

مقایسه مدل‌های اندازه‌گیری (کلاسیک و سؤال-پاسخ) از لحاظ برآورد پارامترهای

سؤال و توانایی

نوشته مهدی فراهانی

معرفی مقاله

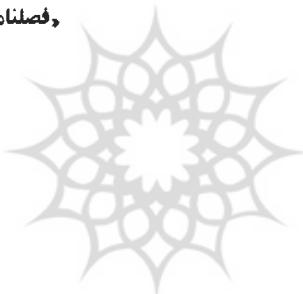
نظریه‌های اندازه‌گیری از یک بعد به دو دسته اساسی تقسیم می‌شود: نظریه کلاسیک و نظریه‌های جدید اندازه‌گیری (IRT).^۱ این پژوهش از طریق داده‌های حاصل از اجرای سه آزمون ریاضیات، فیزیک و درس فنی که در مورد ۴۳۰ نفر از داوطلبان کنکور داخلی وزارت نیرو اجرا شده بود، به مقایسه نظریات کلاسیک و جدید از لحاظ برآورد پارامترهای سؤال و توانایی برداخته است.

تحلیل‌های کلاسیک داده‌ها از طریق برنامه SPSS و برآورد پارامترهای سؤال و توانایی بر حسب مدل‌های جدید اندازه‌گیری از طریق نرم افزار رایانه‌ای BILOG در کالیفرنیای آمریکا انجام گرفته است. مقایسه مدل‌های مختلف اندازه‌گیری از نظر برآوردهای متفاوت یا مشابه پارامترهای سؤال به وسیله تابع آگاهی و آزمون^۲ وابسته، به آزمون و ارزیابی گذاشته شد. تابع نشان داد که مدل کلاسیک و مدل‌های IRT برآوردهای متفاوتی برای پارامترهای سؤال به دست می‌دهند و برآورد پارامترهای سؤال بر پایه مدل‌های

IRT، به ویژه مدل سه پارامتری، دقیق‌تر از برآورد پارامترهای سؤال بر اساس مدل کلاسیک و مدل‌های ساده‌تر IRT است. مقایسه مدل‌ها از نظر برآورد متفاوت پارامتر توانایی آزمودنی‌ها به وسیله آزمون کای اسکوئر آزموده شد. نتایج این مرحله نیز متفاوت مدل‌ها را در برآورد پارامتر توانایی آشکار ساخت و نشان داد که مدل سه پارامتری نسبت به مدل کلاسیک و حتی مدل‌های یک و دو پارامتری IRT برآوردهای متفاوت‌تر و دقیق‌تری ارائه می‌دهد.

این مقاله خلاصه‌ای است از پایان‌نامه تحصیلی دوره کارشناسی ارشد آقای مهدی فراهانی، کارشناس آموزش و زارت نیرو که با راهنمایی آقای دکتر محمد‌کاظم سلیمانی‌زاده، عضو هیأت علمی دانشگاه علامه طباطبائی تهیه شده و در اختیار فصلنامه قرار گرفته است. بدین وسیله از ایشان سپاس‌گزاری می‌شود.

«فصلنامه»



پژوهشگاه علوم انسانی و مطالعات فرهنگی
پرستال جامع علوم انسانی

مقدمه

مدل یا نظریه، رکن اساسی هر رشته علمی محسوب می‌شود. در اندازه‌گیری و روان‌سنجی نیز نظریه‌ها و مدل‌هایی وجود دارد که از لحاظ تاریخی و سیر روند تکاملی، به دو دسته کلاسیک (نظریه ضعیف نمره حقیقی) و سؤال - پاسخ (به اختصار IRT) تقسیم می‌شوند (۱).

مبانی مدل کلاسیک اندازه‌گیری را در اوایل قرن حاضر، اسپیرمن معرفی و پایه‌ریزی کرد (۲). این مدل سپس در دو کتاب گالیکسن و لرد و ناویک به اوج توسعه و بسط خود رسید (۳ و ۴). اما هم‌زمان با بسط این مدل، ضعف‌های جدی آن پیش‌تر آشکار شد و روان‌سنجان و متخصصان آزمون‌سازی را پیش از پیش به سمت مدل‌های جدید سوق داد (۵). از نیمه دوم قرن پیشتم به تدریج زمینه ارائه نظریات جدید مطرح شد و کسانی مانند لرد (۶)، راش (به نقل از رایت، ۱۹۷۷) (۷)، برن بام (۸)، رایت و همبلتون (۹) در این مسیر گام‌های مؤثری برداشتند.

هم اینک فعالیت‌های آزمون‌سازی و اندازه‌گیری در زمینه‌های مختلف - از پیشرفت تحصیلی گرفته تا سنجش نگرش‌ها و ... - در آمریکا و اروپا و براساس مدل‌های جدید (IRT) بررسی و ساخته می‌شود و مدل کلاسیک اعتبار پیش‌تر برای بحث در مورد تاریخچه نهضت آزمون‌سازی یا برآورده پارامترهای نظریات جدید به عنوان برآورده اولیه و مقدماتی مورد استفاده قرار می‌گیرد. معلمان هر چند در محدوده کلاس درس به ظاهر کم‌تر می‌توانند از مدل‌های اندازه‌گیری بهره ببرند اما اطلاع از مبانی نظری طراحی، اجراء و تجزیه و تحلیل آزمون‌های پیشرفت تحصیلی و یافته‌های جدید، پیش و بصیرت بهتری در مورد یکی از وظایف مهم معلمان - یعنی سنجش منحصلان - در اختیار آن‌ها قرار می‌دهد.

مطالعه منابع مربوط به موضوع پژوهش

در بعضی از مطالعات قبلی، محققان به مقایسه مدل‌ها از نظر دقیقت برآورده پارامترهای سؤال و توانایی پرداخته و برخی دیگر، تأثیر حجم نمونه آزمودنی و سؤال یا نقص مفروضات را در برآورده پارامترها بررسی کرده‌اند. با توجه به محدودیت مقاله حاضر، به طور عمده نتایج دسته اول (مقایسه مدل‌ها در برآورده پارامترها) ارائه می‌شود.

یکی از نتایج مطالعات مربوط به مقایسه دقیقت برآورده پارامترها در مدل‌های اندازه‌گیری حاکی از آن است که مدل منطقی سه پارامتری نسبت به مدل‌های یک و دو پارامتری با آزمون‌های ۲۰ سؤالی در برآورده جایگاه افراد در صفت مکنون و رتبه‌بندی آزمودنی‌ها براساس صفت مورد سنجش دارای قدرت پیش‌تری است. نکته دیگر آن‌که

پژوهشگران با تقسیم آزمودنی‌ها به دو گروه بالا و پایین ($0 \leq L \leq 2/5$ و $2/5 < T \leq 1$) و مقایسه دقت برآوردهای جایگاه حقیقی افراد بر حسب مدل‌های IRT، نشان دادند که افزایش دقت و قابلیت پیش‌بینی توانایی افراد توسط مدل سه پارامتری نسبت به سایر مدل‌ها، در گروه‌های با توانش پایین بیشتر از گروه‌های با توانش بالاست؛ زیرا امکان استفاده از حدس و شанс کاذب در گروه‌های با توانایی کم بیشتر است و تنها مدل سه پارامتری در برآوردهای پارامترها به عامل C_i (مجذوب پایین ICC) توجه می‌کند. مقایسه مدل‌های یک و دو پارامتری (بررسی تأثیر پارامتر قدرت تشخیص سؤال در برآوردهای توانایی افراد) تمایز و تفاوت جدی نشان نداد (۱۰).

راید برای تحلیل داده‌های چهار خرده آزمون مورد استفاده - شامل محاسبات عددی، تجسم فضای سه بعدی، خزانه لغات و استدلال ریاضی - از نرم‌افزارهای BILOG و TESTFACT بهره گرفت و بر اساس یک نمونه ۴۰۶ نفره از آزمودنی‌ها و با حذف سؤال‌هایی که کمتر از ۷۵ درصد آزمودنی‌ها به آنها پاسخ داده بودند، نتیجه گرفت که هر چهار خرده آزمون از لحاظ سطح دشواری سؤال‌ها و قدرت تشخیص افراد در سطوح مختلف توانایی، تفاوت داشته است. بنابراین، مدل‌های یک و دو پارامتری از لحاظ برآوردهای تفاوت معنی دار نشان داده‌اند (۱۱).

همون در تحقیقی با استفاده از آزمون تهران - استنفرد - بینه (TSB) (۱۲) به بررسی و مقایسه برآوردهای پارامترهای دشواری و توانایی پرداخت و در واقع، توانمندی مدل راش را در برآوردهای پارامترها در شرایط نقص مفروضات بررسی کرد. نتیجه کلی تحقیق مذکور آن است که مدل راش برای برآوردهای پارامتر دشواری سؤال‌ها وقفي $\alpha = 0.8$ سؤال‌ها تفاوت دارد، مناسب نیست اما برای برآوردهای توانایی افراد مناسب و خوب است (۱۳).

در مورد مدل دو پارامتری و تفاوت برآوردهای توانایی بر پایه آن و مدل کلاسیک، انصاریان به پژوهش دست زد. او با استفاده از داده‌های حاصل از اجرای آزمون هوش تهران - استنفرد - بینه (TSB) به برآوردهای منحنی ویژه سؤال‌ها، پارامترهای دشواری و قدرت تشخیص سؤال‌ها و توانایی آزمودنی‌ها اقدام کرد. نتیجه آن که نمرات خام یکسان دارای برآوردهای یکسانی از توانایی و موقعیت آزمودنی بر روی پیوستار ممکن نبودند (۱۴) و (۱۵).

دیوجی طی یک بررسی، کاربرد مدل یک پارامتری راش را برای سؤال‌های چند گزینه‌ای مورد بررسی قرار داده است اما به رغم استفاده از مدل راش برای برآوردهای پارامترها در سؤال‌های چند گزینه‌ای، به عقیده دیوجی به علت نبود پارامتر حدس و قدرت تشخیص یکسان در مدل راش، این کاربردها درست نیست (۱۶). البته علاوه بر دیوجی،

محققان دیگری هم به نامناسب بودن استفاده از مدل راش برای سوال‌های چندگزینه‌ای اشاره کرده‌اند؛ از جمله، آندرسن عدم برازش مدل را به نابرابری قدرت تشخیص نسبت داده است. همبلتون و تراب نشان داده‌اند که مدل دو پارامتری، توزیع نمرات را بهتر از مدل راش پیش‌بینی می‌کند (۹).

همبلتون و موری از طریق نمودار باقی‌مانده برای آزمون‌های ریاضی، برازش مدل سه پارامتری و عدم برازش مدل تک پارامتری را برای داده‌ها مطرح کرده‌اند (۱۶).

یکی از موضوع‌ها و نکات مهم در مورد مدل‌های IRT، حجم نمونه آزمودنی و سؤال است. این دو عامل، بهویژه در مدل سه پارامتری، می‌تواند برآورد پارامترهای سؤال و توانایی تأثیرات جدی داشته باشد. همبلتون و کوک در یک مطالعه با انتخاب آزمون‌هایی با سه طول 10_0 و 20_0 و 80_0 سؤالی و نمونه‌هایی با حجم 5_0 و 20_0 و 100_0 آزمودنی به بررسی اثرات حجم نمونه آزمودنی و ویژگی‌های خزانه سؤال و تعداد سؤال بر خطای استاندارد برآورد توانایی اقدام کردند. طول آزمون 10_0 سؤالی حداقل طول ممکن برای یک آزمون و آزمون 80_0 سؤالی نیز از طول‌های متداول است. در مورد حجم نمونه آزمودنی 5_0 و 100_0 نفر نیز به همین‌گونه استدلال کرده‌اند. سؤال‌ها از دو خزانه سؤال استخراج شدند. در عمل، سؤال‌های خزانه 1 دارای دامنه عریض‌تری برای پارامترهای دشواری و قدرت تشخیص سؤال بودند. پارامتر حدس هر دو خزانه سؤال 25_0 در نظر گرفته شد. جمع‌بندی نتایج این مطالعه به صورت زیر است:

۱. حجم نمونه پاسخ‌گویان و طول آزمون، دو عامل سیار مهم در دقت منحنی‌های (θ) است. موارد نقض و استثنای این امر به نوسانات نمونه‌گیری مربوط می‌شود.
۲. در کرانه‌های پیوستار توانایی، دقت منحنی‌های (θ) SE حتی با وجود نمونه‌های بزرگ آزمودنی، بسیار پایین است.
۳. در اکثر موارد با نمونه‌های 20_0 آزمودنی و 20_0 سؤال، دقت برآورد خطای استاندارد توانایی قابل قبول خواهد بود. البته این نکته بیشتر در دامنه وسط توانایی $[1_0, +1_0]$ صادق است.
۴. افزایش طول تست از 10_0 به 20_0 بیش از افزایش آن از 20_0 به 80_0 سؤال، دقت SE را بهبود می‌بخشد.
۵. در مورد حجم نمونه نیز افزایش افراد از 5_0 به 20_0 ، بیش از 20_0 به 100_0 نفر دقت برآورد SE را ارتقا می‌دهد (۱۷).

لرد طی یک مطالعه و ضمن مقایسه مدل‌های یک و دو پارامتری IRT در برآورد نمره حقیقی آزمودنی‌ها، تلاش کرده است تأثیر حجم نمونه را بررسی کند. داده‌های مطالعه

شامل پاسخ ۳۰۰۰ دانش آموز کلاس ششم به آزمون خزانه لغات متropolitn با برنامه LOGIST تجزیه و تحلیل شده است. نتایج مطالعه نشان داد وقتی حجم نمونه کوچک باشد، پارامتر قدرت تشخیص (α_i) سوال‌ها و پارامتر مجانب یا حدس سوال‌ها (c_i) را نمی‌توان به دقت تعیین کرد. از این رو، در بعضی موقعیت‌های معین و محدود و با حجم نمونه کوچک تراز ۱۰۰ یا ۲۰۰ آزمودنی، برآورد کننده نمره حقیقی X آزمودنی در مدل راش (یک پارامتری) می‌تواند اندازی بهتر از برآورد کننده نمره حقیقی بر پایه مدل دو پارامتری باشد (۶).

بیان اهداف و فرضیه‌های پژوهش

هدف اصلی پژوهش حاضر مقایسه مدل‌های اندازه گیری (کلاسیک و سوال - پاسخ) از لحاظ برآوردهای متفاوت یا مشابهی است که برای پارامترهای سوال‌های آزمون و توانایی آزمودنی‌ها به دست می‌دهند.

فرضیه‌های این پژوهش که آزمون آن‌ها مورد توجه است، عبارت اند از:

۱. کاربرد مدل‌های سوال - پاسخ (با تعداد پارامتر مناسب) برای برآورد دقیق مشخصات سوال بر مدل کلاسیک برتری دارد.

۲. برآورد توانایی آزمودنی‌ها با استفاده از مدل‌های IRT (با تعداد پارامتر مناسب) از برآورد توانایی افراد بر پایه مدل کلاسیک دقیق‌تر است.

۳. در صورت وجود عامل حدس در پاسخ دادن به سوال‌ها، افزودن پارامتر حدس (c_i) به مدل IRT، مدل برآزنده‌تری برای داده‌ها ایجاد می‌کند.

روش اجرای پژوهش

الف. آزمودنی‌ها

جامعه این پژوهش را همه داوطلبان آزمون ورودی دوره‌های داخلی وزارت نیرو تشکیل می‌دهد و نمونه تحقیق تعداد ۵۵۳ نفر از داوطلبانی هستند که در آزمون داخلی گریش دانشجو (مورخ ۱۳۷۳/۳/۶) در رشته قدرت (قطع کارданی) شرکت کرده‌اند. برای نمونه‌برداری همه شرکت‌کنندگان انتخاب شدند. در واقع، شرکت‌کنندگان در آزمون مذکور نمونه‌ای از همه داوطلبان فرض شده‌اند. حجم نمونه اولیه ۵۵۳ نفر بود اما تعدادی از پاسخ‌نامه‌ها به علت مخدوش و غیرقابل استفاده بودن از نمونه حذف شد و حجم نمونه نهایی به ۴۳۰ نفر کاهش یافت.

ب. روش‌های آماری

برای تجزیه و تحلیل داده‌ها ابتدا در ایران مشخصه‌های کلاسیک سؤال‌ها و آزمون‌ها محاسبه شد. سپس داده‌ها که شامل پاسخ‌های آزمودنی به سؤال‌های چهارگزینه‌ای سه خرده آزمون ۲۰ سؤالی بود، از طریق نظام شبکه جهانی اطلاعات (Internet) به یکی از دانشگاه‌های آمریکا (دانشگاه UCLA) ارسال گردید. پس از تحلیل داده‌ها با نرم‌افزار بای لوگ، خروجی کامپیوتر شامل برآورد پارامترهای سؤال و توانایی افراد، به ایران فرستاده شد.^{۱۳} خلاصه اطلاعات در مورد خرده آزمون ریاضیات به همراه نمودارهای دشواری و قدرت تشخیص سؤال‌ها در پایان مقاله ارائه شده است (نمودار شماره ۲ و جدول شماره ۴).

برای تعیین برتری مدل‌های سؤال - پاسخ بر مدل کلاسیک در برآورد دقیق مشخصات سؤال (فرضیه ۱ پژوهش) از یک ابزار نیرومند نظریات جدید اندازه‌گیری به نام تابع آگاهی^{۱۴} استفاده شد. تابع آگاهی نظامی است که وروی آن پارامترهای سؤال و خروجی آن میزان آگاهی دهنده‌گی آزمون می‌باشد. متفاوت بودن تابع آگاهی یک آزمون بر حسب مدل‌های اندازه‌گیری، بیانگر تفاوت مدل‌ها از برآوردهایی است که برای پارامترهای سؤال‌های آزمون مذکور محاسبه شده است. برای بررسی معناداری تفاوت تابع آگاهی آزمون‌ها به علت وابسته بودن داده‌ها، از آزمون ابرای داده‌های وابسته استفاده شد و تابع آگاهی هر آزمون که براساس مدل‌های یک و دو پارامتری و کلاسیک برآورد شده بود، با تابع آگاهی همان آزمون در مدل سه پارامتری مقایسه گردید. معناداری تفاوت این توابع آگاهی با ۱ آزمون شد.

به منظور آزمون فرضیه دوم - تفاوت یا عدم تفاوت مدل‌ها در برآورد توانایی و سطح صفت مکنون آزمودنی‌ها - از آزمون مجدور کای از نوع نیکوبی برآش استفاده شد تا مدل‌های یک و دو پارامتری و کلاسیک را در مقایسه با مدل سه پارامتری آزمون کند. برای این منظور، ابتدا نمرات به مقیاس استاندارد یا Z برده شدند و سپس به ۱۲ طبقه از $۵/۵$ - ۳ - ۲ - ۱ تا ۳ - $۲/۵$ تقسیم گردیدند. آنگاه فراوانی طبقات براساس آزمون نیکوبی برآش با درجات آزادی $۱ - k = ۱$ مقایسه و در دو سطح معناداری $۰/۰۵$ و $۰/۰۱$ بررسی شد.

برای بررسی و تعیین برآش یا عدم برآش هر یک از مدل‌های IRT با داده‌ها، یعنی به منظور آزمون فرضیه ۳ پژوهش مبنی بر برآزنده‌گی بیشتر مدل سه پارامتری نسبت به سایر مدل‌های IRT، نرم‌افزار BILOG از نوعی آزمون مجدور کای استفاده می‌کند. فرض صفر آزمون نیکوبی برآش مدل - داده‌ها بر تناسب و برآش مدل با داده‌ها تأکید می‌ورزد و در

واقع، تفاوت مدل با داده‌ها را انکار می‌کند و فرض خلاف عدم برآذش را بیان می‌دارد. در عمل، سطح احتمال مجدور کای محاسبه شده هر سؤال با 0.05 و مقایسه می‌شود. در صورت بزرگتر بودن سطح احتمال هر سؤال از 0.05 یا 0.01 ، نتیجه گرفته می‌شود که سؤال با مدل دارای برآذش نسبی ($\alpha < 0.05$) یا برآذش کامل ($\alpha > 0.05$) است.

ب. ابزار گردآوری داده‌ها

ابزار مورد استفاده برای گردآوری داده‌های پژوهش شامل سه آزمون بیست سؤالی ریاضیات، فیزیک و درس فنی به صورت چهارگزینه‌ای بوده است. درس‌های مذکور جزء مواد امتحانی اصلی و مشترک آزمون‌های گزینش دانشجو در وزارت نیرو به شمار می‌روند. سایر مواد امتحانی تعداد آزمودنی کمی دارد. این آزمون‌ها به وسیله متخصصان حیطه‌های مزبور که معمولاً جزء کارشناسان وزارت نیرو هستند، طراحی و تهیه می‌شود. در مورد نحوه اجرای ابزار تا حد قابل قبولی می‌توان شرایط تقریباً استاندارد و اصولی را برای آن‌ها در نظر گرفت. از جمله در ابتدای دفترچه آزمون درباره شیوه پاسخ‌گویی به سؤال‌ها، مدت زمان اجرا، وجود نمره منفی در آزمون، تعداد سؤال‌های هر خردۀ آزمون و ... توضیحاتی ذکر شده است.

یافته‌های پژوهش

برای آزمون فرضیه ۱، مقایسه مدل سه پارامتری و مدل کلاسیک از نظر برآوردهایی که برای پارامترهای سؤال‌های بابه دست می‌دهند، از تابع آگاهی خردۀ آزمون‌ها بهره گرفته شد. تفاوت توابع آگاهی هر آزمون که حاصل مدل‌های مختلف بود، محاسبه و با آزمون ۱ برای داده‌های وابسته آزمون شد. نتایج نشان داد که نه تنها بین تابع آگاهی هر آزمون براساس مدل کلاسیک تفاوت قابل توجهی دیده می‌شود و این تفاوت حتی در سطح $\alpha < 0.01$ و بایش از ۹۹ درصد اطمینان معنادار است بلکه توابع آگاهی مدل‌های دو پارامتری و یک پارامتری نیز برای آزمون از تابع آگاهی هر خردۀ آزمون براساس مدل کلاسیک در همین سطح تفاوت معناداری دارد. در واقع، با درجه آزادی ۳۲ و مقدار ۱ میان ۴/۲ تابع آگاهی آزمون‌ها بین مدل‌های یک و دو پارامتری معنادار نبود و سایر مقادیر همه تفاوت معناداری داشتند. بنابراین، می‌توان گفت علاوه بر مدل سه پارامتری IRT، حتی مدل‌های دو و یک پارامتری نیز پارامترهای سؤال‌ها را دقیق‌تر و مناسب‌تر از مدل کلاسیک برآورد می‌کنند و فرضیه صفر رد و فرضیه اول پژوهش با بایش از ۹۹ درصد اطمینان تأیید می‌شود (جدول شماره ۱).

جدول شماره ۱ - محاسبه آزمون اگروههای وابسته برای تفاوت بین توابع آگاهی آزمون‌ها
بر حسب مدل‌های مختلف

تابع آگاهی	آزمون ریاضیات			آزمون فیزیک			آزمون درس فنی		
DIF(I-F)	MEAN	STD	T(OH)	MEAN	STD	T(OH)	MEAN	STD	T(OH)
DF (۱، ۳)	۱/۶۶	۳/۶۲	۲/۶۲	۱/۸۱	۳/۶۹	۲/۸۲	۱/۵۵	۲/۹۹	۲/۹۷
DF (۲، ۳)	۱/۶۴	۳/۷۴	۲/۵۲	۱/۵۷	۳/۲۴	۲/۷۹	۱/۱۷	۲/۳۷	۲/۸۳
DF (۱، ۲)	.۰/۰۲	.۰/۵۷	.۰/۱۵	.۰/۲۴	.۰/۹۴	۱/۴۸	.۰/۳۸	۱/۱۹	۱/۸۳
DF (cl. ۳)	۲/۹۲	۴/۷۱	۳/۵۶	۲/۸۱	۴/۵۹	۳/۵۲	۲/۵۸	۳/۷۹	۳/۹۱
DF (cl. ۲)	۱/۲۸	۱/۶۳	۴/۵۰	۱/۲۴	۱/۸۷	۳/۸۲	۱/۴۱	۱/۹۲	۴/۲۳
DF (cl. ۱)	۱/۲۶	۱/۳۳	۵/۴۴	۱/۰۰	۱/۰۵	۵/۴۵	۱/۰۳	۰/۹۷	۶/۱۴

$$n = ۳۳$$

$$df = ۳۲$$

$$t(er) .۰/۰۵ = ۱/۶۹$$

$$t(er) .۰/۰۱ = ۲/۴۵$$

فرضیه ۲ مدعی است که مدل سه پارامتری نظریه سؤال - پاسخ توانایی افراد را نسبت به مدل کلاسیک اندازه‌گیری به گونه‌ای متفاوت و دقیق‌تر برآورد می‌کند. به این ترتیب، باید برای آزمون این فرضیه، تفاوت مدل سه پارامتری از مدل کلاسیک در برآورد توانایی بررسی شود. به این منظور، آزمون مجذور کای بین مدل سه پارامتری و مدل کلاسیک (البته مدل‌های دو و یک پارامتری نیز) اجرا شد تا تفاوت فراوانی‌های افراد در طبقات مختلف آزمون شود. نتایج نشان داد که نه تنها توانایی برآورد شده برای افراد براساس مدل سه پارامتری از مدل کلاسیک متفاوت است بلکه حتی مدل‌های دو و یک پارامتری نیز در برآورد پارامتر توانایی آزمودنی‌ها با مدل سه پارامتری تفاوت و تمایز دارد. این امر در سطح $۰/۰ < ۰/۰۲$ هم معنی‌دار بود. از سوی دیگر، از آنجاکه مدل سه پارامتری از لحظه تعداد پارامتر مناسب‌ترین مدل برای داده‌های حاضر محسوب می‌شود و طبق نتایج آزمون خوبی برآزنده‌گی، برازش و مناسبت کاملاً آشکاری با داده‌های پژوهش دارد، توانایی برآورد شده برای افراد را که از مدل سه پارامتری به دست آمده است، می‌توان دقیق‌تر و مناسب‌تر از توانایی حاصل از سایر مدل‌های اندازه‌گیری تلقی کرد. بنابراین، فرضیه صفر رد و فرضیه دوم پژوهش حاضر نیز با بیش از ۹۹ درصد اطمینان تأیید می‌شود (جدول شماره ۲).

جدول شماره ۲- برآزندگی مدل - داده‌ها بر حسب مدل‌های IRT (تعداد سوال‌ها)

۳-PAR				۲-PAR				۱-PAR				آزمون‌ها
برآزش کامل $\alpha > .05$	برآزش نسی $.01 < \alpha < .05$	بدون برآزش $\alpha < .01$	برآزش کامل $\alpha > .05$	برآزش نسی $.01 < \alpha < .05$	بدون برآزش $\alpha < .01$	برآزش کامل $\alpha > .05$	برآزش نسی $.01 < \alpha < .05$	بدون برآزش $\alpha < .01$	برآزش کامل $\alpha > .05$	برآزش نسی $.01 < \alpha < .05$	بدون برآزش $\alpha < .01$	
۱۷	۲	۱	۱	۱	۱۸	۱	۳	۱۶				آزمون ریاضیات
۱۶	۲	۲	۲	۱	۱۷	۰	۱	۱۹				آزمون بیرهند
۱۷	۲	۱	۳	۱	۱۶	۰	۲	۱۸				آزمون درس می

$r \leq df \geq 4$

$1 \leq df \geq 9$

$1 \leq df \geq 8$

جدول شماره ۳- مجذور کای محسوبه شده بین پارامتر توانایی مدل سه پارامتری
و مدل‌های دو و یک پارامتری و کلاسیک

درس فنی		فیزیک				ریاضی				آزمون‌ها	
مدل‌ها	دو پارامتری	یک پارامتری	دو پارامتری	یک پارامتری	کلاسیک	دو پارامتری	یک پارامتری	کلاسیک	دو پارامتری	یک پارامتری	کلاسیک
۸۶/۱	۱۲/۲	۴۹/۵	۸۲	۲۱/۸	۲۲/۹	۲۱۹/۶	۵۰/۶	۲۰/۹			

$df = 11 \quad X^2_{(cr)} + .05 = 19/675 \quad X^2_{(cr)} + .01 = 24/725$

برای آزمون فرضیه ۳ پژوهش از نوعی آزمون خوبی برآزندگی استفاده شد و برآزش سوال‌های آزمون با مدل‌های یک، دو و سه پارامتری بررسی گردید. براساس نتایج به دست آمده، مدل سه پارامتری برآزش چشمگیری با داده‌ها داشت؛ در حالی که نه تنها مدل دو پارامتری بلکه مدل یک پارامتری نیز بدون برآزش شناخته شد. بنابراین، فرضیه سوم پژوهش نیز با بیش از ۹۹ معنادار شناخته شد و فرض صفر رد و فرض پژوهش (خلاف) تأیید گردید. بدین ترتیب مدل سه پارامتری، برای داده‌های آزمون‌های مورد استفاده در این پژوهش نسبت به سایر مدل‌های IRT برآزندگی و مناسب‌تر شناخته شد (جدول شماره ۳).

نتیجه‌گیری

مطابق نتایج تحقیقات و مطالعات قبلی در زمینه نظریه‌های جدید اندازه‌گیری، IRT و مقایسه آن با نظریه کلاسیک آزمون، این مطالعه نیز نشان داد که در سطح بالایی از اطمینان می‌توان گفت:

۱. مدل‌های IRT نسبت به مدل کلاسیک اندازه‌گیری در برآورد پارامترهای سؤال‌ها و توانایی آزمودنی‌ها دارای مناسبت، دقت و برازنده‌گی بیشتری است. این نتیجه در مورد آزمون‌های پیشرفت تحصیلی چهارگزینه‌ای که مبنای مطالعه حاضر بوده است، با بیش از ۹۹ درصد اطمینان صدق می‌کند.
۲. در بین مدل‌های نظریه سؤال - پاسخ (IRT) برای برآورد پارامترهای سؤال و توانایی افراد، مدل سه پارامتری در مورد آزمون‌های پیشرفت تحصیلی چندگزینه‌ای این پژوهش، نسبت به مدل‌های یک و دو پارامتری برتری خاصی نشان داد.
۳. در بین مدل‌های یک و دو پارامتری IRT از لحاظ برآورد پارامترهای سؤال براساس داده‌های خرد آزمون‌های حاضر، تفاوت چشم‌گیری ملاحظه نمی‌شود. از این رو می‌توان تأثیرگذاری پارامتر قدرت تشخیص سؤال‌ها را برآورد پارامتر دشواری چندان شدید و جدی ندانست. به زبان دیگر، سؤال‌های مورد استفاده در خرد آزمون‌های این مطالعه دارای قدرت تشخیص خیلی متفاوت و مؤثری نیستند اما در مورد برآورد پارامتر توانایی آزمودنی‌ها، می‌توان نتیجه گرفت که براساس داده‌های حاضر، بین مدل‌های یک و دو پارامتری در مقام مقایسه با مدل سه پارامتری، برآورد پارامتر توانایی تا حدی متفاوت است و در مورد آزمون‌های چندگزینه‌ای پارامتر شیب بر روی برآورد پارامتر توانایی تأثیر داشته است.

پژوهشگاه علوم انسانی و مطالعات فرهنگی

پرتابل جامع علوم انسانی



پی‌نوشت‌ها

۱. نظریات جدید اندازه‌گیری و روان‌سنجی نخست با اصطلاح صفت مکون یا خصیصه مکون بهشدت پیوند خورد اما به تدریج با عنوان نظریه سؤال - پاسخ یا Item Response Theory (با علامت اختصاری IRT) یا نظریه منحنی ویژه سؤال رواج یافت که برای مقاصد آزمون‌سازی و تحلیل آماری داده‌ها مناسب‌تر به نظر می‌رسد (همبلتون، ۱۹۹۳).

2. Information Function

۳. برای تحلیل داده‌ها در آمریکا به وسیله نرم‌افزار BILOG، علاوه بر مساعی فراوان استاد محترم راهنمای دکتر سلیمانی زاده، نگارنده بر خود لازم می‌داند از عنایت استاد ارجمند دکتر جمال عابدی، عضو هیأت علمی دانشگاه مذکور که تحلیل داده‌ها را مسیر کردن، تشکر و سپس گزاری نماید.



منابع

- Allen, J.M., & Yen, M.W. (1979). **Introduction to measurement theory**. California: wadsworth.
- ثرندایک، رابرт؛ روان‌سنجی کاربردی، مترجم: حیدرعلی هونم، تهران، دانشگاه تهران، ۱۳۶۹.
- Gulliksen, H. (1950). **Theory of mental tests**. New York: John Wiley & Sons.
- Lord, F.M., & Novick, M.R. (1968). **Statistical Theories of mental test scores**. Reading, MA: Addison-wesley.
- Hambleton, R.K., & van der Linden, W.J. (1982). Advances in item response theory and applications: An introduction. **Applied Psychological Measurement**, 6, 373-378.
- Lord, F.M. (1983). Small N justifies Rasch model. In D.J. Weiss (ed.). **New Horizons in testing**. New York: Academic press Inc.
- Wright, B.D. (1977a). Misunderstanding of the Rasch model. **Journal of Educational Measurement**, 14, 219-226.
- Birnbaum, A. (1968). Some Latent trait models and their use in inferring an examinee's

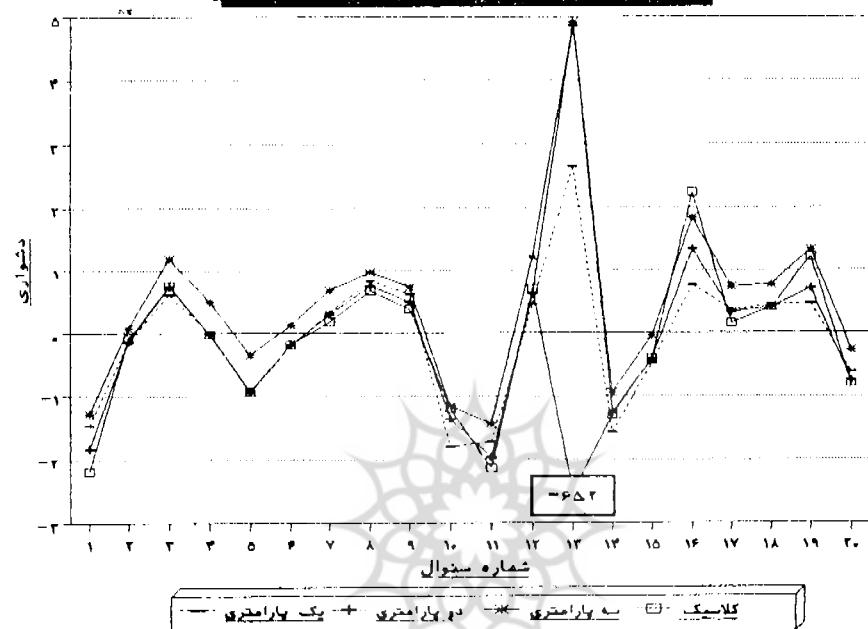
- ability. In F.M. Lord & M.R. Novick. **Statistical theories of mental test scores**, MA: Addison - wesley.
9. Hambleton, R.K. (1993). Principles and selected applications of item response theory. In R.L. Linn (Ed.), **Educational Measurement**. U.S.A.: oryx press.
10. Hambleton, R.K., & Cook, L.L. (1977). Latent trait models and their use in the analysis of educational test data. **Journal of Educational Measurement**, 14, 75-96.
11. Reid, C.A. (1993). **Latent trait modeling of the general test battery used with a rehabilitation client population: An investigation of Model - Data Fit**. Source: DAI-B 54/12. p. 6497. Jun 1994.
۱۲. هونن، حیدرعلی؛ مقایسه مدل تک‌پارامتری راش و مدل دوپارامتری، پایان‌نامه منتشر نشده دانشگاه آزاد اسلامی، ۱۳۷۳.
۱۳. هونن، حیدرعلی؛ هوش آزمای انفرادی تهران - استنفرد - بینه. فصلنامه علوم تربیتی دانشگاه تهران، پژوهشنامه روان‌سنجی، دوره جدید، سال یکم، شماره ۴-۱.
۱۴. انصاریان، علیرضا؛ برآورد خم ویژه سوال و توانایی آزمودنی‌ها در مقیاس تهران - استنفرد - بینه بر پایه مدل دوپارامتری صفت مکنون. پایان‌نامه منتشر نشده دانشگاه آزاد اسلامی، ۱۳۷۱.
۱۵. هونن، حیدرعلی؛ روش تهیه آزمون هوش، تهران، دانشگاه تهران، ۱۳۷۵.
16. Divgi, D.R. (1986). Does the Rasch model really work for multiple choice items? Not if you look closely. **Journal of Educational Measurement**, 23, 283-298.
17. Hambleton, R.K., & Cook, L.L. (1983). The robustness of item response models and effects of test length and sample size on the precision of ability estimates. In D.J. Weiss (Ed.), **New horizons in testing** (pp. 31-49). New York: Academic Press.



پیوست‌ها

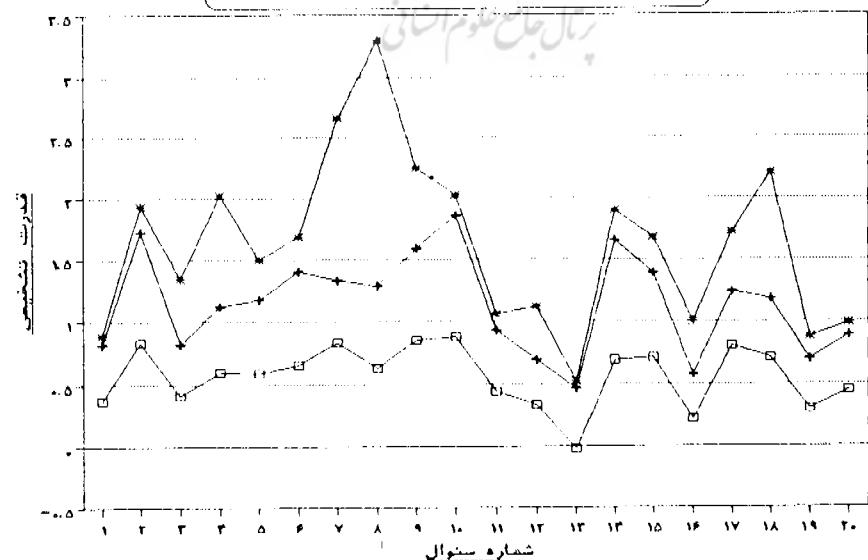
شودار ۱

مقایسه پارامتر دشواری سوالات آزمون ریاضی
برحسب مدل‌های کلاسیک و ستوال - پاسخ



شودار ۲

مقایسه پارامتر شیب سوالات آزمون ریاضی
برحسب مدل‌های کلاسیک و ستوال - پاسخ



جدول شماره ۴ - آمارهای پارامتری سوالات خود آزمون ریاضی بر حسب مدل های کلاسیک و سوال - پاسخ (IRT)



پژوهشگاه علوم انسانی و مطالعات فرهنگی
پرتمال جامع علوم انسانی