

eテストティングの最新技術

植野真臣
電気通信大学

本講演の内容

1. 40万を超える等質テスト生成アルゴリズム
2. 項目露出数を制約するテスト生成
3. 項目露出を制限する適応型テスト
4. 決定木を用いた適応型テスト
5. 深層学習によるテスト理論 Deep IRT

1. 40万を超える 等質テスト生成アルゴリズム



湊本壱真, 植野 真臣 : 等質テスト構成における整数計画法を用いた最大クリーク探索の並列化, 電子情報通信学会論文誌 D, Vol.J103-D, No.12, pp.881-893 (2020)

eテストティング：等質テスト生成

- 数理モデルを用いて**スコアの予測誤差が等質**となるように問題の組み合わせを列挙



問題を格納する
データベース



等質テスト群を生成


等質テスト生成法

- テストに含まれる項目は異なるが，等質なテスト群
- 具体的には各テストの難易度が等しくなるように，統計的な性質，得点分布，所要時間等が一定
- テスト管理者の経験と勘で構成されてきたが，テストを自動構成する手法が数多く提案
 - Big Shadow Method [van der Linden 2005]
 - Set Packing Problem [Belov and Armstrong 2006]
 - Genetic algorithm method [Sum et al. 2008]
 - Bees algorithm method [Songmuang and Ueno 2011]

- W. J. van der Linden, *Linear Models for Optimal Test Design*. Springer, 2005.
- D. I. Belov and R. D. Armstrong, "A constraint programming approach to extract the maximum number of non-overlapping test forms," *Computational Optimization and Applications*, vol. 33, pp. 319–332, 2006.
- K.-T. Sun, Y.-J. Chen, S.-Y. Tsai, and C.-F. Cheng, "Creating irtbased parallel test forms using the genetic algorithm method," *Applied Measurement in Education*, vol. 2, no. 21, pp. 141–161, 2008.
- P. Songmuang and M. Ueno, "Bees algorithm for construction of multiple test forms in e-testing," *IEEE Transactions on Learning Technologies*, vol. 4, pp. 209–221, 2011.
- T. Ishii, P. Songmuang, and M. Ueno, "Maximum clique algorithm and its approximation for uniform test form assembly," *IEEE Transactions on Learning Technologies*, vol.7, no.1, pp.83–95, 2014.
- T. Ishii and M. Ueno, "Algorithm for uniform test assembly using a maximum clique problem and integer programming," *International Conference on Artificial Intelligence in Education* Springer, pp.102–112 2017.

最大クリーク法（上の文献の中で最も正確で最大のテスト構成数）

2018年度電子情報通信学会論文賞受賞



1. Takatoshi Ishii, Maomi Ueno, "Algorithm for Uniform Test Assembly Using a Maximum Clique Problem and Integer Programming", International Conference on Artificial Intelligence in Education (AIED), LNAI 10331, pp. 102-112. 2017
2. Takatoshi Ishii, Pokpong Songmuang, Maomi Ueno, "Maximum Clique Algorithm and its approximation for Uniform Test Form Assembly", IEEE Transactions on Learning Technologies, Vol.7(1), pp.83-95, 2014.

最大クリーク法の問題

- 空間計算量によるテスト構成数の上限
 - 最先端の最大クリークアルゴリズムは MCT [Tomita et al. 2017], MoMC [CM Li, Jiang, and Many' a. 2017] など
 - 時間計算量 $O(2^{0.19171|V|})$ で探索可能.
 - しかし, 空間計算量が $O(|V|^2)$ と大きく, 最大で 10万程度のテスト構成が限界

提案手法：等質テスト構成における整数計画法を用いた最大クリーク探索の並列化

二段階探索アルゴリズム

[第一段階]

時間計算量 $O(|2|^{0.19171|V|})$ が小さく，空間計算量 $O(|V|^2)$ が大きい最大クリーク法で メモリが許す限りテスト生成

[第二段階]

時間計算量 $O(|V| \cdot 2^n)$ が大きく，空間計算量 $O(|V|)$ が小さい整数計画法を用いた手法に切り替えてテスト生成、 並列探索アルゴリズムに改善

湊本 竜真，植野 真臣：等質テスト構成における整数計画法を用いた最大クリーク探索の並列化，電子情報通信学会論文誌 D, Vol.J103-D, No.12, pp.881-893 (2020)

実験

Item bank size	OC	Hybrid RBP	Proposal
500	0	17	17
	5	9,774	14,331
	10	126,987	127,149
1000	0	33	34
	5	62,965	97,492
	10	127,432	131,300
2000	0	69	70
	5	103,164	129,257
	10	126,532	140,700
978	0	35	35
(actual)	5	61,859	73,693
	10	122,681	124,200

→テスト構成数が大きくなると、差異が大きい


実験

Item bank size	OC	Hybrid RBP	Proposal
500	0	17	17
10			
		127,432	131,300
2000	0	69	70
	5	103,164	129,257
	10	126,532	140,700
978	0	35	35
(actual)	5	61,859	73,693
	10	122,681	124,200

大規模アイテムバンクを用いて、
計算時間を28日間まで延長し、追加実験

→テスト構成数が大きくなると、差異が大きい

実験




まとめ

- 最大クリーク法と整数計画法を用いた手法を改善した二段階並列探索アルゴリズムを提案
- 約44万の等質テストを生成できた.

2. 項目露出数を制約するテスト生成

植野晶：項目露出を考慮した整数計画法による等質テスト構成，電気通信大学卒業論文 (2021)

あるハイステークス試験における2013年度と2017年度の
実際の等質テストのスコアの測定誤差




項目露出数（出題数）のヒストグラム

- 特定の良問を集中的に選択してしまうことで良問の露出数（出題数）が増加
- 項目の特性が良問から大きく変化



測定誤差の劣化が急速に進行




問題項目の露出数の偏りを減少 させなければならない！！

- RndMCPにより最大クリーク列挙
- 探索後に露出率(最大露出数/構成数)最小のクリークを出力

Takatoshi Ishii and Maomi Ueno: Clique Algorithm to Minimize Item Exposure for Uniform Test Forms Assembly, Artificial Intelligence in Education – 17th International Conference, AIED 2015, 638-641


RndMCP法(Ishii 2014)の問題



RndMCPでアイテムバンクからランダムにテスト生成されたときの 同一項目が含まれるテスト数


RndMCP法(Ishii 2014)の問題

これらはクリークに含まれても重複数条件で等質テストに採用されないので生成するのが非効率



RndMCPでアイテムバンクからランダムにテスト生成されたときの 同一項目が含まれるテスト数

提案手法 ランダムテストの生成



- ①各テストをアイテムバンクからランダムに生成する際、これまで生成されたテストに含まれた回数が最大の項目をアイテムバンクから削除.
- ②テストが生成されなくなると削除された項目をアイテムバンクに戻し①に戻る。
- ③メモリ限界(100000個) まで繰り返し頂点を生成する


実験結果

Pool Size	OC	従来手法			提案手法		
		テスト構成数	最大露出数	露出率	テスト構成数	最大露出数	露出率
500	0	10	1	0.10000	10	1	0.10000
	5	4339	354	0.08159	4989	365	0.07316
	10	99976	13009	0.13012	99970	5372	0.05374
1000	0	18	1	0.05556	18	1	0.05556
	5	46392	3364	0.07251	50778	1626	0.03202
	10	100000	8740	0.08740	100000	2847	0.02847
2000	0	32	1	0.03125	32	1	0.03125
	5	96732	3761	0.03888	97422	1398	0.01435
	10	100000	4035	0.04035	100000	1418	0.01418
978(実データ)	0	18	1	0.05556	19	1	0.05263
	5	45806	5177	0.11302	54794	1726	0.03150
	10	100000	16495	0.16495	100000	2755	0.02755

- 露出率減少
- テスト構成数も増加

実験結果

実データ, OC=5
提案手法で生成



- クリークに含まれる頂点に含まれる項目の方が多くなる
- クリークに含まれる頂点に含まれる項目露出の偏りが軽減


まとめ

- アイテムバンクの項目を露出数に応じて制限しテスト構成する手法を提案
- 従来手法の露出数の偏りを改善できた

3. 項目露出を制限する適応型テスト

Ueno and Miyazawa, Uniform adaptive testing using maximum clique algorithm, Artificial Intelligence in Education (AIED) 482-493 , 2019

適応型テストのアルゴリズム



利点

測定精度を下げずに 受検者に出題する問題項目数を減少させることができる

→


問題項目露出数を減少させることができるかもしれない

問題


- 適応型テストは、同一の能力を持つ受検者に同一の問題項目を出題してしまう。項目露出数の偏りはより増大してしまう。

等質項目グループを用いた等質適応型テスト

等質テスト生成手法を用いて
等質項目グループを構成



等質項目グループから
適応的に出題



先行研究

1. シャドーテストを用いた適応型テスト (van der Linden, 2005)

① 所望の条件 (露出数) を満たすシャドーテストを構成

② シャドーテストから情報量が最大の項目を選択

2. アイテムバンク分割法

(Kingsbury 1989, Hetter 1997)

アイテムバンクを複数のグループにランダムに分割し、露出数が最小のグループから情報量が最大の項目を選択

実験結果(実データ)


アイテム・バンク	方法	重複項目	等質項目グループ数	平均出題項目数	項目露出最大値	項目露出数平均
978	従来適応型テスト	----- -	-----	65.5	1000	67
	LINDEN(1998)	0	-----	87.9	90	89.9
	Kingsbury (項目数50)	0	20	63.5	382	45.1
	Kingsbury (項目数100)	0	10	61.7	556	44.66
	提案(項目数50)	0	7	41.2	143	42.1
		10	8669	40.7	136	41.6
	提案(項目数100)	0	2	54.8	500	56
		10	7088	54.3	179	55.5

実験結果


- 驚くべきことにすべてのアイテムバンクを用いた適応型テストよりも分割された等質項目グループから適応型テストを実施した場合、項目露出頻度が劇的に一様となるだけでなく、テスト精度が大幅に向上し、受検者に提示される項目数も劇的に減少することがわかった。
- アイテムバンクのテスト項目が多すぎると初期値と能力スコアが乖離する場合、局所解に陥る問題が発見された。
- 最適な等質項目グループの項目数が存在することが示唆され、現在、どのような条件にすれば最も 露出頻度を一様にし、テスト精度を高くできるかを知るための実験を現在行っている。

Ueno and Miyazawa, Uniform adaptive testing using maximum clique algorithm, Artificial Intelligence in Education (AIED) 482-493 , 2019


理由



アイテムバンク内の項目の反応曲線



等質項目グループ内の項目の反応曲線



4. 決定木を用いた適応型テスト

赤坂尚紀, 決定木を用いた適応型テストの多階層木圧縮による生成時間削減、
電気通信大学卒業論文 (2021)

項目選択に要する時間


- ▶ 等質適応型テストでは項目選択が複雑になり、項目選択の計算時間が増大
- ▶ あらかじめ決定木を作成しておき項目選択を高速化

M. Ueno, P. Songmuang (2010)

M. Ueno (2013)


Delgado-Gómez (2019)

Rodríguez-Cuadrado (2020)



- 決定木を用いた適応型テストDT[Ueno & Sonmuang 2010]

- 事前にすべての受検者の回答パターンに対する決定木を生成



各節は m 番目の出題項目 i_m をもち、項目 i_m に対する回答 $u_{i_m}(=0,1)$ によって分岐する。
各回答パターンに対して能力値 $\hat{\theta}$ を推定。

M. Ueno, P. Songmuang (2010), “Computerized Adaptive Testing based on Decision Tree”,
The 10th IEEE International Conference on Advanced Learning Technologies, pp.191-193.

- M. Ueno, P. Songmuang (2010), "Computerized Adaptive Testing based on Decision Tree", The 10th IEEE International Conference on Advanced Learning Technologies, pp.191-193.
- M. Ueno (2013), "Adaptive Testing Based on Bayesian Decision Theory", Artificial Intelligence in Education 2013, pp.712-716.
- D. Delgado-Gomez, Juan C. Laria, Diego Ruiz-Hernandez (2019), "Computerized adaptive test and decision trees: A unifying approach", Expert Systems With Applications 117 pp.358-366. (Elsevier)
- Javier Rodríguez-Cuadrado, David Delgado-Gómez, Juan C. Laria,
Sara Rodríguez-Cuadrado (2020), "Merged Tree-CAT: A fast method for building precise computerized adaptive tests based on decision trees",
Expert Systems With Applications 143 pp.122-130 (Elsevier)

• 決定木を用いた適応型テストの課題


- 分枝数の指数的增加に伴い、情報量の計算や分枝の探索に要する時間・空間計算量が増加
- 大きな木の生成が困難

- Merged Tree-CAT[Rodríguez-Cuadrado, Delgado-Gómez & Laria 2020]

- 推定能力値とその分布が類似している分枝をマージすることで, 分枝数を削減する手法
- Tree-CATが高性能な計算機で7日間を要したテストの生成を, 一般的な計算機で数十秒で生成可能

• 分枝数の削減

- 各分枝に項目を割り当てる前に，対応する推定能力値とその分布が類似している分枝をマージ



- 決定木生成時間はそれでも長い


- Merged Tree-CATを用いてもテスト生成に時間を要する
- Merged Tree-CATは同一階層のマージのみ

提案手法：決定木を用いた適応型テストの 多階層木圧縮による生成時間削減

- 現在生成中の階層の分枝同士のマージの後,
既に生成した上位階層の頂点ともマージ
- 決定木をさらに圧縮しテスト生成時間を削減

• 上位階層の頂点とのマージ

- 上位階層の頂点のうち、推定能力値が類似しているものをマージする




実験1

- 978項目の実アイテムバンクを使用
- 500人のシミュレーションから生成した受検者を使用
- 出題項目数: 10
- K^* : 200, δ : 0.6
- その他のパラメータはRodríguez-Cuadrado, Delgado-Gómez and Laria [2020]と同様
- Tree-CAT法, Merged Tree-CAT法, Restricted法と比較

実験1

能力推定精度の比較



➤ 能力推定精度はTree-CAT, Merged Tree-CATと同程度

実験1

テスト生成時間の比較

Method	決定木生成	項目選択時間(すべての項目の和)
Proposal	2.6(min)	0
Tree-CAT	33.5(min)	0
Merged Tree-CAT	3.1(min)	0
Restricted	0	11(sec)

- テスト生成時間は分枝のマージを行う提案手法と Merged Tree-CATが圧倒的に短い

実験2

(より条件を増やしてMerged Tree-CATと比較)

- シミュレーション及び実データを使用
- 500人のシミュレーションから生成した受検者を使用
- 出題項目数: 10, 30, 70
- K^* : 200, 300, 500
- その他のパラメータは実験1と同様
- Merged Tree-CATと比較

実験2

能力推定精度の比較

Method			Merged Tree-CAT			Proposal		
Test length			10	30	70	10	30	70
		K^*						
Item Bank	500	200	0.247	0.117	0.083	0.249	0.118	0.083
		300	0.245	0.115	0.080	0.246	0.116	0.081
		500	0.243	0.114	0.078	0.244	0.114	0.079
	1000	200	0.234	0.104	0.062	0.235	0.104	0.062
		300	0.233	0.104	0.061	0.233	0.105	0.062
		500	0.231	0.103	0.060	0.231	0.104	0.061
	2000	200	0.226	0.099	0.056	0.227	0.099	0.056
		300	0.224	0.097	0.055	0.225	0.098	0.055
		500	0.223	0.096	0.053	0.223	0.097	0.054
	978	200	0.325	0.178	0.108	0.329	0.180	0.110
		300	0.323	0.175	0.105	0.325	0.176	0.107
		500	0.320	0.173	0.101	0.321	0.175	0.104

➤ Merged Tree-CATと同程度の能力推定精度を維持している

実験2

決定木生成時間(min)の比較

Method			Merged Tree-CAT			Proposal		
Test length			10	30	70	10	30	70
		K^*						
Item Bank	500	200	1.4	8.4	26.9	1.2	6.5	21.4
		300	2.0	12.4	40.3	1.8	9.1	31.2
		500	2.7	19.5	66.3	2.5	15.4	52.8
	1000	200	2.8	17.2	53.6	2.4	12.7	41.9
		300	4.0	25.1	79.9	3.7	18.2	57.9
		500	5.2	39.3	131.0	5.0	28.6	93.1
	2000	200	5.7	35.8	113.2	5.0	26.7	89.0
		300	7.1	52.0	173.8	6.5	37.6	125.3
		500	9.3	79.4	276.9	9.0	59.2	195.8
	978	200	3.1	18.3	61.4	2.6	13.7	45.3
		300	4.2	26.5	86.3	3.9	19.2	62.6
		500	5.7	43.1	143.5	5.3	31.0	102.6

- 決定木生成時間が削減されている
- アイテムバンクが大きい場合，出題項目が多い場合が顕著

実験2

決定木の圧縮率

Test length			10	30	70
		K^*			
Item Bank	500	200	0.857	0.767	0.797
		300	0.899	0.734	0.788
		500	0.926	0.788	0.789
	1000	200	0.857	0.738	0.782
		300	0.923	0.725	0.725
		500	0.935	0.728	0.711
	2000	200	0.877	0.746	0.786
		300	0.915	0.726	0.721
		500	0.940	0.740	0.703
	978	200	0.839	0.749	0.738
		300	0.922	0.727	0.726
		500	0.926	0.719	0.715

- 提案手法で生成された頂点数をMerged Tree-CATの頂点数で割った割合
- アイテムバンクが大きいほど、出題項目が多いほど圧縮されている

まとめ

- 決定木を用いた適応型テストにおける，多階層木圧縮手法を提案
- 能力推定精度を保ちながら，決定木生成時間を削減することができた

5. 深層学習によるテスト理論 Deep IRT

- IRTには多くの仮定がある.
- 深層学習を用い, 反応の局所独立性、受検者（能力）の母集団と独立ランダムサンプリングを仮定しないDeep IRTを紹介する.


木下 涼, 植野 真臣: 深層学習によるテスト理論: Item Deep Response Theory, 電子情報通信学会論文誌 D, Vol.J103, No.4, pp.314-329 (2020)

Deep IRTの利点


- 1)IRT のリンケージ手法では、通常テスト間に共通する項目を利用する。 DeepIRTではテスト間に共通する項目がない場合にも従属性条件によりリンケージできる。
- 2)反応の局所独立性、受検者（能力）の母集団と独立ランダムサンプリングを仮定しない

木下 涼, 植野 真臣：深層学習によるテスト理論：
Item Deep Response Theory,電子情報通信学会
論文誌 D, Vol.J103, No.4, pp.314-329 (2020)

Deep IRTの構造



受検者ネットワークの構造



ランダムサンプリングとそれが成り立たない (system)場合のリンクージ精度の結果 注)DRM が提案手法

割り当て法	テスト項目数	共通項目数	受検人数	手法	RMSE	pearson	kendall	割り当て法	テスト項目数	共通項目数	受検人数	手法	RMSE	pearson	kendall
random	10	5	50	DRM	0.469	0.890	0.748	system	10	5	50	DRM	0.665	0.778	0.568
				2PLM	0.420	0.912	0.781					2PLM	1.111	0.381	0.237
			100	DRM	0.447	0.900	0.766				100	DRM	0.622	0.807	0.629
				2PLM	0.438	0.904	0.770					2PLM	0.779	0.696	0.466
		0	50	DRM	0.458	0.896	0.747			0	50	DRM	0.797	0.702	0.467
				2PLM	0.456	0.896	0.751				50	2PLM	1.170	0.314	0.184
			100	DRM	0.605	0.817	0.665				100	DRM	0.721	0.740	0.561
				2PLM	0.440	0.903	0.767					2PLM	1.176	0.308	0.197
	30	5	50	DRM	0.341	0.942	0.848			5	50	DRM	0.701	0.754	0.513
				2PLM	0.303	0.954	0.864				50	2PLM	0.808	0.673	0.457
			100	DRM	0.319	0.949	0.865				100	DRM	0.501	0.875	0.716
				2PLM	0.292	0.957	0.870					2PLM	0.573	0.836	0.672
		0	50	DRM	0.328	0.946	0.860			0	50	DRM	0.661	0.781	0.586
				2PLM	0.308	0.952	0.858				50	2PLM	0.786	0.691	0.489
			100	DRM	0.339	0.943	0.851				100	DRM	0.579	0.832	0.664
				2PLM	0.314	0.951	0.858					2PLM	0.762	0.709	0.506
	50	5	50	DRM	0.317	0.950	0.882			5	50	DRM	0.376	0.929	0.802
				2PLM	0.251	0.969	0.895				50	2PLM	0.426	0.909	0.760
			100	DRM	0.312	0.964	0.891				100	DRM	0.393	0.923	0.811
				2PLM	0.243	0.970	0.896					2PLM	0.805	0.750	0.543
		0	50	DRM	0.360	0.935	0.856			0	50	DRM	0.635	0.798	0.599
				2PLM	0.274	0.962	0.876				50	2PLM	0.782	0.694	0.489
			100	DRM	0.261	0.966	0.884				100	DRM	0.408	0.916	0.785
				2PLM	0.251	0.968	0.892					2PLM	0.612	0.812	0.532

実験 2 : 二つの母集団からサンプリングされる テストデータへの頑健性

平均 μ_1, μ_2 の異なる二つの母集団から30ずつ能力パラメータをサンプリングし, 50 項目からなるテストデータ行列を 2PLM により作成する. ここで, 各母集団に共通する標準偏差 σ^2 は, 全体の標準偏差が 1 に近づくように設定した. このテストデータの反応をランダムで欠損値とし, モデルを学習する. 次に, 学習したパラメータをもとに欠損値の反応予測を行う. 10 交差検証で算出した正解率を示す.


実験 2 : 混合分布からの欠測予測精度

μ_1	μ_2	σ^2	Deep IRT	IRT
-0.1	0.1	0.9	0.833	0.850
-0.2	0.2	0.8	0.783	0.800
-0.3	0.3	0.7	0.817	0.800
-0.4	0.4	0.6	0.833	0.783
-0.5	0.5	0.5	0.783	0.767
-0.6	0.6	0.4	0.850	0.833
-0.7	0.7	0.3	0.789	0.800
-0.8	0.8	0.2	0.867	0.833
-0.9	0.9	0.1	0.850	0.833
Average			0.823*	0.811


実験 3 の結果 実データでの未知の反応予測精度

実データ				2PLM		Deep IRT	
	受験者数	項目数	欠損率	正解率	F 値	正解率	F 値
情報	169	50	0%	0.817	0.760	0.817	0.779
批判的思考	1221	179	87.80%	0.669	0.665	0.679	0.679
プログラミング 1	94	13	0%	0.731	0.690	0.742	0.722
プログラミング 2	74	19	6.80%	0.730	0.685	0.770	0.746
統計	26	25	33.80%	0.840	0.802	0.920	0.908
情報倫理	31	90	46.30%	0.867	0.712	0.900	0.833
技術者倫理	85	69	26.40%	0.941	0.792	0.929	0.814
模試_数学	12348	48	16.40%	0.810	0.806	0.830	0.783
模試_物理	9172	24	12.00%	0.765	0.585	0.733	0.599
AL __物理	239	119	93.60%	0.729	0.729	0.725	0.725
AL __化学	1139	364	92.10%	0.724	0.724	0.722	0.722
AL __生物	192	114	90.60%	0.776	0.774	0.792	0.791
平均				0.783	0.727	0.797	0.758*

AL_生物における推定能力分布



2PL ロジスティックモデル



Deep IRT

まとめ

- Deep-IRT は 局所独立性の仮定がなく 様々な教育応用に対応できる.
- Deep-IRTは能力に特定の分布からのランダムサンプリングを仮定しておらず、リンケージを必要としないだけでなく ランダムサンプリングが難しい教育現場のデータなどにも応用可能である.
- Deep-IRT は現実データでは 予測精度、能力測定精度ともに優位性がある.
- Deep-IRT も基本は 微分可能なロジスティック関数の潜在変数モデルであるが、IRTよりDeep に構成することにより ロバストに予測精度を向上させることができた.

ご清聴ありがとうございました！！