



An Investigation of the Evaluators' Ratings of the Performance Exams in the Field of Arts Using Multi-Faceted Rasch Model

Sara Hajatpour Qala Rudkhani¹, Balal Izanloo²

1. Master of Educational Research, Kharazmi University, Tehran, Iran. Email: hajatpoursara94@gmail.com.
2. Assistant Professor, faculty of Psychology and Education, Kharazmi University, tehran, iran; (Corresponding Author), Email: izan.b@knu.ac.ir

Article Info

Received: 2023.01.13

Received in revised
form: 2023.05.04

Accepted: 2023.06.15

Published online:
2023.06.27

ABSTRACT

Article Type:

Research Article

Objective: The present study was done in order to examine the severity/leniency and the central tendency level of raters in scoring of performance tests performed by National Organization for Educational Testing (NOET).

Methods: For this purpose, the secondary data in Sketch Architecture Test (1396 and 1397 solar, respectively with 5437 and 7459 people), Industrial design test (1396 solar, 1365 people), Music recognition test (1397 solar, 569 people), playwriting test (1396 solar, 97 people). The data were analyzed by classical methods and many-faceted Rasch models and the results extracted.

Results: The results from classical methods show that in both Sketch Architecture Tests, raters' consistency is generally acceptable, but in other tests (Industrial design, music cognition and playwriting) homogeneity is low. Raters' consensus is low in all five examined tests. Results from many-facet Rasch models show that in both Sketch Architecture Tests rater's severity and use of lower scores of rating scale effects are present, but as expected, there was not any effect for central tendency. Unfortunately, due to the nature of incorrect data collection designs in Industrial design, music cognition and playwriting tests analysis with many-facet Rasch models was not possible.

Conclusion: Based on findings it is recommended that when global performance tests are evaluated by the NOET organization raters, firstly; the proper design for evaluating have been selected and used, and secondly; to prevent the effect of severity or leniency and agreement (consensus) reduction between raters, the training of them for scoring performance tests to be considered

Keywords: Multi-faceted Rush models, severity, leniency, central tendency, performance tests tests.

Cite this article: Hajatpour Qala Rudkhani, Sara; Izanloo, Balal (2023). An Investigation of the Evaluators' Ratings of the Performance Exams in the Field of Arts Using Multi-Faceted Rasch Model. *Educational Measurement and Evaluation Studies*. 13(42):100-123 pages.

DOI: 0.22034/EMES.2023.528161.2244



© The Author(s).

Publisher: National Organization of Educational Testing (NOET)



سازمان سنجش آموزش کشور

مطالعات اندازه‌گیری و ارزشیابی آموزشی

شایا چاپی: ۲۴۷۶-۲۸۶۵ شایا الکترونیکی: ۲۷۸۳-۹۴۲

بررسی رتبه‌دهی ارزیابان آزمون‌های عملکردی سراسری (طراحی صنعتی، شناخت موسیقی، نمایش عروسکی، طراحی معماری و اسکیس معماری) بر اساس روش‌های کلاسیک و مدل‌های چندوجهی راش

سارا حاجت پورقلعه رودخانی^۱، بلال ایزانلو^۲

۱. کارشناس ارشد تحقیقات آموزشی، دانشگاه خوارزمی، تهران، ایران. رایانه: hajatpour.sara98@gmail.com

۲. استادیار دانشکده روانشناسی و علوم تربیتی، دانشگاه خوارزمی، تهران، ایران؛ (نویسنده مسئول)، رایانه: izan.b@khu.ac.ir

اطلاعات مقاله	چکیده
نوع مقاله:	پژوهش حاضر به منظور بررسی میزان جدیت/تساهله و گرایش به مرکز ارزیابان در نمره‌گذاری آزمون‌های عملکردی سراسری سازمان سنجش انجام شد.
مقاله پژوهشی	روش پژوهش: برای این منظور از داده‌های ثانویه آزمون‌های طراحی معماری سال‌های ۱۳۹۶ (۵۴۳۷ نفر)، اسکیس معماری ۱۳۹۷ (۷۴۵۹ نفر)، طراحی صنعتی سراسری سال ۱۳۹۶ (۱۳۶۵ نفر)، موسیقی سال ۱۳۹۷ (۵۶۹ نفر) و نمایش عروسکی سال ۱۳۹۷ (۹۷ نفر) استفاده شد. داده‌ها با استفاده از روش‌های کلاسیک و مدل‌های چندوجهی راش تحلیل و نتایج استخراج شد.
دریافت: ۱۴۰۱/۱۰/۲۳	یافته‌ها: در هر دو آزمون طراحی معماری، در کل میزان همسانی (مطابقت نسبی بین درجه‌بندی ارزیابان) قابل قبول، ولی در آزمون‌های طراحی صنعتی، شناخت موسیقی و نمایشنامه‌نویسی میزان همسانی پایین است. میزان اجماع (توافق) در هر پنج آزمون مورد بررسی نیز پایین است.
اصلاح: ۱۴۰۲/۰۲/۱۴	نتیجه‌گیری: نتایج حاصل از مدل‌های چندوجهی نشان داد اثر سخت‌گیری ارزیاب و استفاده از نمره‌های کرانه‌ای پایین در نمره‌گذاری، در هر دو آزمون طراحی معماری وجود داشت، ولی مطابق انتظار اثر گرایش به مرکز وجود نداشت.
پذیرش: ۱۴۰۲/۰۳/۲۵	به دلیل استفاده از طرح‌های جمع‌آوری داده‌های نامناسب (مثلاً در همه پاسخ‌ها یا تکالیف یک آزمون، هر داور فقط ۲ مورد مجزا از هم را ارزیابی می‌کند و هیچ همپوشی بین موارد ارزیابی شده توسط ارزیابان وجود ندارد تا با هم به صورت درست مقایسه شوند یا این که در یک آزمون هر تکلیف یا سوال توسط داوران متفاوت ارزیابی می‌شود) در آزمون‌های طراحی صنعتی، شناخت موسیقی و نمایشنامه نویسی امکان تحلیل با مدل‌های چندوجهی وجود نداشت. با توجه به یافته‌ها توصیه می‌شود به هنگام ارزیابی آزمون‌های عملکردی سراسری، اولاً از طرح مناسب برای ارزیابی استفاده شود و دوماً با آموزش ارزیابان در زمینه نمره‌گذاری آزمون‌های عملکردی از تاثیر عواملی مثل جدیت یا تساهله و کاهش توافق جلوگیری به عمل آید.
انتشار: ۱۴۰۲/۰۴/۰۶	

واژه‌های کلیدی: مدل‌های چندوجهی راش، جدیت، تساهله، گرایش مرکزی، آزمون‌های عملکردی سراسری.

۱ استناد: حاجت پورقلعه رودخانی، سارا و ایزانلو، بلال (۱۴۰۲). بررسی رتبه‌دهی ارزیابان آزمون‌های عملکردی سراسری (طراحی صنعتی، شناخت موسیقی، نمایش عروسکی، طراحی معماری و اسکیس معماری) بر اساس روش‌های کلاسیک و مدل‌های چندوجهی راش. مطالعات اندازه‌گیری و ارزشیابی آموزشی. ۱۳(۴۲)، ۱۰۰-۱۳۳ صفحه.

DOI:0.22034/EMES.2023.528161.2244



CC

BY

NC

BY

NC

حق مؤلف © نویسنده‌گان.

ناشر: سازمان سنجش آموزش کشور

مقدمه

تاثیر ویژگی‌های رفتاری ارزیاب بر رتبه‌بندی عملکرد افراد در آزمون‌های مختلف از نظر تجربی روشن است (Engelhard^۱). نمره‌گذاری انجام شده توسط ارزیابان باید از عینیت لازم برخوردار بوده و تاثیر سوگیرهای مختلف مثل تساهل/جدیت^۲، گرایش مرکزی^۳، اثر هاله‌ای^۴ و محدودیت دامنه^۵ تا حد امکان کاهش یابد. اصطلاح تساهل معمولاً برای تمایل ارزیاب به درجه‌بندی بالاتر و اصطلاح جدیت به تمایل ارزیاب به درجه‌بندی پایین‌تر از نقطه میانی مقیاس اندازه‌گیری، اشاره دارد. نتیجه آنی تساهل یا جدیت آن است که رتبه‌ها در سطح بالا یا پایین هر مقیاس اندازه‌گیری جمع می‌شوند. در گرایش مرکزی ارزیابان از طفه وسط مقیاس اندازه‌گیری بیش از حد استفاده می‌کنند، درحالی که از کاربرد طبقات کرانه‌ای اجتناب می‌نمایند. منظور از اثر هاله‌ای آن است که برداشت کلی فرد ارزیاب از فرد و شایستگی‌های او بر ارزیابی از صفات مختلف وی تاثیر دارد. محدودیت دامنه برای موقعیت‌هایی استفاده می‌شود که در آن درجه‌بندی‌ها اطراف هر نقطه‌ای در پیوستار درجه‌بندی جمع می‌شوند. فرقی نمی‌کند که این نقطه، نقطه بالایی مقیاس درجه‌بندی باشد یا نقطه پایین و یا نقطه وسطی. دسته‌ای از اثرات ارزیاب که معمولاً کمتر مورد اشاره قرار می‌گیرند عبارتند از: ۱- عدم دقت^۶- ۲- خطای منطقی^۷- ۳- خطای مقابل^۸- ۴- تاثیرات رفتارها، عقاید، نگرش‌ها و ویژگی‌های شخصیتی ارزیاب^۹- ۵- تاثیرات مشخصات مربوط به ارزیاب یا ارزیابی‌شونده^{۱۰}- ۶- خطای مجاورت^{۱۱}- ۷- خطای تاخر یا تقدم^{۱۲}- ۸- اثرهای ترتیب^{۱۳} (Myiford و Wolfe^{۱۴}، ۲۰۰۳).

در بافت نظریه کلاسیک از روش‌های مختلفی برای برسی عملکرد ارزیابان استفاده می‌شود. شاخص اجماع پایایی بین ارزیابان^{۱۵}، که به توافق بین ارزیابان^{۱۶} نیز معروف است، به این که ارزیابان مستقل تا چه اندازه درجه‌بندی یکسانی از یک آزمون شونده یا شیء خاص ارائه می‌دهند اشاره دارد (مطابقت مطلق درجه‌بندی‌ها). در مقابل شاخص همسانی پایایی بین ارزیابان به این نکته اشاره دارد که ارزیابان مستقل تا چه اندازه به آزمون شونده‌ها یا اشیایی که قرار است رتبه‌بندی شوند رتبه نسبی یکسانی اختصاص می‌دهند (مطابقت نسبی درجه‌بندی‌ها) (Astemler و Sais^{۱۷}، ۲۰۰۸؛ Tinsley و Waihs^{۱۸}، ۲۰۰۰). برای مثال ممکن است یک ارزیاب به آزمون شوندگان امتیازهایی بدهد که به طور مداوم یک یا دو نمره کمتر از امتیازی است که یک رتبه‌دهنده دیگر به همان آزمون شوندگان اعطا می‌کند. در این حالت ترتیب نسبی آزمون شوندگان (مطابقت نسبی) برای هر دو ارزیاب یکسان و برآورد هسمانی آنها بالا خواهد بود، ولی ارزیاب‌ها در هیچ موردی به توافق دقیق (اجماع) نرسیده‌اند (Ayks، ۲۰۱۱). شاخص‌های اجماع که معمولاً در عمل استفاده می‌شوند عبارتند از: شاخص توافق دقیق^{۱۹} و کاپای وزن دار کوهن^{۲۰}. توافق دقیق برابر است با تعداد مواردی که رتبه‌های یکسانی دریافت کرده‌اند تقسیم بر تعداد کل مواردی که توسط هر دو ارزیاب درجه‌بندی شده‌اند. شاخص کاپا توافق بین

¹. Engelhard². Leniency, Severity³. Central Tendency⁴. Halo Effect⁵. Restriction Of Range⁶. Inaccuracy⁷. Logical Error⁸. Contrast Error⁹. Proximity Error¹⁰. Recency Or Primacy Error¹¹. Order Effects¹². Myford & Wolfe¹³. consensus index of interrater reliability¹⁴. Interrater Agreement¹⁵. Stemler & Tsai¹⁶. Tinsley & Weiss¹⁷. Exact Agreement Index¹⁸. Cohens Weighted Kappa

ارزیابان (دو ارزیاب) را به خاطر توافقی که صرفاً به دلیل حدس انتظار می‌رود اصلاح می‌کند. شاخص‌های همسانی عبارتند از: ضریب همبستگی گشتاوری^۱ و تاو b کندال^۲. ضریب همبستگی گشتاوری پیرسون که به آن ^۳ پیرسون نیز می‌گویند میزان رابطه خطی بین رتبه‌بندی دو داور را نشان می‌دهد. تاو b کندال میزان مطابقت بین دو مجموعه رتبه‌ای که عملکرد آزمون شونده‌ها را رتبه‌بندی کرده نشان داده و رتبه‌های گره‌دار را لحاظ می‌کند. هر دو شاخص پایابی در دامنه صفر و یک قرار دارند، مقادیر بالای این دو شاخص همبستگی یا مطابقت قوی‌تر بین درجه‌بندی‌ها را نشان می‌دهد. در شاخص توافق دقیق مقادیر ۷/۰ بالا محسوب می‌شود و مقادیر ۱/۰ بسیار پایین در نظر گرفته می‌شود. مقادیر بین ۰/۴ تا ۰/۵ در سنجش‌های پرمخاطره جزو مقادیر بسیار پایین محسوب شده و رضایت بخش نیستند. مقادیر کاپای کوهن وزن دار قابل قبول، نزدیک ۰/۷ به بالا قرار دارند. اگرچه در اکثر موارد نتیجه شاخص‌های اجماع و همسانی یکسان است، ولی در موارد استثنایی ممکن است مقادیر همسانی بالا ولی مقادیر اجماع پایین‌تر از حد قابل قبول باشند (فلایس و همکاران^۳، ۲۰۰۳). معمولاً وقتی براساس همبستگی پیرسون در مورد همسانی بین ارزیابان قضایت کنیم مقادیر همسانی قابل قبول است ولی وقتی براساس تأثیر کندال در مورد همسانی قضایت ارزیابان قضایت شود میزان همسانی چنان قابل قبول نیست، چرا که ضریب تأثیر کندال وجود گره در رتبه‌بندی‌ها را لحاظ می‌کند به همین دلیل مقدار همسانی کاهش می‌یابد.

یکی از روش‌های کلاسیک بررسی انواع سوگیری و نقش آنها در رتبه‌بندی و نمره‌گذاری استفاده از نظریه تعمیم‌پذیری^۴ است، که جزو رویکردهای کلاسیک اندازه‌گیری محسوب شده و به کمک مبانی تحلیل واریانس، سهم هر عامل موثر در نمره‌گذاری مشخص می‌شود (اسمیت و کولکوبیچ^۵، ۲۰۰۴). امروزه علاوه بر نظریه تعمیم‌پذیری از رویکرد مدل‌های چندوجهی راش نیز برای تحلیل رتبه‌های اختصاص یافته به تکالیف و فعالیت‌های افراد استفاده می‌شود. ملاک انتخاب بین این دو رویکرد تحلیلی روشی است. اگر هدف برآورده میزان شباهت نمره‌های خام مشاهده شده گروهی از دانش‌آموzan و نمره‌های خامی که گروه مشابهی ممکن است تحت شرایط ایده‌آل به دست آورند باشد، نظریه تعمیم‌پذیری مفید خواهد بود. ولی در صورتی که برای هر فرد برآوردن نمره‌ای که تا حد امکان از ویژگی‌های عوامل ایجاد‌کننده آن مستقل باشد اهمیت دارد، باید از رویکرد مدل‌های چندوجهی راش^۶ (MFRM) استفاده کرد (کیم و ویلسون^۷، ۲۰۰۹).

عموماً سنجش‌های عملکردی نه تنها وجهه آزمون شونده و سوال (یا فعالیت) را در بر می‌گیرد، بلکه وجوده دیگری مثل، ارزیاب‌ها، معیار نمره‌گذاری، مصاحبه کننده‌ها و احتمالاً موارد بیشتری را شامل می‌شود. پیشنهادات اولیه برای بسط مدل اصلی راش به منظور در نظر گرفتن همزمان سه یا چند وجه (عامل‌های آزمایشی) توسط میکو^۸ (۱۹۶۹)، کمپ^۹ (۱۹۷۰) و کمپ^۹ (۱۹۷۲) انجام شد. این رویکرد که مبتنی بر مدل‌های خصیصه پنهان است و در بافت مدل‌های راش شکل گرفته و گسترش پیدا کرده، به طبقه‌ای از مدل‌های اندازه‌گیری اشاره دارد که برای تحلیل همزمان چند متغیر که به طور بالقوه بر تاییج سنجش تاثیر دارند مناسب است. از زمان اولین بیان نظری گسترده مدل‌های چندوجهی توسط لیناکر^{۱۰} (۱۹۸۹) تعداد کاربردهای اساسی اندازه‌گیری چندوجهی راش در حوزه‌های سنجش زبان، اندازه‌گیری روانشناسی و تربیتی، علوم بهداشت و بسیاری حوزه‌های دیگر به سرعت در حال افزایش است. نقل قول زیر از کتاب لیناکر (۱۹۸۹) نیروهای پشت پرده موثر که باعث رشد سریع رویکرد MFRM در تحلیل و ارزیابی

^۱. Product-Moment Correlation

^۲. Kendalls Tau-b

^۳. Fleiss

^۴. generalizability theory

^۵. Smith & Kulikowich

^۶. multi-facet Rasch models(MFRM)

^۷. Kim and Wilson

^۸. Micko

^۹. Kempf

^{۱۰}. Linacre

سنجهای مبتنی بر ارزیاب شده‌اند را برجسته می‌کند. «یک طراح آزمون وظیفه‌شناس متوجه می‌شود که روش متدائل تصمیم‌گیری برای عملکردهای درجه‌بندی شده به طور مستقیم بر اساس نمره‌های خام برای آزمودنی‌هایی که با ارزیاب‌های سخت‌گیر مواجه‌اند ناعادلانه است. همچنین ممکن است زمانی که آزمون‌شونده‌های فاقد صلاحیت در یک رشته حیاتی صرف‌با به این خاطر که با ارزیابان سهل‌گیر مواجه شده‌اند گواهی (مدرک) دریافت کرده‌اند. این نوع شرایط واقعی این سوال را مطرح می‌کند که چگونه می‌توان اندازه‌های منصفانه و معناداری از درجه‌بندی‌های رتبه‌ای به ناچار مشکوک تهیه کرد؟

برای درک مدل‌های چندوجهی راش گریز کوتاهی به مدل اصلی راش و مدل‌های چند مقوله‌ای^۱ راش لازم است. فرم لگاریتم شانس مدل اصلی راش با گرفتن لگاریتم طبیعی (لگاریتم در مبانی عدد نپر که تا رقم اعشار برابر $e^{2/718}$ است) از نسبت شانس (بخش داخل پرانتر در رابطه زیر که نسبت احتمال پاسخ درست به سوال n توسط فرد n به احتمال پاسخ نادرست به همان سوال توسط همان فرد را نشان می‌دهد) به دست می‌آید. این مدل برای سوال‌هایی که پاسخ به آنها در نهایت به صورت نادرست (صفراً و درست (یک) طبقه‌بندی می‌شود مناسب است.

$$\ln \left[\frac{P(x_{ni}=1)}{P(x_{ni}=0)} \right] = \theta_n - \beta_i \quad (1)$$

لگاریتم طبیعی نسبت شانس را لجیت^۲ می‌گویند، که خلاصه عبارت " واحد لگاریتم شانس"^۳ است. تحت این مدل، لجیت یک تابع خطی ساده از پارامتر توانایی فرد n (θ_n) و پارامتر دشواری سوال i (β_i) است. هم توانایی آزمون شونده و هم دشواری سوال، در این مقیاس بیان شده است. به طور کلی، لجیت واحد اندازه‌گیری مقیاس مربوط به هر پارامتر مشخص شده در مدل راش است. با توجه به مدل نشان داده شده در معادله ۱، یک لجیت برابر فاصله‌ای در طول مقیاس اندازه‌گیری است که شانس موفقیت را تقریباً $e^{2/718}$ افزایش می‌دهد، که همان مقدار عدد e است (ليناکر و رایت^۴؛ لودلو و هیلی^۵؛ ۱۹۹۵). مدل دوازشی راش که پایه اصلی سایر مدل‌های راش است را می‌توان به بیش از دو طبقه مرتب شده گسترش داد. سوال‌هایی که طبقات پاسخ آنها ذاتاً دارای بیش از دو طبقه مرتب شده است را سوال‌های چندمقوله‌ای گفته و آزمون یا مقیاسی که حاوی این گونه سوال‌ها باشد را مقیاس‌های درجه‌بندی می‌گویند، به طوری که با اجرای آنها داده‌های چند مقوله‌ای حاصل می‌شود. مثلاً سوال‌های نوع لیکرت^۶ با طبقات پاسخ مرتب شده 4 تایی (و گاهی 5 تایی) که نگرش افراد در خصوص موضوعات مختلف را اندازه‌گیری می‌کنند دارای طبقات کاملاً مخالف^۷، مخالف^۸ موافق^۹ یا کاملاً موافق^{۱۰} هستند. در بافت رویکرد راش به اندازه‌گیری، برای پرداختن به داده‌های حاصل از اجرای مقیاس‌های درجه‌بندی، مدل‌های چندمقوله‌ای راش گسترش یافته‌اند. روشن است که این مدل‌ها به مدل دو مقوله‌ای اصلی راش پارامترهایی اضافه می‌کنند. هدف از این کار توصیف کارکرد مقیاس‌های درجه‌بندی حاوی سوال‌های چند مقوله‌ای است (أندریچ^{۱۱}، راش پارامترهایی^{۱۲}؛ امبرتسون و رایز^{۱۳}؛ استینی و نرینگ^{۱۴}؛ پنفیلد^{۱۵}؛ ۲۰۱۴، ۲۰۰۶).

¹. Polytomous

². logit

³. Log Odds Unit

⁴. Linacre & Wright

⁵. Ludlow & Haley

⁶. Category Likert

⁷. Strongly Disagree

⁸. Disagree

⁹. Agree

¹⁰. Strongly Agree

¹¹. Andrich

¹². Embretson & Reise

¹³. Ostini & Nerin

¹⁴. Penfield

¹⁵. Rating Scale Model

(RSM) است. مدل RSM برای بازنمایی دشواری نسبی انتقال از یک طبقه مقیاس درجه‌بندی به طبقه پاسخ بعدی پارامتر آستانه^۱ را اضافه می‌کند. به بیان دقیق‌تر پارامتر آستانه یا خریب طبقه^۲, τ_k , جایی در بعد پنهان است که احتمال مشاهده طبقات پاسخ مجاور k و k-1 برابر است. به عبارت دیگر، به شرط آن که آزمودنی در یکی از این دو طبقه پاسخ مجاور قرار داشته باشد، τ_k یک نقطه انتقال روی بعد پنهان است که در آن احتمال آنکه آزمودنی به یکی از دو طبقه مجاور پاسخ دهد برابر ۵۰٪ است. این نقاط انتقال را آستانه‌های راش-آندریچ^۳ می‌گویند (بوند و فوکس^۴, ۱۹۹۸؛ لیناکر، ۲۰۰۶a؛ ۲۰۱۴b؛ آندریچ^۵, ۲۰۰۵a). فرم لگاریتم شانس مدل RSM برابر است با:

$$\ln \left[\frac{P_{nik}}{P_{nik-1}} \right] = \theta_n - \beta_i - \tau_k \quad (2)$$

در اینجا P_{nik} احتمال آن که آزمون شونده n به طبقه k سوال i پاسخ دهد است؛ P_{nik-1} احتمال آن که آزمون شونده n به طبقه k-1 سوال i پاسخ دهد؛ طبقه پاسخ یک مقیاس درجه‌بندی با m+1 طبقه است (یعنی، τ_k دشواری پاسخ به طبقه k نسبت به طبقه k-1) است. دشواری سوال چندمقوله ای β_i , جایی بر روی بعد پنهان تعریف می‌شود که پایین‌ترین و بالاترین طبقات دارای احتمال یکسان هستند. مدل RSM فرض می‌کند همه سوال‌های (مقیاس‌های درجه‌بندی) موجود در آزمون دارای یک مجموعه پارامتر آستانه برابر هستند. بنابراین، مدل فقط زمانی باید استفاده شود که سوال‌ها ساختار مقیاس درجه‌بندی مشترکی دارند. یعنی، زمانی که سوال‌ها تعداد طبقات پاسخ یکسانی دارند و دشواری نسبی بین طبقات در بین سوال‌ها یکسان است. زمانی که سوال‌ها از نظر تعداد طبقات پاسخ متفاوتند یا زمانی که انتظار می‌رود دشواری نسبی بین طبقات پاسخ از یک سوال دیگر تغییر می‌کند، مدل امتیاز جزئی^۶ (PCM) جایگزین مناسبی است. مدل PCM برای هر سوال پارامترهای آستانه جداگانه‌ای برآورد می‌کند، که اجازه می‌دهد ساختار مقیاس درجه‌بندی هر سوال منحصر به‌فرد باشد.

فرم لگاریتم شانس مدل امتیاز جزئی برابر است با:

$$\ln \left[\frac{P_{nik}}{P_{nik-1}} \right] = \theta_n - \beta_i - \tau_{ik} \quad (3)$$

در اینجا P_{nik} احتمال آن که آزمون شونده n به طبقه k سوال i پاسخ دهد و P_{nik-1} احتمال آن که آزمون شونده n به طبقه k-1 سوال i پاسخ دهد. k طبقه پاسخ مقیاس درجه‌بندی است که $m_i + 1$ طبقه دارد (یعنی، τ_{ik}). دشواری پاسخ به طبقه k در سوال i نسبت به طبقه k-1 است (مسترز^۷, ۱۹۸۲؛ ۲۰۱۰).

در یک موقعیت سنجش شامل ارزیابان، با استفاده از یک مقیاس درجه‌بندی (مثل، یک مقیاس چهار طبقه‌ای) برای ارزیابی کلی کیفیت عملکرد آزمون شونده حداقل با دو وجه قابل تمایز ارزیابها و آزمون شونده‌ها وجود دارد. اگر آزمون شونده‌ها به هر یک از فعالیت‌ها پاسخ دهند، و ارزیابان درجه عملکرد آزمون شونده را در هر فعالیت به‌طور جداگانه درجه‌بندی کنند، پس لازم است وجه فعالیت نیز در نظر گرفته شود. یعنی آزمون شونده‌ها، فعالیت‌ها و ارزیابها یک موقعیت سه وجهی را تشکیل می‌دهند. مدل اندازه-گیری چندوجهی راش مناسب این موقعیت در زیر ارایه شده است.

$$\ln \left[\frac{P_{nljk}}{P_{nljk-1}} \right] = \theta_n - \delta_I - \alpha_j - \tau_k \quad (4)$$

¹. Threshold

². Category Coefficient

³. Rasch Andrich Thresholds

⁴. Bond & Fox

⁵. Partial Credit Model

⁶. Masters

در این معادله $P_{nljk} = \text{احتمال اینکه آزمون شونده } n \text{ در فعالیت } l \text{ از ارزیاب } j \text{ رتبه } k \text{ دریافت کند}$, $\theta_n = \text{توانایی آزمون شونده } n$, $\delta_l = \text{سطح دشواری فعالیت } l$, $\alpha_j = \text{سختگیری ارزیاب } j \text{ و } \tau_k = \text{دشواری دریافت رتبه } k$ است. همان‌طور که در معادله ۴ نشان داده شده مدل MFRM اساساً یک مدل جمع‌پذیر خطی است که بر تبدیل لجستیک رتبه‌های مشاهده شده به مقیاس لجیت استوار است ("جمع‌پذیر" درینجا به معنی "ترکیب شده به وسیله قوانین جمع و تفریق" است). با استفاده از واژگان آماری استاندارد، می‌توان تبدیل لجستیک نسبت احتمال‌های طبقات متولی (یعنی، لگاریتم شانس) را به عنوان متغیر وابسته با وجود مختصات مختلف، مثل آزمون‌شونده‌ها، فعالیت‌ها، ارزیاب‌ها که به لحاظ مفهومی به عنوان متغیرهای مستقل که بر لگاریتم‌های شانس تأثیرگذار هستند در نظر گرفت (هیز^۱، ۱۹۹۴؛ مایرز، ول و لورج^۲، ۲۰۱۰). پارامتر آستانه، τ_k ، چگونگی برخورد با داده‌های رتبه‌ای را نشان می‌دهد. این پارامتر مشخص می‌کند که برای تمام عناصر هر وجه مدل مقیاس رتبه‌ای^۳ (RSM) باید استفاده شود.

برای مثال، در یک تحلیل، با مقیاس چهار طبقه‌ای طوری برخورد می‌شود که همه ارزیاب‌ها آن را در کرده‌اند و هر طبقه مقیاس رتبه‌ای را به شیوه بسیار مشابه استفاده کرده‌اند. درخصوص وجه فعالیت، این موضوع به این معنی است که یک درجه‌بندی خاص، مثل "۲" در فعالیت ۱، معادل با درجه‌بندی "۲" در فعالیت ۲ و در سایر فعالیت‌های موجود در سنجش فرض می‌شود. به بیان دقیق‌تر، پارامترهای آستانه به طور همزمان در بین ارزیاب‌ها، فعالیت‌ها و آزمون‌شونده‌های درجه‌بندی برآورد می‌شوند؛ یعنی، مجموعه‌ای از پارامترهای آستانه که ساختار مقیاس درجه‌بندی را تعریف می‌کنند برای همه ارزیاب‌ها (و نیز برای همه فعالیت‌ها و آزمون‌شونده‌ها) یکسان است.

به جای این کار، پارامتر آستانه را می‌توان طوری مشخص کرد تا ساختارهای مقیاس درجه‌بندی در بین عناصر یک وجه خاص متغیر باشد، در این صورت مدل امتیاز جزئی^۴ (PCM) سه وجهی حاصل می‌شود. به تغییر در معنی عبارات استفاده شده در مدل RSM سهوجهی در مقایسه با عبارت‌های استفاده شده در مدل RSM اصلی توجه کنید. مدل RSM سه وجهی پاسخ آزمودنی به یک طبقه خاص مقیاس درجه‌بندی را مدل سازی نمی‌کند، بلکه این مدل نوع RSM پاسخ ارزیاب به یک طبقه خاص مقیاس ارزیابی را بر اساس آنچه که وی معتقد است عملکرد آزمون‌شونده را مشخص می‌سازد مدل سازی می‌نماید. به زبان دیگر در معادله ۴، پارامتر آستانه، τ_k ، به دشواری پاسخ دادن به طبقه k ام (نسبت به طبقه $1-k$) مقیاس درجه‌بندی اشاره ندارد، بلکه به دشواری دریافت پاسخ در طبقه k (نسبت به $1-k$) اشاره دارد. بنابراین مهم است که بین دشواری که پاسخ به یک طبقه خاص نشان می‌دهد و دشواری مشاهده شده در آن طبقه تمایز قائل شویم (ليناکر و رایت، ۲۰۰۲).

به طور کلی، وقتی داده‌ای که باید مدل سازی شوند حاوی درجه‌بندی‌ها باشند، مشخص کردن RSM چندوجهی (یا PCM چند وجهی) به این پیش‌فرض که ارزیابان از طبقات مختلف مقیاس درجه‌بندی استفاده کرده‌اند اشاره دارد. پس می‌توان بحث اصلی را به صورت زیر بیان کرد: آیا این منطقی است که فرض کنیم که همه ارزیاب‌ها از مقیاس به روشنیکاری ارزیابی را بر روی تفاوت‌های عملکردی به دست آمده در طبقات مجاور توافق دارند، یا آیا ممکن است برخی ارزیابان کم و بیش از سبک خود برای انتصاف معنی به طبقات پیروی کنند؟ با افزایش تجارب حرفه‌ای، هر ارزیاب معمولاً شیوه یا فرایند خاصی برای رتبه‌بندی فعالیت اتخاذ می‌کند، شیوه‌ای که برای انطباق با کار روزانه ارزیاب تکامل یافته، اما ممکن است از شیوه سایر ارزیابان تا حد زیادی متفاوت باشد. آشنازی ارزیاب‌ها با مقیاسی که استفاده می‌شود مطمئناً به افزایش موافقت ارزیاب در استفاده از مقیاس کمک می‌کند، اما اینکه در هر نمونه خاص چه میزان توافق می‌تواند به دست آید در واقع یک سوال بی‌پاسخ باقی می‌ماند.

¹. Hays

². Myers, Well & Lorch

³. Rating Scale Model

⁵. Partial Credit Model

از دیدگاه اندازه‌گیری، شیوه اصولی برای پاسخ‌گویی به این سوال مستلزم اجرای تحلیل PCM چندوجهی و مقایسه نتایج درجه‌بندی طبقه در بین ارزیابان است. همان‌گونه که در معادله ۴ نشان داده شده است، میزان سخت‌گیری ارزیاب (α) به وضوح مدل‌سازی می‌شود. بنابراین تحلیل بر اساس مدل، برآورد میزان سخت‌گیری هر ارزیاب را نشان می‌دهد. بهطور کلی، میزان سخت‌گیری ارزیاب زمانی وجود دارد که ارزیاب‌ها درجه‌بندی‌هایی را فراهم کنند که به طور ثابت ذسبت به سایر ارزیابان یا درجه‌بندی‌های ملاکی تعیین شده (عنی اجماع رتبه‌بندی‌ها که تو سطح گروهی از ارزیابان خبره به سطوح خاصی از توانایی آزمودنی فراهم شده) سخت‌تر باشند. به طور ویژه در معادله ۴^۱ و نیز سایر معادلات پیچیده‌تر مدل‌های چندوجهی، پارامتر α میزان سخت‌گیری ارزیاب α ; را مدل‌سازی می‌کند. یعنی، هر چه مقدار این پارامتر بزرگ‌تر باشد، درجه‌بندی پیش‌بینی شده کمتر خواهد شد. به بیان دیگر، این مدل نشان می‌دهد که ارزیابان سخت‌گیر یا جدی، تمایل دارند به آزمون شونده‌ها نمره‌های پایین‌تری اختصاص دهند، که در نتیجه توانایی آزمون شونده کمتر می‌شود. بر عکس ارزیابان آسان‌گیر تمایل دارند نمره‌های بالاتری به آزمودنی‌ها بدهند. بنابراین، اگر کسی علاقه به مدل‌سازی سهل‌گیری ارزیاب داشته باشد، پارامتر α باید (به جای اینکه از معادله مدل کم شود) به معادله مدل اضافه شود.

به خاطر هزینه و به دلایل بهره‌وری، به ویژه در بافت سنجش‌های مقیاس بزرگ، معمولاً همه ارزیاب‌ها عملکردهای همه آزمون‌شونده‌ها را ارزیابی نمی‌کنند. غالباً، طرح سنجش به شیوه درجه‌بندی دوگانه^۲ محدود می‌شود؛ یعنی فقط دو ارزیاب از میان گروه بزرگی از ارزیاب‌های نسبتاً شایسته به طور مستقل مجموعه یکسانی از عملکردهای آزمون شونده‌ها را ارزیابی می‌کنند. در چنین موقعیت‌هایی، ماتریس داده‌هایی که همه نمرات داده شده به آزمون شونده‌ها را در بر دارد ناقص است؛ یعنی تعداد زیادی داده گمشده وجود خواهد داشت. به شرط اینکه طرح درجه‌بندی دارای پیوندهای کافی بین عناصر وجود باشد، توانایی آزمون شونده، میزان سخت‌گیری ارزیاب و پارامترهای دشواری تکلیف^۳، یا هر پارامتری که در یک مدل خاص مشخص شده را می‌توان هنوز براساس چهارچوب رایج مرجع برآورد کرد. به عبارت دیگر، مدل‌های راش در برابر داده‌های گمشده مقاوم هستند، چرا که این مدل‌ها فقط برای نقاط داده‌های مشاهده شده ارزیابی می‌شوند. به همین دلیل در مدل‌های راش نیازی به محاسبه یا تعديل داده‌های مشاهده نشده نیست. زمانی که بیشتر از سه وجه وجود داشته باشد، ساخت طرح درجه‌بندی مناسب می‌تواند کاملاً یک فعالیت چالش برانگیز باشد. برای مطالعه بیشتر در این خصوص به اکس (۲۰۱۱) مراجعه شود.

آزمون‌های عملکردی سراسری رشتهداری مختلف مقاطع گوناگون، مثل گروه هنر و معماری که هر ساله توسط سازمان سنجش استفاده می‌شوند از اهمیت زیادی برخوردارند، چرا که آینده تحصیلی و در نهایت شغلی شرکت کنندگان در این آزمون‌ها تا حد زیادی به نتایج این آزمون‌ها وابسته است. متاسفانه تا به امروز کاری پژوهشی جدی در خصوص این آزمون‌ها صورت نگرفته است. چون ارزیابان این آزمون‌ها را درجه‌بندی و نمره‌گذاری می‌کنند، لازم است کیفیت درجه‌بندی‌های حاصل از ارزیابی بررسی، مشخص و کیفیت نمره‌گذاری ارزیابان این آزمون‌ها با روش‌های آماری مناسب و مختلف بررسی شود. با توجه به مباحث مطرح شده، هدف پژوهش حاضر بررسی نمره‌گذاری ارزیابان آزمون‌های عملکردی رشته هنر بر اساس رویکردهای کلاسیک و نیز مدل چندوجهی راش است. از این رو اهداف این پژوهش عبارت است از: ۱) بررسی میزان اجماع (توافق) و همسانی ارزیابان^۲ بر سی میزان جدیت/تساهله ارزیابان در رتبه‌بندی آزمون رشته هنر در مقطع کارشناسی ارشد^۳ بررسی میزان گرایش به مرکز ارزیابان در فرایند رتبه‌دهی.

مبانی نظری و پیشینه پژوهش

استفاده از مدل‌های چندوجهی برای بازخورد انفرادی در تصحیح بعدی مصححان تاثیر دارد. به این صورت که وقتی مصححان با استفاده از مقیاس رتبه‌ای، بخش‌های نوشتاری و گفتاری آزمون شغلی انگلیسی را (که در استرالیا برای پذیرش پزشکان مهاجر به این کشور برگزار می‌گردد) مورد ارزیابی قرار دادند، بازخورد انفرادی با استفاده از نتایج مدل‌های چندوجهی راش، باعث کاهش

¹. Double-Rating

². task difficulty parameters

چهار خطای سخت‌گیری، سهل‌گیری، منظم بودن، و ارزیابی کلی قبل و بعد از بازخورد انفرادی شده است. اگرچه مصححان دید مشتبی نسبت به بازخورد انفرادی دارند (ناک^۱، ۲۰۱۱).

آموزش ارزیابان، منجر به مقیاس‌های دارای ثبات بیشتر بین مصححین می‌شود و سوگیری در استفاده از طبقه‌بندی‌های مقیاس رتبه‌بندی را کاهش می‌دهد (ولف و مکوی^۲، ۲۰۱۲). به علاوه، از آنجا که ریشه کن کردن کامل تنوع مصححین تقریباً غیرممکن است، حتی اگر آموزش کاربردی باشد، بهتر است روش آموزش به عنوان روندی در نظر گرفته شود که مصححین را بیشتر سازگار و متکی به خود می‌سازند (پایابی درونی مصحح‌ها) به جای آنکه به یکدیگر متکی باشند (پایابی بین مصحح‌ها). آموزش باعث می‌شود کیفیت رتبه‌بندی مصححین با تجربه و بی‌تجربه پس از آموزش بهبود یابد؛ با این حال، مصححین بی‌تجربه ثبات بالاتر و سوگیری کمتری دارند. از این‌رو، هیچ گونه شواهدی وجود ندارد که مصححین بی‌تجربه تنها به دلیل عدم تجربه کافی باید از رتبه‌بندی کنار گذاشته شوند. به علاوه، مصححین بی‌تجربه، از نظر اقتصادی، مقرنون به صرفه‌تر از مصححین با تجربه هستند، و برای تصمیم‌گیرنده‌ها هزینه کمتری جهت رتبه‌بندی دارند. بنابراین، به جای تخصیص بودجه هنگفت به مصححین با تجربه، تصمیم‌گیرنده‌ها از بودجه استفاده بهتری در جهت ایجاد برنامه‌های آموزشی بهتر داشتند (بیژنی^۳، ۲۰۱۸).

در پژوهش‌های داخلی اثرات ارزیابان بر نمره‌گذاری آنها از متون فارسی که توسط دانشجویان غیرفارسی زبان نوشته شده است با استفاده از مدل‌های چند وجهی راش مورد بررسی قرار گرفته است. نتایج حاکی از آن است که از ۵ ملاک ارزیابی استفاده شده توسط ارزیابان (شامل دستور، دایره وائزگانی، انسجام معنایی، تنوع محتوا و پرورش موضوع و ظاهر متن) مصححان نسبت به «انسجام معنایی» سوگیری بیشتری نشان داده‌اند و علاوه بر این، نسبت به هر دو موضوع نگارش نیز سوگیری داشته‌اند. نتایج حاکی از تفاوت‌های معنی دار بین سوگیری‌های دو مصحح است (اسفندياري^۴، ۲۰۱۴). تاثیر نوع ارزیابی (خود ارزیاب‌ها، ارزیابان همتا و ارزیابان معلم^۵) بر نتایج حاصل از آن نیز بررسی شده است. نتایج حاکی از آن است که ارزیاب‌های معلم سخت‌گیرتر، و خودارزیاب‌ها سهل‌گیرتر هستند و ارزیابان داخل هر گروه تغییرپذیری زیادی دارند. به علاوه از ۱۵ معیار ارزیابی (شامل، «محتوا»، «بسط جمله کلیدی مقاله»، «ارتباط موضوع مقاله با محتوای مقاله»، «مقدمه»، «انسجام»، «نتیجه گیری»، «سیر منطقی»، «تنوع کلمات»، «انتخاب واژه‌ها»، «جزای کلام»، «تنوع ساختارهای دستوری»، «دستور»، «امالی واژه‌ها»، «شکل ظاهری کلمات»، و «به کار گیری علائم سجاوندی») در معیارهای «انتخاب کلمات»، «تنوع کلمات» و «ارتباط موضوع مقاله با محتوای مقاله» نسبت به بقیه معیارهای ارزیابی سخت‌گیرانه‌تر بوده است؛ در صورتی که در ارتباط با «سیر منطقی» و «امالی کلمات» سهل‌گیری وجود داشته است (اسفندياري و مايفورد^۶، ۲۰۱۳).

روش پژوهش

این طرح از نظر روش‌شناسی جزء روش‌های کمی از نوع توصیفی-همبستگی محسوب می‌شود. ارزیابانی که در سازمان سنجش برای نمره‌گذاری آزمون‌های مختلف عملکردی از آنها برای نمره‌گذاری استفاده می‌شود جامعه این پژوهش هستند. در این پژوهش با استفاده از روش‌های کلاسیک و رویکرد چندوجهی راش رفتار رتبه‌دهی ارزیابان تحلیل و بررسی شد و براساس شاخص‌های به دست آمده در مورد سوگیری‌های مد نظر موجود در داده‌ها قضایت گردید. چون داده‌های این پژوهش قبلاً توسط

¹. Knoch

². Wolfe & McVay

³. Bijani

⁴. Esfandiari

⁵. Self-assessors, peer-assessors, and teacher assessors

⁶. Myford

سازمان سنجش آموزش کشور جمع‌آوری شده از این حیث جزو داده‌های ثانویه محسوب می‌شوند به همین دلیل در این پژوهش نیاز به ابزار جمع‌آوری داده‌ها نیست. در پژوهش فعلی داده‌های مربوط به رتبه‌دهی ارزیابان در آزمون‌های طراحی معماری سال-های ۱۳۹۷ (۵۴۳۷ نفر)، اسکیس معماری ۱۳۹۶ (۷۴۵۹ نفر)، طراحی صنعتی سراسری سال ۱۳۶۵ (۱۳۶۵ نفر)، موسیقی سال ۱۳۹۷ (۵۶۹ نفر) و نمایش عروسکی سال ۱۳۹۷ (۹۷ نفر) در اختیار پژوهشگران قرار گرفت. برای تحلیل با مدل‌های چندوجهی راش از بسته immer (روپیتز و استاینفیلد^۱، ۲۰۱۸a و ۲۰۱۸b) و برای محاسبه شاخص‌های همسانی و توافق از بسته IRR (گامر، Lemon، Flows و Sineg^۲، ۲۰۱۲) در R (تیم هسته R، ۲۰۱۹) استفاده شد.

در بین آزمون‌های تحلیل شده، تنها آزمونی که شرایط تحلیل با مدل چندوجهی راش را داشت آزمون طراحی صنعتی بود. با این حال، به دلیل نامناسب بودن طیف صفر تا صد استفاده شده، تحلیل با مدل‌های چند وجهی راش برای این آزمون نیز با مشکل مواجه شد (چرا که در طیف صفر تا صد تعداد زیادی از رتبه‌ها یا اصلاح مورد استفاده قرار نگرفته بودند و در عین حال دامنه رتبه‌ها در هیچ یک از متغیرها به صد نیز نمی‌رسید). به همین دلیل ابتدا رتبه‌های صفر تا صد آزمون طراحی صنعتی بر ۱۰ تقسیم شدند تا طیف رتبه‌ها به بازه صفر تا ۱۰ تبدیل شد. سپس برای از بین بردن بخش اعشاری نمره‌های حاصل، رتبه‌ها به نزدیک‌ترین عدد صحیح گرد شدند. به این ترتیب در نهایت طیف داده‌ها به بازه صفر تا ۹ منتقل گردید.

یافته‌ها

برای تحلیل از روش‌های مختلف توصیفی مثل فراوانی، درصد، میانگین، میانه، نما، انحراف معیار، کجی و کشیدگی استفاده شده است. سپس از شاخص‌های مختلف پایابی، برای بررسی همسانی و اجماع و نیز از مدل‌های چند وجهی راش برای پاسخ‌گویی به سوال‌های پژوهش استفاده شده است. همان‌طور که در جدول ۱ مشخص است بیشترین شرکت‌کنندگان مربوط به آزمون اسکیس معماری سال ۱۳۹۷ و کمترین تعداد شرکت کننده مربوط به آزمون نمایش عروسکی همین سال است. بر اساس شاخص‌های توصیفی در آزمون اسکیس معماری سال ۱۳۹۷، رتبه‌های ارزیابان گروه سوم بیشترین میانگین (۱۳/۶۰) و کمترین پراکندگی (۱۰/۹۰) را دارد، در حالی که رتبه‌های ارزیابان گروه دوم کمترین میانگین (۱۱/۴۹) و بیشترین پراکندگی (۱۲/۷۵) را دارا هستند.

با توجه به طیف صفر تا صد رتبه‌ها می‌توان گفت در کل رتبه‌های اختصاص داده شده ارزیابان به کارهای عملی داوطلبان پایین است، که با توجه رقابتی بودن آزمون دور از انتظار نیست. چون توزیع رتبه‌ها کشیدگی مثبت دارد، مقادیر میانه به عنوان شاخص گرایش مرکزی مناسب‌تر، نشان می‌دهند که رتبه‌های اختصاص داده شده به کارهای عملی بسیار پایین است. در شاخص‌های توصیفی آزمون طراحی صنعتی سال ۹۶ رتبه‌های ارزیابان در سوال ۸ بیشترین میانگین (۴/۵۱) و پراکندگی (۳/۵۸) را دارد، در حالی که سوال‌های ۵ و ۶ کمترین میانگین (به ترتیب ۰/۷۳ و ۰/۴۶) و پراکندگی (به ترتیب ۱/۲۴ و ۱/۳۰) را دارا می‌باشند. اگر چه اختلاف چندانی بین این میانگین‌ها وجود ندارد، ولی با توجه به طیف صفر تا ۷۰ می‌توان گفت در کل رتبه‌های اختصاص داده شده ارزیابان به داوطلبان پایین است، که این موضوع ممکن است به دلیل دشواری سوال یا جدیت ارزیابان باشد.

سوال ۲ دارای کجی و کشیدگی منفی (به ترتیب ۱/۱۹ و -۰/۱۳) و سوال ۶ دارای کجی و کشیدگی مثبت (به ترتیب ۳/۳۴ و ۱۱/۹۱) بالایی است که حاکی از وضعیت خاص رتبه‌ها در این دو سوال دارد. در شاخص‌های توصیفی آزمون موسیقی سال ۱۳۹۷ رتبه‌های ارزیابان در بخش هارمونی دارای بیشترین میانگین (۲۱/۲۸) و پراکندگی (۴/۹۴) و در بخش کتریپان دارای کمترین میانگین (۷/۵۴) و پراکندگی (۱۷/۸۶) است. در بخش کتریپان و شناخت موسیقی، میانه و نما هر دو صفر است که نشان دهنده این است که ۵۰٪ نمره‌ها بالاتر و ۵۰٪ پایین‌تر از صفر قرار دارند. شاخص‌های توصیفی آزمون نمایش عروسکی سال ۱۳۹۷ نشان می‌دهد که میانگین رتبه‌های داوطلبان در هر دو بخش نمایشنامه‌نویسی

¹. Robitzsch & Steinfeld

². Gamer, Lemon, Fellows & Singh

عروسوکی (۱۶/۴۶) و نقد و تحلیل نمایش (۱۶/۳۵)، تقریباً یکسان است ولی پراکندگی رتبه‌ها در بخش نقد و تحلیل نمایش (۲۳/۸۵) در برابر ۱۷/۶۵ برای بخش نمایشنامه نویسی عروسوکی بیشتر است، و نما در هر دو بخش صفر است. شاخص‌های توصیفی آزمون طراحی معماری سال ۱۳۹۶ زمان می‌دهد که رتبه‌های ارزیابان در بخش پلن دارای بیشترین میانگین (۱۶/۵۲) و در بخش سکشن دارای کمترین میانگین (۸/۲۴) و بیشترین پراکندگی (۱۱/۴۱) است. رتبه‌های ارزیابان در بخش پرسپکتیو کمترین پراکندگی (۸/۶۷) را دارد. با توجه به طیف صفر تا ۱۰۰ رتبه‌ها می‌توان گفت رتبه‌های اختصاص داده شده داوران به کارهای عملی داوطلبان در سطح پایین قرار دارد، که با توجه به رقابتی بودن آزمون و یا جدیت ارزیابان در رتبه‌دهی دور از انتظار نیست.

جدول ۱: آماره‌های توصیفی آزمون‌های مختلف عملکردی در پژوهش حاضر

آزمون	متغیر	میانگین	میانه	نما	انحراف معیار	کجی	کشیدگی	کمینه	بیشینه
اسکیس معماری	گروه اول	۱۲/۱۱	۸	۵	۱/۸۲(۰/۰۲۸)	۱۲	۳/۲۴(۰/۰۵۷)	۰	۷۸
(۱۳۹۷ ۷۴۵۷ نفر)	گروه دوم	۱۱/۴۹	۶	۳	۲/۲۴(۰/۰۲۸)	۱۲/۷۵	۵/۶۰(۰/۰۵۷)	۰	۸۶
گروه سوم	مجموع	۱۳/۶۰	۱۰	۱۰	۱/۵۲(۰/۰۲۸)	۱۰/۹۰	۲/۵۲(۰/۰۵۷)	۰	۸۰
میانگین	میانگین	۱۲/۴۰	۲۵	۱۸	۳۳/۵۱	۱/۸۱(۰/۰۲۸)	۳/۲۱(۰/۰۵۷)	۰	۲۲۸
۱	سوال ۱	۱/۶۹	۱/۵۰	۱	۱/۲۱	۰/۷۲(۰/۰۷)	۰/۱۰(۰/۱۳)	۰/۰	۶
۲	سوال ۲	۳	۳	۳	۱/۸۶	-۰/۱۹(۰/۰۷)	-۱/۱۳(۰/۱۳)	۰/۰	۶
۳	سوال ۳	۱/۷۸	۱/۵۰	۰/۰	۱/۴۲	۰/۷۳(۰/۰۷)	-/-۰۲(۰/۱۳)	۰/۰	۶
۴	سوال ۴	۲/۳۰	۲	۰/۰	۱/۸۶	۰/۴۵(۰/۰۷)	۰/۶۷(۰/۱۳)	۰/۰	۸
۵	سوال ۵	۰/۷۳	۰/۰	۰/۰	۱/۲۴	۲/۳۸(۰/۰۷)	۷/۱۹(۰/۱۳)	۰/۰	۸
۶	سوال ۶	۰/۴۶	۰/۰	۰/۰	۱/۳۰	۳/۳۴(۰/۰۷)	۱۱/۹۱(۰/۱۳)	۰/۰	۱۰
۷	سوال ۷	۳/۱۰	۳	۲	۲/۲۳	۰/۶۴(۰/۰۷)	۰/۰۹(۰/۱۳)	۰/۰	۱۲
۸	سوال ۸	۴/۵۱	۴	۰/۰	۳/۵۸	۰/۳۹(۰/۰۷)	-۰/۸۶(۰/۱۳)	۰/۰	۱۴
جمع نمرات		۱۷/۶۲	۱۶/۵۰	۱۳/۷۵	۹/۴۷	۰/۷۰(۰/۰۷)	۱/۰۴(۰/۱۳)	۰/۰	۵۳/۵
موسیقی ۱۳۹۷	هارمونی	۲۱/۲۸	۶	۰/۰	۲۶/۹۴	۱/۰۵(۰/۱۳)	۰/۱۹(۰/۲۰)	۰/۰	۹۷
(۵۶۹ نفر)	کنترپوان	۷/۵۴	۰/۰	۰/۰	۱۷/۸۶	۲/۰۳(۰/۱۳)	۵/۹۸(۰/۲۰)	۰/۰	۹۰
شناخت موسیقی ایرانی		۱۳/۶۲	۰/۰	۰/۰	۲۳/۰۷	۱/۸۵(۰/۱۳)	۱/۶۲(۰/۲۰)	۰/۰	۱۰۰
نمایشنامه نویسی	عروسوکی	۱۶/۴۶	۱۲	۰	۱۷/۶۵	۱/۰۹(۰/۲۵)	۰/۷۲(۰/۴۹)	۰	۷۴
نقد و تحلیل نمایش (۹۷ نفر)	نقد و تحلیل نمایش	۱۶/۳۵	۳	۰	۲۳/۸۵	۱/۶۱(۰/۲۵)	۱/۶۹(۰/۴۹)	۰	۹۰
طراحی معماری ۱۳۹۶	از زیاب ۱	۲۰/۲۷	۱۷	۱۵	۱۳/۹۰	۱/۷۰(۰/۰۳)	۳/۳۴(۰/۰۷)	۰	۹۲
(۵۴۳۷ نفر)	از زیاب ۲	۱۷/۱۸	۱۷	۱۸	۸/۴۴	۰/۰۴(۰/۰۳)	۱/۰۳(۰/۰۷)	۰	۶۰
بخش پلن	از زیاب ۳	۱۲/۱۱	۸	۵	۱۱/۱۷	۱/۸۴(۰/۰۳)	۴/۴۱(۰/۰۷)	۰	۸۰
بخش پرسپکتیو	کل	۱۶/۵۲	۱۴	۱۳/۳۳	۹/۹۲	۱/۲۴(۰/۰۳)	۲/۰۷(۰/۰۷)	۰	۶۸/۳۳
بخش سکشن	از زیاب ۱	۴۵/۱۰	۸	۷	۶۷/۷	۵۰/۱(۰/۰۳)	۲۷/۳(۰/۰۷)	۰	۵۶
بخش سکشن	از زیاب ۲	۸۹/۷	۷	۱۰	۶۴/۵	۲۴/۱(۰/۰۳)	۴۱/۵(۰/۰۷)	۰	۸۰
بخش سکشن	از زیاب ۳	۴۵/۱۷	۱۵	۱۰	۱۴/۱۲	۸۸(۰/۰۳)	۴۵(۰/۰۷)	۰	۶۶
بخش سکشن	کل	۱۱/۹۹	۱۱	۸/۷۷	۷/۲۰	۷۱(۰/۰۳)	۲۹(۰/۰۷)	۰	۴۳/۶۷
بخش سکشن	از زیاب ۱	۳۱/۶	۲	۰	۲۴/۱۱	۹۹/۲(۰/۰۳)	۹۵/۱۰(۰/۰۷)	۰	۸۵

۸۰	۰	۲۴/۸(۰/۰۷)	۴۴/۲(۰/۰۳)	۴۶/۹	۰	۲	۵۱/۶	ارزیاب ۲
۸۰	۰	۲۷/۲(۰/۰۷)	۶۰/۱(۰/۰۳)	۹۹/۱۴	۰	۵	۷۸/۱۱	ارزیاب ۳
۸۱/۶۷	۰	۵/۲۹(۰/۰۷)	۲/۱۲(۰/۰۳)	۱۱/۴۱	۰	۳/۳۳	۸/۲۴	کل

*تعداد کل افراد ۱۴۹۲۷ نفر

در جدول ۲ منظور از همسانی، همبستگی بین رتبه‌های گروهی یا فردی ارزیابان در آزمون‌های اسکیس معماری و بخش‌های مختلف آزمون طراحی معماری است. شاخص استفاده شده در این حالت همبستگی پیرسون و تاو b کندال است. در صورتی که در آزمونهای طراحی صنعتی، موسیقی و نمایس عروسکی از شاخص آلفای بین سوال‌های آزمون برای نشان دادن همسانی درونی رتبه‌های ارزیابان به سوال‌ها استفاده شده است. با توجه به نتایج جدول ۲ در آزمون اسکیس معماری، وقتی براساس همبستگی پیرسون در مورد همسانی بین ارزیابان قضایت کنیم مقادیر همسانی قابل قبول است. ولی وقتی براساس تاو b کندال در مورد همسانی نمره‌گذاری ارزیابان قضایت کنیم میزان همسانی چندان قابل قبول نیست، چرا که ضریب تاو کندال وجود گره در رتبه‌بندی‌ها را لحاظ می‌کند به همین دلیل مقدار همسانی کاهش می‌یابد. بر این اساس اگرچه میزان همسانی بین رتبه‌بندی ارزیابان تقریباً قابل قبول است ولی میزان توافق بین سه ارزیاب در آزمون اسکیس معماری به هیچ وجه رضایت بخش نیست (جدول ۲، ستون دوم از سمت چپ، کاپای کوهن بدون وزن و به خصوص وزن‌دار). در آزمون طراحی صنعتی نوع طرح استفاده شده به این صورت است که ۴ دور هشت سوال را ارزیابی کرده‌اند، ولی هر کدام از این ۴ دور فقط ۲ سوال از ۸ سوال را ارزیابی می‌کنند. به این ترتیب داور اول فقط سوال ۱ و ۲، داور دوم فقط سوال ۳ و ۴، داور سوم فقط سوال ۵ و ۶ و داور چهارم فقط سوال ۷ و ۸ را ارزیابی می‌کند. نمره‌گذاری سه سوال اول در طیف صفر تا ۴ نمره‌گذاری سوال چهار و پنج در طیف صفرتا ۸، نمره‌گذاری سوال ۶ در طیف صفر تا ۱۰ و نمره‌گذاری سوال ۷ در طیف صفر تا ۱۲، و نمره‌گذاری سوال ۸ در طیف صفر تا ۱۴ انجام می‌شود. با توجه به این که هر ارزیاب فقط دو سوال را ارزیابی می‌کند امکان محاسبه شاخص‌های محاسبه شده برای آزمون اسکیس در اینجا وجود ندارد.

جدول ۲: شاخص‌های همسانی (پیرسون، تاو b کندال و آلفا) همراه با پایایی اجماع (توافق) برای آزمون‌های عملکردی مختلف

آزمون								
آزمون		مقایسه		همبستگی پیرسون		دو ارزیاب		چند ارزیاب
ارزیاب	(تاو b کندال)	ارزیاب	ارزیاب	کاپای کوهن	کاپای کوهن	کاپای	فلیز	لایت
بدون وزن	وزن-	عدم-	بدون وزن	وزن-	دار	توافق		
۱-۲	۰/۸۶(۰/۶۳)	۰/۰۸	۰/۲۰	۰/۱۵	۰/۰۵	۰/۰۶	اسکیس معماری ۱۳۹۷	
۱-۳	۰/۸۰(۰/۰۸)	۰/۰۵	۰/۱۱	۰/۱۰	۰/۰۱	۰/۰۶	طراحی معماری ۱۳۹۶ (بخش پلان)	
۲-۳	۰/۷۹(۰/۶۱)	۰/۰۴	۰/۰۸	۰/۰۶	۰/۰۶	۰/۰۶	طراحی معماری ۱۳۹۶ (بخش پرسپکتیو)	
۱-۲	۰/۶۹(۰/۵۶)	۰/۰۷	۰/۰۷	۰/۳۵	۰/۴۱	۰/۰۵	طراحی معماری ۱۳۹۶ (بخش سکشن)	
۱-۳	۰/۶۵(۰/۰۵۳)	۰/۰۴	۰/۰۲	۰/۰۱	۰/۰۰۱	۰/۰۶		
۲-۳	۰/۷۰(۰/۰۵۵)	۰/۰۵	۰/۰۸	۰/۰۷	۰/۰۷	۰/۰۵		
۱-۲	۰/۵۰(۰/۰۴۲)	۰/۰۶	۰/۰۶	۰/۱۲	۰/۱۵	۰/۰۵		
۱-۳	۰/۶۴(۰/۰۵۷)	۰/۰۶	۰/۰۴	۰/۳۸	۰/۰۵	۰/۰۰۵		
۲-۳	۰/۴۱(۰/۰۳۹)	۰/۰۳	۰/۰۰۷	۰/۰۰۷	۰/۰۲	۰/۰۰۵		
۱-۲	۰/۸۵(۰/۰۸۱)	۰/۳۳	۰/۳۵	۰/۴۰	۰/۴۰	۰/۰۲۸		
۱-۳	۰/۸۹(۰/۰۸۶)	۰/۲۶	۰/۱۹	۰/۲۱	۰/۲۱	۰/۰۲۸		
۲-۳	۰/۸۸(۰/۰۸۱)	۰/۲۶	۰/۲۴	۰/۲۹	۰/۲۹	۰/۰۲۸		

۰/۰۵	۰/۰۳	۰/۷۳*	طراحی صنعتی ۱۳۹۶
۰/۰۴	۰/۰۲	۰/۳۴*	موسیقی ۱۳۹۷
۰/۰۸	۰/۰۸	۰/۴۷*	نمایش عروسکی ۱۳۹۷

*آلفا فقط برای سوال‌های آزمون‌های طراحی صنعتی ۱۳۹۶، موسیقی ۱۳۹۷ و نمایشنامه نویسی ۱۳۹۷ قابل محاسبه بود.

با توجه به داده‌های موجود برای این آزمون اگر فرض کنیم همه سوال‌ها یک چیز را اندازه‌گیری می‌کنند می‌توان شاخص آلفا، کاپای لایت، کاپای فلیز (و انواع ضرایب توافق درون طبقه‌ای که نتایج آن در ادامه ارایه شده است) را محا سبه کرد. میزان آلفا به عنوان شاخص هم‌سانی درونی بین ارزیابان ۰/۷۳ است که یک مقدار مزدی است. این در صورتی است که ضرایب توافق کاپای فلیز و لایت بسیار پایین بوده و اجماع ضعیف را نشان می‌دهند. توجه کنید که با توجه به شرایط داده‌ها باید این شاخص‌ها را با احتیاط تفسیر کرد. در آزمون موسیقی، که دارای سه بخش هارمونی، کنترپوان و شناخت موسیقی است، در بخش هارمونی دو داور دو سوال را ارزیابی کرده‌اند. بنابر این هر کدام از دو داور هر دو سوال را مورد بررسی قرار داده‌اند. در بخش کنترپوان دو سوال توسط یک داور بررسی شده است و در بخش شناخت موسیقی سه سوال توسط دو داور مورد ارزیابی قرار گرفته است، بنابر این هر کدام از دو داور هر سه سوال را ارزیابی نموده‌اند. در اینجا نیز فرض می‌شود که نمره‌های بخش‌های مختلف نشان دهنده یک خصیصه هستند و همه داوران یک چیز را ارزیابی کرده‌اند و شاخص‌های مختلف هم‌سانی (در اینجا آلفا)، توافق و همبستگی درون طبقه‌ای (که در ادامه گزارش شده‌اند) بر همین اساس محاسبه شده‌اند. مقادیر جدول ۲ برای آزمون موسیقی حاکی از همسانی و اجماع بسیار پایین است، که با توجه به وضعیت داده‌هایی که در اختیار پژوهشگر قرار گرفت دور از انتظار نیست.

در آزمون نمایش عروسکی که دارای دو بخش نمای شنامه نویسی و نقد و تحلیل نمایش است، هر کدام از داوران هر دو بخش را مورد ارزیابی قرار می‌دهند. باز هم با این فرض که نمره‌های بخش‌های مختلف نشان دهنده یک خصیصه هستند و همه داوران یک چیز را ارزیابی کرده‌اند، شاخص‌های مختلف هم‌سانی (در اینجا آلفا)، توافق و همبستگی درون طبقه‌ای محاسبه شده‌اند (جدول ۲). مقادیر جدول ۲ برای آزمون نمایش عروسکی حاکی از همسانی و اجماع بسیار پایین است، که با توجه به وضعیت داده‌هایی که باز در اختیار پژوهشگر قرار گرفت دور از انتظار نیست. در آزمون طراحی معماری بر اساس نتایج جدول ۲ میزان هم‌سانی بین رتبه‌بندی ارزیابان در بخش پلان و پرسپکتیو پایین است و در بخش سکشن تقریباً قابل قبول است. میزان توافق بین ارزیابان در هر سه بخش آزمون طراحی معماری در جدول ۲ اصلاً رضایت‌بخش نیست.

جدول ۳: ضرایب همبستگی درون طبقه‌ای (ICC) برای رتبه‌های ارزیابان در آزمون‌های عملکردی مختلف

آزمون	مدل	ثبتات	توافق	
اسکیس ۱۳۹۷	یک طرفه	براساس میانگین رتبه هر فرد	براساس میانگین رتبه هر فرد	براساس میانگین رتبه
موسیقی ۱۳۹۷	دو طرفه	۰/۹۳(۰/۹۲-۰/۹۳)	۰/۸۱(۰/۸۰-۰/۸۲)	۰/۹۳(۰/۹۲-۰/۹۳)
طراحی صنعتی ۱۳۹۶	یک طرفه	۰/۹۳(۰/۹۲-۰/۹۳)	۰/۸۱(۰/۷۹-۰/۸۲)	۰/۹۳(۰/۹۲-۰/۹۳)
نمایش عروسکی ۱۳۹۷	دو طرفه	۰/۹۳(۰/۹۲-۰/۹۳)	۰/۸۱(۰/۷۹-۰/۸۲)	۰/۹۳(۰/۹۲-۰/۹۳)
طراحی معماری ۱۳۹۶ (بخش پلان)	یک طرفه	۰/۱۴(۰/۱۲-۰/۱۶)	۰/۵۶(۰/۰۵۳-۰/۰۶۰)	۰/۱۴(۰/۱۲-۰/۱۶)
طراحی معماری ۱۳۹۶ (بخش پرسپکتیو)	دو طرفه	۰/۷۳(۰/۷۱-۰/۷۵)	۰/۱۷(۰/۱۱-۰/۲۳)	۰/۶۲(۰/۴۶-۰/۷۳)
موسیقی ۱۳۹۷	یک طرفه	۰/۱۱(۰/۰۶-۰/۱۶)	۰/۲۷(۰/۱۶-۰/۳۷)	۰/۲۷(۰/۱۶-۰/۳۷)
نمایش عروسکی ۱۳۹۷	دو طرفه	۰/۳۴(۰/۲۴-۰/۴۳)	۰/۱۳(۰/۰۸-۰/۱۹)	۰/۳۲(۰/۱۹-۰/۴۲)
طراحی معماری ۱۳۹۶ (بخش پرسپکتیو)	یک طرفه	۰/۴۸(۰/۲۲-۰/۶۵)	۰/۳۱(۰/۱۲-۰/۴۸)	۰/۴۸(۰/۲۲-۰/۶۵)
طراحی معماری ۱۳۹۶ (بخش پرسپکتیو)	دو طرفه	۰/۴۷(۰/۲۱-۰/۶۵)	۰/۳۱(۰/۱۲-۰/۴۸)	۰/۴۷(۰/۲۱-۰/۶۵)
طراحی معماری ۱۳۹۶ (بخش پرسپکتیو)	یک طرفه	۰/۵۵(۰/۵۳-۰/۵۶)	۰/۵۵(۰/۵۳-۰/۵۶)	۰/۷۸(۰/۷۷-۰/۷۹)
طراحی معماری ۱۳۹۶ (بخش پرسپکتیو)	دو طرفه	۰/۵۶(۰/۴۱-۰/۶۷)	۰/۸۴(۰/۸۳-۰/۸۵)	۰/۸۰(۰/۶۶-۰/۸۷)
طراحی معماری ۱۳۹۶ (بخش پرسپکتیو)	یک طرفه	۰/۵۸(۰/۵۶-۰/۶۰)	۰/۵۸(۰/۵۶-۰/۶۰)	۰/۳۱(۰/۳۰-۰/۳۳)

۰/۶۴(۰/۳۱-۰/۷۸)	۰/۳۷(۰/۱۸-۰/۵۲)	۰/۷۴(۰/۷۲-۰/۷۵)	۰/۴۸(۰/۴۷-۰/۵۰)	دو طرفه
۰/۹۱(۰/۹۱-۰/۹۱)	۰/۷۷(۰/۷۶-۰/۷۸)	۰/۹۱(۰/۹۱-۰/۹۱)	۰/۷۷(۰/۷۶-۰/۷۸)	یک طرفه
۰/۹۱(۰/۸۴-۰/۹۵)	۰/۷۶(۰/۶۴-۰/۸۵)	-۰/۹۴	۰/۸۳(۰/۸۲-۰/۸۴)	دو طرفه

۰/۹۴(۰/۹۳)

جدول ۳ انواع ضرایب همبستگی درون طبقه‌ای^۱ (ICC) آزمون‌های مختلف در حالت‌های گوناگون را نشان می‌دهد. ستون دوم از سمت راست دارای دو سطح یک طرفه و دو طرفه است. سطح یک طرفه به معنی آن است که فقط آزمودنی‌ها به طور تصادفی از جامعه مورد نظر انتخاب شده‌اند. سطح دو طرفه به این معنی است که هم داوطلبان و هم ارزیابان از جوامع مورد نظر به طور تصادفی انتخاب شده‌اند. ستون سوم و چهارم از راست دارای دو سطح ثبات و توافق هستند. از این رو وقتی دنبال ثبات (همسانی) هستیم مقادیر ردیف ثبات را مد نظر قرار می‌دهیم و وقتی دنبال توافق با شیم مقادیر ردیف توافق مد نظر قرار می‌گیرد. زیر بخش‌های ستون سوم و چهارم از راست به واحد تحلیل اشاره دارد که می‌تواند هر یک از افراد یا میانگین رتبه چند ارزیاب باشد. در این تحلیل برای محاسبه ضرایب ICC، ترکیب مختلف این عامل‌ها لحاظ شده است.

بر اساس نتایج جدول ۳ در آزمون اسکیس معماری وقتی فقط داوطلبان و یا هم ارزیابان تصادفی در نظر گرفته شوند و هدف برآورد ثبات رتبه‌بندی‌ها یا توافق بین ارزیابان باشد، مقادیر شاخص ICC تقریباً ۰/۸۰ است، که اگرچه این مقدار قابل قبول است ولی نشان می‌دهد که تغییر سطوح مختلف عوامل تاثیر چندانی بر شاخص‌های ICC ندارد. در مقابل وقتی واحد تحلیل میانگین رتبه‌بندی ارزیابان است میزان شاخص ICC تقریباً ۰/۹۳ افزایش می‌یابد که نشان در این حالت میزان شاخص‌های ICC افزایش یافته است. یعنی وقتی رتبه هر فرد به عنوان واحد تحلیل انتخاب می‌شود میزان ثبات و توافق تقریباً یکسان است، ولی وقتی واحد تحلیل میانگین رتبه‌های ارزیابان است میزان ثبات و توافق تا حدی افزایش می‌یابد. از این رو می‌توان گفت تنها عامل موثرکه باعث می‌شود هم ثبات و هم توافق افزایش یابد میانگین رتبه بندی‌ها است.

در آزمون طراحی صنعتی برا ساس ضرایب همبستگی درون طبقه‌ای در جدول ۳ در مدل یک طرفه و دو طرفه همیشه تحلیل میانگین رتبه‌ها بالاتر از تحلیل رتبه هر فرد است، که باز با توجه وضعیت خاص داده‌ها دور از انتظار نیست. به خصوص وقتی که در مدل دو طرفه میانگین رتبه‌ها در حالت ثبات (همسانی) تحلیل می‌شوند.

در آزمون موسیقی برا ساس ضرایب همبستگی درون طبقه‌ای جدول ۳ در تمام حالات مقادیر بسیار پایین است ولی باز هم نتایج تحلیل برا ساس میانگین رتبه‌ها بیشتر از تحلیل رتبه هر فرد است، و باز هم مقادیر مدل دو طرفه بیشتر از مقادیر مدل یک طرفه است.

در آزمون نمایش عروسكی نیز برا ساس ضرایب همبستگی درون طبقه‌ای جدول ۳ در تمام حالات مقادیر بسیار پایین است ولی باز هم تحلیل میانگین رتبه‌ها بیشتر از تحلیل رتبه هر فرد است، و باز هم مقادیر مدل دو طرفه بیشتر از مقادیر مدل یک طرفه است در آزمون طراحی معماری نیز با توجه به ضرایب همبستگی درون طبقه‌ای در جدول ۳ می‌توان گفت در مدل یک طرفه و دو طرفه همیشه تحلیل مبتنی بر میانگین رتبه‌ها بالاتر از تحلیل مبتنی بر رتبه هر فرد است. در اینجا نیز وقتی رتبه هر فرد به عنوان واحد تحلیل انتخاب می‌شود میزان ثبات و توافق پایین، وقتی واحد تحلیل میانگین رتبه‌های ارزیابان است میزان ثبات و توافق افزایش می‌یابد.

یافته‌های مبتنی بر مدل‌های چندوجهی

با توجه به این که فقط داده‌های آزمون طراحی صنعتی شرایط تحلیل با مدل‌های چندوجهی را داشت، داده‌های سایر آزمون‌ها با این مدل‌ها تحلیل نشد. همان طور که در بخش روش پژوهش ذکر شد، به دلیل مشکلات

¹. Intraclass correlation

مریبوط به نمره‌گذاری در آزمون طراحی صنعتی، مقیاس نمره‌ها از صفر تا صد از طریق تقسیم بر ۱۰ به طیف صفر تا نه تبدیل شد.

بر اساس نتایج جدول ۴ در بخش پلن، داور اول از همه طیف رتبه‌های ۱ تا ۹ استفاده نموده است، ولی بیشتر رتبه‌های ۱ تا ۳ را در نظر گرفته است. داور دوم و سوم بیشتر به استفاده از طیف رتبه‌های صفر تا ۵ تمایل داشته‌اند. همچنین میانگین رتبه داور اول بیشتر و میانگین رتبه داور سوم کمتر است. در بخش پرسپکتیو داور سوم از طیف رتبه‌های صفر تا ۸ استفاده نموده است ولی بیشتر به رتبه‌های صفر تا ۴ تمایل داشته است.

جدول ۴: آماره‌های توصیفی آزمون طراحی معماری ۱۳۹۶ در مقیاس صفر تا ۹

corr	sd	mean	0	1	2	3	4	5	6	7	8	9	rater	بخش
۰/۶۹	۱/۴۳	۲	۰/۰۵	۰/۳۵	۰/۳۸	۰/۰۹	۰/۰۶	۰/۰۴	۰/۰۲	۰/۰۱	۰/۰۱	۰/۰	۱	پلان
۰/۶۹	۰/۹۱	۱/۷	۰/۰۸	۰/۲۸	۰/۵۰	۰/۱۰	۰/۰۴	۰/۰	۰/۰	NA	NA	NA	۲	
۰/۶۸	۱/۲۳	۱/۱	۰/۳۶	۰/۳۲	۰/۲۱	۰/۰۴	۰/۰۵	۰/۰۱	۰/۰	۰/۰	۰/۰	NA	۳	
۰/۶۴	۰/۸۵	۱/۰۵	۰/۲۵	۰/۵۱	۰/۱۹	۰/۰۳	۰/۰۱	۰/۰	۰/۰	NA	NA	NA	۱	پرسپکتیو
۰/۴۶	۰/۷۰	۰/۷۲	۰/۴۲	۰/۴۵	۰/۱۳	۰/۰	۰/۰	۰/۰	۰/۰	NA	NA	NA	۲	
۰/۶۳	۱/۲۷	۱/۷۳	۰/۱۵	۰/۳۳	۰/۲۸	۰/۱۳	۰/۰۷	۰/۰۳	۰/۱	NA	NA	NA	۳	
۰/۶۴	۰/۸۵	۱/۰۵	۰/۲۵	۰/۵۱	۰/۱۹	۰/۰۳	۰/۰۱	۰/۰	۰/۰	NA	NA	NA	۱	سکشن
۰/۶۶	۰/۷۰	۰/۷۲	۰/۴۲	۰/۴۵	۰/۱۳	۰/۰	۰/۰	۰/۰	۰/۰	NA	NA	NA	۲	
۰/۶۳	۱/۲۷	۱/۷۳	۰/۱۵	۰/۳۳	۰/۲۸	۰/۱۳	۰/۰۷	۰/۰۳	۰/۰۱	NA	NA	NA	۳	

NA=not available

داور اول رتبه‌های ۱ تا ۳ را در نظر گرفته و داور دوم فقط طیف رتبه‌های صفر تا ۲ را استفاده نموده است. میانگین رتبه‌های بخش پرسپکتیو در داور سوم (۱/۷۳) بیشترین و در داور دوم (۰/۷۲) کمترین است. همچنین در بخش سکشن، داور سوم طیف رتبه‌های صفر تا ۸ را استفاده نموده، ولی بیشتر رتبه‌های صفر تا ۴ را در نظر گرفته است. داور اول فقط به استفاده از رتبه‌های صفر تا ۳ تمایل داشته است. و داور دوم فقط طیف رتبه‌های صفر تا ۲ را در نظر گرفته است. در بخش سکشن رتبه‌های داور سوم بیشترین میانگین (۱/۷۳) و رتبه‌های داور دوم کمترین میانگین (۰/۷۲) را داراست. در هر سه بخش بیشتر داوران به استفاده از رتبه‌های کرانه پایین تمایل داشته‌اند. در بخش پلان هر سه داور در نمره‌گذاری توافق دارند ولی در بخش پرسپکتیو داور سوم از نظر نمره‌گذاری با دیگر داوران توافق ندارد.

جدول ۵: مقایسه مدل‌های PCM و GPCM برای تعداد طبقات پنهان مختلف در بخش پلن

BIC	AIC	par	Deviance	Model
۳۹۵۸۴	۳۹۴۲۶	۲۴	۳۹۳۷۷,۶۸	PCM
۳۹۴۹۰	۳۹۳۱۸	۲۶	۳۹۲۶۶,۳	GPCM
۳۹۳۰۳	۳۹۱۰۹	۲۲	۳۹۱۱۴,۰۴	LOCLCA(3)
۳۸۷۷۰	۳۸۶۱۲	۲۴	۳۸۵۶۳,۶۶	LOCLCA(4)
۳۸۶۴۴	۳۸۴۷۲	۲۶	۳۸۴۲۰,۳۵	LOCLCA(5)
۳۸۶۵۹	۳۸۴۷۴	۲۸	۳۸۴۱۸,۳۶	LOCLCA(6)
۳۸۶۴۴	۳۸۴۴۶	۳۰	۳۸۳۸۶,۱۴	LOCLCA(7)
۳۸۶۶۰	۳۸۴۴۹	۳۲	۳۸۳۸۴,۹۱	LOCLCA(8)
۳۸۶۷۷	۳۸۴۵۳	۳۴	۳۸۳۸۵,۴۴	LOCLCA(9)

بخش پن آزمون طراحی معماری: مقایسه سه ارزیاب در بخش پلن براساس مدل‌های مختلف در جدول ۵ حاکی از آن است که با توجه به شاخص‌های AIC و BIC، برازش مدل GPCM^۱ بهتر از مدل PCM است، که نشان می‌دهد سه ارزیاب از نظر قدرت تشخیص و دقت با هم فرق دارند و آن‌طور که در مدل PCM مبتنی بر رویکرد چندوجهی راش فرض می‌شود، نمی‌توان آنها را از این جنبه یکسان در نظر گرفت. براساس نتایج حاصل از مدل‌های مختلف LOCLCA^۲ جدول ۵ و با توجه به شاخص‌های AIC و BIC برای هر یک از آنها، می‌توان گفت در بهترین حالت مدل حاوی هفت طبقه پنهان بهتر از مدل PCM که توانایی را پیوسته فرض می‌کند، با داده‌ها برازش دارد. این هفت طبقه حاکی از طبقات پنهانی هستند که ارزیابان افراد را در آن‌ها قرار داده‌اند. البته خود شاخص Deviance از مدل حاوی هشت طبقه پنهان حمایت می‌کند.

با توجه به پارامترهای بتای (Beta) سه ارزیاب در مدل GPCM که در جدول ۶ ارایه شده، می‌توان گفت در کل ارزیاب سوم سخت‌گیرترین فرد (۱/۷۲) و ارزیاب دوم سهل‌گیرترین فرد (۱/۲۰) است. این وضعیت به تفکیک هر یک از طبقات صفر تا ۹ نیز قابل مشاهده است (مقادیر زیر هر یک از ستون‌های Cat9 تا Cat1 برای هر یک از سه ارزیاب را مقایسه کنید. عدد کمتر نشان‌دهنده سهل‌گیری و عدد بزرگتر نشانه سخت‌گیری است. عبارت NA به عدم استفاده ارزیاب از رتبه مربوطه اشاره دارد). به علاوه براساس مقادیر ستون آلفا (alpha)، ارزیاب دوم دارای بیشترین قدرت تشخیص (۲/۷۳) و ارزیاب اول دارای کمترین قدرت تشخیص (۲/۱۰) است.

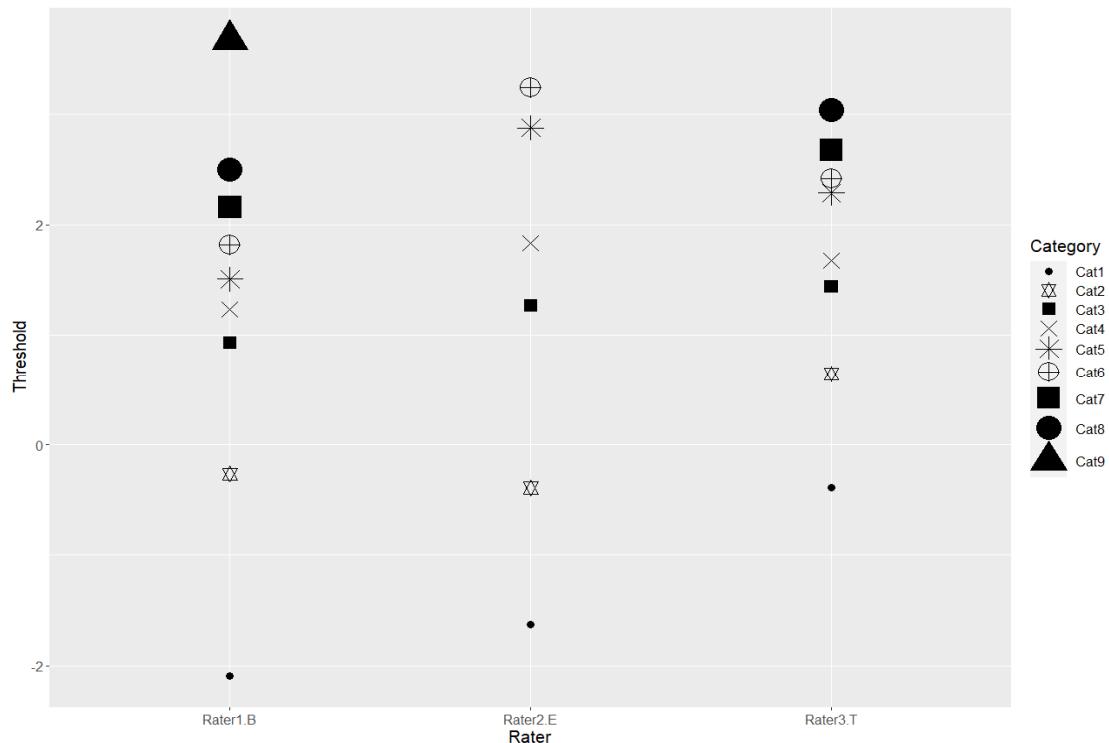
جدول ۶: آماره‌های مربوط به سه ارزیاب در آزمون طراحی معماری بخش پلان

Cat9	Cat8	Cat7	Cat6	Cat5	Cat4	Cat3	Cat2	Cat1	Beta	alpha	ارزیاب
۲/۳۸	۱/۰۲	۰/۹۴	۰/۵۲	۰/۲۰	-۰/۰۶	-۰/۱۲	-۰/۰۳	-۳/۳۵	۱/۲۷	۲/۱۰	۱
NA	NA	NA	۱/۸۸	۱/۸۳	۰/۵۶	۰/۱۵	-۱/۶۰	-۲/۸۲	۱/۲۰	۲/۷۳	۲
NA	۰/۹۸	۰/۹۵	۰/۳۴	۱/۲۰	-۰/۰۴	۰/۱۷	-۱/۱۰	-۲/۰۱	۱/۷۲	۱/۶۵	۳

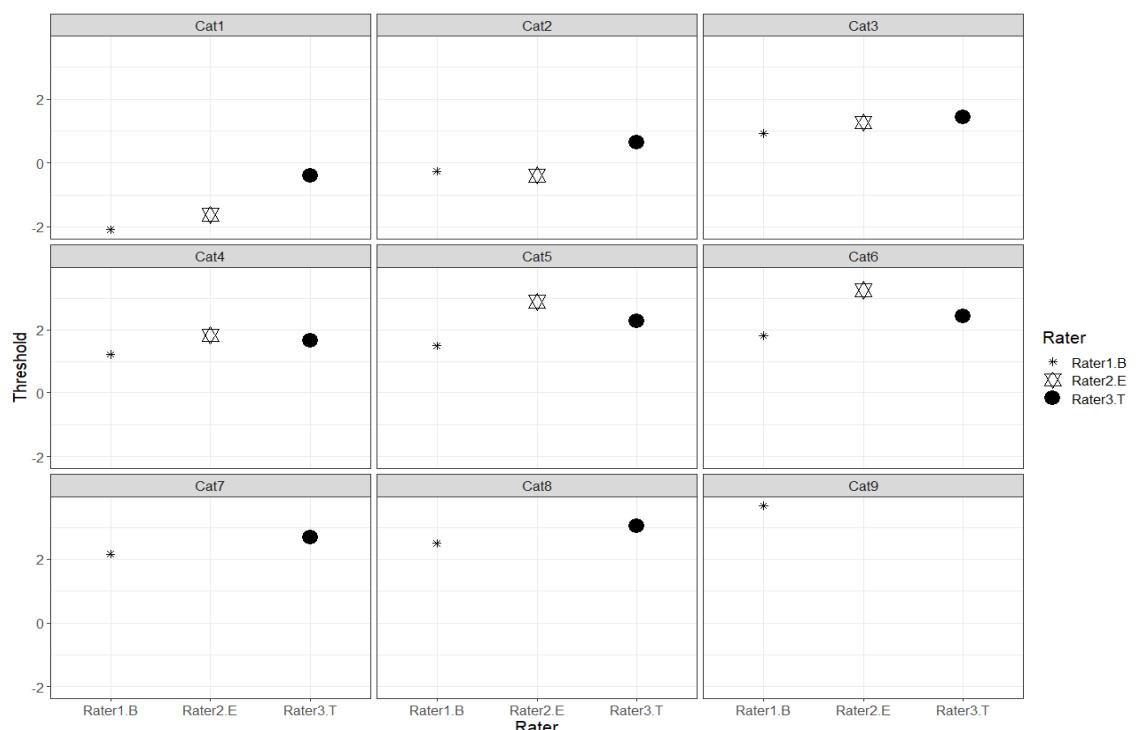
براساس نتایج نمودار ۱ ارزیاب اول از تمام طبقات طیف نمره‌گذاری استفاده کرده، ولی ارزیاب سوم و به خصوص دوم از طبقات طیف بالای مقیاس نمره‌گذاری اصلاً استفاده نکرده‌اند، که حاکی از سخت‌گیری آنها در استفاده از این طبقات است. ارزیاب دوم و به خصوص اول در استفاده از طبقات اول سهل‌گیر بوده‌اند. با توجه به اینکه تعییربذری در طبقات پایین بیشتر از طبقات بالا است می‌توان گفت توافق بین ارزیابان در طبقات بالا بیشتر از طبقات پایین است. هر چند که این توافق بسیار پایین است. به نظر می‌رسد نوعی گرایش به مرکز در ارزیاب دوم و به خصوص سوم وجود دارد. براساس نمودار ۲ سخت‌گیری داور سوم تقریباً در تمام طبقات مشهود است، به خصوص طبقات بالا که اصلاً توسط وی و ارزیاب دوم استفاده نشده‌اند. ارزیاب اول از تمام طبقات نمره‌گذاری استفاده کرده است. بخش پر سپکتو آزمون طراحی معماری: براساس شاخص‌های برازش Deviance AIC و BIC جدول ۷، باز هم برازش مدل GPCM^۱ بهتر از مدل PCM است که نشان می‌دهد، سه ارزیاب از نظر دقت یکسان نیستند. براساس شاخص‌های برازش Deviance AIC و BIC مدل‌های مختلف LOCLCA^۲ می‌توان گفت در بهترین حالت مدل حاوی ۴ و یا ۵ طبقه پنهان بهتر از مدل PCM که توانایی را پیوسته فرض می‌کند با داده‌ها برازش دارد. این ۵ طبقه حاکی از طبقات پنهانی هستند که ارزیابان افراد را در آن‌ها قرار داده‌اند. به بیان دقیق‌تر، شاخص‌های برازش Deviance AIC و BIC از مدل حاوی ۵ طبقه پنهان و شاخص BIC از مدل حاوی ۴ طبقه پنهان حمایت کرده است.

¹. generalized partial credit model

². located latent class Rasch models



نمودار ۱: مقایسه سه ارزیاب بخش پلن براساس ۹ طبقه. محور افقی از چپ به راست ارزیاب ۱ تا ۳ و محور عمودی دشواری هر یک از ۹ طبقه



نمودار ۲: مقایسه سه ارزیاب در بخش پلن براساس ۹ طبقه مختلف رتبه‌بندی

جدول ۷: مقایسه مدل‌های PCM و GPCM برای تعداد طبقات پنهان مختلف در بخش پرسپکتو

BIC	AIC	par	Deviance	Model
۳۶۹۰۵	۳۶۷۶۰	۲۲	۳۶۷۱۶,۰۷	PCM
۳۶۶۰۳	۳۶۴۴۴	۲۴	۳۶۳۹۶,۵	GPCM
۳۶۶۴۹	۳۶۵۰۴	۲۲	۳۶۴۶۰,۴۲	LOCLCA(3)
۳۶۶۰۶	۳۶۴۴۸	۲۴	۳۶۳۹۹,۵۳	LOCLCA(4)
۳۶۶۱۷	۳۶۴۴۶	۲۶	۳۶۳۹۳,۷۴	LOCLCA(5)
۳۶۶۳۵	۳۶۴۵۱	۲۸	۳۶۳۹۴,۹۲	LOCLCA(6)
۳۶۶۵۱	۳۶۴۵۴	۳۰	۳۶۳۹۳,۷۹	LOCLCA(7)

با توجه به پارامترهای بتای (Beta) سه ارزیاب براساس مدل GPCM در جدول ۸ می‌توان گفت در کل در بخش پرسپکتو، ارزیاب دوم سخت‌گیرترین فرد (۲/۴۳) و ارزیاب سوم سهل‌گیرترین فرد (۱/۴۳) است. این وضعیت به تفکیک هر یک از طبقات صفر تا ۸ نیز قابل مشاهده است مقادیر زیر هر یک از ستون‌های Cat8 تا Cat1 برای هر یک از سه ارزیاب را مقایسه کنید. عدد کمتر نشان‌دهنده سهل‌گیری و عدد بزرگتر نشانه سخت‌گیری است. عبارت NA به عدم استفاده ارزیاب از رتبه مربوطه اشاره دارد. به علاوه براساس مقادیر ستون Alpha (Alpha) ارزیاب اول دارای بیشترین قدرت تشخیص (۳/۲۸) و ارزیاب دوم (۱/۰۷) دارای کمترین قدرت تشخیص است.

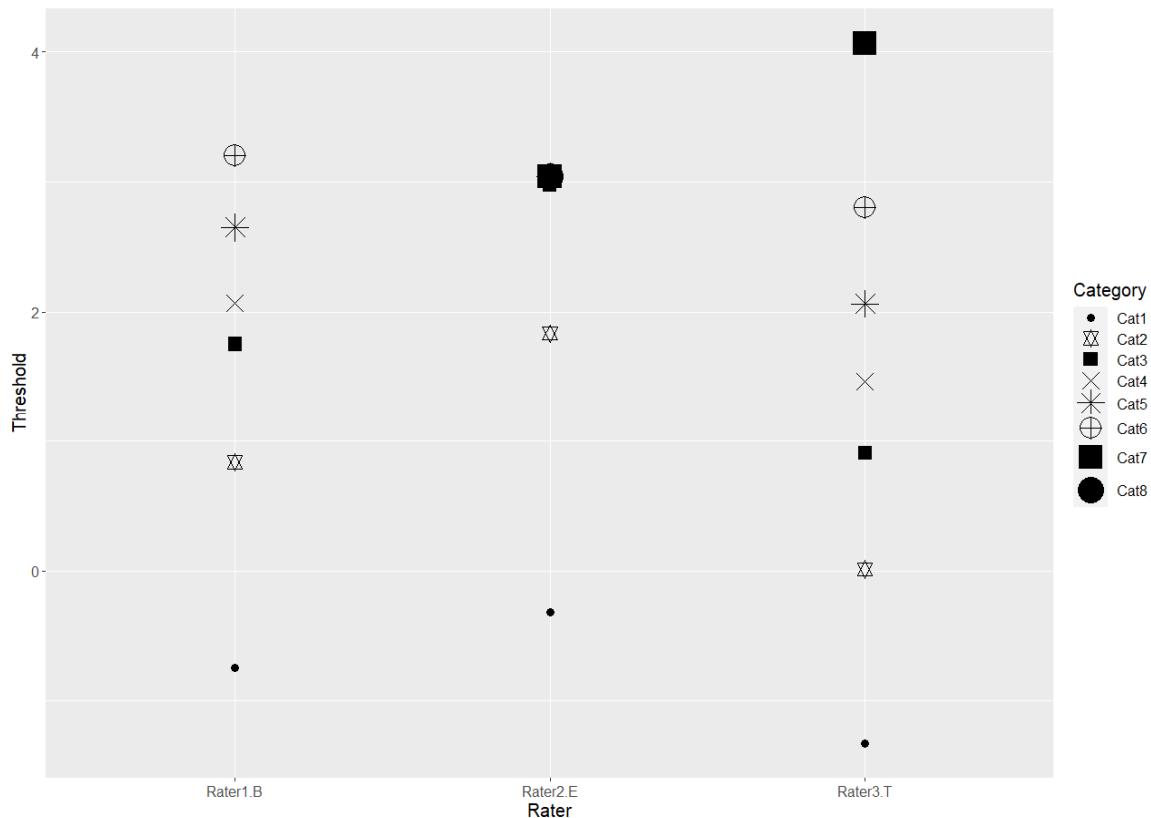
جدول ۸: آماره‌های مربوط به سه ارزیاب در آزمون طراحی معماری بخش پرسپکتو

ارزیاب	Beta	Alpha	Cat1	Cat2	Cat3	Cat4	Cat5	Cat6	Cat7	Cat8
۱	۱/۶۳	۳/۲۸	-۲/۳۷	-۰/۷۸	۰/۲۳	۰/۳۵	۱/۰۴	۱/۵۲	NA	NA
۲	۲/۴۳	۱/۰۷	-۲/۶۵	-۰/۶۳	۱/۹۴	۲/۰۵	۶/۵۸	۰/۸۸	-۱/۱۷	-۷/۰۱
۳	۱/۴۳	۱/۷۰	-۲/۷۰	-۱/۳۷	-۰/۴۲	۰/۰۱	۰/۶۱	۱/۳۰	NA	۲/۵۸

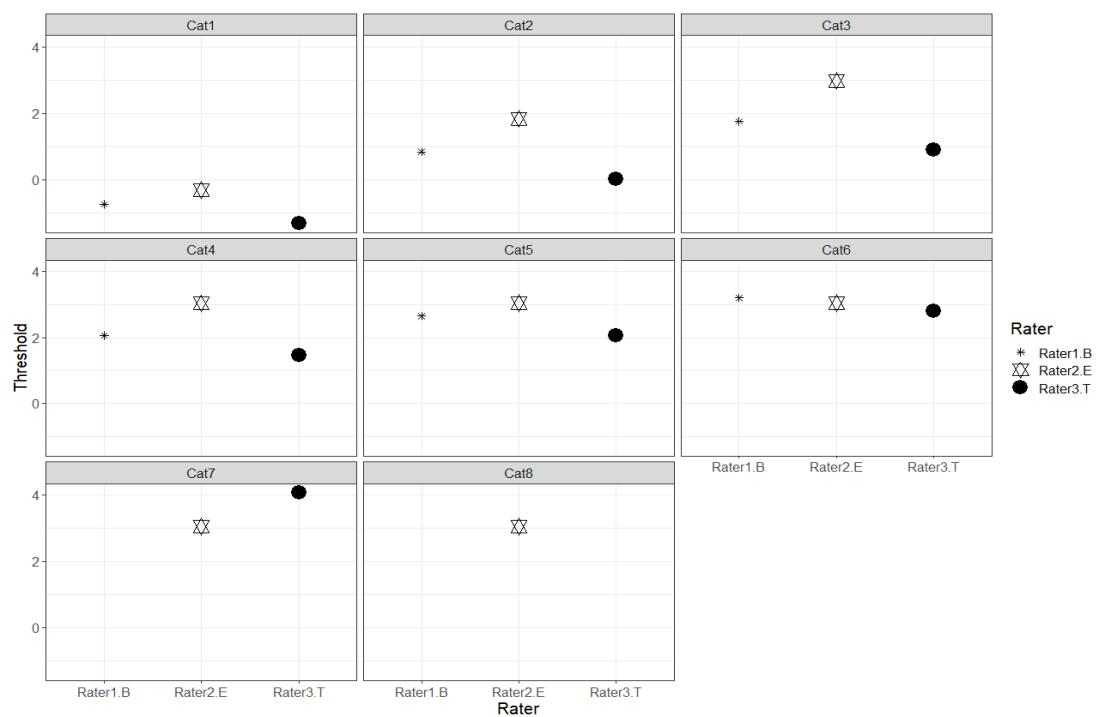
براساس نتایج نمودار ۳ هر سه ارزیاب از طبقه ۹ مقیاس نمره‌گذاری اصلاً استفاده نکرده‌اند که حاکی از سخت‌گیری آنها در استفاده از این طبقه است. ارزیاب اول و خصوصاً سوم در استفاده از طبقات اول سهل‌گیر بوده‌اند.

با توجه به اینکه تغییرپذیری در طبقات پایین بیشتر از طبقات بالا است می‌توان گفت توافق بین ارزیابان در طبقات بالا بیشتر از طبقات پایین است. هر چند که این توافق بسیار پایین است. به نظر می‌رسد نوعی گرایش به مرکز در ارزیاب دوم و به خصوص اول وجود دارد. بخش سکشن آزمون طراحی معماری: مقایسه سه ارزیاب با استفاده از شاخص‌های برازش Deviance و AIC در بخش سکشن براساس مدل‌های PCM و GPCM در جدول ۹ حاکی از آن است که باز هم مطابق انتظار برازش مدل GPCM بهتر از مدل PCM است، که نشان می‌دهد دقیق سه ارزیاب با هم فرق دارد.

براساس نتایج حاصل از مدل‌های مختلف LOCLCA در جدول ۹ و با توجه به شاخص‌های برازش Deviance، AIC و BIC می‌توان گفت در بهترین حالت مدل حاوی هشت طبقه پنهان بهتر از مدل PCM که توانایی را پیوسته فرض می‌کند با داده‌ها برازش دارد. این هشت طبقه حاکی از طبقات پنهانی هستند که ارزیابان افراد را در آن‌ها قرار داده‌اند. براساس پارامترها بتای (Beta) مدل GPCM برای سه ارزیاب در جدول ۱۰ می‌توان گفت که در کل ارزیاب دوم سخت‌گیرترین فرد (۲/۰۷) و ارزیاب سوم سهل‌گیرترین فرد (۱/۴۸) است.



نمودار ۳: مقایسه سه ارزیاب بخش پرسپکتیو در ۹ طبقه. محور افقی از چپ به راست ارزیاب ۱ تا ۳ و محور عمودی دشواری هر یک از ۹ طبقه



نمودار ۴: مقایسه سه ارزیاب در بخش پرسپکتیو براساس ۹ طبقه مختلف رتبه‌بندی

جدول ۹: مقایسه مدل‌های GPCM و PCM برای تعداد طبقات پنهان مختلف در بخش سکشن

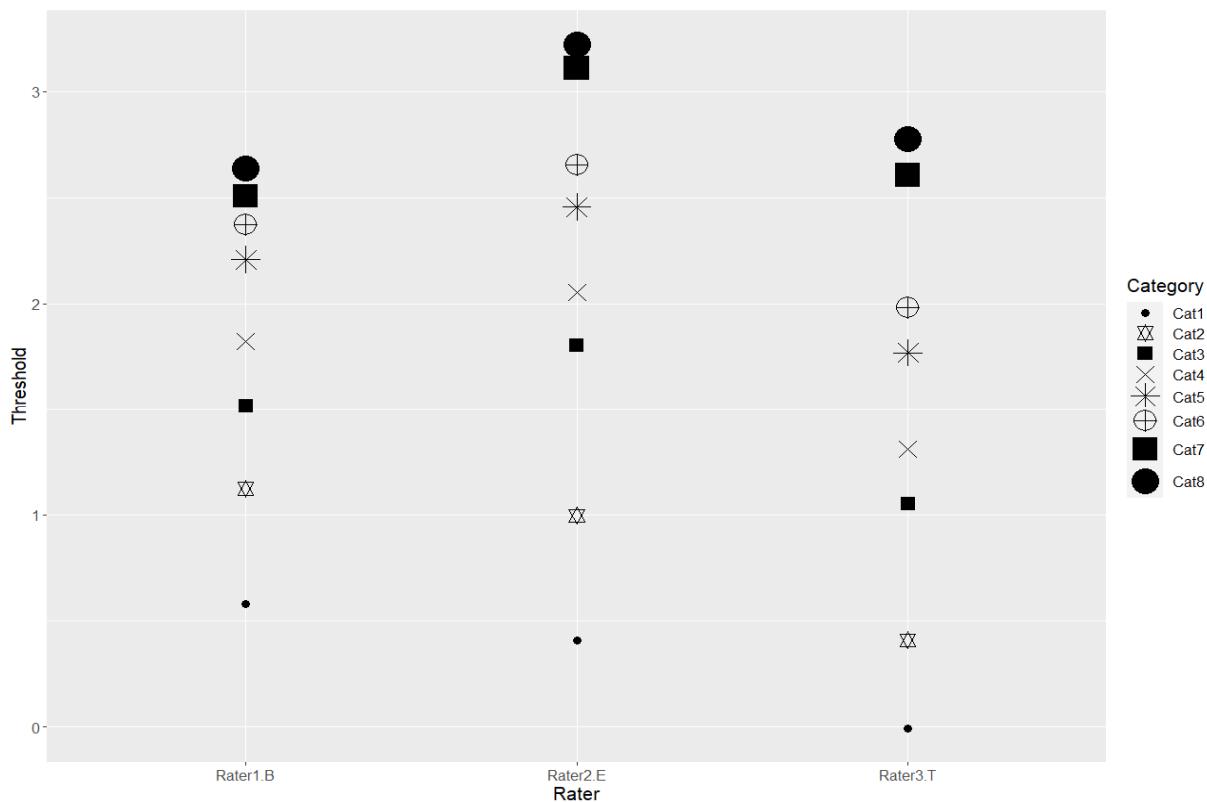
BIC	AIC	par	Deviance	Model
۲۷۹۴۸	۲۷۷۸۴	۲۵	۲۷۷۳۳,۸۲	PCM
۲۷۰۲۹	۲۶۸۵۲	۲۷	۲۶۷۹۷,۶۴	GPCM
-----	-----	-----	-----	-----
۲۷۸۸۲	۲۷۶۹۸	۲۸	۲۷۶۴۱,۹۵	LOCLCA(3)
۲۷۱۹۷	۲۶۹۹۹	۳۰	۲۶۹۳۹,۰۵	LOCLCA(4)
۲۷۰۱۴	۲۶۸۰۴	۳۲	۲۶۷۳۹,۰۳	LOCLCA(5)
۲۷۰۳۱	۲۶۸۰۷	۳۴	۲۶۷۳۸,۷۴	LOCLCA(6)
۲۶۹۵۸	۲۶۷۲۱	۳۶	۲۶۶۴۸,۵۵	LOCLCA(7)
۲۶۹۴۴	۲۶۶۹۳	۳۸	۲۶۶۱۷,۲۷	LOCLCA(8)
-----	-----	-----	-----	-----
۲۶۹۷۰	۲۶۷۰۶	۴۰	۲۶۶۲۶,۲۳	LOCLCA(9)

این وضعیت به تفکیک هر یک از طبقات صفر تا ۹ نیز قابل مشاهده است (مقادیر زیر هر یک از ستون‌های Cat1 تا Cat8 برای هر یک از سه ارزیاب را مقایسه کنید. عدد کمتر نشان‌دهنده سهل‌گیری و عدد بزرگتر نشانه سخت‌گیری است. عبارت NA به عدم استفاده ارزیاب از رتبه مربوطه اشاره دارد). به علاوه براساس مقادیر ستون آلفا (alpha) ارزیاب اول دارای بیشترین قدرت تشخیص (۵/۲۱) و ارزیاب دوم دارای کمترین قدرت تشخیص (۳/۸۷) است.

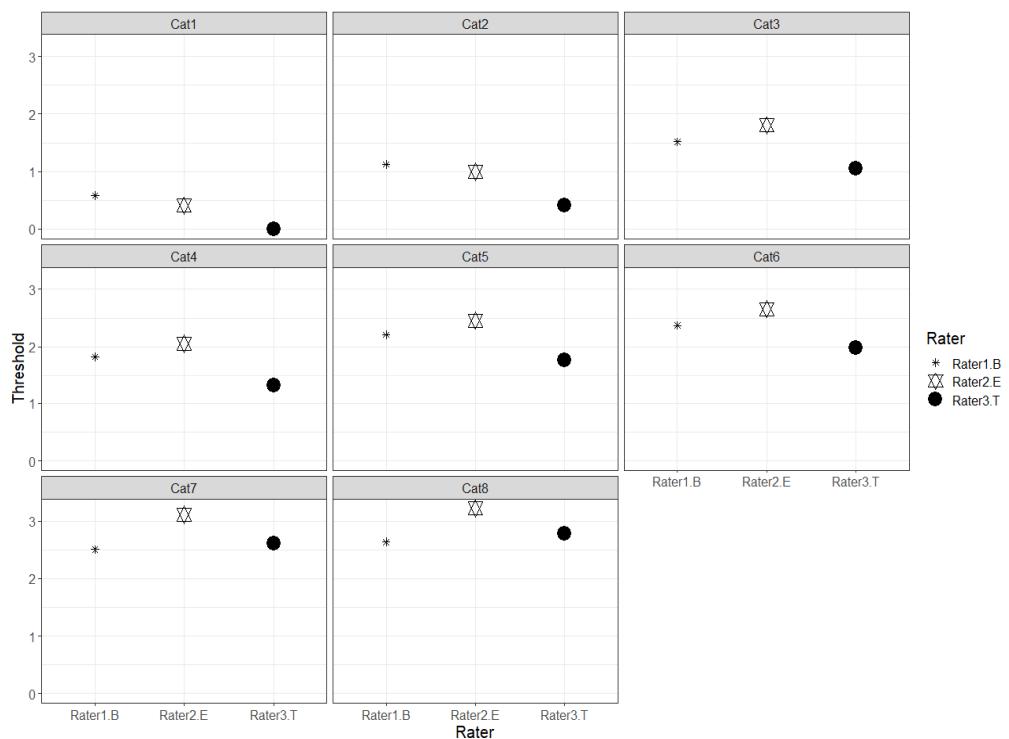
جدول ۱۰: آماره‌های مربوط به سه ارزیاب در آزمون طراحی معماري بخش سکشن

Cat8	Cat7	Cat6	Cat5	Cat4	Cat3	Cat2	Cat1	Beta	alpha	ارزیاب
۰/۶۸	۰/۶۹	۰/۵۳	۰/۴۲	-۰/۰۴	-۰/۳۱	-۰/۷۱	-۱/۲۵	۱/۸۵	۵/۲۱	۱
۰/۸۷	۱/۲۶	۰/۴۵	۰/۴۷	-۰/۱۱	-۰/۱۸	-۱/۱۱	-۱/۶۵	۲/۰۷	۳/۸۷	۲
۲/۵۸	NA	۰/۴۲	۰/۳۵	-۰/۲۳	-۰/۳۸	-۱/۱۰	-۱/۶۷	۱/۴۸	۴/۹۶	۳

براساس نتایج نمودار ۵ و ۶ هر سه ارزیاب از طبقه ۹ مقیاس نمره‌گذاری اصلاً استفاده نکرده‌اند که حاکی از سخت‌گیری آنها در استفاده از این طبقات است. ارزیاب اول و خصوصاً سوم در استفاده از طبقات اول سهل‌گیر بوده‌اند. با توجه به اینکه تغییرپذیری در طبقات پایین بیشتر از طبقات بالا است می‌توان گفت توافق بین ارزیابان در طبقات بالا بیشتر از طبقات پایین است. هر چند که این توافق بسیار پایین است. به نظر می‌رسد نوعی گرایش به مرکز در ارزیاب دوم و اول نیز وجود دارد.



نمودار ۵: مقایسه سه ارزیاب بخش سکشن براساس ۹ طبقه. محور افقی از چپ به راست ارزیاب ۱ تا ۳ و محور عمودی دشواری هر یک از ۹ طبقه



نمودار ۶: مقایسه سه ارزیاب در بخش سکشن براساس ۹ طبقه مختلف رتبه‌بندی

بحث و نتیجه‌گیری

با توجه به بحث مطابقت مطلق (که با روش‌های مثل شاخص توافق دقیق و کاپای وزن دار کوهن ارزیابی می‌شود) و نسبی (که با روش‌های مثل ضریب همبستگی گشتاوری پیرسون و تاو b کن达尔 ارزیابی می‌گردد) درجه‌بندی‌ها، می‌توان گفت در آزمون‌های اسکیس معماری شاخص‌های هم‌سانی مثل همبستگی پیرسون و تاو b کن达尔 ارزیابی می‌گردند. در ترتیب‌بندی ارزیابان است، ولی براساس تاو b کن达尔 میزان توافق مطلق چندان قابل قبول نیست، که با توجه به سرنوشت ساز بودن این آزمون نگران کننده است. به بیان دقیق‌تر، براساس شاخص‌های توافق نتایج نشان داد که در آزمون‌های اسکیس معماری وقتی ارزیابان دو به دو با هم مقایسه شوند یا وقتی هر سه ارزیاب با هم مقایسه شوند میزان توافق یا اجماع بسیار پایین است که با توجه به اهمیت این آزمون اصلاً قابل قبول نیست. در آزمون طراحی معماری فقط در بخش سکشن همسانی قابل قبولی بین سه ارزیاب وجود دارد. در بخش‌های پلان و پرسپکتیو همسانی در حد متوسط و پایین است که قابل قبول نیست.

براساس شاخص‌های اجماع در بخش‌های پلان و پرسپکتیو توافق بین ارزیابان بسیار پایین است، در حالی که در بخش سکشن یک توافق نسبی ضعیف بین ارزیابان وجود دارد. این موضوع نشان می‌دهد که احتمالاً بخش سکشن از نظر محتوایی با بخش‌های پلان و پرسپکتیو متفاوت است. اثر جدیت به این معنی است که ارزیاب تمایل دارد پایین‌تر از نقطه میانی مقیاس اندازه‌گیری، درجه‌بندی نماید. اثرات ارزیاب، از جمله جدیت، می‌تواند نمره‌های آزمون‌ها را تا حد زیادی تحت تاثیر قرار دهد و در نتیجه داوطلبان حتی اگر از توانایی بالایی هم برخوردار باشند قربانی این اثر ارزیاب می‌شوند. بهتر است برای کاهش اثرات جدیت و تاثیر آن بر رتبه‌دهی آزمون‌ها و مقابله با جدیت بیشتر ارزیابان مقیاس‌های درجه‌بندی طراحی شود، که در سمت مثبت آن چند طبقه مقیاس و در سمت منفی آن تعداد کمتری طبقه مقیاس وجود دارد؛ همچنین برای تعدیل نمره‌های ارزیابان در جدیت از روش‌های آماری استفاده شود (اکس ، ۲۰۱۱)، ارزیابان در اثر گرایش به مرکز از طبقه وسط مقیاس اندازه‌گیری بیش از حد استفاده می‌کنند. پیامد گرایش به مرکز در نمره‌گذاری آزمون‌ها این است که درجه‌بندی‌ها در وسط مقیاس جمع شده و طیف موثر مقیاس کاهش یافته و باعث می‌شود قدرت تشخیص درجه‌بندی‌ها کاهش یابد. این موضوع موجب می‌شود هم پایایی و هم روایی کاهش یابد (دکاتیس^۱، ۱۹۷۷). مطابق انتظار در پژوهش حاضر اثر گرایش به مرکز در بین ارزیابان مشاهده نشد، بلکه نتایج بیشتر از سخت‌گیری آنها حکایت داشت. با توجه به نتایج حاصل از پژوهش حاضر می‌توان گفت ارزیابان می‌توانند نمرات فرآگیران را تا حد زیادی تحت تاثیر قرار دهد. بنابر این نیاز است به ارزیابان قبل از تصحیح و نمره‌گذاری آزمون‌ها آموزش لازم و کافی داده شود تا آن‌ها کمترین میزان خطأ را در زمان ارزیابی و نمره‌گذاری داشته باشند. این آموزش می‌تواند به روش‌های مختلف انجام شود. به علاوه لازم است طرح نمره‌گذاری استفاده شده در آزمون‌های عملکردی مورد بازبینی قرار بگیرد به طوری که امکان ارزیابی دوران از روی داده‌ها با مدل‌های مختلف فراهم شود. از سوی دیگر طیف نمره‌گذاری صفر تا ۱۰۰ یا صفر تا ۷۰ برای نمره‌گذاری آزمون‌های عملی سازمان سنجش مناسب نیست. به این دلیل که طیف استفاده شده آنقدر گسترشده است که برخی از طبقات آن اصلاً توسط ارزیابان استفاده نمی‌شود و در عین حال تصمیم‌گیری در خصوص اختصاص رتبه را برای ارزیاب با مشکل همراه می‌سازد. به علاوه در پیشینه ارزیابی آزمون‌های عملی سیستمی شبیه این طیف مشاهده نشد. به همین دلایل بهتر است طیف محدودتری مثل صفر تا ۱۰ برای این منظور استفاده شود. این طور به نظر می‌رسد که طیف صفر تا ۱۰۰ یا صفر تا ۷۰ استفاده شده توسط ارزیابان به هنگام ارزیابی کارهای عملی به عنوان نمره مورد استفاده قرار می‌گیرد نه رتبه‌ای که ارزیابان به کارهای افراد اختصاص می‌دهند، که البته جای بحث دارد. در کنار این موضوع باید توجه شود که مطابق نتایج حاصل از مدل‌های

^۱. DeCotiis

چند وجهی راش در بخش‌های مختلف آزمون طراحی معماری ارزیابان تمایل دارند داوطلبان را در بخش پلن در هفت تا هشت طبقه، در بخش پرسپکتو در چهار تا پنج و در بخش سکشن در هشت گروه طبقه‌بندی کنند. این یافته تاییدی بر عدم تناسب و ناهمخوانی طیف نمره‌گذاری استفاده شده با آنچه که ارزیابان در عمل انجام می‌دهند است. به علاوه لازم است استفاده از رویکردهای موجود در مدل‌های چند وجهی راش مورد توجه قرار گیرد، چرا که می‌تواند مقیاس‌های دقیق‌تر و کاربردی‌تری فراهم سازد تا ارزیابان بتوانند با استفاده از آن، نمرات دقیق‌تری به آزمون‌های عملی بدهند. چرا که آماره‌های موجود در رویکرد مدل‌های چند وجهی به ما می‌گویند که تا چه اندازه مقیاس‌های طراحی شده برای نمره‌گذاری دقیق است.

References

- Andrich, D. (2005). *Rasch, Georg. Encyclopedia of Social Measurement*, 3, 299–306. Angeles, CA: Sage.
- Bijani, H. (2018). Effectiveness of A Training Program on Oral Performance Assessment: The Analysis of Tasks Using the Multifaceted Rasch Analysis. *Journal of Modern Research in English Language Studies*, 5(4), 27-53.
- Bond, T. G., & Fox, C. M. (2015). *Applying the Rasch model: Fundamental measurement in the human sciences* (3rd ed.). New York, NY: Routledge.
- DeCotiis, T. A. (1977). An analysis of the external validity and applied relevance of three rating formats. *Organizational Behavior and Human Performance*, 19, 247-266.
- Eckes, T. (2011). *Introduction to many-facet Rasch measurement*. Frankfurt am Main: Peter Lang.
- Embretson, S. E., & Reise, S. P. (2000). *Item response theory for psychologists*. Mahwah, NJ: Erlbaum.
- Engelhard Jr, G. (1994). Examining rater errors in the assessment of written composition with a many-faceted Rasch model. *Journal of Educational Measurement*, 31(2), 93-112.
- Esfandiari, R. (2014). A Many-Facet Rasch Measurement of Bias among Farsi-Native Speaking Raters toward Essays Written by Non-Native Speakers of Farsi. *Journal of Teaching Persian to Speakers of Other Languages*, 3(VOL.3,NO.3,(TOME 8)), 25-54.
- Esfandiari, R. & Mvford, C. M. (2013). Severity Differences Among Self-Assessors, Peer-Assessors, and Teacher Assessors Rating EFL Essays. *Assessing Writing*, 18(2): 111-131.
- Fleiss, J. L., Levin, B., & Paik, M. C. (2003). *Statistical methods for rates and proportions* (3rd ed.). Hoboken, NJ: Wiley.
- Gamer, M., Lemon, J., Fellows, I., & Singh, P. (2019). *IRR: various coefficients of interrater reliability and agreement*. 2012. R package version 0.84, 1.
- Hays, W. L. (1994). *Statistics* (5th ed.). Belmont, CA: Wadsworth.
- Kempf, W. F. (1972). Probabilistische Modelle experimentalpsychologischer Versuchssituationen [Probabilistic models of designs in experimental psychology]. *Psychologische Beiträge*, 14, 16–37.
- Kim, S. C., & Wilson, M. (2009). A comparative analysis of the ratings in performance assessment using generalizability theory and the many-facet Rasch model. *Journal of applied measurement*, 10(4), 408–423.
- Knoch, U. (2011). Investigating the effectiveness of individualized feedback to rating behavior: A longitudinal study. *Language Testing*, 28, 179–200.
- Linacre, J. M. (1989). *Many-facet Rasch measurement*. Chicago: MESA Press.
- Linacre, J. M. (2006a). Demarcating category intervals. *Rasch Measurement Transactions*, 19, 1041–1043.
- Linacre, J. M. (2014b). *A user's guide to FACETS: Rasch-model computer programs*. Chicago: Winsteps.com. Retrieved from <http://www.winsteps.com/facets>.
- Linacre, J. M., & Wright, B. D. (1989). The length of a logit. *Rasch Measurement Transactions*, 3, 54–5.
- Linacre, J. M., & Wright, B. D. (2002). Construction of measures from many-facet data. *Journal of Applied Measurement*, 3, 484–509.
- Ludlow, L. H., & Halev, S. M. (1995). Rasch model logits: Interpretation, use, and transformation. *Educational and Psychological Measurement*, 55, 967–975.

- Masters, G. N. (2010). The partial credit model. In M. L. Nering & R. Ostini (Eds.), *Handbook of polytomous item response theory models* (pp. 109–122). New York, NY: Routledge.
- Micko, H. C. (1970). Eine Verallgemeinerung des Meßmodells von Rasch mit einer Anwendung auf die Psychophysik der Reaktionen [A generalization of Rasch's measurement model with an application to the psychophysics of reactions]. *Psychologische Beiträge*, 12, 4–22.
- Myers, J. L., Well, A. D., & Lorch, R. F. (2010). *Research design and statistical*.
- Myford, C. M., & Wolfe, E. W. (2003). Detecting and measuring rater effects using many-facet Rasch measurement: Part I. *Journal of applied measurement*, 4(4), 386–422.
- Ostini, R., & Nering, M. L. (2006). Polytomous item response theory models. Thousand Oaks, CA: Sage.
- Penfield, R. D. (2014). An NCME instructional module on polytomous item response theory models. *Educational Measurement: Issues and Practice*, 33(1), 36–48.
- Robitzsch, A., & Steinfeld, J. (2018a). *immer: Item response models for multiple ratings*. R package version 1.1-35.
- Robitzsch, A., & Steinfeld, J. (2018b). Item response models for human ratings: Overview, estimation methods, and implementation in R. *Psychological Test and Assessment Modeling*, 60(1), 101–139.
- Smith Jr. E. V., & Kulikowich, J. M. (2004). An application of generalizability theory and many-facet Rasch measurement using a complex problem-solving skills assessment. *Educational and Psychological Measurement*, 64(4), 617–639.
- Stemler, S. F., & Tsai, J. (2008). Best practices in interrater reliability: Three common approaches. In J. W. Osborne (Ed.), *Best practices in quantitative methods* (pp. 29–49). Los Angeles, CA: Sage.
- Tinsley, H. F. A., & Weiss, D. J. (2000). Interrater reliability and agreement. In Wolfe, E. W. (1997). *The relationship between essay reading style and scoring proficiency in a psychometric scoring system. Assessing Writing*, 4, 83–106.
- Wolfe, E. W., & McVav, A. (2012). Application of latent trait models to identifying substantively interesting raters. *Educational Measurement: Issues and Practice*, 31(3), 31–37.