーニングにおける適応的支援には提案モデルが有効であると言える.

第6章 まとめ

近年,教育の現場では,個々の学習者の理解度や苦手分野を把握し,学習すべき項目や適応的ヒントを提供するアダプティブラーニングが注目を集めている.本論文では,アダプティブラーニングに用いるため,段階的ヒントを含む学習データに適応し,学習者が項目に正答するまでに必要とするヒント数を予測する新たなモデルを提案した.具体的には,文献[7]のアイデアを拡張し,受検者と項目とヒントを独立したニューラルネットワークの入力とし,それぞれの出力を組み合わせることで項目へのパフォーマンスを予測する深層学習モデルであり,リンケージ処理なしでも,学習者のヒント提示後のパフォーマンス予測精度の向上に大きく寄与することを明らかにした.

評価実験では既存手法と提案モデルを用いて学習者の反応予測精度比較を行い,提案モデルが既存手法の反応予測精度を改善することを明らかにした.実データ実験により,提案モデルには以下の利点があることが明らかとなった.

- 1) 一つの課題につき解決に必要なスキル（知識）が一つあると仮定した上で能力値推定を行い,課題への反応予測を行なっている.
- 2) 過去の反応履歴から未知の項目への反応予測をする際に提案モデルが最も高精度な予測が可能である.
- 3) 深層学習を採用するため,従来の段階的ヒントモデルに必要なリンケージ処理をなしでも,学習者のヒント提示後のパフォーマンスをよく予測できる.

また,能力推定に用いる学習データ数と能力の変動幅の最適値を推定することで様々な学習データに適応することを示した.さらに,実験結果から反応予測精度向上には学習データの忘却を調整することが重要であることがわかった.提案モデルは既存手法と比較して反応予測精度が有意に高いモデルであるため,段階的でない独立なヒントにも適応できるが期待される[29][30]. 実際のアダプティブラーニングシステムに提案手法を組み込み,その有効性を実データから示すことを今後の課題にする.

謝辞

本研究を行うにあたり,親切にご指導を頂いた植野真臣教授,宇都雅輝准教授に厚く御礼を申し上げます.ゼミ発表中のコメントが大変励みになりました.並びに研究についてご助言をいただきました川野秀一准教授に,感謝しております.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堤さん、木下さんに感謝いたします.御陰様で問題点を修正することができました.皆様ありがとうございます.

参考文献

- [1] <https://www.digital-knowledge.co.jp/product/edu-ai/adaptive/>
- [2] D. Wood, “Scaffolding contingent tutoring and computer-supported learning,” *Int. J. Artificial Intelligence in Education*, pp.280–292, 2001.
- [3] 植野真臣,松尾淳哉,“項目反応理論を用いて適応的ヒントを提示する足場かけシステム,” *信学論(D)*,vol.J98-D, no.1, pp.17–29, Jan. 2015.
- [4] M. Ueno and Y. Miyazawa, “Probability based scaffolding system with fading,” *Artificial Intelligence in Education - 17th International Conference, AIED 2015*, pp.492–503, 2015.
- [5] M. Ueno and Y. Miyazawa, “IRT-based adaptive hints to scaffold learning in programming,” *IEEE Trans. Learning Technologies*, vol.14, no.8, Aug. 2017.
- [6] 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,” *信学論 (D)* , vol.J102-D, no.2, pp.79–92, Feb. 2019.
- [7] 木下 涼,植野真臣,“深層学習によるテスト理論 : Item Deep Response Theory,” *信学論 (D)* , vol.J103, no.4, pp.314–329, April 2020.
- [8] M. J. Kolen and R. L. Brennan, *Test Equating, Scaling, and Linking: Methods and Practices* (2nd ed.), 01 2004.
- [9] F. Samejima, “Estimation of latent ability using a response pattern of graded scores,” *Psychometrika Monography*, no.17, pp.1–100, 1969.
- [10] 植野真臣,知識社会における e ラーニング,培風館,2007.
- [11] 植野真臣,永岡慶三,e テスティング,培風館,2009.
- [12] 豊田秀樹,岩間徳兼,中村彩子,齋藤康寛,“項目反応理論を用いたテスト運用への切り

替えコスト軽減の試み—多数の潜在特性尺度の同時等化法を利用して—,” 日本オペレーションズ・リサーチ学会和文論文誌,vol.58,pp.122–147, 2015.

- [13] F.M. Lord, Applications of item response theory to practical testing problems, L. Erlbaum Associates Hillsdale, N.J, 1980.
- [14] W.J. van der Linden and M.D. Barrett, “Linking item response model parameters,” Psychometrika, vol.81, no.3, pp.650–673, Sept. 2016.
- [15] G.L. Marco, “Item characteristic curve solutions to three intractable testing problems,” Journal of Educational Measurement, vol.14, no.2, pp.139–160, 1977.
- [16] B.H. Loyd and H.D. Hoover, “Vertical equating using the rasch model,” Journal of Educational Measurement, vol.17, no.3, pp.179–193, 1980.
- [17] T. Haebara, “Equating logistic ability scales by a weighted least squares method,” Japanese Psychological Research, vol.22, no.3, pp.144–149, 1980.
- [18] M.L. Stocking and F.M. Lord, “Developing a common metric in item response theory,” Applied Psychological Measurement, vol.7, no.2, pp.201–210, 1983.
- [19] W. Shen, X. Wang, X. Bai, and Z. Zhang, “Deepcontour: A deep convolutional feature learned by positive-sharing loss for contour detection,” 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp.3982–3991, June 2015.
- [20] 谷澤明紀,本多康弘,“情報処理技術者試験における e テスティング,” 日本テスト学会第 12 回大会発表論文抄録集,第 33 巻,pp.54–57,2014.
- [21] M. Ueno, “Animated agent to maintain learner’s attention in e-learning,” Proceedings of E-Learn: World Conference on E-Learning in Corporate, Government, Healthcare, and Higher Education 2004, eds. by J. Nall and R. Robson,pp.194–201,Association for the Advancement of Computing in Education (AACE),Washington, DC, USA,2004.
- [22] M. Ueno, “Data mining and text mining technologies for collaborative learning in an ilms

- "samurai".,," ICAIT '04 Proceedings of the IEEE International Conference on Advanced Learning Technologies, pp.1052–1053, 01 2004.
- [23] M. Ueno, "Intelligent lms with an agent that learns from log data," Proceedings of E-Learn: World Conference on E-Learning in Corporate, Government, Healthcare, and Higher Education 2005, ed. by G. Richards, pp.3169–3176, Association for the Advancement of Computing in Edu
- [24] 植野真臣,松尾淳哉,“項目反応理論を用いて適応的ヒントを提示する足場かけシステム,” 信学論(D),vol.J98-D, no.1, pp.17–29, Jan. 2015.
- [25] Martin,D,A and Quinn,Kevin.:Dynamic Ideal Point Estimation via Markov Chain Monte Carlo for the U.S.Supreme Court,1953-1999, Political Analysis,Volume 10, Issue 2,pp.134-153(2002)
- [26] R.J. Patz and B.W. Junker, “Applications and extensions of MCMC in IRT: Multiple item types, missing data, and rated responses,” J. Educational and Behavioral Statistics, vol.24, no.4, pp.342–366, 1999.
- [27] M. Uto and M. Ueno, “Item response theory for peer assessment,” IEEE Trans. Learning Technologies, vol.9, no.2, pp.157–170, 2016.
- [28] D.P. Kingma and J. Ba, “Adam: A method for stochastic optimization,” arXiv:1412.6980, 2014.
- [29] J. I. Lee and E. Brunskill, “The impact on individualizing student models on necessary practice opportunities,” in Proc. 5th Int. Conf. Educational Data Mining, 2012, pp. 118–125.
- [30] Y. Engestrom, Learning by Expanding: An Activity-Theoretical Approach to Developmental Research, 2nd ed. London, U.K.: Cambridge Univ. Press, 2014.