

نظریه کلاسیک آزمون و محدودیتهای آن

دکتر حسین سپاسی*

چکیده

نظریه کلاسیک آزمون سالها است به عنوان یک نظریه منجم مورد استفاده متخصصان آزمون‌سازی فرار گرفته است. اگرچه هنوز بسیاری از آزمونهای تربیتی و روانی برآسان مفروضه‌های این نظریه ساخته می‌شوند، ولی در سالهای اخیر روان‌سنجان به این نتیجه رسیده‌اند که نظریه کلاسیک آزمون دیگر قادر به حل مسائل و مشکلاتی که بر سر راه ساختن این آزمونها و مقابله با وجود دارد نیست. مثلاً، این نظریه تصویر روشنی درباره ارتباط بین مسئوالات آزمون و خصیصه‌ها توانایی آور نداشت که به وسیله این مسئوالات اندازه‌گیری می‌شود فراهم نمی‌آورد. متخصصان آزمون‌سازی نلاش کرده‌اند محدودیتهای این نظریه را روشن می‌سازند و پایه‌های نظریه‌های جدیدی را در ساختن آزمون‌های روانی و تربیتی بنا نهند. در این مقاله، ابتدا سعی شده است مختصرآمیز مقایمه اساسی نظریه کلاسیک آزمون در ساختن آزمونها و مقابله‌اشاره گردد. آنگاه، می‌رور مختصری بر پایه‌ی (Reliability) آزمون به عنوان یکی از مقایمه‌های زیربنایی نظریه کلاسیک خواهیم داشت، که ابتدا نوسط اسپیرمن (Spearman) طی در دهه اول قرن حاضر ارائه گردید. در پایان، مقاله به محدودیتهای این نظریه خواهد پرداخت و آنها را از دیدگاه متخصصان روان‌سنجی بوردنقد و بورسی کامل اقرار می‌دهد. روان‌سنجان جدید جمله بر این باورند که چون آزمونها و مقابله‌های اندازه‌گیری باید برآوردهای واقعی از خصیصه‌های مورد اندازه‌گیری فراهم آورند، به نظریه‌های جدیدتری برای ساختن آزمونهای روانی و تربیتی نیاز داریم.

مقدمه

نژدیک به یک قرن است که نظریه کلاسیک آزمون متشاء و مقصد بیشتر تضمین گیریها در

زمینه اندازه‌گیری تواناییهای روانی و تربیتی توسط محققان و پژوهشگران بوده است. روانشناسان، معلمان، مشاوران، مدیران، و دانشجویان علوم رفتاری علاقه‌مندند اطلاعاتی درباره این نظریه و سایر نظریه‌های آزمون کسب نمایند. آنان می‌خواهند بدانند نظریه‌های آزمون برچه اصولی استوارند، برای رسیدن به این هدف از چه قواعد و شرایطی استفاده کنند، و نکات مهم در خصیصه مورد اندازه‌گیری را جگونه تعبیر و تفسیر نمایند. به بیان دیگر، نظریه‌های آزمون چه هستند و در چه مواردی بحث می‌کنند. آیا روانشناسان در زمینه تحقیق، معلمان در زمینه تدریس و با دانشجویان علوم رفتاری در تحصیل روزانه خود به نظریه‌های آزمون نیاز دارند؟ آیا معنمان نمی‌توانند پیشرفت دانش‌آموزان را با آزمونهایی که خود می‌سازند اندازه‌بگیرند؟ آیا این نظریه‌ها (نظریه‌های آزمون) ریشه در روانشناسی دارند یا این که خود رشتہ مستقلی را تشکیل می‌دهند؟

تا اوآخر قرن حاضر به علت افزایش تقاضا شاعد انبوی از آزمونها خواهیم بود که امکان دارد هر کدام به نحوی در اندازه‌گیری تواناییهای روانی و تربیتی مورد استفاده تردیگیرند و مثاء تصمیم‌گیریهای مهمی واقع شوند. مهربن و لهمان (Mehrens & Lehman ۱۹۸۴) می‌گویند بسیاری از آزمونهای موجود از عوی نظریه‌های آزمون پیروی نمی‌کنند و آزمونهای پیشرفت تحصیلی معمولاً ضعیف تهیه می‌شوند. آنها اعتقاد دارند که این قبیل آزمونها بندرت می‌توانند تواناییهای آزمودنیهارا اندازه‌گیری کنند. با وجودی که آزمونها تنها وسیله اندازه‌گیری خصوصیات روانی و تربیتی به شمار نمی‌زنند، ولی به گفته ابل (Abl ۱۹۹۱) تا آن زمان که جایگزین بهتری برای آزمونها پیدا نشود است باید به استفاده از آنها ادامه داد.

در این مقاله ابتدا، سعی خواهد شد تفاہیم نظریه کلاسیک آزمون، اولین نظریه منسجم در آزمون‌سازی، به طور مختصر بیان گردد و آنچه را که لازم است خواننده در این باره بداند توضیح داده شود. دیر زمانی طولانی است که اصول اندازه‌گیری آزمونهای روانی و تربیتی بر اساس نظریه کلاسیک آزمون استوار است، ولی با گذشت زمان و پیشرفت مبانی علمی نظریه‌ها و توسعه تکنولوژی، اکنون اصول این نظریه آزمون مورد انتقاد روان‌سنجان جدید قرار گرفته است. در پایان مقاله سعی خواهد شد به محدودیتهای این نظریه که چشم‌انداز روشی برای

ایجاد نظریه‌های دیگر در آزمون‌سازی فراهم اورده‌اند پرداخته شود.

نظریه کلاسیک آزمون

به واسطه پیشرفت چشمگیری که در زمینه مطالعه رفتار توسط دانشمندان علوم رفتاری به عمل آمد، نظریه‌های متفاوتی در زمینه آزمون و آزمون‌سازی ایجاد شده است که دانستن آنها برای معلمان و دانشجویان علوم تربیتی و روانشناسی از اهمیت فراوانی برخوردار است. معمولاً، متخصصان روانسنجی در بیان نظریه‌های خود از مدل ریاضی برای ساختن شکل آزمون و تفسیر نمره‌های آن استفاده می‌کنند. یک مدل ریاضی شامل مجموعه فرضهای درباره داده‌هاست که به وسیله آن روابط ویژه بین سازه‌های قابل مشاهده و سازه‌های غیرقابل مشاهده مدل را توصیف می‌کند (Feldt, ۱۹۷۵). شایان ذکر است که همه مدل‌های ریاضی نمی‌توانند اساسی علمی برای اندازه‌گیری تم جنبه‌های مختلف توانایی فراهم آورند. ولی، در عین حال وجود چنین مدل‌هایی ما را قادر می‌سازد که رابطه بین نمره‌های مشاهده شده و رفتار مورد نظر را به شیوه علمی مورد بررسی قرار دهیم و از آن برای پیش‌بینی و تخمین بعضی ویژگیهای آزمودنیها استفاده کنیم. این نظریه‌ها معمولاً چهارچوبی کلی برای بررسی فرایند نهیه آزمونها فراهم می‌آورند. نظریه کلاسیک آزمون نیز در همین راستا به وجود آمده است.

سابقه نظریه کلاسیک آزمون به کار اسپیرمن، (Spearman) روانشناس انگلیسی در اوائل سالهای ۱۹۰۰ میلادی بر می‌گردد. وی در خلال سالهای ۱۹۰۴ و ۱۹۱۳ با استفاده از مفهوم همبستگی مطالعاتی انجام داد و از لحاظ ریاضی نشان داد که نمره‌های آزمون اندازه‌های گمراه کننده‌ای از خصوصیات آزمودنیها فراهم می‌کنند. کوشتهای اسپیرمن (۱۹۱۳) برای توصیف نمره‌های خطای مقادیر نمره‌های وقوعی موجب گردید تا وی اساس مدل نظریه کلاسیک آزمون را به وجود آورد. بعداً پژوهشگران دیگری چون گیلفورد (Guilford, ۱۹۳۰)، گولیکسن (Guliksen, ۱۹۴۵)، مگنوسون (Magnuson, ۱۹۶۷) و لرد و نویک، (Lord & Novick, ۱۹۶۸)، به تجدید نظر در مدل اسپیرمن پرداختند و آن را به صورتی که امروز مورد استفاده قرار می‌گیرد دور آورند.

مدل اسپرمن بر این اساس است که هر نمره مشاهده شده آزمون را می‌توان ترکیبی از دو عامل یکی نمره واقعی و دیگری نمره خطأ دانست که به نحاظ ریاضی به صورت فرمول زیر بیان می‌گردد:

$$X = T + E$$

در این فرمول، X نمره مشاهده شده آزمون، T نمره واقعی، و E نمره خطای تصادفی نام دارند. با استفاده از این مدل ریاضی، می‌توان نتایج معین دیگری درباره نمره واقعی (T) و نمره مشاهده شده (X) به دست آورد. به عنوان مثال، چنانچه در فرمول فوق نمره مشاهده شده و نمره خطای درست باشند می‌توانیم نمره واقعی مربوط به خصیصه مورد نظر را محاسبه کنیم. به بیان دیگر، چنانچه نمره واقعی و نمره مشاهده شده را داشته باشیم، مقدار E خطای اندازه‌گیری را می‌توان از فرمول زیر به دست آورد.

$$E = X - T$$

براساس مدلی که نظریه کلاسیک برای توصیف روابط بین نمره‌ها و خصوصیات مورد اندازه‌گیری بیان می‌کند فرضهای دیگری نیز به شرح زیر بیان شده‌اند:

۱- نمره‌های خطای تصادفی هستند و میانگینی برابر صفر دارند، ۲- همبستگی بین نمره‌های واقعی و نمره‌های خطای برای جامعه‌ای از آزمودنیها برابر صفر است، ۳- موقعی که آزمودنیها به دو آزمون متفاوت پاسخ می‌دهند و چنانچه دو نمره هر آزمودنی بطور تصادفی از و توزیع مستقل نمره‌های مشاهده شده ممکن به دست آمده باشند، همبستگی بین نمره‌های خطای دو آزمون صفر است، و ۴- بین نمره‌های واقعی و نمره‌های مشاهده شده و نمره‌های خطای رابطه خطی وجود دارد (آناستازی Anastasi ۱۹۸۸).

پس از این که نمره‌های مشاهده شده آزمودنیها محاسبه شد و خطای معیار اندازه‌گیری معلوم گردید، چنانچه بخواهیم نمره واقعی آزمودنیها را برآورد کنیم، و یا به بیان دیگر بخواهیم رابطه بین شوالات آزمون و خصیصه مورد بررسی را اندازه بگیریم، نظریه کلاسیک آزمون از فرمول آماری برای بسط و توصیف این مفاهیم استفاده می‌کند. مفهوم پایایی (Reliability) در نظریه کلاسیک آزمون مفهوم بسیار مهمی به شمار می‌رود، به همین جهت در زیر سعی خواهد شد تا

به اختصار به شرح آن پرداخته شود.

پایایی

طرح کردن نمره واقعی و نمره مشاهده شده گویای آن است که عی رغم میل باطنی معلم که به نمره واقعی داشت آموزن علاقه دارد، در عمل آنچه از میزان آموخته‌های آنان در اختیار دارد صرفاً نمره‌های مشاهده شده است. ولی مستولی که می‌توان طرح کرد این است که آیا نمره‌های مشاهده شده ترجیح نمایند به نمره‌های واقعی نزدیک‌ترند؟ شاخصی که می‌تواند این ارتباط را برمی‌کند ضریب همبستگی نام دارد. آن شاخص همبستگی که ترجیح ارتباط بین نمره‌های واقعی و نمره‌های مشاهده شده را تعیین می‌کند به شاخص پایایی (Reliability Index) مشهور است.

فرمولی که برای محاسبه شاخص پایایی ساخته شده است، براساس مدل ریاضی رابطه بین نمره‌های واقعی، نمره‌ی مشاهده شده و نمره‌های خطای در بالا به آنها اشاره شد استوار است. براساس این مدل ریاضی، شاخص پایایی را می‌توان به عنوان نسبت انحراف معیار نمره‌های واقعی به انحراف معیار نمره‌های مشاهده شده به شرح زیر بین کرد.

$$\rho_{XT} = \frac{\sigma_T}{\sigma_X}$$

در فرمول فوق ρ_{XT} بـ عنوان شاخص پایایی یا رابطه بین نمره‌های واقعی و نمره‌های مشاهده شده، σ_T انحراف معیار نمره‌های واقعی، و σ_X انحراف معیار نمره‌های مشاهده شده تعریف شده‌اند. ترجمه کنید که فرمول فوق یک مفهوم نظری است و تنها همبستگی بین تمام نمره‌های واقعی و نمره‌های مشاهده شده ممکن را که از آزمون کردن همه اعفای جامعه بزرگی از آزمودنیهای دست می‌آید توصیف می‌کند.

اما، در عمل این مفهوم ارزش چندانی ندارد، چه نمره‌های واقعی مستقیماً قابل مشاهده نیستند و امکن این که تمام نمره‌های مشاهده شده جامعه بزرگی ز آزمودنیهای را به دست آوریم نیز وجود ندارد.

بنابر این، به جای آن می‌توان گروهی از آزمودتیها را در دو مرغوبیت متفاوت و با آزمونی یکسان یا با دو فرم همتا از یک آزمون مورد آزمایش قرار می‌داد. چنانچه دو آزمون شرایط لازم آزمونهای همتا را دارا باشند، این امکان وجود دارد که رابطه‌ای ریاضی بین α^P (ضریب همبستگی بین نمره‌های واقعی و مشاهده شده) و α_X (ضریب همبستگی بین نمره‌های مشاهده شده دو آزمون همتا)، پیدا کنیم. بر حسب نظریه کلاسیک آزمون زمانی می‌توانیم دو آزمون را همبا بنامیم که ۱- هر آزمودنی در هر دو فرم آزمون نمره یکسانی بیاورد، و ۲- واریانس خطاهای دو فرم آزمون مساوی باشند. به بیان دیگر، دو آزمون دارای میانگین و واریانس‌های یکسانی هستند. علاوه بر این هاپکیتز (Hopkins ۱۹۹۰) می‌گوید می‌توان چنین فرض کرد که محتوای دو آزمون همبا با همدیگر جور باشند.

به نظر می‌رسد خوانندگان این مقاله در حال حاضر اطلاعاتی درباره جزئیات نظریه کلاسیک آزمون داشته باشند و از اصول نظری آن در تدریس، تحقیق، و نوشته‌های خود به طور گسترده استفاده می‌کنند. افراد دیگری هم که علاقمند اطلاعات دقیتری درباره این نظریه کلاسیک کسب کنند می‌توانند به اکثر کتابهای سنجش و اندازه‌گیری و روانسنجی مراجعه نمایند. بنابر این به همین مرور مختص درباره این نظریه اکتفا می‌شود. آنچه در این مقاله بیشتر مورد توجه قرار خواهد گرفت پرداختن به محدودیتهای این نظریه منسجم است که در حال حاضر اساس ساخت و اعتباریابی بسیاری از آزمونهای روانی و تربیتی را در کشورمان تشکیل می‌دهد. در باقی مانده این مقاله به بررسی محدودیتهای نظریه کلاسیک آزمون می‌پردازیم.

محدودیت‌های نظریه کلاسیک آزمون

امروزه تعداد آزمونهای پیشرفته، استعداد، و شخصیت که بر اساس مفروضه‌های نظریه کلاسیک ساخته شده‌اند بسیارند. ولی، با وجود سابقه طولانی شهرت نظریه کلاسیک، در سالهای اخیر این نظریه مورد انتقاد متخصصان روانسنجی قرار گرفته است. از بررسی مقالات پژوهشگران می‌توان مدارک زیادی گردآوری کرد که به محدودیتهای آزمونها و مقیاسهایی که بر اساس نظریه کلاسیک آزمون ساخته شده‌اند اشاره می‌کنند. برای مثال، برخی از روان‌سنجان

چون لرد (۱۹۸۰) و رامبرگ (Ramberg ۱۹۹۲) از نظریه کلاسیک به عنوان یک نظریه قدیمی باد می‌کنند و معتقدند که مفروضه‌های نت قادر به حل مسائل و مشکلات آزمون‌سازی نیستند. بنابراین، نظریه‌های دیگری برای توصیف نمره‌های آزمون یا مقیاس اندازه‌گیری (به عنوان مثال، نمره واقعی و نمره خط) بر اساس مفروضه‌های جدیدتری ارائه داده‌اند. برای این که خرانده از این محدودیتها آگاهی پیدا کند و دریابدکه چرا نظریه کلاسیک آزمون، که زمانی از آن به عنوان نظریه منسجم باد می‌شد، دیگر قادر به حل مسائل و مشکلات در آزمون‌سازی نیست، در زیر به تشریح این محدودیتها می‌پردازیم.

۱. اولین محدودیت به یکی از مفایم زیربنایی نظریه کلاسیک آزمون یعنی برآورد پایایی که بر اساس فرمهای همتای آزمون استور اشاره می‌کند. در عمل، اندازه‌های همتایی که به وسیله آنها برتران به اندازه‌گیری پیشرفت پرداخت مشکل یافته می‌شوند چراکه افراد در اجرای نوبت دوم بهمیج وجه عیناً همان افراد در اجرای نوبت اول آزمون نیستند. آنان مسائلی را فراموش می‌کنند، مهارت‌های جدیدی را نداشته باشند، و یا ممکن است سطح انگیزش و هیجان آنها تغییر کند و جزو اینها (هیولین و درسکو Huline & Drasgow ۱۹۸۰). به عقیده این پژوهشگران چون نظریه کلاسیک قویاً بر مفهوم فرمهای همتای آزمون استوار است، تعجبی ندارد که کاربرد آن امروزه با مشکل‌اندی همراه‌گردد.

۲. به نظر وايس (Weiss ۱۹۸۱) محدودیت دیگر نظریه کلاسیک این است که فقط از نمونه‌ای از آزمودنیهای تخدین پایایی آزمون استفاده می‌کند. وی اشاره می‌کند که تخمین پایایی در چنین حالتی تابعی از مجموعه سوالات آزمون و نمونه افرادی خواهد بود که آزمون را در مورد آنها اجرا کرده‌ایم. به گمان وی استنباط منطقی غلط این است چنانچه یک آزمودنی دردو نمونه متفاوت از آزمودنیها مورد اندازه‌گیری قرار گیرد امکان دارد دو خطای اندازه‌گیری متفاوت به دست آید و تخمین نمره و نوعی او بر اساس این که در کدام نمونه مورد اندازه‌گیری قرار گیرد متفاوت خواهد بود. همبتون (Hamberton ۱۹۸۴) هم نظر مشابهی ابراز می‌دارد. وی می‌گوید این یک محدودیت نظریه کلاسیک آزمون یعنی تعداد و ترازمانی که تخمین پایایی بر اساس نمونه‌ای از آزمودنیها استوار باشد به طور مقتضی نمی‌توان آن را در

- تفیر نمره‌ها یا در تخمین دقت اندازه‌گیریها مورد استفاده قرار داد.
۳. گاهی امکان دارد بخواهیم خصوصیات اندازه‌گیری آزمون یا یک مقیاس را در مورد گروههای دیگری که ممکن است از اعضاء گروه اصلی بزرگتر یا ناهمانگر باشند به کار ببریم. تفاوتی که ممکن است معانی سوالات برای گروههای مختلف داشته باشد و هم چنین فقدان ربط داشتن تک‌تک سوالات برای ارزیابی خصوصیات و سازه‌ها در برخی از جامعه‌های فرعی، این امکان را به وجود می‌آورد که به اندازه‌گیریها غیرهم‌ارز در مورد گروههای مختلف متوجه گردد. این‌کار، تفاوت‌گذاری آزمون یا منیاس را در مورد این گروههای فرعی بیشتر ساختگی ناواقعی نشان می‌دهد. هبولین و دراسکو (1993) معتقدند که نظریه کلاسیک آزمون راه‌حل مناسبی برای این مسأله ارائه نمی‌دهد. آنها اظهار می‌دارند مواقعي که خصوصیات یک ابزر اندازه‌گیری باید در مورد گروههای دیگر غیر از گروه مورد نظر مورد مقایسه قرار گردد، سازنده آزمون باید تعیین کند که آزمون، مثلایک آزمون روانی یا هوشی، اندازه‌گیری سوداری از تواناییهای گروههای دیگر، مثلاً گروههای اقلیت، فراهم نمی‌آورد. در نظریه کلاسیک آزمون تفاوت در شاخصهای استاندارد مثلًا، دشواری سوال (Item difficulty)، نسبت پاسخهای درست (Item Discrimination Index) نمی‌تواند برای ارزیابی این سوگیریها به کار برد. گاهی اوقات شاخص تمیز سوال سوالات آزمون یا مقیاس (Nizir قادر به از میان برداشتن این سوگیری نمی‌باشد. به عنوان مثال، گاهی مشاهده می‌شود که شاخص تمیز نسبت پاسخهای درست گروههای ملاک (بالا و پایین) به هر سوال آزمون را معکوس ارزیابی می‌کند. همبلتون، ۱۹۸۴ می‌گوید این شاخصها از پیدا کردن سوگیری تفاوت درون-گروهی در خصوصیتی که به وسیله آزمون اندازه‌گیری می‌شود عاجزند.
۴. بیکر (Baker, 1985) محدودیت دیگر این نظریه را عدم مشخص بودن چگونگی روپرورش آزمونی با سوالات آزمون ذکر می‌کند. در توضیح این محدودیت لازم به یادآوری است که باید رابطه‌ای بین پاسخهای سوال و خصوصیتی که به وسیله آزمون یا مقیاس اندازه‌گیری می‌شود وجود داشته باشد. به بین دیگر، می‌توان احتمال پاسخ مثبت به سوال را

تابعی از خصوصیت یا توانایی مورد ارزیابی به وسیله آزمون یا مقابس فرض کرد. اساس فرض نویق این است که افرادی که از خصوصیت مورد اندازه‌گیری به وسیله آزمون یا مقابس از مقادیر بیشتری برخوردارند، به عنوان مثال، افرادی که رضایت شغلی بالانری دارند یا دانش‌آموختانی که پیشرفت ریاضیات عالیتری نشان می‌دهند، قاعده‌تاً باید احتمال پاسخ مثبت آنان در مقایسه با افرادی که مقادیر کمتری از این خصوصیات را دارند بیشتر باشد. موقعی که سعی می‌کنیم سوالات آزمون یا مقابس را با سطح توانایی آزمودنیها جو رکنیم دانستن احتمال پاسخ مثبت آزمودنی به هر سؤال یا مقابس بسیار باهمیت است. مثلاً، چنانچه سازنده آزمون بخواهد از نمره‌های آزمودن یا مقابس، خصوصیات پاسخ آزمودنیها را در یک جامعه یا جامعه‌های بزرگتر برآورد کند و یا این که بخواهد آزمونی را با خصوصیات ویژه‌ای برای جامعه خاصی از آزمودنیها طرح‌ریزی کند، آن‌گاه داشتن اطلاعات درباره احتمال پاسخ دادن مثبت به هر یک از سوالات آزمون یا مقابس برای وی بسیار با اهمیت به شمار می‌رود.

هیولین و دراسکو (۱۹۸۲) می‌گویند نمره‌های واقعی و خطای و یا سایر مفروضه‌هایی که اساس نظریه کلاسیک آزمون را تشکیل می‌دهند معمولاً به صورت نمره کل آزمون تعریف می‌شوند. بنابر این، واحد تحلیل در نظریه کلاسیک کل آزمون محسوب می‌گردد. آنان می‌افزایند چنانچه بین احتمال پاسخ به سوالات خصوصیه‌ای که توسط آزمون یا مقابس اندازه‌گیری می‌شود ارتباط باشد، نمره‌های واقعی و خطای آزمودنیها را بهتر می‌توان برآورد کرد و این کاری است که نظریه کلاسیک آزمون قادر به انجام آن نیست.

۵. یکی دیگر از محدودیتهای نظریه کلاسیک آزمون به شیوه و تکنیک طرح و ساختن آزمون یا مقابس برمی‌گردد، یعنی این که مقایسه توانایی آزمودنیها معمولاً به وسیله یک آزمون یا فرمهای همتای آن محدود می‌گردد. یک اشکال این شیوه این است چون بسیاری از آزمونهای پیشرفت و استعداد نوعاً برای دانش‌آموزان با توانایی در حد متوسط ساخته می‌شوند، تخمینهای بسیار دقیقی از توانایی دانش‌آموزان قوی یا ضعیف فرام نمی‌أورند. به عفیده لرد، (۱۹۸۰) موقعی که دشواری آزمون با سطح توانایی نظری بیش از آزمودنی جو ر نباشد، شاهد تغییر در پایایی آزمون خواهیم بود. وی اشاره می‌کند چنانچه سوالات آزمون را طوری بسازیم که با

سطوح توانایی آزمودنیها جور باشند، می‌توانیم از طول آزمون بدون این که کاهش در پایابی آن فرامم گردد بکاهیم. ولی، اگر آزمونی درست کنیم که سوالات آن از لحاظ سطح دشواری متناظر باشند، در این حالت کار مقایسه بین آزمودنیها با مشکل مواجه خواهد شد. لر: برای توجیه این مطالب می‌گویید دو دانشآموز را که در دو آزمون با دشواری متفاوت عملکردی معادل ۵۰ درصد به دست آورده‌اند نمی‌توان دارای توانایی یکسانی به حساب آوردم. و یا دانشآموزی را که در یک آزمون آسان به ۶۰ درصد سوالات پاسخ درست داده است نمی‌توان به لحاظ توانایی بالاتر یا پایین‌تر از دانشآموزی دانست که در یک آزمون مشکل به ۴۰ درصد سوالات پاسخ درست داده است. کار مقایسه آزمودنیها را که به تموثهای از سوالات آزمون با دشواری متفاوت پاسخ داده‌اند به آسانی نمی‌توان به وسیله مدل نظریه کلاسیک آزمون مورد بررسی قرار داد (رامبرگ، ۱۹۹۲).

هبولین و دراسکو (۱۹۸۳) نیز به شیوه تهیه، تجدیدنظر، و همازنی در نظریه کلاسیک آزمون اشاره می‌کنند. آنان اظهار می‌دارند که این نظریه قادر نیست برآوردهای مستقیمی از مقدار اطلاعات موجود در نمره‌های مشاهده شده درباره توانایی آزمودنیها در نقاط ویژه‌ای در امتداد این پیوستار فراهم آورد. به گفته ایشان آماردهایی که برای نظریه کلاسیک آزمون محاسبه می‌شوند (مثلًا، خطای معیار اندازه‌گیری و ضریب آلفا) دقیقت آزمون یا مقیاس را به صورت گروهی نشان می‌دهد و هیچ مطلبی برای گفتن درباره دقیقت آزمون یا مقیاس در نقاط ویژه‌ای روی پیوستار خصیصه مکنون (مثلًا، نمره برش برای تضمیم‌گیری در مورد استخدام یا رضایت شغلی بالا) ندارد.

۶. لوین (Levin, ۱۹۷۸) به محدودیت دیگر نظریه کلاسیک آزمون که وریانس خطای آزمون را برای تمام آزمودنیها یکسان فرض می‌کند اشاره می‌نماید. ری سو گوید معمولاً می‌توان افرادی را مشاهده کرد که مثلاً به سوالات آزمونی با ثبات تر و دقیق‌تر از دیگران پاسخ می‌دهند. به بیان دیگر، میزان ثبات و دقیقت آزمودنیها در اجرای امتحانات یا تکالیفی که ه آنها واگذار می‌شود نسبت به توانایی آنها متفاوت است. بنابراین، عملکرد آزمودنها با سطح توانایی عالی در پاسخ به چندین فرم آزمونهای همتا امکان دارد از عملکرد آزمودنیها با سطح توانایی

متوسط با ثبات‌تر باشد.

۷. محدودیت دیگر نظریه کلاسیک آزمون به عدم توانایی آزمون یا مقیاس در توصیف برخی مسائل که آزمودن‌بهادر پاسخ دادن به شوالات آزمون یا مقیاس مراججه می‌شوند مربوط می‌گردد. به عنوان مثال، پاسخ دهنده‌گان امکان دارد پرسشنامه نگرشی را بدون خواندن برخی سوالات پاسخ دهد، یا دانش‌آموز ضعیفی ممکن است با رونویسی از روی ورقه دانش‌آموز قوی بغل دستی نمره بالایی بگیرد، یا این که یک آزمودنی امکان دارد بخشی از پاسخ‌نامه را جا بگذارد و بنابر این نمره پایینی در آزمون کسب نماید. سئولی که متخصصان آزمون‌سازی در این زمینه می‌پرسند این است که چگونه می‌توان این الگوهای نامناسب پاسخ آزمودنها را پیدا کرد؟ هیولین و دراسکو (۱۹۸۳) می‌گویند پاسخ این سوال در آزمون‌سازی از اهمیت ویژه‌ای برخوردار است و از آنجاکه نظریه کلاسیک آزمون کل آزمون را به عنوان واحد تحلیل به شمار می‌آورد از عهده پاسخ دادن به آن برتمی‌آید. آنان توجه را به نظریه‌های دیگر آزمون‌سازی معطوف می‌سازند که برای شناسایی الگوهای غیرمعمول پاسخ به سوالات آزمون روش جدیدی در اختیار سازنده آزمون قرار می‌دهد. این روان‌سنجان معتقدند که اغلب می‌توان پاسخهای غیرمعمول را به سهولت شناسایی کرده، چه این که این قبیل پاسخها در مقایسه با الگوهای پاسخ معمول که بسیار بابتند الگوهای بی‌ثباتی فراهم می‌آورند.

به عنوان مثال، چنانچه فرض کنیم یک آزمودنی باغوش در پاسخ دادن به تمام سوالات باهوش باقی خواهد‌ماند (با پاسخ دادن صحیح به اکثر سوالات)، چنانچه او بخشی از سوالات را جا بگذارد، بدون شک بررسی پاسخ او به سوالات الگری غیرمعمول را نشان می‌دهد، یعنی الگویی بثبتات (دادن پاسخ درست) در بخش‌هایی از آزمون و الگویی بی‌ثبتات (دادن پاسخ غلط) در بخش دیگری از آزمون دارد. هیولین و دراسکو (۱۹۸۳)، معتقدند که نظریه کلاسیک آزمون توان شناسایی این مسائل را ندارد. در مقابل، نظریه‌های جدید آزمون روش‌های مطمئن‌تری برای پیدا کردن چنین الگوهای غیرمعمول آزمودنها ارائه می‌دهند.

به واسطه این محدودیتها، نظریه کلاسیک و شیوه‌های مربوط به آن نتوانسته است راه حن رضایت‌بخشی برای مسائلی که آزمون با آن مواجه است پیدا کند. بنابر این، پژوهشگران و

منخصمان روان‌سنگی سعی کرده‌اند نظریه‌های مناسبتری برای ساختن آزمونهای روانی و تربیتی تدوین کنند. در حال حاضر، مشهورترین مدل‌ها برای تخمین پاسخ آزمودنی به مجموعه‌ای از سوالات آزمون، حول «نظریه خصیصه مکنون» (Latent Trait Theory) فراهم آمده است. نام دیگر این نظریه که امروزه شهرت بسیار یافته «نظریه پاسخ به سوال» (Item Response Theory) است که تشریح آن به مقاله دیگری نیازمند است.

Hulin, C. L. & Drasgow, D. E. (1983). Item Response Theory. In D. J. Detterman & R. A. Gagné (Eds.), *Handbook of Cognition and Instruction* (pp. 381-412). New York: Academic Press.

Levin, J. R. (1978). Correcting planning on experiment in the testing problems. New Jersey: Prentice-Hall.

Gulliksen, H. (1958). *Measures of mental ability*. New York: McGraw-Hill.

Mehrens, A. W. & Lehman, J. C. (1965). *Principles of educational measurement*. New York: Harper & Row.

Gulliksen, H. (1958). *Evaluation in education and psychology*. New York: Rinehart & Winston, Inc.

Romberg, A. T. (1992). *Mathematical assessment: Validity and fairness*. New York: State University of New York.

Spearman, C. (1907). Demonstration of formula for true

منابع

منابع انگلیسی

- Anastasi, A. (1988). *Psychology testing* (6th ed.). New York: McGraw-Hill
- Baker, B. F. (1985). *The basics of item response theory*. Portsmouth, New Hampshire: Heineman.
- Bloom, S. B. (1978). *Toward a theory of testing, measurement, evaluation, and assessment*. Cseir Report # 10 UCB.
- Cronbach, L. J. (1969). Review of the theory of Achievement Test Issues. *Psychometrika*, 35: 509 - 511.
- Ebel, L. R. & Frisbie, A. D. (1991). *Essentials of educational measurement*. Engelwood Cliffs, New York: Prentice Hall.
- Feldet, L. S. (1975). Estimation of the reliability of a test divided into two parts of unequal length. *Psychometrika*, 40: 557-561.
- Guilford, J. P. (1930). *Psychometric methods* (2nd ed.) New York: McGraw-Hill
- Guliksen, H. (1945). *Theory of Mental Test*. New York: John Wiley.
- Hambleton, K. R & Novick, M. R. (1973). Toward an integration of theory and methods for criterion testing and measurement. *Journal of Educational Measurement*, 11: 159-170.
- Hambleton, K. R. (1984). Item Response Theory. Boston: Kluwer Nijhof Publishing

- Hoyt, E. J. (1941). Test reliability estimated by analysis of variance. *Psychometrika*, 6: 153-160.
- Hulin, C. L., & Drasgow, D. E. (1982) Recovery of two and three parametrics logistic item characteristic courses. *Applied Psychology Measurement*, 6: 153-160.
- Hulin, C. L. & Drasgow, D. E (1983). Item Response Theory. Homewood, Ill: Dow Jonse Boston.
- Levin, J. R. (1978). Correcting planning on experiment in the company of measurement errors. *Applied Psycholog Measurement*. 2: 382-85.
- Lord, M. F. (1980). Application of Item Response Theory to practical testing problems. New Jersy: Larrence Association Publisher.
- Lord, M. F & Novick, M. R. (1968). Theories of Mental Test Scores. Reading, Massachusset: Addison-Wesley.
- Mehrens, A W & Kaminiski, D. C. (1989). Methods of improving standardised test scores. *Educational Measurement, Issues & Practic*, 8: 14-22.
- Mehrens, A W & Lehman, J. C. (1984). *Measurement and evaluation in education and psychology*. New York: Rienhart & Winston, Inc.
- Magnuson, D. (1967). *Test Theory*. Boston: Addison - Wesley
- Romberg, A. T. (1992). Mathematic Assessment and evaluation. New York: State University of New York.
- Spearman, C. (1907). Demonstration of formula for true

- measurement correlation. *American Psychology*, 18: 161-196.
- Spearman, C. (1913). Correlation of sum and differences. *British Journal of Psychology*, 5: 17-42.
- Stevens, S. S. (1946). *On the theory of scales of measurement*. New York: John Wiley.
- Torgerson, W. S. (1958). Theory of scores of measurement. *Science*, 103: 677-680.
- Weiss, J. D. (1981). Test theory and methods. *Annual Review of Psychology*, 32: 629-658.