

طراحی و پیاده‌سازی بانک سؤال مدرج شده در آزمون‌های سراسری^۱

سلیمان ذوالقارنی^۲

تاریخ دریافت: ۱۳۸۹/۰۹/۰۸

تاریخ پذیرش: ۱۳۹۱/۰۲/۱۵

چکیده

نوشته حاضر فرایند ایجاد یا توسعه یک بانک سؤال مدرج شده بر اساس تئوری سؤال پاسخ با استفاده از داده‌های ۳۰ سؤال کنکور آزمایشی حساب دیفرانسیل است که روی یک نمونه ۳۴۰۹ نفری اجرا شده است. تابع آگاهی کل سؤالات برابر با $\frac{۴۳}{۲۱}$ است که در فاصله ± ۳ پیوستار توانایی نقطه بیشینه آن روی ۹۵٪ است و در این نقطه، توانایی افراد با حداقل خطای برآورد شده است. یکی از نکات برجسته در راه اندازی چنین بانکی برآورد توانایی افراد بر اساس آزمون‌های مداد-کاغذی استاندارد و کم خطای اهداف ویژه است تا بتوان در هزینه، تلاش و زمان صرفه جویی کرد و امنیت آزمون‌ها را بالا برد. بعلاوه فرایند آزمون گیری را که به صورت سنتی و مداد-کاغذی اجرا می‌شود با طی مراحل بعدی به صورت سنجش انطباقی کامپیوتري ارتقاء داد. برای ارائه مثال از بین سؤالات این بانک یک خرده آزمون کوتاه مداد-کاغذی با سؤالاتی که قدرت تمیز بالا و ضریب دشواری بیشتری دارند، انتخاب شده است. دامنه دشواری این خرده آزمون کوتاه بین $a_i \leq b_i \leq 2$ و ضریب تمیز $a_i \leq 2$ قرار داده شد و در نهایت ۵ سؤال برگزیده شده است که تابع آگاهی این خرده آزمون برابر با $12/48$ و نقطه بیشینه آن روی پیوستار توانایی برابر با $1/35$ است. بعلاوه سطح دشواری آزمون $40/4$ واحد انحراف معیار افزایش یافته و به علت کوتاه شدن دامنه آزمون از ۳۰ سؤال به ۵ سؤال میزان

^۱. برگرفته از پژوهشی با همین نام در سازمان سنجش آموزش کشور، مرکز تحقیقات، ارزشیابی، اعتبارسنجی و تضمین کیفیت آموزش عالی سال ۱۳۸۹

^۲. کارشناس پژوهشی سازمان سنجش آموزش کشور salarnik2001@yahoo.com

آگاهی دهی از توانایی آزمون دهنده‌گان نیز ۳/۴۶ برابر کاهش پیدا کرده است. بعلاوه برای اجرای سنجش انطباقی یک شبیه سازی انجام شده است که تنها ۸ تا ۱۰ سؤال نیاز بوده تا با ۰/۰۱ احتمال خطابه همان دقیقت آزمون ۳۰ سؤالی توانایی افراد را اندازه‌گیری کرد.

واژگان کلیدی:

بانک سؤال، تئوری سؤال پاسخ، آزمون های کامپیوتری، گنجینه سؤال، سنجش انطباقی، بانک تست

مقدمه

یکی از بزرگ ترین مزیت‌های تئوری سؤال پاسخ^۱ (IRT) این بوده است که روش‌های آن این امکان را به راحتی در اختیار سازمان‌ها و مراکز آزمون‌گیری قرار داده تا بتوانند سؤالات خود را در یک بانک سؤال ذخیره کرده و آزمون هایی با پارامترهای دلخواه برای اهداف ویژه اجرا کنند و هم‌زمان بتوانند از یک بانک سؤال انواع آزمون های موازی و معادل تهیه کنند.

به طور معمول یک بانک سؤال مجموعه‌ای از سؤالات مقیاس‌های تک بعدی است که پارامترهای سؤالات آن بر اساس یکی از مدل‌های IRT به دست آمده است و از لحاظ حیطه موضوعی، سطح آموزش و شناسنامه توصیفی سؤال تفکیک شده است و هدف از راه اندازی آن علاوه بر بالابردن امنیت برای جلوگیری از لو رفتن سؤالات، ساخت آزمون های مدادکاغذی با ویژگی‌های معین و اجرای کامپیوتری آزمون‌ها و بدست آوردن بهترین برآورد از توانایی آزمون دهنده‌گان با کمترین خطای است (گرون‌لند، ۱۹۹۸).

در یک گنجینه سؤال غنی به راحتی می‌توان آزمونی را طراحی کرد که با احتمال بسیار بالایی روی توزیع صفت مکنون جامعه آزمون دهنده‌گان منطبق باشد و یا در اجرای آزمون های ملاک مرجع سؤالاتی را انتخاب کرد که دقیقاً روی یک نقطه از پیوستار توانایی مورد نظر بتواند آزمون دهنده‌گان را برای اعطای گواهی یا درجه به دو نیمه تفکیک کند.

علاوه با بکار بردن روزافزون سنجش انطباقی کامپیوتری^۲ (CAT) که در آن موقعیت اجرای آزمون برای هر آزمون دهنده و نوع آزمون یکسان است با این تفاوت که سؤالات مشابه یکدیگر نیستند، داشتن گنجینه ای بزرگ از سؤالات مدرج شده امکان انعطاف پیشتری در برگزاری این آزمون‌های استاندارد شده به سازمان‌ها می‌دهد. تهیه و توسعه گنجینه سؤالات در سنجش انطباقی نیز مستلزم تخصیص و جدا کردن ابعاد داده‌ها قبل از برآوردگی مدل های IRT است. در سنجش انطباقی هدف به حداقل رساندن خطای اندازه گیری در برآورد توانایی افراد با کمترین تعداد سؤالات است.

^۱.Item Response Theory

^۲. Computerized Adaptive Testing

۱- گام های ضروری برای طراحی بانک سؤال برای آزمون های خطی و سنجش انطباقی

۱-۱- تهیه آزمون اولیه و کنترل کیفی

برنامه های سنجشی استاندارد در مقیاس بزرگ چه مداد کاغذی و چه کامپیوترا مستلزم فرایند طراحی سؤالات، تهیه و کنترل کلید پاسخ سؤالات، سرهم کردن سؤالات، بازبینی محتوای سؤالات برای اطمینان یابی از اینکه مجموعه سؤالات تمام حیطه مورد نظر را تحت پوشش قرار می دهد و در واقع آزمون از روایی مناسبی برخوردار است و اجرای تجربی سؤالات روی یک گروه با حجم بهینه از آزمون دهنده‌گان می باشد. در واقع هر مرحله باید به عنوان یک مرحله کنترل کیفی مدنظر قرار گیرد. به طور ایده‌آل، گام‌های مربوط به کنترل کیفیت باید در ابتدای اجرا، نمره گذاری و گزارش آزمون آغاز شود. تلاش‌های جدی برای کنترل کیفیت یک نقش حیاتی در کمک به تضمین کارکردهای مناسب سؤال‌ها و آزمون‌ها ایفا می‌کند. کمپیون و مایلر (۲۰۰۶) بیان کرده اند که نیاز به فرایندهای کنترل کیفی موثر به عنوان یاوری برای اطمینان یابی از روایی آزمون است.

۱-۲- برآورد پارامتر سؤالات و توانایی: برازنده‌گی مدل به داده‌ها

تعداد سؤالات و نوع سؤالات نقش بسیار مهمی در فرایند انتخاب مدل آماری مناسب برای بدست آوردن توانایی آزمون دهنده‌گان و برآورد پارامتر سؤالات دارد. عمدتاً در آزمون گیری هایی که مبنی بر IRT هستند برای احتمال پاسخگویی فرد به سؤالاتی که به صورت «(پاسخ نادرست) و ۱(پاسخ درست) نمره گذاری می شوند یکی از مدل‌های یک، دو و یا سه پارامتری برای برآورد توانایی به کار می رود. در آزمون های سراسری به علت چهارگزینه ای بودن سؤالات مدل سه پارامتری بهترین برآشش با ماهیت داده ها دارد. در این مدل احتمال پاسخ صحیح یک فرد ز به یک سؤال θ تابعی است از توانایی او θ و سه پارامتر سؤال a_i, b_i, c_i

$$P(u_i = 1 | \theta_j, a_i, b_i, c_i) = c_i + (1 - c_i) / [1 + \exp(-1.7a_i(\theta_j - b_i))] \quad (1)$$

که پارامتر ها عبارتند از شبیه a_i ، دشواری b_i و حدس پذیری c_i سؤال. همچنین در این آزمون ها چون ممکن است تعدادی از آزمون دهنده‌گان به تمام سؤالات و یا به هیچ کدام از

سؤالات پاسخ ندهنده مدل‌های بیزین^۱ به علت مقاومتی که در برابر از دست دادن اطلاعات دارند^۲ برای مدرج کردن سؤالات بانک سؤال نسبت به الگوهای آماری دیگر مثل بیشینه درست‌نمایی مشترک^۳ (JML) و بیشینه درست‌نمایی کناری^۴ (MML) و یا بیشینه درست‌نمایی شرطی^۵ (CML) برتری دارند (به ایگن ۲۰۰۴، بیکر و سوک هو کیم ۲۰۰۴، نگاه کنید). شکل کلی معادله بیز در ادامه آمده است.

$$P(\theta_j | u_i, \tau, \xi) = \frac{P(u_i | \theta_j, \xi) g(\theta_j | \tau)}{\int P(u_i | \theta_j, \xi) g(\theta_j | \tau) d\theta_j} \quad \text{معادله (۲)}$$

در این معادله علایم عبارتند از محور احتمال پاسخ فرد_i, توانایی_j, پارامترهای سؤال^۶ وتابع توانایی در توزیع جمعیت^۷.

آزمون‌های متکی بر کامپیوتر چگونه کار می‌کنند؟

سنجهش انطباقی کامپیوتراً یکی از روش‌های پیشرفته اندازه‌گیری است که در آن کامپیوتراً بر اساس سطح توانایی آزمون‌دهنده سؤالات را از گنجینه سؤالات مدرج شده انتخاب و ارائه می‌کند. در CAT هر فرد به آزمونی منحصر به فرد جواب می‌دهد که با سطح توانایی‌های فردی او همخوان شده است. سؤالاتی با مقدار آگاهی کم درباره توانایی آزمون‌دهنده به طور نرمال حذف می‌شود و به همین دلیل به چنین آزمون‌هایی انطباقی یا سنجهش برازش یافته گفته می‌شود.

برای اجرای CAT چهار چیز نیاز است.

۱- بانک سؤالی که بر اساس یکی از مدل‌های IRT طراحی شده

۲- معیار مشخص برای انتخاب سؤال

۳- یک الگو برای نمره‌گذاری سؤال

۴- تصمیم‌گیری برای پایان زمان آزمون (گرین، بوک، مامفریز، لین و روکاس، ۱۹۸۴).

^۱.Bayes

^۲.loss of information

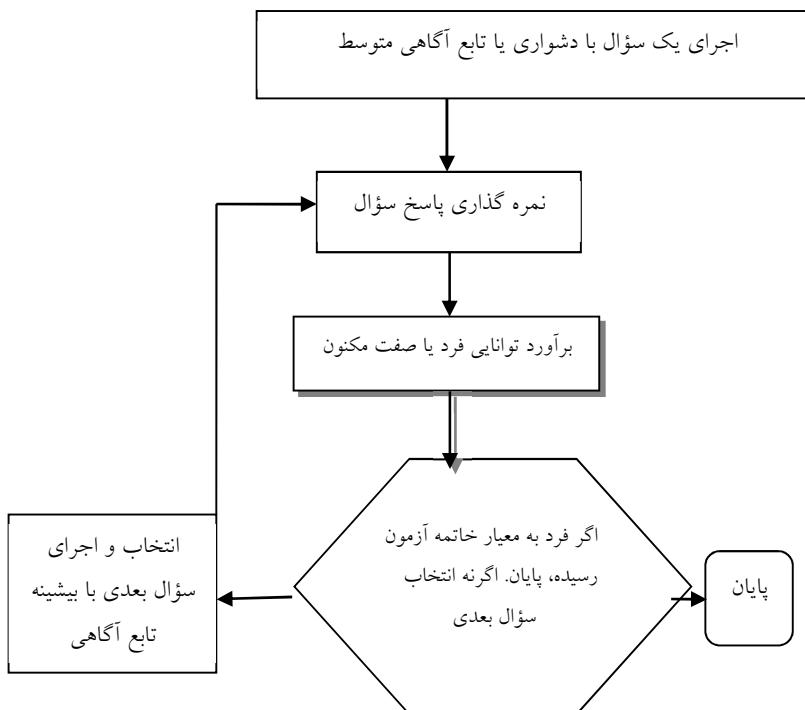
^۳.Joint Maximum Likelihood

^۴. Marginal Maximum Likelihood

^۵.Conditional Maximum Likelihood

در سنجش انطباقی فرایند اجرای آزمون به گونه‌ای است که در آن بر اساس پاسخ‌گویی آزمون دهنده به سؤالات قبل، سؤالات بعدی اجرا می‌شود. این فرایند از طریق به کار بردن الگوریتمی است که در آن بهترین سؤال بعدی، بر اساس توانایی برآورده شده قبلى فرد انتخاب می‌شود تا وقتی که زمان آزمون پایان یابد و یا محتواي مورد نظر در آزمون مورد پوشش قرار گیرد.

نمودار شماره ۱. الگوریتم سنجش انطباقی کامپیوتری



یک نکته قابل توجه در CAT این است که کامپیوتر تقلیدی از یک آزمون گیرنده خردمند را نمایش می‌دهد. به ویژه زمانی که آزمون گیرنده سؤالی را می‌پرسد که برای آزمون دهنده خیلی مشکل است سؤال بعدی به گونه‌ای است که به طور قابل ملاحظه آسان است. این امر از این حقیقت ناشی می‌شود که اگر سؤالاتی ارائه شوند که بسیار سخت و یا بسیار آسان باشند اطلاعات خیلی کمی از توانایی تک‌تک آزمون دهنده گان به دست می‌آید. اما هنگامی که

سؤالات همراه با افزایش سطح توانایی افراد ارائه شود آگاهی بیشتری می‌توان از میزان توانایی افراد به دست آورد(راینر، ۱۹۸۷).

در نمودار ۱ چهارچوب کارکردی CAT نشان داده شده است. نتیجه چنین رویکردی افزایش دقت اندازه‌گیری در محدوده گسترده‌ای از سطوح توانایی است (کارسلون، ۱۹۹۴). در حقیقت CAT به منظور کاهش زمان و کنار زدن آزمون‌های سنتی و ناکارآمدی ایجاد شده است که سؤالات آسان را به افراد با توانایی بالا و سؤالات سخت را به آزمون‌دهندگان با توانایی کم ارائه می‌دهد(دانکل، ۱۹۹۹).

نتایج و داده‌ها

نوشتن سؤال و تهیه آزمون گام اولیه در ایجاد بانک سؤال است. داده‌های به کار برده شده

برای این بانک تنها در برگیرنده ۳۰ سؤال چهارگزینه‌ای حساب دیفرانسیل با احتمال $\frac{1}{4}$

پاسخ صحیح و $\frac{3}{4}$ پاسخ خطأ برای هر سؤال بوده که به صورت آزمایشی روی یک گروه

۳۴۰۹ نفری اجرا شده است. برای ایجاد بانک سؤال ابتدا باید سؤالات آزمون به صورت پیش

تجربی اجرا شوند. سؤالات اجرا نشده در بانک را نیز می‌توان بر اساس اصول آزمون سازی

بر مبنای سؤالات لنگر مدرج و در بانک ذخیره کرد. بعد از جمع‌آوری داده‌ها برای شناسایی

ابعاد آزمون و شناسایی صفت مکنون از نرم‌افزار MSP (سیجت سما و مولن آیر، ۲۰۰۲) برای

مشخص کردن ابعاد آزمون استفاده شده است. نتایج نشان داد که آزمون دو^۱ بعد برجسته دارد

که در اولین^۲ بعد با سطح آستانه مقیاس پذیری پیش‌گریده $0/30$ تعداد ۲۴ سؤال وارد شده اند.

ضریب مقیاسی H آنها برابر با $0/39$ بودست آمده که نشان دهنده تک^۳ بعدی بودن بهینه این ۲۴

سؤال است و سطح معناداری آن برابر با $11/60 = Z$ که نشان دهنده سطح مقیاس پذیری H

بیشتر سؤالات و الگوی تکنوا افزایی^۱ آنها است. البته این تنها در سطح تبیین آماری و شهودی

می‌باشد و سازندگان آزمون باید در سطح نظری هم سؤالات آزمون را از لحاظ محتوایی

تفکیک کنند تا بتوانند ابعاد آزمون‌ها را هم از جنبه شهودی و هم از جنبه محتوایی و نظری

تفکیک کنند و سپس هر بعد را جداگانه تحلیل و وارد بانک سؤال کنند. بعلاوه ضریب پایایی

^۱. Monotone Homogeneity Model

این ۲۴ سؤال برابر با $Rho=0.90$ بوده است. مقیاس دوم تنها از دو سؤال تشکیل شده که عبارتند از سؤال ۱۷ و ۲۸. ضریب مقیاسی این دو سؤال برابر است با 0.32 و ضریب پایابی آن برابر با 0.35 است که شاخص خوبی برای یک مقیاس برای اندازه گیری پیشرفت تحصیلی نمی باشد. دلیل آن را هم می توان کم بودن تعداد سؤالات و کوتاه بودن دامنه این مقیاس بیان کرد و سؤالات ۱، ۱۴، ۱۵ و ۲۲ چیزی به غیر از صفت مکنون مورد نظر در سؤالات قبلی این آزمون اندازه می گرفتند و به عبارتی در حیطه ابعاد این آزمون جا نمی گیرند به ویژه سؤال ۲۲ که ضرایب کلاسیک آن مثل درجه دشواری بسیار بالا، ضریب تمیز کم و ضرایب IRT آن مثل شب و تابع آگاهی آن نسبت به دیگر سؤالات پایین بوده است. در هنگام فرایند مدرج کردن باید چنین سؤالاتی از مجموعه سؤالات کنار گذاشته شوند تا پارامترهای برآورده شده بهینه باشند.

جدول شماره ۱. مقادیر ضریب دشواری، مقیاس پذیری H ، سؤال ۲۴ پس از کنار گذاشتن سؤالات بدکارکرد.

تعداد سؤال	شماره سؤال	دشواری سؤال	Item H
1	Item2	0.21	0.33
2	Item3	0.26	0.33
3	Item4	0.39	0.36
4	Item5	0.16	0.30*
5	Item6	0.42	0.44
6	Item7	0.23	0.4
7	Item8	0.38	0.39
8	Item9	0.44	0.46
9	Item10	0.57	0.44
10	Item11	0.49	0.4
11	Item12	0.44	0.41
12	Item13	0.33	0.39
13	Item16	0.21	0.32
14	Item18	0.53	0.4
15	Item19	0.26	0.38
16	Item20	0.18	0.31
17	Item21	0.23	0.39
18	Item23	0.09	0.34
19	Item24	0.25	0.46
20	Item25	0.3	0.37
21	Item26	0.13	0.36
22	Item27	0.13	0.49
23	Item29	0.51	0.38
24	Item30	0.2	0.34

همان طور که می‌بینیم بر اساس یک توزیع نرمال برای پیدا کردن ارزش‌های H بزرگتر از $0/30$ تعداد ۲۴ سؤال در این مقیاس باقی مانده‌اند.

از نرم افزار Bilog-MG (زموسکی و همکاران، ۱۹۹۹) و بر اساس مدل سه پارامتری IRT برای مدرج کردن این آزمون ۳۰ سؤالی استفاده شده است. پارامتر سؤالات بانک وابسته است به مدل انتخاب شده IRT برای تحلیل داده‌ها و برآورد توانایی افراد. در این تحقیق از روش توزیع پسین مورد انتظار بیز^۱ (EAP) برای مدرج کردن سؤالات و همچنین برآورد توانایی آزمون دهنگان استفاده شده است. در این روش یک توزیع نرمال که از روی داده‌ها برآورد شده است برای برآورد بهینه پارامترها و مدرج کردن سؤالات به عنوان توزیع پیشین در معادله‌ای که تابع درستنمایی توانایی را محاسبه می‌کند ضرب می‌شود تا توزیع پسین مورد انتظار بدست آید. این عمل برای تک‌تک سؤالات و برای تک‌تک آزمون دهنگان صورت می‌گیرد. نتیجه این عمل برآورد مقادیر ثابتی هم برای پارامترهای سؤالات و هم برای توانایی افراد است (واندر لیندن، ۲۰۱۰: ۶-۲۰). همان طور که اشاره شد، در فرایند مدرج کردن سوالات، بعدیت آزمون^۲ نقش بسیار حیاتی در برآورد پارامترها دارد و باید فرض استقلال موضعی هم در داده‌های مربوط به سؤالات و هم در بین آزمودنی‌ها وجود داشته باشد. باید در نظر داشت که مدلی که برای بدست آوردن پارامترها به کار می‌رود با داده‌ها برازش داشته باشد. در جدول ۲ زیر پارامترهای IRT سؤالات آمده است.

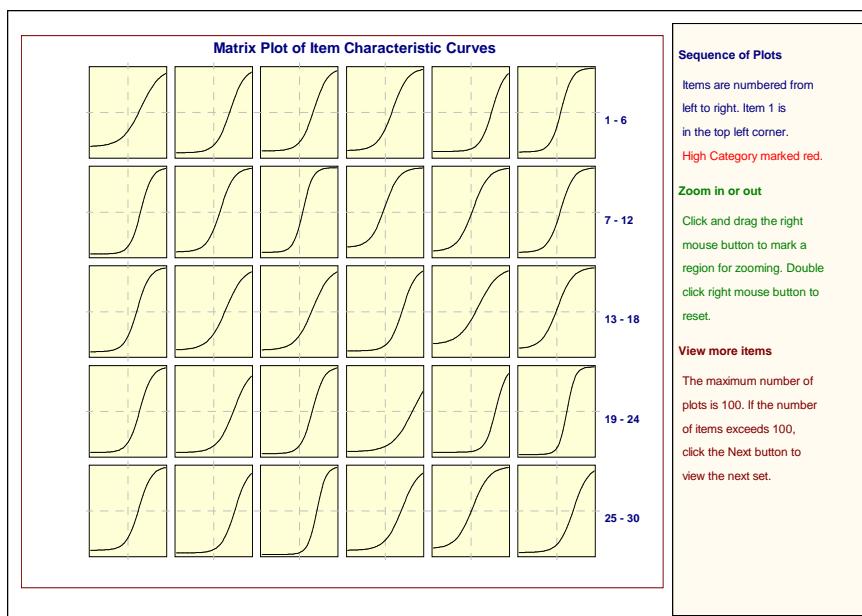
جدول شماره ۲. پارامترهای a، b، c و سؤالات همچنین مقدار لوجیت و ضریب همبستگی پیرسون و ضریب دورشته ای

NAME	a	b	c	LOGIT	PEARSON	BISERIAL
Item 1	1.32	1.05	0.12	0.63	0.37	0.477
Item 2	1.755	1.319	0.051	1.3	0.434	0.611
Item 3	1.838	1.155	0.072	1.06	0.454	0.615
Item 4	1.676	0.609	0.075	0.47	0.483	0.615
Item 5	2.028	1.703	0.066	1.69	0.361	0.548
Item 6	2.307	0.366	0.06	0.3	0.572	0.722
Item 7	2.277	1.025	0.033	1.19	0.542	0.749
Item 8	1.859	0.537	0.056	0.47	0.521	0.663
Item 9	2.608	0.289	0.052	0.24	0.603	0.758
Item 10	1.765	-0.048	0.108	-0.27	0.483	0.608

^۱. Expectation A Posteriori^۲. test dimensionality

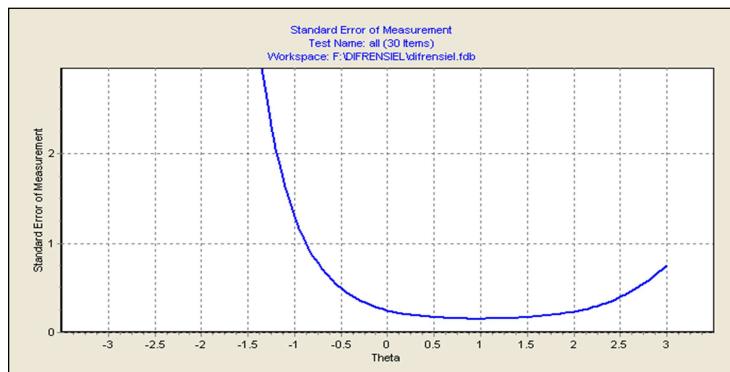
Item 11	1.62	0.152	0.062	0.03	0.482	0.604
Item 12	1.949	0.32	0.051	0.25	0.539	0.679
Item 13	2.017	0.733	0.054	0.72	0.536	0.697
Item 14	1.409	0.992	0.073	0.77	0.42	0.549
Item 15	1.447	1.056	0.073	0.84	0.417	0.549
Item 16	1.881	1.392	0.064	1.36	0.424	0.602
Item 17	1.269	0.611	0.135	0.23	0.387	0.487
Item 18	1.629	0.054	0.088	-0.13	0.48	0.602
Item 19	2.093	0.953	0.041	1.03	0.529	0.714
Item 20	1.512	1.615	0.04	1.54	0.385	0.566
Item 21	2.165	1.038	0.028	1.21	0.534	0.74
Item 22	1.197	2.253	0.051	1.78	0.272	0.421
Item 23	2.38	1.982	0.044	2.27	0.321	0.559
Item 24	3.083	0.818	0.018	1.08	0.638	0.867
Item 25	1.986	0.873	0.062	0.84	0.506	0.667
Item 26	1.853	1.697	0.031	1.87	0.403	0.636
Item 27	2.78	1.389	0.015	1.9	0.528	0.84
Item 28	1.48	1.346	0.061	1.17	0.397	0.547
Item 29	1.514	0.135	0.08	-0.03	0.46	0.576
Item 30	1.721	1.333	0.037	1.37	0.446	0.636

نمودار شماره ۲. منحنی ویژگی یا ICC سؤال



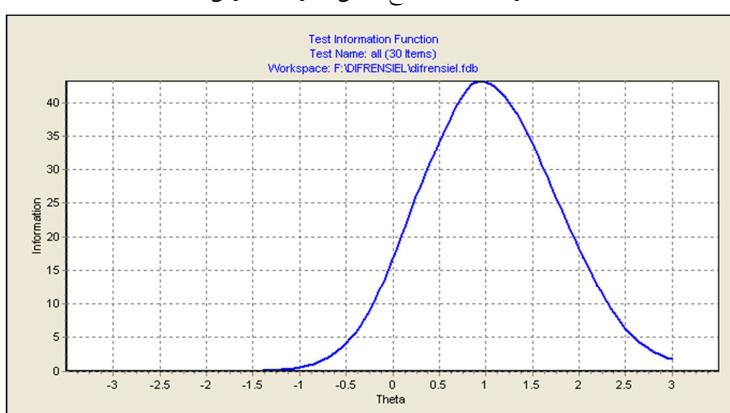
از نرم افزار FastTEST Professional 2.3.0 نیز برای بانک کردن سؤال ها به همراه تمام مشخصه های آماری و نوشتاری آنها استفاده شده است. این نرم افزار قابلیت ذخیره کردن تمام اطلاعات سؤالات و آزمون را دارد. در نمودار ۳ می توان مقدار خطای آزمون در بانک سوال کالیبر شده در فاصله های مختلف تنا مشاهده کرد.

نمودار شماره ۳. افزایش خطای برآورده تنا در آزمون ۳۰ سؤالی با فاصله گرفتن از نقطه ۰/۹۵ صدم تنا



در نمودار ۴ تابع آگاهی این آزمون ۳۰ سؤالی در بانک آمدده است

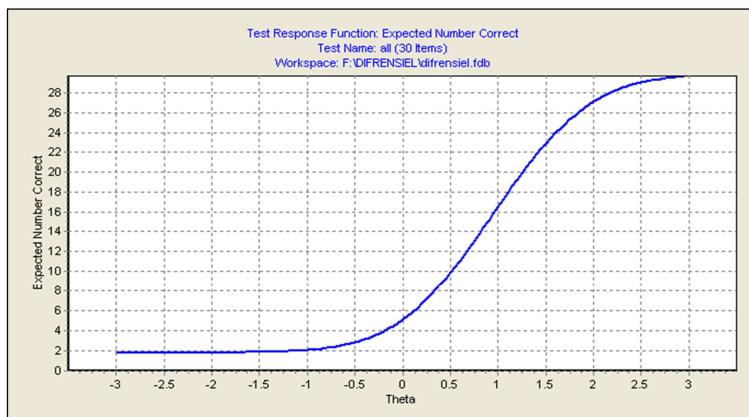
نمودار شماره ۴. تابع آگاهی آزمون ۳۰ سؤالی



همان طور که در نمودار ۵ می بینیم منحنی ویژگی آزمون ارتباط نزدیکی با تابع آگاهی آزمون دارد. به عبارت دیگر بیشترین شب آزمون نیز در نقطه ۰/۹۵، تنا است. جایی که قدرت تمیز آزمون در تفکیک افراد به بیشترین مقدار خود می رسد و در این نقطه آزمون با احتمال بالایی افراد قوی و ضعیف را از یکدیگر جدا می کند. خطای برآورده در این نقطه به ۰/۱۵۲۱ می

رسد. انتظار می رود افرادی که توانایی برابر با $0/95$ دارند تقریباً به بیش از ۱۵ سؤال پاسخ دهنده: یعنی نصف.

نمودار شماره ۵. ویژگی آزمون ۳۰ سؤالی



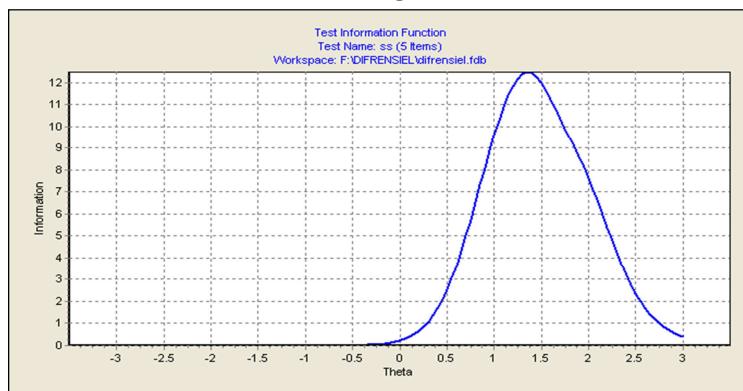
انتخاب سؤال از بانک

معمولًاً در یک بانک سؤال مدرج ایده‌آل به اندازه کافی سؤال هست که بتوان فرم‌های چندگانه‌ای از سؤالات ساخت که به کمک آنها بتوان توانایی افراد را اندازه گرفت (راوی و نوینگ، ۲۰۰۲). یک گنجینه خوب و بزرگ کمک می‌کند تا سؤالات بهتری به توانایی افراد برآذش داده شود و در نتیجه بتوان توانایی افراد را با دقت بیشتر برآورد کرد. بسته به اهداف آزمون گیری سازمان‌ها و یا مراکز آموزشی، برای انتخاب یک مجموعه سؤال از بانک رویکردهای متفاوتی وجود دارد. یکی از این روش‌ها که به ویژه در سنجش برآذش یافته کاربرد دارد، انتخاب سؤال بر اساس تابع آگاهی سؤالات است. با توجه به نمودار ۳ و ۴ می‌توان دید که در این گنجینه ۳۰ سؤالی بهترین تابع آگاهی در امتداد پیوستار تنا بین نمره ۰ تا ۲ است که نقطه ماقسیم آن تقریباً $0/95$ می‌باشد. این مقدار برابر با $43/21$ است. خارج از این محدوده، آگاهی از توانایی آزمون دهنگان بسیار کاهش می‌یابد و نمی‌توان به خوبی سطح توانایی افراد را پیش‌بینی کرد. بنابراین پیوستار تابع آگاهی به ما می‌گوید که هر سطح از توانایی به چه خوبی اندازه گیری می‌شود. به طور کلی یک تابع آگاهی زمانی ایده‌آل است که خط آن در بخش گسترده‌ای از پیوستار توانایی افقی باشد و توانایی را در تمام سطوح بتواند با بیشترین دقت برآورده کند.

باید بدانیم که تابع آگاهی آزمون از مجموع تابع آگاهی تک‌تک سوالات آزمون به‌دست می‌آید. این امر کمک می‌کند تا در آزمون‌گیری‌های متفاوت بسته به اهداف هر آزمون دقیقاً سوالاتی را از گنجینه سوالات انتخاب کنیم که بیشترین آگاهی از توانایی آزمون دهنده‌ها را در فاصله دلخواه بدست دهد. صفت مکنون افرادی که در این نقطه از مقیاس توانایی قرار دارند (در نقطه ۰/۹۵ تا) با کمترین خطا برآورده است و هر چه نمرات از این نقطه فاصله داشته باشند احتمال خطای برآورد توانایی افزایش می‌یابد. نمودار ۳ افزایش مقدار خطا را در برآورد توانایی افراد در آزمون ۳۰ سوالی نشان می‌دهد.

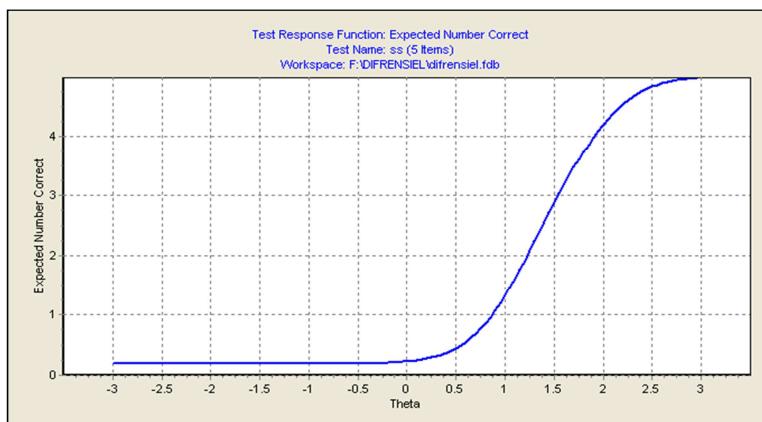
رویکرد دوم انتخاب سوالاتی است که بهترین شب را در یک فاصله دلخواه داشته باشند همان طور که می‌دانیم پارامتر شب سوال نمایان‌گر توان سوال در جداسازی آزمون دهنگان قوی و ضعیف است. رویکرد سوم انتخاب سوال در یک فاصله معین روی پیوستار صفت مکنون با دامنه‌ای از ضربی دشواری دلخواه است و یا می‌توان از رویکرد ترکیبی استفاده کرد. به عنوان مثال در این گنجینه ۳۰ سوالی ما قصد داریم روی پیوستار صفت مکنون که از ۳+۳ امتداد دارد سوالاتی را انتخاب کنیم که ضربی دشواری آنها برابر یا بین نقطه ۱ تا ۲ باشد. یعنی $2 \leq b_i \leq 1$ و شب هر سوال بزرگتر مساوی مقدار دلخواه ۲ باشد به عبارتی $a_i \leq 2$. با این محدودیت‌های تعریف شده در نهایت پنج سوال از این ۳۰ سوال انتخاب شدند. سوال ۵، ۷، ۲۱، ۲۳ و ۲۷. این سوالات در روی پیوستار توانایی در دامنه ۱ تا ۲ به علت شب بیشتر از ۲ بهترین قدرت جداسازی افراد را دارند. در نمودار ۶ تابع آگاهی این آزمون ۵ سوالی روی پیوستار تناشان داده شده است. در این نمودار بهترین برآورد از توانایی افراد در نقطه ۱/۳۵ تا صورت خواهد گرفت. تابع آگاهی آزمون در این نقطه برابر است با ۱۲/۴۸۳۵ و مقدار خطای معیار برآورده است با ۰/۷۸۳۰. همانطور که می‌بینیم مقدار آگاهی از توانایی افراد از ۱۲/۴۸ به ۱۲/۴۳ کاهش یافته است که بزرگ‌ترین دلیل آن کاهش دامنه آزمون از ۳۰ سوال به ۵ سوال است.

نمودار شماره ۶. تابع آگاهی آزمون ۵ سؤالی



و ضریب دشواری آزمون تقریباً ۰/۴ واحد انحراف استاندارد افزایش پیدا کرده و آزمون سخت تر از مجموعه ۳۰ سؤالی شده است. انتظار می‌رود افرادی که ترتیب برابر با ۱/۵ دارند حداقل به ۳ سؤال از مجموعه پنج سؤالی پاسخ دهند (به نمودار ۷ نگاه کنید).

نمودار شماره ۷. منحنی ویژگی آزمون ۵ سؤالی



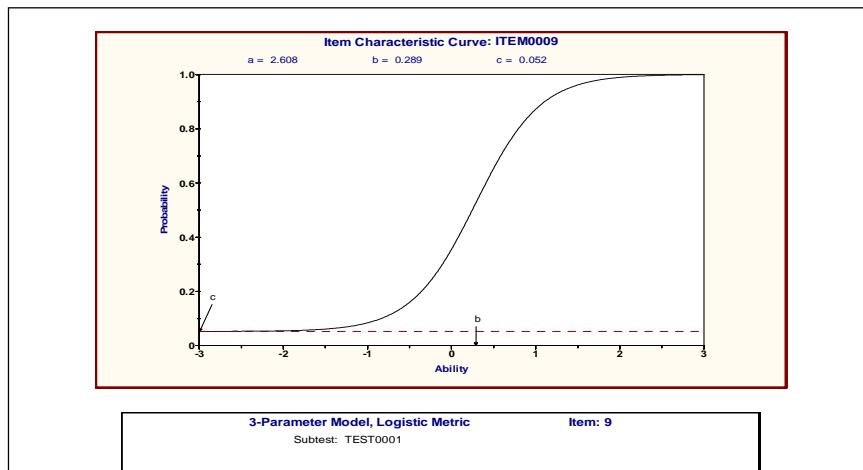
البته باید دوباره یادآوری شود که اگر گنجینه سؤالات خیلی بزرگ باشد برای انتخاب یک مجموعه سؤال دلخواه، طبیعتاً بیش از ۵ سؤال انتخاب خواهد شد و در نتیجه در آزمون های مدادکاغذی که سؤالات آن از بانک مدرج شده تهیه شده است می‌توان توانایی را با دقت بیشتری برآورد کرد.

در مرحله بعد یک شبیه سازی پیش تجربی^۱ برای اجرای واقعی سؤال ها روی یک شبکه کامپیوتری بر مبنای CAT و بر اساس نرم افزار POSTSIM (ویس، ۲۰۰۵) صورت گرفته است. برای این کار تمام ۳۰ سؤال به عنوان یک آزمون جدید روی یک گروه ۵۰ نفری از فایل داده های پاسخ سوال ها، اجرای مجازی شده است. به این ترتیب که بهترین سؤال که معمولاً باید شبیه بالایی داشته باشد ارایه می شود و سپس سؤالات بعدی بر اساس پاسخ گویی فرد به این سؤال ارایه می شوند. اگر پاسخ صحیح بود سؤال بعدی با بهترین تابع آگاهی برای فرد انتخاب می شود و اگر پاسخ غلط بود سؤال آسان تری ارائه می شود تا زمانی که بهترین اندازه توانایی افراد، با کمینه خطای بیشینه تابع آگاهی به دست آید. این الگو از روی رکورد های فایل پاسخ های افراد ایجاد می شود و ترتیب ارایه هر سؤال در فایلی که به همراه خروجی نرم افزار شبیه سازی است برای هر فرد ارایه می گردد. هدف از شبیه سازی این است که آزمون گیرنده از ماهیت سؤالات ویژه ای که از بانک انتخاب کرده و می خواهد در شبکه کامپیوتری بر اساس الگوی CAT اجرا کند مثل تابع آگاهی، پارامترهای سؤالات و نظایر آن، یک چشم انداز اولیه داشته باشد و بتواند سؤالات بدکارکرد را برای CAT خارج کند. در این شبیه سازی سؤال ۹ که دارای شبیه زیاد و دشواری مناسبی است برای نقطه شروع اجرای سؤال در CAT انتخاب شده است. نمودار این سؤال، در زیر آمده است. نتایج نشان داد که تنها ۸ تا ۱۰ سؤال برای بدست آوردن توانایی این افراد با احتمال خطای برآورد $p \leq 0.01$ بر اساس الگوی سنجش انطباقی کافی بوده است. در مقایسه با آزمون مدادکاغذی تنها یک سوم سؤالات به همان خوبی آزمون ۳۰ سؤالی کارایی دارند^۲.

^۱. Post-Hoc

^۲. اطلاعات بیشتر در این زمینه را می توان در پژوهه ای تحت همین عنوان در مرکز مطالعات تحقیقات و ارزشیابی آموزشی سازمان سنجش آموزش کشور بدست آورد.

نمودارشماره ۸ نمودار سؤال ۹، به عنوان نقطه شروع پاسخ‌گویی به سؤالات در سنجش انطباقی کامپیوتری



نمودارشماره ۹.تابع آگاهی ۳۰ سؤال (برونداد POSTSIM) که برای سنجش انطباقی کامپیوتری روی ۵۰ نفر به طور شبیه سازی شده اجرا شده است



نتیجه گیری

به علت اینکه روش های جدید اندازه گیری هم در تئوری و هم در عمل دارای توان بالایی هستند، در آزمون سازی هایی که بر مبنای این روش ها صورت بگیرد خطای برآورد به نحو چشم گیری کاهش می یابد و کار آزمون سازی نیز با حداقل هزینه و زمان صورت خواهد گرفت. عملا در بعضی از فرایند های آموزشی، اجرای آزمون های ورودی برای دوره های خاص ضروری است. به عنوان مثال، دوره های آموزش زبان انگلیسی نیازمند تعیین سطح افراد در حیطه های چندگانه است. وجود یک بانک سؤال مدرج شده کمک خواهد کرد تا

بدون تلف کردن هزینه، انرژی و زمان، بهترین دوره های آموزشی که دقیقاً با سطح ورودی افراد همخوان باشد را اجرا کرد. یا فرض کنیم برای گروههای آموزشی متفاوت نیاز به دوره های ویژه ای باشد می توان به یک بانک یا گنجینه سوال مدرج رجوع کرد، سوالات مرتبط با موضوع را انتخاب و به راحتی ویژگی های دوره آموزشی و کم و کیف تمرکز بر موضوعات خاص دوره را مشخص کرد.

از مزایای دیگر بانک سوال این است که اجازه می دهد سوالات دلخواه را طراحی و در آن ذخیره کرد و برای ساخت یک آزمون و یا خرده آزمون دیگر نیازی به قرار دادن افراد در قرنطینه و تهیه مجموعه زیادی از سوالات آزمایشی و پیش تجربی نباشد و به جای آن تنها از یک بانک، سوالات را بیرون آورد.

یکی دیگر از مزایای بانک سوال این است که به برنامه ریزان درسی کمک می کند تا به زبان مشترکی در رابطه با اهداف برنامه درسی و موضوعات آن دست یابند. همچنین سوالات مدرج شده مشخص می کند که آیا دانشجویان از پس تکالیف خود بر می آیند یا نه. جایگاه هر سوال روی یک پیوستار سلسله مراتبی به افراد درگیر در آموزش این امکان را می دهد تا دشواری نسبی یک تکلیف درسی خاص را مشخص کنند و این امر کمک می کند تا راه های آموزش سلسله مراتبی مطالب را از لحاظ دشواری مشخص کرد و برنامه درسی بهتری سازمان دهی کرد.

همانطور که گفتیم در روش‌های کلاسیک آزمون سازی نمره افراد تحت تاثیر سختی یا آسانی آزمون قرار می گیرد و برآورد توانایی افراد تابع سختی یا آسانی آزمون است و سوالات نیز در مجموعه آزمون معنی پیدا می کنند. عمدتاً دیده شده که در آزمون سازی‌هایی که بصورت سنتی اجرا می شود، سوالات یا بسیار دشوار هستند که تعداد کمی می توانند به آن جواب دهند و یا آسان هستند و تعداد زیادی نمره مشابه ای دریافت می کنند. این امر باعث محدودیت در گزینش افراد می شود. اما با استفاده از یک بانک سوال مدرج شده می توان بهترین سوالات را که همسان با توانایی آزمون دهنگان است انتخاب کرد. با در اختیار داشتن یک بانک سوال می توان تاثیر حذف یک سوال از مجموعه آزمون یا اضافه کردن سوالات بیشتر به آزمون را به راحتی کنترل کرد. یادآوری می شود که برآورد توانایی بر اساس آزمون-های حاصل از یک بانک سوال مدرج شده وابسته به سوال و گروه آزمودنی‌ها نیست یعنی

هم ویژگی های سؤالات استقلال دارند و هم توانایی و مقدار صفت مکنون افراد. به این ترتیب ایجاد فرم های موازی از یک آزمون با وزنی دقیقاً برابر اما سؤالات متفاوت به راحتی امکان پذیر است.

محدودیت های بانک سؤال

مهتمرين گام اساسی در ایجاد یک بانک سؤال، طراحی آن است که شامل فراهم سازی افراد متخصص در این زمینه، مشخص کردن چیزهایی که برای راه اندازی یک بانک لازم است و مشخص کردن آنچه که امیدواریم با راه اندازی یک بانک سؤال انجام پذیرد.

بی شک ایجاد یک بانک سؤال و تحلیل آزمون ها و سؤالات بر اساس IRT همه مشکلات آزمون سازی را حل نخواهد کرد و همچنان مسئله لو رفتن سؤالات در اجرای آزمایشی و یا اجرای بیش از حد یک سؤال و آشنا شدن افراد با راه حل آن باقی مانده است اما این ها مشکلاتی هستند که در آزمون گیری های سنتی نیز وجود دارند. ویژگی های برآورده توانایی در IRT کمک می کند تا تاثیر آشنایی افراد به پاسخ گویی به سؤال به حداقل برسد: چون بنابر دلایل قبلی که گفته شد برآورده توانایی با ویژگی های سؤال استقلال موضوعی دارند به ویژه اگر آزمون تک بعدی باشد. اما بیشترین سعی باید بر این باشد که همیشه بهترین سؤالات در یک بانک سؤال نگهداری شود و بیشترین تلاش نیز در زمینه نوشتن سؤالات باکیفیت شود. بعلاوه یک بانک سؤال باید در حیطه موضوعی کاملاً غنی باشد و آزمونی که از بانک تهیه می شود روایی کاملی داشته باشد تا بتواند صفت مکنون را در آن حیطه موضوعی خاص کاملاً پوشش دهد و برای سؤالات ضعیف سؤالات معادلی با کیفیت بهتر در دسترس باشد. برای این که بتوان به طور صحیح سؤالات آزمون ها را مدرج کرد و مقیاس آنها را طراحی کرد سؤالات مستلزم آنند که به آزمون دهنده هایی با دامنه ای گسترده از توانایی ارائه شوند.

بعلاوه در ساخت آزمون و ایجاد بانک سؤال باید مسئله بعدیت آزمون و گنجینه سؤالات مدنظر قرار گیرد. بر این اساس حتی اگر سؤال هایی در دو بعد متفاوت برای یک موقعیت آزمون گیری مناسب باشد، سؤالات باید در دو بعد تحلیل و به عنوان دو آزمون تفسیر شوند. هر بانک سؤال در برگیرنده سؤالات گوناگونی است که ممکن است بعدیت آزمون ساخته شده از بانک را مورد تردید قرار دهد. این امر نیازمند کالیبر کردن مجدد سؤالات، معادل سازی و سازماندهی مجدد آزمون ها و سؤالات است که به نوبه نیازمند حجم بالایی از برنامه ریزی،

طراحی، دانش نظری و عملی است. باید تاکید شود که اگر فرایند ساختن بانک سؤال به طور ناشیانه طراحی شود و از روش‌های مختلفی که برای تحلیل بعدیت آزمون‌ها و سؤالات، تعیین پارامترهای سؤالات، برآورد توانایی افراد و نظایر آن وجود دارد به طور ناآگاهانه استفاده شود در نهایت چیزی که تهیه می‌شود انباری از سؤالات به ظاهر تفکیک شده اما بسیار نهایت در هم و برهم است که باعث اتلاف وقت و نهایتاً هدر دادن هزینه‌ها شده است.

این امکان وجود دارد که مؤسسات و سازمان‌ها بتوانند بانک سؤال را با موفقیت ایجاد کنند و با استفاده از مدل‌های مختلف IRT آزمون‌های خود را مدرج کنند اما نیازمند دانش گسترده‌ای در مورد IRT و تئوری‌های مربوط به هوش و پیشرفت تحصیلی هستند و حوزه‌های امتحانی یا مؤسسات و سازمان‌هایی که یک پروژه بانک سؤال را انجام می‌دهند باید آگاهی کاملی از جنبه‌های عملی و همین طور تئوریک بانک سؤال داشته باشند. هم‌چنین این مؤسسات و سازمان‌ها، نیازمند کارکنانی هستند که بتوانند سؤالات آزمون را از لحاظ فنی، سازگاری و همخوانی با برنامه تحصیلی، تک بعدی بودن و قوان بالقوه هر سؤال برای اندازه‌گیری پیشرفت تحصیلی نقادانه مورد بررسی قراردهند.

فهرست منابع

- Baker, F. B., Kim, H.K. (2004), “*Item Response Theory: Parameter Estimation Techniques*”, Second Edition, Revised and Expanded. Marcel Dekker, Inc., 207 Madison Avenue, New York 12701, USA.
- Brennan, Robert I. (2006), “*Educational Measurement*”, Fourth edition, American council on education.
- Chang, Chih -Hung. (2007), “*Developing tailored instruments: item banking and computerized adaptive assessment*”, Northwestern University Feinberg School of Medicine.
- Eggen, Theo J.h.m. (2004), “*Contributions to the theory and practice of computerized adaptive testing.Omslag*”, RoelOttow / Harold Kainama.Druk: Print Partners Ipskamp B.V., Enschede © Copyright 2004. ISBN 90-5834-056-2.
- Georgiadou, E., Triantafillou, E., Economides, A. (2007), “*A review of item exposure control strategies for computerized adaptive testing developed from 1983 to 2005*”, Journal of Technology, Learning, and Assessment, 5(8). Retrieved [date] from <http://www.jtla.org>.
- Ho Yu, Chong, Angel Jannasch-Pennell, & Samuel DiGangi. (2008), “*A Non-Technical Approach for Illustrating Item Response Theory*”, Journal of Applied Testing Technology.
- Rudner, Lawrence. (1998), “*Item Banking ERIC/AE Digest*”, ERIC Clearinghouse on Assessment and Evaluation Washington DC. ED423310.
- Sijtsma, K. & Molenaar I.W. (2002), “*Introduction to Nonparametric Item Response Theory*”, Thousand Oaks, CA: Sage Publications.
- Sukamolson, Suphat. (1996), “*Computerized test/item banking and computerized adaptive testing for teachers and lecturers*”, Language Institute Chulalongkorn University.
- Thompson, Nathan A., & Weiss, David A. (2011), “*A Framework for the Development of Computerized Adaptive Tests*”, *Practical Assessment, Research & Evaluation*, 16(1). Available online: <http://pareonline.net/getvn.asp?v=16&n=1>.
- Tshering, Gembo. (2006), “*IRT in Item Banking, Study of DIF Items and Test Construction (Item Response Theory in Item Banking, Study of Differentially Functioning Items and Test Construction)*”, Master of Science-Track Educational Evaluation and Assessment Educational Science and Technology. University of Twente the Netherlands.

Van der Linden. J. & Glas, C. A.W. (2010), “*Elements of Adaptive Testing*”, Statistics for Social and Behavioral Sciences. New York: Springer. <http://www.springer.com/>

Weiss, D. J. (2005), “*Manual for POSTSIM: Post-hoc simulation of computerized adaptive testing*”, Version 2.0. St. Paul MN: Assessment Systems Corporation.

