

# 短時間で能力ランクを判定するための Moodle プラグインの開発

秋山 實<sup>\*1</sup>

Email: [akiyama@ei.tohoku.ac.jp](mailto:akiyama@ei.tohoku.ac.jp)

\*1: 東北大学大学院 教育情報学教育部

©Key Words 潜在ランク理論, コンピュータ適応型テスト, Moodle

## 1. はじめに

近年, eラーニングやインストラクショナルデザインなど新しい教育のツールや方法論が普及してきており, 適切なタイミングで学習者の理解度や能力を効率的かつ短い時間で測定することが必要になっている。

### 1.1 テストの長さや精度のトレードオフ

全ての受験者が全ての問題を受験する従来のテスト(以後, リニアテストと呼ぶ)の測定精度は, テストを構成する問題の数が多いほど高くなる。しかし, 問題が多いテストは時間がかかる。

表1 サンプル数とモデル適合度指数(RFI)

ランク	受験者数		
	160	80	40
3	<u>0.773</u>	<u>0.776</u>	0.659
4	<u>0.814</u>	<u>0.822</u>	<u>0.728</u>
5	<u>0.827</u>	<u>0.838</u>	<u>0.725</u>
6	<u>0.842</u>	<u>0.849</u>	<u>0.760</u>
7	<u>0.844</u>	<u>0.856</u>	<u>0.763</u>
8	<u>0.847</u>	<u>0.860</u>	<u>0.767</u>
9	<u>0.844</u>	<u>0.858</u>	<u>0.757</u>
10	<u>0.845</u>	<u>0.851</u>	<u>0.768</u>
11	<u>0.839</u>	<u>0.852</u>	<u>0.761</u>
12	<u>0.831</u>	<u>0.847</u>	<u>0.750</u>

### 1.2 コンピュータ適応型テストとその特徴

コンピュータ適応型テスト(Computerized Adaptive Test: CAT)は受験者の回答を基にその時点の受験者の能力を動的に推定し, 次に出題する問題を選択・出題するため, 受験者の能力から大きくかけ離れた易しい, あるいは, 難しい問題は出題されない。したがって, リニアテストに比べ, 半分以下の問題でリニアテストと同程度の精度で受験者の能力を測定できると言われている。

CATを採用すれば測定精度を落とさずに短時間でテストを実施できるが, CATには問題バンク(特性パラメータの値が予め推定された問題のデータベース)が必要であり, 予備テストを実施しておく必要がある。多くのCATが項目応答理論(Item Response Theory, IRT)に基づいて設計されており, 適切に特性パラメータを推定するために必要なサンプル数は, 最もシンプルなモデルである1パラメータロジスティックモデルを採用した場合でも200名, 20問以上の回答データが必要と言われている<sup>2)</sup>。

### 1.3 潜在ランク理論の特長

潜在ランク理論<sup>3)</sup>(Latent Rank Theory, LRT, 後述)は, IRTに比べモデルの制約が少ないため, 少ないサンプル数で特性パラメータを適切に推定でき, IRTを適用できないサンプル数が少ない状況にも適用することができる<sup>4)</sup>。

表1は「日本語を読むための語彙量テスト」<sup>5)</sup>(後述)の回答データを受験者数160名からランダムに削除して, 80名, 40名と減らした時の各ランクにおけるモデル適合度指標の一つであるRFI<sup>6)</sup>(Relative Fit Index)をEXAMETRIKA<sup>7)</sup>によって算出したものである。RFIは0から1あるいはそれ以上の値をとり, 大きければ大きいほどモデル適合が良いと判断できる。本研究ではモデル適合度が良好であると判断する基準をRFIが0.7以上(アンダーラインで示す)とする。表1をみると広い範囲でモデル適合度は良いといえる。IRTは適用できないような, 受験者数40名, 問題数150問であってもLRTの場合, 特性パラメータの推定が可能である。

問題数についても同様のことが言える<sup>4)</sup>。問題数50問, 受験者数40名でもランク数5から15までの範囲で上記と同様のモデル適合度が得られる。

## 2. 潜在ランク理論

LRTは, 発表の当初はニューラルテスト理論<sup>10)</sup>(Neural Test Theory, NTT)と呼ばれていた。「テストの解像度は連続値で表わすほど高くない」<sup>3)</sup>と考へ, LRTでは受験者の能力を5から20程度のランクという離散値で表わす。これは順序尺度である。順序尺度は順序にだけ意味があり, ランクに加減乗除などの演算はできない。これに対してIRTでは受験者の能力を連続値で表わす。これは間隔尺度である。LRTにおいて推定精度を定義する場合, 順序尺度では差に意味がないので誤差の指標であるRMSE(Root Mean Square of Error)を計算することはできないので, 真値のランクと推定値のランクが一致しない率を使う。

受験者の能力を離散値で表すことで測定が粗くなるというよりは, 問題の特性を表わすアイテム参照プロファイル(Item Reference Profile: IRP, 図1)や受験者の各ランクへの所属確率を表わすランクメンバーシッププロファイル(Rank Membership Profile: RMP, 図2)という概念の導入により, IRTよりも特性パラメータを豊かに表現できるという特長を持っている。




図1 ランク数10の場合のIRPの例




図2 ランク数10の場合のRMPの例

## 2.1 IRP

IRPは、IRTの項目特性曲線に相当するもので、ランク数と同じ数の要素を持つベクトルで、それぞれのランクの要素は、そのランクの能力を持つ受験者がその問題を受験した場合に正答する確率を表している。

図1のItem1は隣接するランクの正答確率の差が大きく、能力差を識別する力があり、難しい問題である。Item2は隣接するランクの正答確率の差が小さいので、受験者の能力を識別する力が弱く、全体的に正答率が高いので易しい問題といえる。

## 2.2 RMP

IRTでは能力値が一つの値で表されるが、LRTではランク数と同じ数の要素を持つベクトルで表され、それぞれのランクの要素は、そのランクにその受験者が所属する確率を表している。

図2の受験者021は、ランク6の所属確率が最も大きく、隣接するランクの所属確率との差が大きいので能力ランク6であるが、受験者022は、ランク8の所属確率が最も大きいですが、ランク7も次に大きく、ランク7からランク8に能力が変化していると見ることができる。(その逆の可能性もある)

## 2.3 ランク

受験者の能力を表すランクは、RMPの各ランクのうち最も大きい所属確率を持つランクとして定義されている。

受験者の能力をいくつのランクに区分するかは、IRTのモデルのパラメータ数と同じく、LRTで用いるモデルを決定することと同様の意味がある。異なるランク数の特性パラメータは比較することも、同じか否かを判定することもできない。

## 3. 評価

評価は、「日本語を読むための語彙量テスト」の182人の回答データとそれをもとにEXAMETRIKAで分析して得たEXCELファイル(IRP, RMPなど特性パラメータと問題の名前を含む)をMoodleにアップロードして、シミュレーションを行った。

### 3.1 使用したテストと回答データ

「日本語を読むための語彙量テスト」は「日本語を読むための語彙データベース<sup>(12)</sup>」から100語につき1語の割合でサンプリングした150語を使って問題を作

成し、15,000語までの語彙量を測定することができる。1,000語ごとに五種(和語、漢語、外来語、混種語)と品種の割合を統制したサンプリングを行っている。

2010年5月から10月にかけて日本、オーストラリア、ニュージーランドの5大学・機関の日本語プログラムで実施して得た回答データのうち、日本語学習歴のない中国語母語話者を除いた182名からランダムに抽出した160名のデータを使用している。

### 3.2 シミュレーションによる評価

LRT-CATの性能を知るには、シミュレーションが役に立つ。シミュレーションでは、受験者の能力の真値がわかっているため、推定誤差を知ることができるからである。LRT-CATに付加したシミュレーション機能を用いて、小さなアイテムバンクを用いた場合も含め、シミュレーションによる評価を行った。

サンプル数の小さい回答データは、必要なサイズになるよう受験者または問題を間引いて作成した。「日本語を読むための語彙量テスト」の問題は、1,000語毎の語彙量で並んでおり、語彙の種類もバランスを取っているため、3問おきに削除して100問、2問おきに削除して50問の回答データを作成した。受験者の方はランダムなキーを付加してソートし前半を削除する方法で80名、40名の回答データを作成した。これらの回答データをそれぞれランク数4から14までの11通りについてEXAMETRIKAを用いて特性パラメータを推定し、これをLRT-CATの問題バンクとしてアップロードした。

評価の際のシミュレーション条件は、終了条件については、 $\Delta RMP$ を0.01とした。

推定されたランクの一致率は概ね85%を超えている部分をアンダーラインで示す。良好とまでは言えないが精度に関しては概ね有効であることを確認できた。受験問題数は受験者の95%を含む範囲(平均受験問題数+2 \* 標準偏差を小数点以下を切り上げて95%上限値として算出した)では、70%以下になるケースをアンダーラインで示す。(表3)。

### 3.3 実地テストによる評価

LRT-CATを使用してCATを実施した結果と全問解答するリニアテストを同じ受験者に受験させ、推定された能力ランクと受験問題数を比較した。

東京の私立大学の留学生129名が、CAT、リニアテストの順で受験した結果を表4に示す。

実施条件は、シミュレーションと異なり、 $\Delta RMP$ を

表2. シミュレーションのランク一致率  
ランク数

		4	5	6	7
160名	150問	<u>0.98</u>	<u>0.93</u>	<u>0.89</u>	0.83
	100問	<u>0.95</u>	<u>0.90</u>	0.81	0.77
	50問	<u>0.90</u>	<u>0.82</u>	0.74	0.67
80名	150問	<u>0.98</u>	<u>0.95</u>	<u>0.91</u>	<u>0.87</u>
	100問	<u>0.94</u>	<u>0.87</u>	0.84	0.78
	50問	<u>0.82</u>	<u>0.85</u>	0.78	0.74
40名	150問	<u>0.93</u>	0.82	0.79	0.77
	100問	<u>0.97</u>	<u>0.90</u>	<u>0.88</u>	0.81
	50問	<u>0.87</u>	0.77	0.82	0.65

表3 シミュレーションの受験問題数(95.987 上限値)  
ランク数

		4	5	6	7
160名	150問	<u>66</u>	<u>92</u>	106	<u>105</u>
	100問	72	88	93	94
	50問	50	50	50	50
80名	150問	<u>57</u>	<u>85</u>	<u>101</u>	<u>103</u>
	100問	<u>69</u>	<u>60</u>	85	91
	50問	49	48	49	50
40名	150問	<u>66</u>	<u>77</u>	<u>90</u>	<u>95</u>
	100問	<u>56</u>	<u>70</u>	<u>59</u>	<u>57</u>
	50問	45	44	48	48

表4 実地テストの結果  
ランク

	全体	1	2	3	4	5
一致率	0.72.1	NA	0.22	0.364	0.387	0.962
問題数	39	NA	28.2	24.8	21.5	14.4
受験者	129	0	9	11	31	78

表5 リアルデータシミュレーションの結果  
ランク

	全体	1	2	3	4	5
一致率	0.798	1.000	1.000	0.545	0.419	0.987
問題数	30	30	30	30	30	30
受験者	129	2	7	7	19	94

0.03とした。受験者の母語は、76.9%が中国語、12.3%がベトナム語、3.1%がミャンマー語、7.7%がその他の言語であった。

実地テストの結果は、ランク1から4でランク一致率が悪い。そこで、リニアテストの回答データを用いてリアルデータシミュレーション（乱数を使って回答の正誤を決めるのではなく、受験者が実際に回答したリニアテストの回答を使ってLRT-CATのシミュレーションを行う）を最低受験項目数を30問、最大受験項目も30問に指定して実施したところ、各ランク毎のラン

ク一致率が、1.000, 1.000, 0.545, 0.419, 0.987と全体的に良い結果となった。特に、最低ランクと最高ランクで大幅に改善した。根本原因がLRT-CATのアルゴリズムにある可能性は否定できないが、全員に30問受験させることで、150問のテストの約80%の精度で30問（リニアテストの20%）という極めて少ない問題数でテストが実行できることが分かった。

テストの精度や受験問題数は、個々のテストの問題の質に依存している部分が大きく、適用するテストごとにシミュレーションを行って、問題を選択するアルゴリズム、能力を推定するアルゴリズム、終了条件などを最適に設定する必要がある。LRT-CATには、シミュレーション機能があるので最適条件で実施することができる。

このLRT-CATの利用例としては、以下のような手順で、1回だけリニアテストを実施すれば、2回目以降は、LRT-CATで半分程度の問題数で同程度の精度のテストが実施でき、テストの短時間化が実現できると思われる。

- 1) リニアテストを作成し、実施する
- 2) EXAMETRIKAで分析し、目的やモデル適合度などでランク数を決定する
- 3) 結果のEXCELファイルをLRT-CATにアップロードして、シミュレーションを実施し、最適条件を決定する
- 4) LRT-CATで短時間でリニアテストと同じテストを実施する

現在は、2)と3)の手順でEXAMETRIKAを使っているが、今後、LRT-CATに分析機能を取り込むことで手順が簡略化でき、さらに実施しやすくなると思われる、改善を予定している。

Moodleのプラグインとして実装され、Moodle2.3の環境で標準的な活動モジュールとしてインストールでき、コースバックアップ・リストアなどが可能である。配布は、<http://moodle2x.info>で行われている。

#### 4. おわりに

本研究では、オープンソースソフトウェアのeラーニングシステムとして日本の大学でも普及しているMoodleのプラグインとして動作し、潜在ランク理論に基づくコンピュータ適応型テストを実施できるプラグインLRT-CATを開発した。このLRT-CATの応用範囲は広いと思われる。たとえば、Moodle上のコースで、毎回の授業終了間際の数分間で学習内容の理解度を測るテストをLRT-CATで実施し、次回の授業でフォローするなどして落ちこぼれをなくす対策が実施できる。

#### 謝辞

本研究に使用した「日本語を読むための語彙量テスト」の利用を快諾して下さいた東京大学教養学部の松下先生に深く感謝します。

#### 参考文献

- (1) Dougiamas, M.: "Moodle", <<http://moodle.org>>, (2012年12月6日閲覧).

- (2) リン, ロバート (池田央他編): “教育測定学ハンドブック 第3版(上)”, pp.246-247, C.S.L.学習評価研究所, (1992).
- (3) 植野真臣, 荘島宏二郎: “学習評価の新潮流”, pp.83-111, 朝倉書店, (2010).
- (4) 秋山實: “潜在ランク理論のパラメータ推定に必要な問題数と受験者数”, 日本テスト学会第10回大会発表論文抄録集, pp.178-179, (2012).
- (5) 松下達彦: “「日本語を読むための語彙量テスト」の開発”, 2012年日本語教育国際研究大会予稿集, 第一分冊, pp.310, (2012).
- (6) 豊田秀樹編: “共分散構造分析 (AMOS 編)”, pp.245, 東京図書, (2008).
- (7) Shojima, K.: “EXAMETRIA 5.3”, (2008-2012), <<http://www.rd.dnc.ac.jp/~shojima/exmk/>>, (2012年12月6日閲覧).
- (8) 秋山實: “LRT モデルに基づく CAT の開発とシミュレーションによる特性解析”, 日本テスト学会第9回大会発表論文抄録集, pp.146-147, (2011).
- (9) 木村哲夫: “潜在ランク理論に基づくコンピュータアダプティブテストアルゴリズムの提案と検証”, 日本テスト学会誌, 8, pp.70-84, (2012).
- (10) Shojima, K.: “Neural Test Theory”, DNC Research Note, 07-02 (2007), <<http://www.rd.dnc.ac.jp/~shojima/Shojima2007RN07-02.pdf>>, (2012年12月6日閲覧).
- (11) Shojima, K.: “Maximum Likelihood estimation of latent rank under neural test model”, DNC Research Note, 07-04 (2007), <<http://www.rd.dnc.ac.jp/~shojima/ntt/Shojima2007RN07-04.pdf>>, (2012年12月6日閲覧).
- (12) 松下達彦: “日本語を読むための語彙データベース (総合版)”, Ver.4.0, <<http://www.geocities.jp/tatsum2003/>>