

Comparing the Results of the Likert Scales Item's Analysis in the Classical Test Theory and the Item Response Theory

Reihane Rahimi  *

Corresponding Author, Assistant Professor, Department of Educational Science, Farhangian University, Tehran, Iran. E-mail: reyhanerahimi1367@gmail.com

Aso Mojtabehdi 

Ph.D. Student in Measurement & Assessment, Allameh Tabataba'i University, Tehran, Iran. E-mail: asomojtahedi@gmail.com

Abstract

The goal of this research is to explore the Likert scale questions using two distinct methods: Classical Test Theory and Item Response Theory. By comparing the results of these approaches, the study aims to address the question: "Do the outcomes from these two methodologies align, or do they contradict each other?" The research design followed a descriptive methodology and utilized secondary analysis techniques. The study population consisted of 977 junior high school students. After the data screening process, the final sample size for analyzing extraversion items was 783 students, 763 students for openness items, and 784 students for conscientiousness items. The research instruments were the three subscales of extraversion, openness, and conscientiousness from the Neo Personality Test. The statistical analysis yielded results indicating that a strong internal consistency among items enhanced the accuracy and validity of outcomes derived from the graded response model. However, when items exhibit low internal consistency, caution should be exercised, as the model may yield erroneous thresholds or discrimination coefficients (i.e., false negative or positive). Overall, combining multiple methods of statistical analysis can significantly contribute to more effective analysis and obtaining highly accurate results.

Keywords: Graded Response Model; Item Response Theory; Classical Test Theory; Internal Consistency; Threshold; Discrimination Coefficient

Cite this Article: Rahimi, R., & Mojtabehdi, A. (2024). Comparing the Results of the Likert Scales Item's Analysis in the Classical Test Theory and the Item Response Theory. *Educational Measurement*, 14(55), 146-183. <https://doi.org/10.22054/jem.2023.71953.3431>



© 2016 by Allameh Tabataba'i University Press

Publisher: Allameh Tabataba'i University Press

DOI: <https://doi.org/10.22054/jem.2023.71953.3431>

14(55), Spring 2024, 146-183
eISSN: 2470-6240 ISSN: 2252-004X

Received in revised form April 15, 2023
Accepted October 24, 2023
Article Type: Research Article

Received January 25, 2023
Published Online April 03, 2024
Received in revised form April 15, 2023
Accepted October 24, 2023
Article Type: Research Article

1. Introduction

In the field of psychometrics, the study of the relationship between a continuous latent variable and a categorical observed variable is referred to as Item-Response Theory (IRT) (Ostini & Nering, 2006). Unlike the Classical Test Theory (CTT), which focuses on the overall score, IRT is significant as it emphasizes the analysis of items individually. Concentrating on the item level allows for the development, revision, and optimization of scales tailored to specific applications (Baker, 2001; De Ayala, 2013; Embretson & Reise, 2000; Hambleton et al., 1985). In this study, our focus is on exploring polytomous items with Likert scale from both the perspective of Item-Response Theory (IRT) and Classical Test Theory (CTT). The primary objective of this research is to compare the outcomes generated by the two approaches – Item-Response Theory (IRT) and Classical Test Theory (CTT) – and determine whether their results align or conflict with one another. A secondary yet practical aim is to introduce polytomous IRT models to researchers, aiming to facilitate a better comprehension and accurate interpretation of the concepts and outcomes associated with these models. Additionally, the study seeks to address the challenge of understanding polytomous models and their limited applications in a predominantly dichotomous item context.

2. Literature Review

The Graded Response Model (GRM), introduced by Muraki in 1990, is extensively employed in the analysis of Likert scale items. GRM is also known as the Reduced Graded Response Model (R-GRM) or the Parsimonious, Constrained, or Modified Model. The primary distinction between the Graded Response Model (GRM) and the reduced model, the Reduced Graded Response Model (R-GRM), lies in the estimation of discrimination indices. In the R-GRM, a single discrimination index is computed for all items with the assumption of equal discrimination indices across all items. In contrast, the GRM estimates a unique discrimination index for each individual item, allowing for more precise analysis. Both GRM and R-GRM are suitable for analyzing items on a Likert scale (Toland, 2014).

The Graded Response Model (GRM) extends the two-parameter model used for items with multiple ordinal response options. Unlike the two-parameter model, GRM assigns a unique slope parameter to each item, providing more nuanced insights. Furthermore, GRM

distinguishes itself from the two-parameter model in terms of the computation of discrimination index. In contrast to the two-parameter model, which estimates the difficulty parameter, Graded Response Model (GRM) instead calculates the threshold. For each item, the number of thresholds is equal to the total number of categories minus 1. In the Reduced Graded Response Model (R-GRM), a uniform discrimination parameter is estimated for every item. The primary advantage of the R-GRM (Reduced Graded Response Model) model is that it is more parsimonious, as it lessens the total number of parameters required for estimation. However, this simplification implies the assumption that the relationship between the latent trait and each item remains uniform.

3. Methodology

The participants in this research comprised 977 first-year high school students who had previously completed the Neo test. The intended analysis represents a secondary analysis since the data was already collected for another purpose. All available information was considered for analysis, and no additional data sampling was conducted. During the data screening process, certain participants with item nonresponse were excluded from analysis due to the limitations of item-response models. Separate screening was performed for each personality trait to ensure an accurate representation and reliable evaluation. The analysis of extraversion items was based on the data of 783 participants, while the analysis of openness to experience items was conducted using the information of 763 individuals. Similarly, the analysis of conscientiousness items was carried out utilizing the data of 784 subjects. The research was conducted using 3 subscale items of the NEO personality questionnaire, specifically focused on extraversion, openness to experience, and conscientiousness. These subscales were selected because they showcased varying Cronbach's alpha coefficients, permitting the researcher to effectively pursue the objectives of the study.

The alpha coefficient of the openness characteristic amounted to 0.234, indicative of very weak internal consistency amongst the items in this set. The alpha coefficient for extraversion reached 0.527, denoting an averageinternal consistency within the items in this category. In stark contrast, the alpha coefficient for conscientiousness was considerably higher, at 0.759, demonstrating high internal

consistency amongst the items within this category. The presented data analysis comprises 3 distinct sections, each delving into the following aspects: (1) the analysis of openness items, where the lowest internal consistency was found, (2) the analysis of extraversion items, with an average internal consistency, and finally (3) the analysis of conscientiousness items, which displayed the highest internal consistency. Each section incorporates descriptive information, along with CTT and IRT-based analyses.

Within the section dedicated to descriptive information, the following aspects are detailed: (1) the frequency percentage corresponding to each option response, (2) the average (mean) and dispersion (standard deviation) of each subscale, as well as (3) the mean for each item. In the context of dichotomous items, the mean can be considered an approximate representation of the difficulty index. Analysis within this section was conducted using SPSS software. The examination of items via CTT involves calculating the internal consistency coefficient, with Cronbach's alpha serving as the metric for this purpose. Additionally, the correlation between each item and the overall score (which can be taken as the discrimination index for dichotomous items) is reported, alongside the alpha coefficient in the event of removing each individual item. In the section pertaining to the analysis of IRT on Likert scale items, the Graded Response Model (GRM) proposed by Simjima was utilized. Before carrying out the analysis, a comparison between the fit of the GRM and the R-GRM was performed using the Akaike Information Criterion (AIC), Bayesian Information Criterion (BIC), and LRT index, the full report of which can be found in Table 1. For all three subscales, the GRM was deemed superior to its reduced model, exhibiting a more favorable fit with the data. Therefore, all subsequent analyzes

4. Conclusion

In summary, it is evident that the presence of weak items significantly enhances the likelihood of errors and can lead to erroneous conclusions when employing IRT-based analyzes. Our observations align with this, as seen in the case with openness, where items with very low alpha coefficients and weak or even negative correlations between items were found.

Furthermore, the threshold levels encountered in the items of this collection reach seemingly implausible values such as 11 and 10, which

deviates from the typical range reported by Baker (2001). Generally, latent trait scores and threshold parameters are usually confined between -2 and 2, and even values spanning from -3 to 3 may not be entirely unreasonable. Values beyond this range, however, are atypical and might indicate potential issues with the items or less meaningful responses.

Therefore, employing a scale with suboptimal psychometric qualities (characterized by poor accuracy across or at certain locations along the continuum of the latent trait for items) can compromise the interpretation of potential score inferences, and if utilized as an output variable in a statistical analysis, it may lead to a decrease in the validity of statistical conclusion inferences (Kang & Waller, 2005). The research findings of Zamanpour et al. (2018) further support the notion that if the unidimensionality assumption is rigidly adhered to, the items determined to be suitable in both analyses will be identical. Consequently, if all the assumptions are fulfilled and the items exhibit satisfactory psychometric properties, there should be minimal difference between the two types of analyses. Nevertheless, IRT analyzes offer more thorough and nuanced information. For instance, in the analysis of conscientiousness items, the superiority of IRT models was confirmed. This superiority was attributed to the fact that information regarding the information functions of these items was unattainable through CTT analysis alone. In the analysis of conscientiousness items, while the CTT approach demonstrated all appropriate conditions and there was no evidence of any issues, IRT analysis revealed that these items were incapable of detecting individuals with conscientiousness levels exceeding 2 and failed to provide informative data.

IRT analysis should be preceded by a check to ensure that there is sufficient frequency in each category and that all response options have been adequately selected by the participants of the sample. This study observed that in problematic items, most individuals tended to select specific options, which led to unrealistic ICC values. While there are no strict and explicit guidelines regarding the criterion of adequacy, having more responses within each category can enhance the accuracy of the estimation of item parameters and facilitate the evaluation of the usefulness of the response categories.

When insufficient numbers are employed in the response categories, it may be necessary to aggregate them together to create a reduced

response category system. This approach enhances the accuracy and stability of the item parameter estimation (Toland, 2014). In line with the findings of this research, it would be beneficial to utilize both theoretical approaches for examining the items of each test. This approach guarantees that the weaknesses of each theory are explored and effectively addressed, leading to a comprehensive test evaluation. Furthermore, it is recommended that future studies compare various IRT models with CTT analyses, in order to objectively observe and assess the strengths and limitations of each approach from a practical standpoint.

مقایسه نتایج تحلیل سؤالات طیف لیکرت با نظریه کلاسیک آزمون و نظریه سؤال پاسخ

نویسنده مسئول، استادیار گروه آموزش علوم تربیتی، دانشگاه فرهنگیان، تهران، ایران. رایانامه: reyhanerahimi1367@gmail.com

* ریحانه رحیمی

دانشجوی دکتری رشته سنجش و اندازه‌گیری، دانشگاه علامه طباطبائی، تهران، ایران. رایانامه: asomojtahedi@gmail.com

ئاسو مجتبهدی

چکیده

هدف این مطالعه بررسی سؤالات طیف لیکرت با دو رویکرد نظریه کلاسیک آزمون و نظریه سؤال پاسخ و قرار دادن نتایج این دو رویکرد در کنار یکدیگر و پاسخ به این سؤال است که «آیا نتایج این دو رویکرد همسو بوده یا اینکه در تضاد با یکدیگرند؟». روش پژوهش از نوع توصیفی و از حیث تحلیل داده‌ها یک روش تحلیل ثانویه است. ابزار پژوهش ۳ خردۀ مقیاس برونگرایی، گشودگی و مسئولیت‌پذیری آزمون شخصیت نفو فرم کوتاه (NEO-FFI) بود. آزمودنی‌های موردمطالعه در این پژوهش ۷۶۳ نفر از دانش‌آموزان مقطع متوسطه اول بودند که با حذف افراد در مرحله غربالگری داده‌ها، درنهایت تحلیل سؤالات برونگرایی بر روی اطلاعات ۷۸۳ نفر آزمودنی، تحلیل سؤالات گشودگی بر روی اطلاعات ۷۶۳ نفر آزمودنی و تحلیل سؤالات مسئولیت‌پذیری نیز بر روی اطلاعات ۷۸۴ نفر آزمودنی انجام شد. نتایج تحلیل‌های آماری نشان داد که هرچه همسانی درونی سؤالات بالاتر باشد نتایج دقیق‌تر و معتبرتری از مدل مدرج پاسخ به دست می‌آید و برای سؤالات با همسانی درونی پایین از طریق این مدل باید بسیار محاط عمل کرد، زیرا ممکن است آستانه سؤالات را به صورت وارونه نشان داده یا ضریب تشخیص سؤالات را منفی یا مثبت کاذب نشان دهد. درمجموع کاربرد همزمان روش‌های مختلف تجزیه و تحلیل آماری به تحلیل بهتر و رسیدن به نتایج دقیق‌تر کمک خواهد کرد.

کلیدواژه‌ها: مدل مدرج پاسخ، نظریه سؤال پاسخ، نظریه کلاسیک آزمون، همسانی درونی، آستانه، ضریب تشخیص

تاریخ دریافت: ۱۰/۱۱/۱۴۰۴، تاریخ پذیرش: ۰۲/۰۷/۱۴۰۴، تاریخ بازنگری: ۲۶/۰۱/۱۴۰۴، تاریخ انتشار: ۱۵/۰۱/۱۴۰۴

استناد به این مقاله: رحیمی، ریحانه و مجتبهدی، ئاسو. (۱۴۰۳). مقایسه نتایج تحلیل سؤالات طیف لیکرت با نظریه کلاسیک آزمون و نظریه سؤال پاسخ. *فصلنامه اندازه‌گیری تربیتی*, ۱۴(۵۵)، ۱۴۶-۱۸۳. <https://doi.org/10.22054/jem.2023.71953.3431>

مقدمه

ساختن هر مقیاس یا پرسشنامه‌ای که به لحاظ روان‌سنجدی برای اندازه‌گیری یک صفت مکنون مناسب و کارآمد باشد، مستلزم همکاری تیمی از کارشناسان محتو، متخصصان موضوعی و روان‌سنجدی یا کارشناسان سنجش است (Reeve & Fayers, 2005). وظیفه کارشناس حوزه سنجش در این زمینه استفاده از روش‌های مختلف و معتبر در جهت تأیید یا رد مقیاس موردنظر یا تعدیل و اصلاح سؤالات آن برای رسیدن به مقیاسی معتبر برای اندازه‌گیری هر چه دقیق‌تر آن صفت مکنون از طریق نمودهای آشکار آن است؛ اما اگر طبق نظر Messick (1989) روایی^۱ را فرایندی بی‌پایان بدانیم که همواره باید بررسی و شواهدی در جهت تأیید آن جمع‌آوری شود، آیا وظیفه یک متخصص بعد از ساخت آزمون تمام می‌شود؟ بر اساس این دیدگاه همواره باید در جهت یافتن شواهدی برای روایی تلاش کرد. تیلور^۲ حتی به این مقدار نیز رضایت نداده و معتقد است که روایی و رواسازی^۳ در همه وجوه و مراحل تحقیق وجود داشته و مستلزم پیگیری و بررسی بوده و منحصر به ساخت آزمون نمی‌شود. از نظر تیلور هر عاملی که باعث ایجاد شبه در ادعاهای مربوط به سنجش و پژوهش شود، تهدیدی علیه روایی است. او راه چاره برای مقابله با این تهدیدها را رواسازی می‌داند و رواسازی را زیر سؤال بردن ادعاهای در^۴ حوزه روایی درونی^۴، روایی بیرونی^۵، روایی نتیجه‌گیری آماری^۶ و روایی سازه^۷ معرفی می‌کند (Taylor, 2013، ترجمه یونسی، ۱۳۹۸). اگرچه روایی نتیجه‌گیری آماری را تیلور بیشتر از منظر روش‌های آزمایشی مورد بحث قرار می‌دهد، اما این روایی می‌تواند در سایر پژوهش‌ها نیز مدنظر قرار گیرد. با پیشرفت علم آمار و رشد روزافرون مدل‌های آماری، هر پژوهشگری در بررسی مسئله و فرضیه پژوهشی اش با چندین روش مختلف برای رسیدن به مقصود روبه‌رو است که بعضاً باعث سردرگمی و تردید او می‌شود. یکی از این سردرگمی و تردیدها خاص حوزه روان‌سنجدی است. هر پژوهشگر روان‌سنجدی در مسیر پژوهش خود بیشتر با دو رویکرد نظریه کلاسیک آزمون^۸ و نظریه سؤال

-
1. validity
 2. Taylor, C. S.
 3. validation
 4. internal validity
 5. external validity
 6. statistical conclusion validity
 7. construct validity
 8. Classical Test Theory (CTT)

پاسخ^۱ روبرو است و می‌تواند با انتخاب یکی از این رویکردها یا حتی تلفیق دو رویکرد به بررسی مسئله خود پردازد.

نظریه کلاسیک آزمون اولین نظریه منسجم در حیطه اندازه‌گیری بود که در اوایل قرن بیستم مطرح شد (Courville, 2004). در حقیقت تلاش‌های Spearman (1904) منجر به گسترش این نظریه شد و حدود نیم قرن تنها نظریه در حوزه آزمون‌سازی بود. نظریه کلاسیک آزمون، مدلی از خطای اندازه‌گیری بر اساس ضریب همبستگی است. ضریب همبستگی که توسط اسپیرمن بیان شد برای توضیح خطای اندازه‌گیری از دو مفهوم همبستگی واقعی و همبستگی مشاهده شده کمک می‌گیرد. ضریب همبستگی و نظریه کلاسیک آزمون هر دو بر این فرض استوار هستند که میانگین بدست آمده از همه اندازه‌گیری‌های ممکن با اندازه واقعی در جامعه برابر هستند (Cochran, 1997, cited in Courville, 2004). فرض بنیادی نظریه کلاسیک این است که نمره مشاهده شده فرد، ترکیبی از نمره واقعی و نمره خطای است (Lord & Novick, 1968). در دهه ۱۹۷۰ و اوایل ۱۹۸۰ نظریه کلاسیک تنها ابزار روان‌سنجدی بود که در سنجش پایایی آزمون‌ها و نیز در طراحی آزمون‌های استاندارد به کار می‌رفت (Hambleton & Jones, 1993)؛ اما با رشد روزافزون کامپیوترها به تدریج امکان استفاده از نظریه سؤال پاسخ بیشتر شد و بعد از آن به یک چهارچوب اندازه‌گیری مهم تبدیل گردید (Hambleton & Swaminathan, 2013).

در ادبیات روان‌سنجدی تحلیل رابطه بین متغیر پنهان پیوسته با متغیر مشاهده شده طبقه‌ای را نظریه سؤال پاسخ می‌نامند (Ostini & Nering, 2006). از منظر تئوری، نظریه سؤال پاسخ توانست بر ضعف‌های اساسی نظریه کلاسیک غلبه کرده و مدل‌های آن توانایی این را دارد که ویژگی‌های سؤال‌ها را مستقل از نمونه آزمودنی‌ها و نیز توانایی آزمودنی‌ها را مستقل از نمونه سؤال‌های اجراشده، محاسبه کنند. این خصیصه نامتغیر بودن^۲ ویژگی‌های آماری سؤال و آزمودنی، به طور نظری در IRT نشان داده می‌شود (Hambleton & Swaminathan, 2013). درواقع نظریه سؤال پاسخ مجموعه‌ای از مدل‌های آماری را شامل می‌شود که از طریق مدل‌سازی ریاضی بین متغیر پنهان پیوسته فرد و ویژگی‌های سؤال در پی برآورد احتمال پاسخ درست به سؤال هستند. اهمیت نظریه سؤال پاسخ این است که برخلاف نظریه کلاسیک که بر نمره کل تأکید دارد بر تجزیه و تحلیل در سطح سؤال متمرکز است. تمرکز

1. Item Response Theory (IRT)
2. invariance

در سطح سؤال امکان ابداع، بازنگری و بهینه‌سازی مقیاس‌ها را برای کاربردهای خاص فراهم می‌کند (Baker, 2001; De Ayala, 2013; Embretson & Reise, 2000; Hambleton et al., 1985). البته نظریه کلاسیک نیز روش‌های خاص خودش مثل بررسی ضربی تشخیص و دشواری سؤال یا تأثیر سؤال در ضربی همسانی درونی را برای بررسی سؤالات دارد.

سؤال اساسی که در اینجا مطرح می‌شود این است که اگر نظریه سؤال پاسخ در جهت رفع مشکلات نظریه کلاسیک مطرح شد و توسعه یافت چرا هنوز با حجم زیادی از پژوهش‌ها روبه‌رو هستیم که از روش‌های نظریه کلاسیک در جهت بررسی آزمون‌ها استفاده می‌کنند؟ آیا علت، ناکارآمدی این نظریه جدید است یا اینکه دشواری بیش از حد کار با مدل‌های این نظریه و دشواری تفسیر و درک آن توسط کاربران و پژوهشگران باعث ایجاد چنین وضعیتی شده است؟ یا اینکه نظریه کلاسیک با تمام مشکلاتش توان پاسخ‌گویی به نیازهای آزمون‌سازی را دارد؟ حتی در برخی از پژوهش‌ها مشاهده می‌شود که در صورت استفاده از نظریه سؤال پاسخ از نظریه کلاسیک نیز کمک گرفته شده است. برای مثال گاهی برای تعیین تعداد ابعاد یا تشخیص تک‌بعدی بودن آزمون از تحلیل عاملی استفاده شده است (Toland, 2014; Jeong & Lee, 2016).

با توجه به اهمیت روایی نتایج آماری که در ابتدای بحث مطرح شد و با در نظر گرفتن سؤالاتی که درباره چرا بی مغفول ماندن نظریه سؤال پاسخ در میدان عمل، با وجود همه تعاریفی که از آن در نوشتارهای نظری شده است، در این مطالعه بر آن شدیم که به بررسی سؤالات چند ارزشی با طیف لیکرت از دو منظر IRT و CTT پردازیم. اولین هدف این مطالعه، قرار دادن نتایج این دو رویکرد در کنار یکدیگر و پاسخ به این سؤال که آیا نتایج این دو رویکرد همسو بوده یا اینکه ممکن است نتایج در تضاد با یکدیگر باشند. دومین هدف از این مطالعه که بیشتر جنبه کاربردی دارد، آشنا کردن پژوهشگران با مدل‌های IRT چند ارزشی و تلاش در جهت درک و تفسیر درست مفاهیم و نتایج این مدل‌ها است، زیرا تا حدی درک مدل‌های چند ارزشی دشوار بوده و کاربردهای IRT به همان سؤال‌های دوارزشی محدود شده است.

با توجه به اهداف ذکر شده در این پژوهش سؤالات آزمون نئو فرم کوتاه^۱ که دارای طیف لیکرت هستند استفاده شد. شاید ساده‌ترین و واضح‌ترین دلیل برای توسعه مدل‌های

1. NEO-FFI

IRT چند ارزشی این واقعیت باشد که معمولاً در اندازه‌گیری روان‌شناختی کاربردی از سؤالات چند ارزشی استفاده می‌شود؛ بنابراین نظریه سؤال پاسخ برای اینکه یک رویکرد اندازه‌گیری جامع باشد، راهی جز ارائه روش‌های مناسب برای مدل‌سازی این داده‌ها نداشت تا بتواند در بررسی آزمون‌های شخصیت و نگرش سنج نیز کاربرد داشته باشد (Ostini & Nering, 2006). از طرف دیگر معمولاً برای سنجش روایی از تحلیل عامل تأییدی استفاده می‌شود، درصورتی که تحلیل عاملی برای سؤال‌های با پاسخ پیوسته مناسب است درصورتی که طیف لیکرت دارای پاسخ‌های طبقه‌ای بوده و مدل پاسخ مدرج در نظریه سؤال پاسخ برای این منظور مناسب‌تر است (Jeong & Lee, 2016). به همین خاطر قبل از ورود به روش کار و یافته‌ها، ابتدا توضیحاتی در جهت آشنایی خوانندگان با مدل‌های پاسخ مدرج و پاسخ مدرج کاهش‌یافته در بخش بعدی ارائه شده است.

پیشینه پژوهش

مدل‌های اولیه نظریه سؤال پاسخ در رابطه با سؤال‌های دوارزشی (دارای جواب درست یا غلط) به وجود آمدند؛ ولی به مرور زمان مدل‌های دیگری برای بررسی سؤال‌هایی با بیش از دو گزینه که گزینه درست و غلط درباره آن‌ها صدق نمی‌کرد معرفی شدند. یکی از این مدل‌ها، مدل پاسخ مدرج^۱ است که توسط Samejima (1969) معرفی شده و معمولاً بیشترین کاربرد را در تحلیل سؤالاتی با طیف لیکرت دارد. مدل دیگری که در ادامه این مدل توسط Muraki (1990) معرفی شده مدل پاسخ مدرج کاهش‌یافته^۲ (همچنین معروف به محدودشده^۳، تعدیل شده^۴ یا مقرون به صرفه^۵) است. تفاوت مدل GRM با R-GRM در این است که در مدل کاهش‌یافته برای تمامی سؤالات یک ضریب تشخیص برآورده می‌گردد و فرض بر برابری ضرایب تشخیص است، درصورتی که در مدل اصلی برای هر سؤال ضریب تشخیص جداگانه‌ای برآورده می‌گردد. هر دو این مدل‌ها برای بررسی سؤالاتی با طیف لیکرت مناسب هستند (Toland, 2014).

-
1. Graded Response Model (GRM)
 2. Reduced Graded Response Model (R-GRM)
 3. constrained
 4. modified
 5. parsimonious

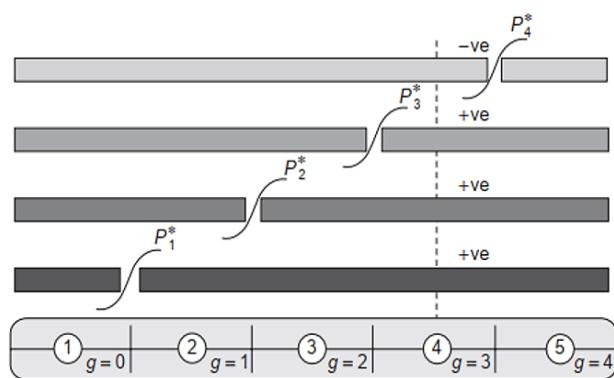
مدل GRM بسطی از مدل دو پارامتری است که برای سؤالات با بیش از دو گزینه که گزینه‌های آن نیز از نوع ترتیبی است، کاربرد دارد. مدل GRM یک پارامتر شیب منحصر به فرد برای هر سؤال ارائه می‌دهد و به لحاظ ضریب تشخیص تفاوتی با مدل دو پارامتری ندارد، اما به جای پارامتر مکانی یا همان دشواری در مدل دو پارامتری، این مدل به برآورد آستانه^۱ می‌پردازد. تعداد آستانه‌های هر سؤال برابر است با تعداد گزینه‌ها آن سؤال منهاج یک، مثلاً در آزمون نئو که دارای ۵ گزینه است، ۴ آستانه برای هر سؤال برآورد می‌گردد؛ بنابراین در یک آزمون ۱۲ سؤالی با ۵ گزینه، ۱۲ پارامتر تشخیص و ۴۸ آستانه برآورد می‌گردد که روی هم رفته ۶۰ پارامتر برای چنین آزمونی برآورد می‌شود؛ اما اگر برای چنین آزمونی از مدل R-GRM استفاده شود کل پارامترهای برآورد شده برابر با ۴۹ پارامتر است؛ زیرا تنها یک پارامتر تشخیص برای تمامی سؤالات برآورد می‌شود. مزیت مدل R-GRM این است که صرفه‌جوی‌تر است، زیرا تعداد پارامترهای موردنیاز برای تخمین را کاهش می‌دهد، اما با این ساده‌سازی، رابطه بین صفت نهفته و هر سؤال یکسان فرض می‌شود.

یکی از مهم‌ترین موارد در کاربرد چنین مدل‌هایی فهم و تفسیر خروجی‌های مدل است. آستانه یکی از پارامترهای مهم و اصلی مدل GRM و R-GRM است که بعضًا دانشجویان و پژوهشگران در تفسیر و فهم آن دچار مشکل می‌شوند. آشنایی با مفهوم پارامتر مکانی یا همان شیب در مدل‌های دوارزشی تا حد زیادی می‌تواند در درک مفهوم آستانه کمک کننده باشد. پارامتر مکانی برابر است با آن میزان از توانایی (صفت مکنون) که احتمال انتخاب پاسخ درست برابر با احتمال پاسخ غلط باشد، یعنی فردی که دارای توانایی مساوی با پارامتر مکانی است، شанс درست جواب دادنش به آن سؤال برابر ۰/۵ است. حال در این مدل‌ها چون با بیش از دو گزینه روبرو هستیم، هر بار گزینه‌ها به دو دسته تقسیم می‌شوند؛ به این شکل که در ابتدا گزینه اول (گزینه با امتیاز کمتر) در مقابل گزینه‌های سطح بالاتر قرار گرفته و برآورد می‌شود که چه میزانی از آن صفت مکنون لازم است تا احتمال انتخاب گزینه اول برابر با احتمال انتخاب مجموعه گزینه‌های بالاتر باشد، این میزان از صفت برآورد شده همان آستانه اول است. در برآورد آستانه دوم، دو گزینه اول (با امتیاز کمتر) در یک دسته و گزینه‌های بالاتر در یک دسته قرار گرفته و باز میزانی از صفت مکنون که لازم است تا احتمال انتخاب این دو طبقه برابر با یکدیگر شوند، برآورد شده و معادل با آستانه دوم تعریف می‌شود. این دسته‌بندی‌های دوتایی تا جایی ادامه پیدا می‌کند که تمامی گزینه‌های ابتدایی

1. threshold

در یک دسته و گزینه انتها یی در دسته دیگر قرار گرفته و آستانه آخر برآورد می‌شود؛ بنابراین آستانه به لحاظ مفهوم تفاوتی با پارامتر مکانی نداشته و حتی می‌توان این گونه تعبیر کرد که پارامتر مکانی همان آستانه در سؤالات دوارزشی بوده و چون دو گزینه بیشتر وجود ندارد و تعداد آستانه نیز برابر با تعداد گزینه‌ها منهای یک است، فقط یک آستانه برآورد شده و نام این یک آستانه را پارامتر مکانی یا دشواری گذاشته‌اند. در شکل زیر که برگرفته از کتاب «مدل‌های نظریه سؤال پاسخ چند ارزشی» تأثیف Ostini and Nering (2006) است مفهوم آستانه به خوبی تصویرسازی شده است. در تصویر زیر سؤالی با ۵ گزینه (g) و ۴ آستانه (P) و طبقه‌بندی‌های ذکر شده و مرز بین طبقات قابل مشاهده است.

شکل ۱. نمایش گرافیکی مدل مدرج پاسخ



در پاراگراف قبلی راجع به آستانه و تفسیر آن بحث شد. به غیر از آستانه، تفسیر و در ک نمودارها یا منحنی‌های حاصل از مدل‌های چند ارزشی نیز دارای اهمیت است. اولین مشکل در شناسایی این منحنی‌ها، نبود یک اسم مشخص و واحد برای نامیدن آن‌هاست. در هر کتاب و مقاله‌ای بنا بر سلیقه نویسنده نامی برای این منحنی‌ها در نظر گرفته شده است. یکی از منحنی‌های استخراج شده از این دو مدل منحنی ویژه عملیاتی^۱ است. منحنی ویژه عملیاتی به نوعی معادل همان ICC در سؤالات دوارزشی است با این تفاوت که ICC برای هر سؤال یک منحنی لاجیت تجمعی در نظر می‌گیرد ولی OCC برای هر آستانه یک منحنی لاجیت تجمعی ارائه می‌دهد. در این منحنی محور افقی متعلق به صفت مکنون و محور عمودی مربوط به احتمال است و برای هر آستانه یک منحنی لاجیت تجمعی رسم شده است. این

1. Operational Characteristic Curve (OCC)

منحنی با نام‌های دیگر از جمله منحنی ویژه کرانی^۱ یا تابع ویژه عملیاتی^۲ نیز معرفی می‌شود؛ علاوه بر این ممکن است نام‌های دیگری نیز برای این منحنی وجود داشته باشد، مهم آن است که بدانید چنین توابعی دارای منحنی لاจیت تجمعی به تعداد آستانه‌های سؤال هستند. منحنی دیگر که بسیار در این مدل‌ها کاربرد دارند منحنی ویژه طبقات^۳ هستند که احتمال انتخاب هر گزینه را نشان می‌دهند. نکته مهم در رابطه با این منحنی این است که در هر سطحی از صفت مکنون، مجموع احتمالات گزینه‌ها برابر با ۱ می‌شود. اگر هر گزینه در یک سؤال به درستی عمل کند، باید در هر سطحی از صفت مکنون یک گزینه بیشترین احتمال را برای انتخاب شدن داشته باشد و ترتیب قرار گرفتن گزینه‌ها بر روی پیوستار صفت مکنون از کوچک به بزرگ باشد؛ یعنی هرچه در پیوستار صفت به سمت بالا می‌رویم احتمال انتخاب گزینه‌های با امتیاز بیشتر افزایش یابد. این منحنی با نام‌های دیگر مثل تابع پاسخ عملیاتی^۴ یا تابع پاسخ طبقه^۵ نیز معرفی می‌شود (Ostini & Nering, 2006).

روش

آزمون‌های موردمطالعه در این پژوهش ۹۷۷ نفر از دانش‌آموزان مقطع متوسطه اول بودند که آزمون شخصیت نئو برای آن‌ها با هدف ارزیابی ویژگی‌های شخصیتی شان اجرا شده بود؛ بنابراین چون این داده‌ها قبل و با هدف دیگری جمع‌آوری شده‌اند، تحلیل موردنظر از حیث داده‌ها یک تحلیل ثانویه محسوب می‌شود. تمامی این اطلاعات برای تحلیل در نظر گرفته شده و نمونه‌گیری از داده‌ها به عمل نیامد؛ البته در جریان غربالگری داده‌ها، به دلیل محدودیت مدل‌های سؤال پاسخ، آزمودنی‌هایی که سؤال بدون پاسخ داشتند از تحلیل کنار گذاشته شدند. غربالگری برای هر ویژگی شخصیتی به صورت جداگانه انجام شد، برای مثال در بررسی ۱۲ سؤال مربوط به ویژگی بروونگرایی افرادی از مجموعه آزمودنی‌ها حذف شدند که حداقل به یکی از ۱۲ سؤال مربوط به بروونگرایی پاسخ نداده بودند و این رویه برای دو ویژگی دیگر نیز به همین منوال صورت گرفت. درنهایت تحلیل سؤالات بروونگرایی بر روی

-
1. Boundary Characteristic Curve (BCC)
 2. Operational Characteristic Function (OCF)
 3. Category Characteristic Curve (CCC)
 4. Operating Response Function (ORF)
 5. Category Operating Response Function (CORF)

اطلاعات ۷۸۳ نفر آزمودنی، تحلیل سؤالات گشودگی بر روی اطلاعات ۷۶۳ نفر آزمودنی و تحلیل سؤالات مسئولیت‌پذیری نیز بر روی اطلاعات ۷۸۴ نفر آزمودنی انجام شد. ابزار مورد استفاده در این پژوهش همان‌طور که قبلًا ذکر شد، سؤالات مربوط به ۳ خرده مقیاس پرسشنامه شخصیت نئو، شامل برون‌گرایی، گشودگی و مسئولیت‌پذیری بود. این ۳ خرده مقیاس از آن جهت انتخاب شدند که ضریب آلفای کرونباخ متفاوتی داشته و می‌توانستند پژوهشگر را در رسیدن به هدف این پژوهش یاری کنند. ضریب آلفا ویژگی گشودگی برابر ۰/۲۳۴ و نشان‌دهنده همسانی درونی بسیار ضعیف بین سؤالات این مجموعه است. ضریب آلفا ویژگی برون‌گرایی برابر با ۰/۵۲۷ و حاکمی از همسانی درونی متوسط بین سؤالات این مجموعه است. ضریب آلفا ویژگی مسئولیت‌پذیری برابر با ۰/۷۵۹ است که نشان از همسانی درونی مطلوب بین سؤالات این مجموعه است. قبل از انجام هرگونه تجزیه و تحلیلی، سؤالات معکوس هر خرده مقیاس مطابق با دستورالعمل نمره‌گذاری معکوس شده و سپس تحلیل‌های نهایی بر روی آن‌ها انجام شد.

تجزیه و تحلیل داده‌ها در ۳ بخش سؤالات گشودگی (با کمترین میزان همسانی درونی)، سؤالات برون‌گرایی (با میزان همسانی درونی متوسط) و سؤالات مسئولیت‌پذیری (با بیشترین میزان همسانی درونی)، ارائه شده است که هر کدام شامل اطلاعات توصیفی، تحلیل مبتنی بر نظریه کلاسیک آزمون و تحلیل مبتنی بر نظریه سؤال پاسخ می‌شوند. در بخش اطلاعات توصیفی در صد فراوانی انتخاب هر گزینه در هر سؤال، میانگین و انحراف استاندارد هر خرده مقیاس و میانگین مربوط به هر سؤال که همان ضریب مقبولیت سؤال است و معادل دشواری در سؤالات دوارزشی است، گزارش شده است. تحلیل‌های این بخش از طریق نرم‌افزار SPSS انجام شد. تحلیل مبتنی بر نظریه کلاسیک آزمون به بررسی ضریب همسانی درونی سؤالات پرداخته و از ضریب آلفا کرونباخ برای رسیدن به این هدف استفاده کرده است. همچنین همبستگی بین هر سؤال با نمره کل آزمون که معادل ضریب تشخیص است و ضریب آلفا در صورت حذف هر سؤال گزارش شده است. در بخش مربوط به تحلیل‌های نظریه سؤال پاسخ با توجه به طیف لیکرت سؤالات، از مدل پاسخ مدرج پیشنهادی سیمجهیما استفاده شد. قبل از انجام تحلیل، برازش مدل پاسخ مدرج و مدل پاسخ مدرج کاهش یافته با استفاده از شاخص ضریب آکائیک^۱ و شاخص ضریب بیزی^۲ و شاخص LRT مورد مقایسه گرفتند.

1. Akaike Information Criterion (AIC)

2. Bayesian Information Criterion (BIC)

که گزارش کامل آن در جدول ۱ آمده است و برای هر ۳ خرده مقیاس مدل پاسخ مدرج بر مدل کاهش یافته آن برتری داشته و برآذش بهتری با داده‌ها نشان داد، بنابراین همه تحلیل‌ها بر اساس مدل پاسخ مدرج که شامل آستانه‌ها و ضرایب تشخیص متفاوت برای هر سؤال است، انجام شد. همچنین تابع آگاهی کلی و تابع آگاهی مربوط به هر سؤال به علاوه منحنی‌های ویژه عملیاتی و منحنی آگاهی مربوط به هر سؤال در این بخش گزارش شده است. تمامی تحلیل‌های این بخش از طریق نرم‌افزار RStudio و با استفاده از پکیج "lme4" انجام شد. کدهای دستوری اجرا شده در پیوست آمده است.

جدول ۱. شاخص‌های برآذش دو مدل پاسخ مدرج و پاسخ مدرج کاهش یافته

p.value	LRT	BIC	AIC	مدل	ویژگی
<0,001	۲۶۳/۱۴	۲۶۷۴۷/۶۶	۲۶۵۲۰/۴۳	GRM-R	گشودگی
		۲۶۵۵۷/۵۲	۲۶۲۷۹/۲۹	GRM	
<0,001	۳۰۰/۷۸	۲۶۶۴۰/۵۷	۲۶۴۱۲/۰۸	GRM-R	برون‌گرایی
		۲۶۴۱۳/۰۹	۲۶۱۳۳/۳	GRM	
<0,001	۵۸/۶۷	۲۶۶۴۰/۵۷	۲۶۴۱۲/۰۸	GRM-R	مسئولیت‌پذیری
		۲۳۳۹۴/۲۶	۲۳۱۱۴/۴	GRM	

بر اساس اطلاعات مندرج در جدول بالا، شاخص ضریب آکائیک و شاخص ضریب بیزی برای هر سه ویژگی در مدل پاسخ مدرج کوچک‌تر از مدل پاسخ مدرج کاهش یافته است و درنتیجه مدل پاسخ مدرج نسبت به مدل کاهش برآذش بهتری دارد. چون به طور معمول مدل‌های پیچیده‌تر برآذش بهتری نسبت به مدل‌های کاهش یافته و ساده‌تر نشان می‌دهند (Sorrel et al., 2016) به این دو شاخص اکتفا نشده و از آزمون LRT که برای مقایسه بین دو مدل که یکی در دیگری آشیانه^۱ کرده، کاربرد دارد، استفاده شد. نتیجه آزمون LRT نشان داد که بین دو مدل به لحاظ آماری تفاوت وجود داشته و برتری مدل پاسخ مدرج بر حسب شانس نبوده است؛ بنابراین تمامی تحلیل‌های گزارش شده در بخش یافته‌ها مبنی بر مدل پاسخ مدرج است.

1. nested

یافته‌ها

در این بخش اطلاعات به دست آمده از تجزیه و تحلیل‌های آماری گزارش شده است. تحلیل‌های انجام شده برای مجموعه سؤالات هر خردۀ مقیاس به طور جداگانه ارائه شده است؛ به‌این ترتیب که ابتدا تحلیل‌های مربوط به ویژگی گشودگی، سپس اطلاعات مربوط به ویژگی برون‌گرایی و درنهایت تحلیل مربوط به ویژگی مسئولیت‌پذیری آمده است. درواقع ابتدا سؤالات با کمترین همسانی درونی (سؤالات گشودگی) سپس سؤالات با همسانی درونی متوسط (سؤالات برون‌گرایی) و درنهایت سؤالات با همسانی درونی مطلوب (سؤالات مسئولیت‌پذیری) گزارش شده‌اند. لازم به ذکر است که به خاطر رعایت اختصار، در جداول و نمودارها به جای ارائه صورت سؤال شماره سؤالات درج گردیده است. برای آگاهی از صورت سؤالات به پیوست مراجعه شود.

گشودگی: این ویژگی سومین ویژگی شخصیتی موردمطالعه در آزمون شخصیت نئو است که با ۱۲ سؤال اندازه‌گیری می‌شود. اندازه نمونه موردمطالعه در این ویژگی برابر با ۷۶۳ نفر است که میانگین نمرات گشودگی آن‌ها برابر با ۲۶/۱۹ و انحراف استاندارد آن برابر با ۴/۷۲ است. کمترین نمره گشودگی برابر با ۹ و بیشترین آن برابر با ۴۰ است. در جدول زیر درصد فراوانی انتخاب هر گزینه توسط افراد، میانگین مربوط به هر سؤال (ضریب مقبولیت)، همبستگی سؤال با نمره کل (ضریب تشخیص بر اساس نظریه کلاسیک آزمون) و آلفا در صورت حذف سؤال گزارش شده است.

جدول ۲. فراوانی درصدی انتخاب هر گزینه، میانگین و همبستگی هر سؤال با نمره کل و ضریب آلفا در صورت حذف سؤال

سؤال	گزینه ۱	گزینه ۲	گزینه ۳	گزینه ۴	گزینه ۵	میانگین	همبستگی	آلفا
۰/۲۶۷	-۰/۰۱۶	۱/۳۵	۱۱/۳	۱۳/۵	۱۲/۸	۲۳/۳	۳۹/۱	۱
۰/۲۷۲	-۰/۰۵۰	۰/۹۸	۵/۱	۷/۱	۱۴/۵	۲۷/۴	۴۵/۹	۲
۰/۲۰۳	۰/۱۱۵	۳/۲۶	۵۴/۴	۲۸/۶	۹/۴	۴/۲	۳/۴	۳
۰/۱۸۵	۰/۱۳۷	۲/۵۸	۳۶/۲	۱۸/۱	۲۴	۱۰/۶	۱۱/۱	۴
۰/۱۸۱	۰/۱۵۲	۲/۶۲	۲۹/۲	۳۰/۸	۲۰/۶	۱۱/۱	۸/۳	۵
۰/۲۴۱	۰/۰۲۹	۲/۰۷	۱۶/۹	۲۳/۷	۲۴/۹	۱۸/۹	۱۵/۶	۶
۰/۲۲۸	۰/۰۵۳	۲/۱۲	۱۳/۴	۲۲	۳۸/۱	۱۶/۳	۱۰/۲	۷
۰/۲۹۸	-۰/۱۲۳	۱/۱۵	۴/۵	۷/۳	۱۹/۸	۳۵/۵	۳۲/۹	۸

مقایسه نتایج تحلیل سؤالات طیف لیکرت با نظریه ... | رحیمی و مجتبی | ۱۶۳

سؤال	گزینه ۱	گزینه ۲	گزینه ۳	گزینه ۴	گزینه ۵	میانگین	همبستگی	آلفا
۰/۱۵۹	۰/۲۰۰	۲/۳۴	۱۸/۲	۲۹/۶	۲۸/۳	۱۵/۲	۸/۷	۹
۰/۱۶۸	۰/۱۸۳	۲/۷۷	۳۴/۱	۲۹/۸	۲۱/۶	۸/۴	۷/۲	۱۰
۰/۱۹۹	۰/۱۲۲	۲/۹۴	۳۸/۳	۳۱/۵	۱۹/۴	۷/۶	۳/۳	۱۱
۰/۲۰۰	۰/۱۱۳	۲/۰۲	۱۴/۲	۲۱/۲	۳۰/۷	۲۰/۳	۱۳/۶	۱۲

بر اساس درصد فراوانی‌های گزارش شده در جدول بالا، در سؤالات ۱، ۲ و ۸ بیش از ۶۰ درصد افراد دو گزینه ابتدایی را انتخاب کرده‌اند و در سؤالات ۳، ۱۰، ۱۱ و ۱۲ بیش از ۶۰ درصد افراد دو گزینه پایانی را برگزیده‌اند. بیشترین ضریب مقبولیت برای سؤال ۳ و برابر با ۳/۲۶ و کمترین آن مربوط به سؤال ۲ و برابر با ۰/۹۸ است. با توجه به محتوای این دو سؤال و در نظر گرفتن این نکته که سؤالات معکوس قبل از انجام هر تحلیلی در جهت سازه گشودگی نمره‌گذاری شده‌اند، می‌توان گفت که بیشتر افراد مورد مطالعه در صورت یافتن راه درست انجام یک کار، مدام آن را تکرار می‌کنند و پدیده‌های طبیعی و هنری نیز آن‌ها را مبهوت می‌کند.

سؤالات ۱، ۲ و ۸ دارای ضریب تشخیص منفی بوده و با سؤالات دیگر مربوط به گشودگی رابطه منفی نشان داده‌اند. از طرف دیگر با توجه به ضریب آلفای کرونباخ مربوط به ۱۲ سؤال گشودگی که برابر با ۰/۲۳۴ است، در صورت حذف سؤالات ۱، ۲، ۶ و ۸ ضریب آلفا افزایش می‌یابد. این نتیجه نشان می‌دهد که این ۴ سؤال تهدیدی برای همسانی درونی سؤالات این مجموعه هستند. در ادامه تحلیل مبتنی بر نظریه سؤال پاسخ که با مدل "GRM" "انجام‌شده گزارش شده است. در جدول زیر ضریب تشخیص و آستانه‌های مربوط به هر سؤال گزارش شده است.

جدول ۳. ضریب تشخیص و آستانه‌های مربوط به هر سؤال

سؤال	ضریب تشخیص	آستانه ۱	آستانه ۲	آستانه ۳	آستانه ۴
۱	۰/۲۷۹	۴/۰۸۴	۱/۸۸۶	-۱/۵۹۲	۰/۲۷۹
۲	۰/۴۳۵	۴/۶۹۴	۲/۴۱۵	-۰/۳۹۴	۶/۸۹۲
۳	-۱/۰۰۵	۱/۷۹۳	۲/۷۶۷	۳/۶۲۹	۰/۲۱۰
۴	-۰/۵۵۳	۰/۴۰۰	۲/۵۱۸	۳/۹۹۰	-۱/۰۵۳
۵	-۰/۶۸۳	۰/۶۷۷	۲/۲۸۵	۳/۷۸۴	-۱/۴۱۵
۶	-۰/۱۸۸	-۱/۹۸۹	۳/۴۹۴	۹/۰۷۲	-۸/۵۱۲

سؤال	ضریب تشخیص	آستانه ۱	آستانه ۲	آستانه ۳	آستانه ۴
۷	-۰/۱۸۶	۱۱/۷۸۸	۵/۵۹۵	-۳/۱۹۳	-۱۰/۰۸۵
۸	۰/۶۸۱	-۱/۱۳۳	۱/۲۷۰	۳/۱۹۹	۴/۷۹۲
۹	-۰/۶۵۹	۳/۸۴۱	۱/۹۴۶	-۱/۱۰۷	-۲/۴۶۱
۱۰	-۱/۰۶۶	۲/۹۸۱	۲/۰۰۲	۰/۶۸۷	-۰/۷۳۲
۱۱	-۰/۹۴۵	۳/۹۸۲	۲/۵۰۵	۱/۰۴۵	-۰/۵۹۹
۱۲	-۰/۲۱۶	۸/۷۶۴۸	۳/۱۹۲	-۲/۷۳۴	-۸/۳۶۸

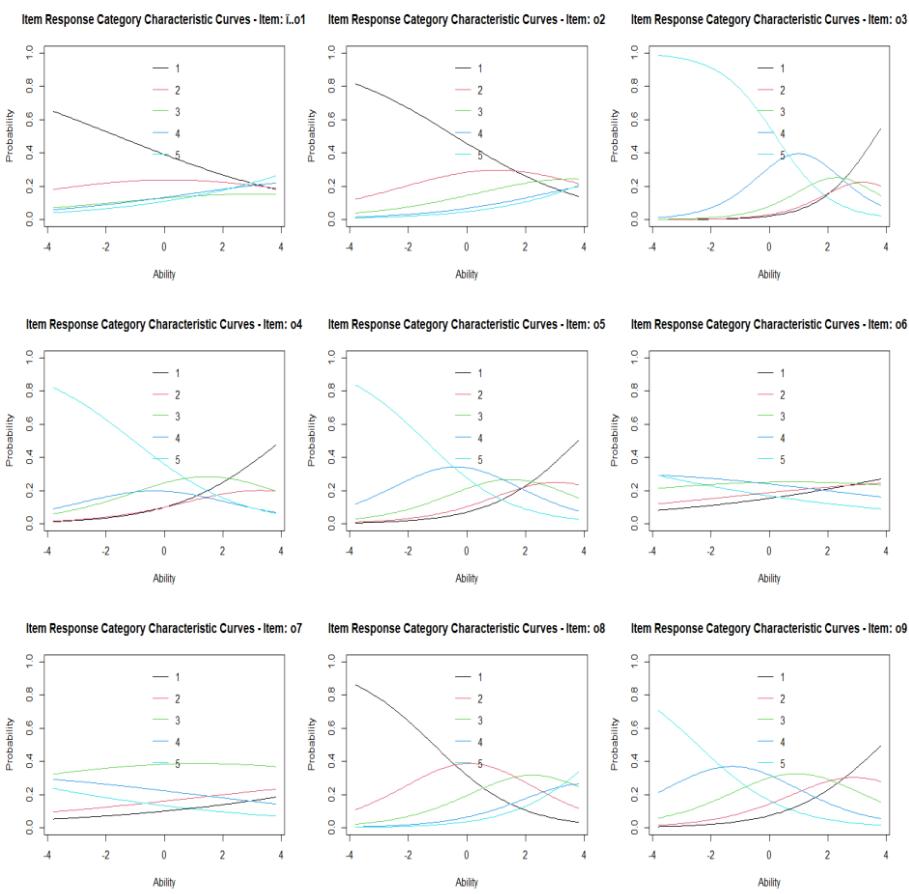
همان‌طور که در جدول بالا مشاهده می‌شود، ضریب تشخیص به دست آمده از نظریه سؤال پاسخ عکس نتیجه‌ای است که از نظریه کلاسیک به دست آمده است؛ در واقع در اینجا همه ضرایب تشخیص منفی و تنها ضریب تشخیص مربوط به سؤالات ۱، ۲ و ۸ مثبت شده است. سؤالات ۳ و ۱۰ ضریب تشخیص بالایی به لحاظ بزرگی دارند متنها ضریب تشخیص‌شان منفی است.

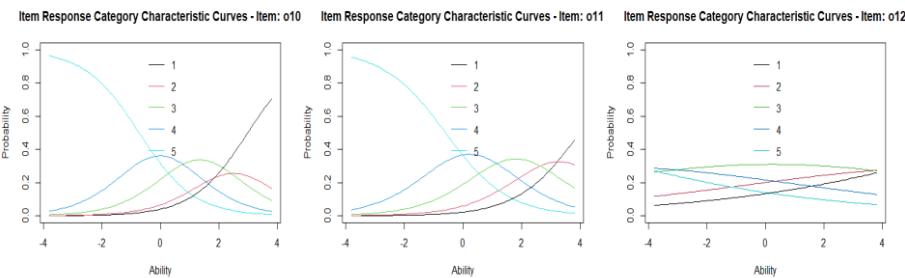
در ستون‌های بعدی جدول میزان آستانه گزارش شده است. تعداد آستانه برای هر سؤال برابر است با تعداد گزینه‌های سؤال منهای یک. با توجه به اینکه در پرسشنامه نو هر سؤال ۵ گزینه دارد، تعداد آستانه‌ها برابر با ۴ است. میزان آستانه اول برای سؤال یک برابر با -۱/۵۹۲ است، این بدان معناست که شخصی با سطح صفت (گشودگی) برابر با ۱/۵۹۲- احتمال اینکه گزینه ۱ را مقابل گزینه‌های دیگر برگزیند ۵۰ درصد است. آستانه دوم برای این سؤال برابر با ۱/۸۸۶ است، یعنی شخصی با گشودگی ۱/۸۸۶ احتمال اینکه گزینه ۱ و ۲ را در مقابل ۳ گزینه بالاتر برگزیند برابر با ۵۰ درصد است. به لحاظ منطقی باید هر چه به سمت آستانه بالاتر می‌رویم میزان سطح صفت موردمطالعه نیز افزایش یابد؛ ولی همان‌طور که در جدول مشاهده می‌شود این روال تنها برای سؤال ۱، ۲ و ۸ صادق بوده و برای سایر سؤالات عکس این روال صدق می‌کند، برای مثال در سؤال ۳، میزان آستانه اول برابر با ۳/۶۲۹ بوده و هرچه به سمت آستانه‌های بالاتر پیش می‌رویم این میزان کاهش یافته و میزان آستانه چهارم به ۰/۲۱ می‌رسد. در واقع سؤالاتی که دارای ضریب تشخیص منفی بودند، میزان آستانه آن‌های به جای اینکه سیر صعودی داشته باشند، یک سیر نزولی را نشان دادند. می‌توان برای نمایش آستانه‌های هر سؤال از منحنی ویژه عملیاتی (OCC) که یک مدل لاجیت تجمعی و معادل ICC در مدل‌های دوارزشی است، استفاده کرد که در اینجا به دلیل حجم زیاد اطلاعات گزارش نشده، ولی در پیوست ارائه شده است.

۱۶۵ | مقایسه نتایج تحلیل سؤالات طیف لیکرت با نظریه ... | رحیمی و مجتبی

در ادامه منحنی ویژه طبقات پاسخ مربوط به هر سؤال گزارش شده است. منحنی ویژه طبقات که با اختصار CCC نامیده می‌شوند نشان می‌دهند که در هر سطح توانایی احتمال انتخاب هر گزینه چقدر است.

شکل ۲. منحنی ویژه طبقات سؤالات گشودگی

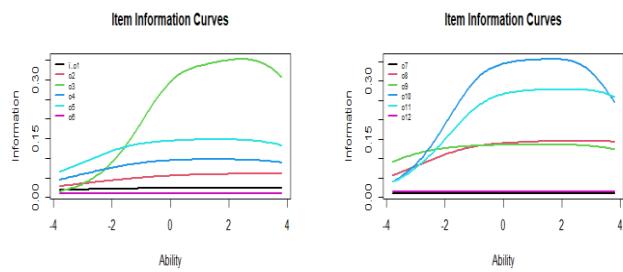




منحنی مشخصات طبقات سوال ۷ و ۱۲ نشان می‌دهد که در هر سطحی از صفت گشودگی احتمال انتخاب گزینه سوم که بیان‌گر حد وسط است، محتمل‌ترین انتخاب است. در سوال اول در طیف وسیعی از صفت گزینه ۱ محتمل‌ترین گزینه انتخابی است و نزدیک به سطح صفت برابر با ۴ گزینه آخر احتمال انتخاب بیشتری را دارد؛ درواقع سایر گزینه‌های این سوال نقش تعیین‌کننده‌ای در تعیین سطح صفت نداشته و وجود آن‌ها در این سوال مهم نبوده است. در سوالات ۳، ۴، ۹، ۱۰، ۱۱ و ۱۲ ترتیب گزینه‌ها عکس شده است، یعنی احتمال انتخاب گزینه‌های با نمره بیشتر در سطح صفت پایین‌تر، بیشتر است؛ این همان نتیجه‌ای است که در مورد ضریب تشخیص و میزان آستانه‌ها نیز شاهد آن بودیم.

درنهایت تابع آگاهی آزمون، محاسبه گردید. آگاهی کل آزمون مبتنی بر این ۱۲ سوال، برابر با 0.68 است که در محدوده $0\text{--}4$ سطح صفت که در این تحلیل مدنظر بود، آگاهی برابر با 0.3 است، یعنی آگاهی این دامنه از سطح صفت تنها شامل $44/9$ درصد از آگاهی کل است. در شکل زیر منحنی آگاهی هر سوال که به اختصار IIC نامیده می‌شود، نمایشن داده شده است. همان‌طور که در تصویر مشاهده می‌شود سوالات ۳، ۱۰ و ۱۱ در دامنه $-2\text{--}4$ بیشترین آگاهی را ارائه می‌کنند، یعنی این سوالات برای برآورده گشودگی افرادی که نمره آن‌ها در بازه $-2\text{--}4$ است، آگاهی‌دهنده‌تر است. سوالات ۱، ۶، ۷ و ۱۲ نیز در تمام سطوح صفت آگاهی پایین و نزدیک به صفر دارند.

شکل ۳: منحنی آگاهی سؤالات گشودگی



برون‌گرایی: این ویژگی دومین ویژگی شخصیتی موردمطالعه در آزمون شخصیت نئو است که با ۱۲ سؤال اندازه‌گیری می‌شود. اندازه نمونه موردمطالعه در این ویژگی برابر با ۷۸۳ نفر است که میانگین نمرات برون‌گرایی آن‌ها برابر با $32/16$ و انحراف استاندارد آن برابر با $5/66$ است. کمترین نمره برون‌گرایی برابر با ۱۳ و بیشترین آن برابر با ۴۵ است. در جدول زیر درصد فراوانی انتخاب هر گزینه توسط افراد، میانگین مربوط به هر سؤال (ضریب مقبولیت)، همبستگی سؤال با نمره کل (ضریب تشخیص بر اساس نظریه کلاسیک آزمون) و آلفا در صورت حذف سؤال گزارش شده است.

جدول ۴. فراوانی درصدی انتخاب هر گزینه، میانگین و همبستگی هر سؤال با نمره کل و ضریب آلفا در صورت حذف سؤال

سؤال	گزینه ۱	گزینه ۲	گزینه ۳	گزینه ۴	گزینه ۵	میانگین	همبستگی	آلفا
۱	۸/۸	۱۷/۲	۱۳/۴	۳۴/۶	۲۵/۹	۲/۵۲	۱/۱۹	۰/۰۱
۲	۹/۱	۱۹/۲	۱۷/۹	۲۹/۹	۲۴	۲/۴۱	۰/۰۳۴	۰/۰۵۲
۳	۷	۹/۸	۱۲/۸	۳۰	۴۰/۴	۲/۸۷	۰/۲۴۵	۰/۴۹۶
۴	۴/۶	۶/۸	۱۵/۱	۳۵/۵	۳۸/۱	۲/۹۶	۰/۳۳۶	۰/۴۷۵
۵	۳/۸	۱۱/۱	۱۹	۳۳/۸	۳۲/۲	۲/۷۹	۰/۲۵۱	۰/۴۹۵
۶	۱۱/۵	۱۷	۱۷/۲	۳۴/۷	۱۹/۵	۲/۳۴	۰/۱۱۲	۰/۵۳۲
۷	۳/۷	۴/۵	۱۵/۲	۳۴/۲	۴۲/۴	۳/۰۷	۰/۳۲۶	۰/۴۷۹
۸	۳/۶	۶/۶	۶/۶	۱۳/۵	۴۰/۲	۳/۰۳	۰/۳۹۳	۰/۴۶۲
۹	۴/۷	۸/۴	۱۲/۳	۲۵/۲	۴۹/۴	۳/۰۶	۰/۳۴۳	۰/۴۷۰
۱۰	۶/۸	۱۲/۹	۲۸/۴	۳۰/۸	۲۱/۲	۲/۴۷	۰/۰۸۵	۰/۵۳۵

سؤال	گزینه ۱	گزینه ۲	گزینه ۳	گزینه ۴	گزینه ۵	میانگین	همبستگی آلفا	۰/۴۸۱	۰/۳۱۹	۲/۹۴	۳۵/۱	۳۵/۵	۲۰/۱	۷	۲/۳	۱۱
۰/۵۶۳	-۰/۰۰۸	۱/۷۱	۱۱/۲	۱۶/۲	۲۷/۲	۲۳/۲	۲۲/۱	۱۲								

مطابق با درصد فراوانی‌های انتخاب هر گزینه، مشاهده می‌شود که به جز سؤال ۱۲ در مورد سایر سؤالات اقبال نسبت به گزینه‌های پایانی بیشتر از گزینه‌های ابتدایی است؛ یعنی بیشتر افراد تمایل به برون‌گرایی داشته‌اند. در سؤالات ۳، ۴، ۷، ۸ و ۱۱ بیش از ۷۰ درصد افراد دو گزینه انتهایی را انتخاب کرده‌اند. بیشترین ضریب مقبولیت برای سؤال ۷ و برابر با ۳/۰۷ و کمترین آن مربوط به سؤال ۱۲ و برابر با ۱/۷۱ است. با توجه به محتوای این دو سؤال و در نظر گرفتن این نکته که سؤالات معکوس قبل از انجام هر تحلیلی در جهت سازه برون‌گرایی نمره گذاری شده‌اند، می‌توان گفت که بیشتر افراد خود را فردی سرشار از انرژی دانسته، ولی ترجیح می‌دهند به تنها ی کار کنند تا اینکه دیگران را راهبری کنند.

سؤال ۱۲ دارای ضریب تشخیص منفی بوده و با سایر سؤالات مربوط به برون‌گرایی رابطه منفی دارد. از طرف دیگر با توجه به ضریب آلفای کرونباخ مربوط به ویژگی برون‌گرایی که برابر با ۰/۵۲۷ است، در صورت حذف سؤالات ۲، ۶، ۱۰ و ۱۲ ضریب آلفا افزایش می‌یابد. این نتیجه نشان می‌دهد که این ۴ سؤال تهدیدی برای همسانی درونی سؤالات این مجموعه هستند. در ادامه تحلیل مبتنی بر نظریه سؤال پاسخ که با مدل "GRM" انجام شده گزارش شده است. در جدول زیر ضریب تشخیص و آستانه‌های مربوط به هر سؤال گزارش شده است.

جدول ۵. ضریب تشخیص و آستانه‌های مربوط به هر سؤال

سؤال	ضریب تشخیص	آستانه ۱	آستانه ۲	آستانه ۳	آستانه ۴
۱	۰/۴۲۰	-۵/۷۴۹	-۲/۶۱۳	-۱/۰۹۶	۲/۵۸۱
۲	۰/۰۹۹	-۲۳/۳۸۱	-۹/۵۰۳	-۱/۶۲۴	۱۱/۶۵۹
۳	۰/۸۹۹	-۳/۲۴۹	-۲/۰۹۴	-۱/۱۷۶	۰/۴۸۲
۴	۰/۹۰۹	-۳/۷۲۳	-۲/۵۸۱	-۱/۳۲۴	۰/۶۱۸
۵	۰/۸۶۷	-۴/۰۸۵	-۲/۲۷۳	-۰/۸۸۹	۰/۹۹۱
۶	۰/۳۳۰	-۶/۳۲۲	-۲/۲۹۱	-۰/۵۸۵	۴/۳۵۵
۷	۱/۲۷۵	-۳/۰۹۶	-۲/۳۶۹	-۱/۲۱۹	۰/۳۰۲

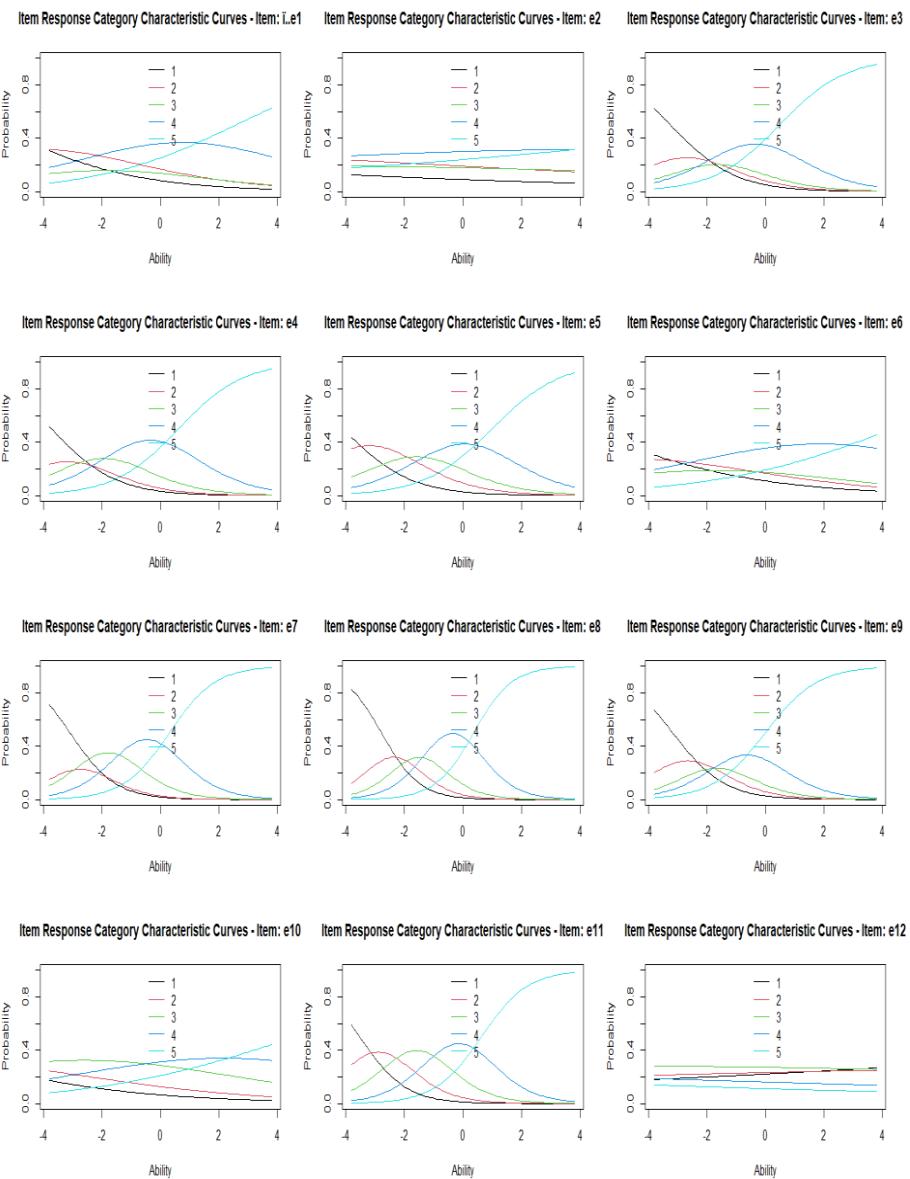
مقایسه نتایج تحلیل سؤالات طیف لیکرت با نظریه ... | رحیمی و مجتبی | ۱۶۹

سؤال	ضریب تشخیص	آستانه ۱	آستانه ۲	آستانه ۳	آستانه ۴
۸	۱/۵۳۰	-۲/۷۸۲	-۱/۹۱۸	-۱/۰۶۲	۰/۳۵۹
۹	۱/۱۱۹	-۳/۱۷۲	-۲/۱۰۲	-۱/۲۴۸	-۰/۰۰۶
۱۰	۰/۲۸۹	-۹/۱۸۸	-۴/۹۰۰	-۰/۲۹۶	۴/۵۹۶
۱۱	۱/۲۶۵	-۳/۵۲۱	-۲/۲۳۷	-۰/۹۰۶	۰/۶۲۲
۱۲	-۰/۰۶۶	۱۸/۹۷۲	۲/۷۷۲	۱۴/۶۹۹	-۳۱/۱۹۳

با بررسی ستون مربوط به ضرایب تشخیص، مشاهده می‌شود که ضریب تشخیص سؤال ۱۲ منفی شده است، یعنی سؤال ۱۲ عکس سایر سؤالات عمل کرده و تشخیص اشتباه در مورد برآورده بروندگاری افراد می‌دهد و این با نتیجه به دست آمده از نظریه کلاسیک آزمون همخوانی دارد. سؤالات ۸ و ۱۱ به ترتیب دارای بالاترین ضریب تشخیص بین سؤالات هستند.

در ستون‌های بعدی جدول میزان آستانه گزارش شده است. در تمامی سؤالات به جز سؤال ۱۲ هرچه به سمت آستانه بالاتر می‌رویم، میزان آستانه افزایش می‌یابد؛ ولی سؤال ۱۲ به دلیل عملکرد معکوس در این مجموعه، میزان آستانه چهارم آن از همه آستانه‌ها کوچک‌تر شده است. منحنی ویژه عملیاتی منطبق بر آستانه‌ها در پیوست ارائه شده است. در ادامه منحنی ویژه طبقات پاسخ مربوط به هر سؤال گزارش شده است.

شکل ۴. منحنی ویژه طبقات سؤالات برون‌گرایی

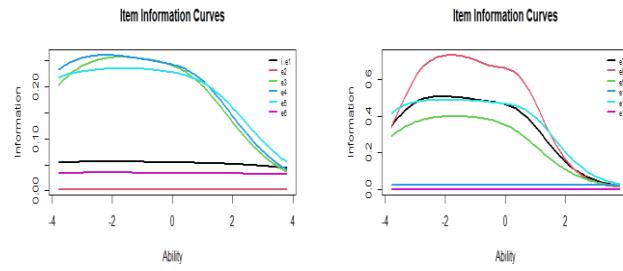


منحنی ویژه طبقات برای سوال ۲ نشان می‌دهد که در سطح گسترده‌ای از صفت مکون (برون‌گرایی) احتمال انتخاب گزینه ۴ و برای سوال ۱۲ احتمال انتخاب گزینه ۳ از سایر گزینه‌ها بیشتر بوده است؛ یعنی سایر گزینه‌های این دو سوال نقش تعیین‌کننده‌ای در تعیین

سطح صفت نداشته و وجود آنها در این سؤال مهم نبوده است. منحنی ویژه طبقات سؤالات ۵، ۸ و ۱۱ نشان می‌دهد که در این ۳ سؤال تمامی گزینه‌ها مؤثر بوده و هر کدام از گزینه‌ها در یک بازه‌ای از سطح صفت برآورده شده بیشترین احتمال انتخاب را نسبت به سایر گزینه‌ها دارند، ضمن اینکه توالی بین گزینه‌ها به خوبی حفظ شده است، یعنی گزینه با امتیاز کمتر برای سطح صفت پایین‌تر محتمل‌تر است. همچنین گزینه ۳ برای سؤال ۱ و گزینه‌های ۱ و ۲ برای سؤال ۱۰ در هیچ سطحی از بروون‌گرایی گزینه محتمل نبوده‌اند و این سؤالات می‌توانستند با تعداد گزینه محدودتری نیز ارائه شوند.

درنهایت تابع آگاهی آزمون، محاسبه گردید. آگاهی کل آزمون مبتنی بر این ۱۲ سؤال، برابر با $0.83/0.83$ است که در محدوده $0-4$ تا 4 سطح صفت که در این تحلیل مدنظر بود، آگاهی برابر با $0.43/0.43$ است، یعنی آگاهی این دامنه از سطح صفت تنها شامل $52/11$ درصد از آگاهی کل است. در شکل زیر منحنی آگاهی هر سؤال نمایش داده شده است. همان‌طور که در تصویر مشاهده می‌شود سؤال ۸ بیشترین آگاهی را در بازه -4 تا 2 نشان داده است و بعد از آن سؤالات ۱۱ و ۹ به ترتیب آگاهی بیشتری نشان دادند. سؤالات ۲، ۱۰ و ۱۲ نیز در تمام سطوح صفت آگاهی پایین و نزدیک به صفر دارند.

شکل ۵. منحنی آگاهی سؤالات بروون‌گرایی



مسئولیت‌پذیری: این ویژگی پنجمین ویژگی شخصیتی مورد مطالعه در آزمون شخصیت نئو است که با ۱۲ سؤال اندازه‌گیری می‌شود. اندازه نمونه موردمطالعه در این ویژگی برابر با 784 نفر است که میانگین نمرات مسئولیت‌پذیری آنها برابر با $36/11$ و انحراف استاندارد آن برابر با $7/01$ است. کمترین نمره مسئولیت‌پذیری برابر با 13 و بیشترین آن برابر با 48 است. در جدول زیر درصد فراوانی انتخاب هر گزینه توسط افراد، میانگین مربوط به هر

سؤال (ضریب مقبولیت)، همبستگی سؤال با نمره کل (ضریب تشخیص بر اساس نظریه کلاسیک آزمون) و آلفا در صورت حذف سؤال گزارش شده است.

جدول ۶. فراوانی درصدی انتخاب هر گزینه، میانگین و همبستگی هر سؤال با نمره کل و ضریب آلفا در صورت حذف سؤال

سؤال	گزینه ۱	گزینه ۲	گزینه ۳	گزینه ۴	گزینه ۵	میانگین	همبستگی	آلفا
۰/۷۴۷	۰/۳۵۳	۳/۲۵	۵۲	۳۱/۹	۸/۸	۴	۲/۳	۱
۰/۷۴۷	۰/۳۵۳	۲/۸۳	۳۱	۳۸	۱۸/۱	۸/۹	۴	۲
۰/۷۴۴	۰/۳۸۴	۲/۸۸	۳۷/۲	۳۵/۳	۱۲	۹/۱	۶/۴	۳
۰/۷۳۶	۰/۴۷۰	۳/۳۹	۶۰/۲	۲۶/۷	۷/۹	۲/۶	۲/۷	۴
۰/۷۳۲	۰/۴۸۲	۳/۰۳	۴۵	۲۸/۸	۱۵/۳	۶/۱	۴/۷	۵
۰/۷۴۵	۰/۳۷۴	۲/۸۹	۳۸/۳	۳۱/۹	۱۶/۱	۸/۵	۵/۲	۶
۰/۷۳۶	۰/۴۵۵	۳/۳۳	۶۰/۲	۲۴/۵	۷	۵/۱	۳/۲	۷
۰/۷۴۵	۰/۳۷۰	۲/۸۸	۳۶/۵	۳۱/۳	۲۰/۸	۶/۹	۴/۶	۸
۰/۷۵۰	۰/۳۳۴	۲/۵۱	۲۶/۳	۲۶	۲۵/۶	۱۶/۳	۵/۷	۹
۰/۷۴۱	۰/۴۰۲	۲/۸۹	۳۵/۷	۳۳/۸	۱۸/۵	۸/۲	۳/۸	۱۰
۰/۷۴۶	۰/۳۶۷	۲/۹۲	۴۶/۹	۲۲/۳	۱۴/۵	۸/۷	۷/۵	۱۱
۰/۷۴۱	۰/۴۰۷	۳/۲۹	۶۳/۸	۱۵/۲	۱۱/۹	۴/۲	۵	۱۲

مطابق با درصد فراوانی‌های انتخاب هر گزینه، مشاهده می‌شود که اقبال شرکت کنندگان به دو گزینه انتهایی بسیار زیاد است؛ یعنی بیشتر افراد خودشان را فردی مسئولیت‌پذیر می‌دانند. در سوالات ۱، ۴ و ۷ بیش از ۸۰ درصد افراد دو گزینه انتهایی را انتخاب کرده‌اند. بیشترین ضریب مقبولیت برای سؤال ۴ و برابر با ۳/۳۹ است، یعنی بیشتر افراد ادعای کرده‌اند که سعی می‌کنند کارهایشان را با احساس مسئولیت انجام دهنند.

ضریب تشخیص تمامی سوالات در این بخش مثبت بوده و بین سوالات و نمره کل همبستگی مطلوبی وجود دارد. از طرف دیگر با توجه به ضریب آلفای کرونباخ مربوط به ویژگی مسئولیت‌پذیری که برابر با ۰/۷۵۹ است، هیچ سؤالی وجود ندارد که در صورت حذف آن ضریب آلفا افزایش یابد. در ادامه تحلیل مبتنی بر نظریه سؤال پاسخ که با مدل "GRM" انجام شده گزارش شده است. در جدول زیر ضریب تشخیص و آستانه‌های مربوط به هر سؤال گزارش شده است.

مقایسه نتایج تحلیل سؤالات طیف لیکرت با نظریه ... | رحیمی و مجتبی | ۱۷۳

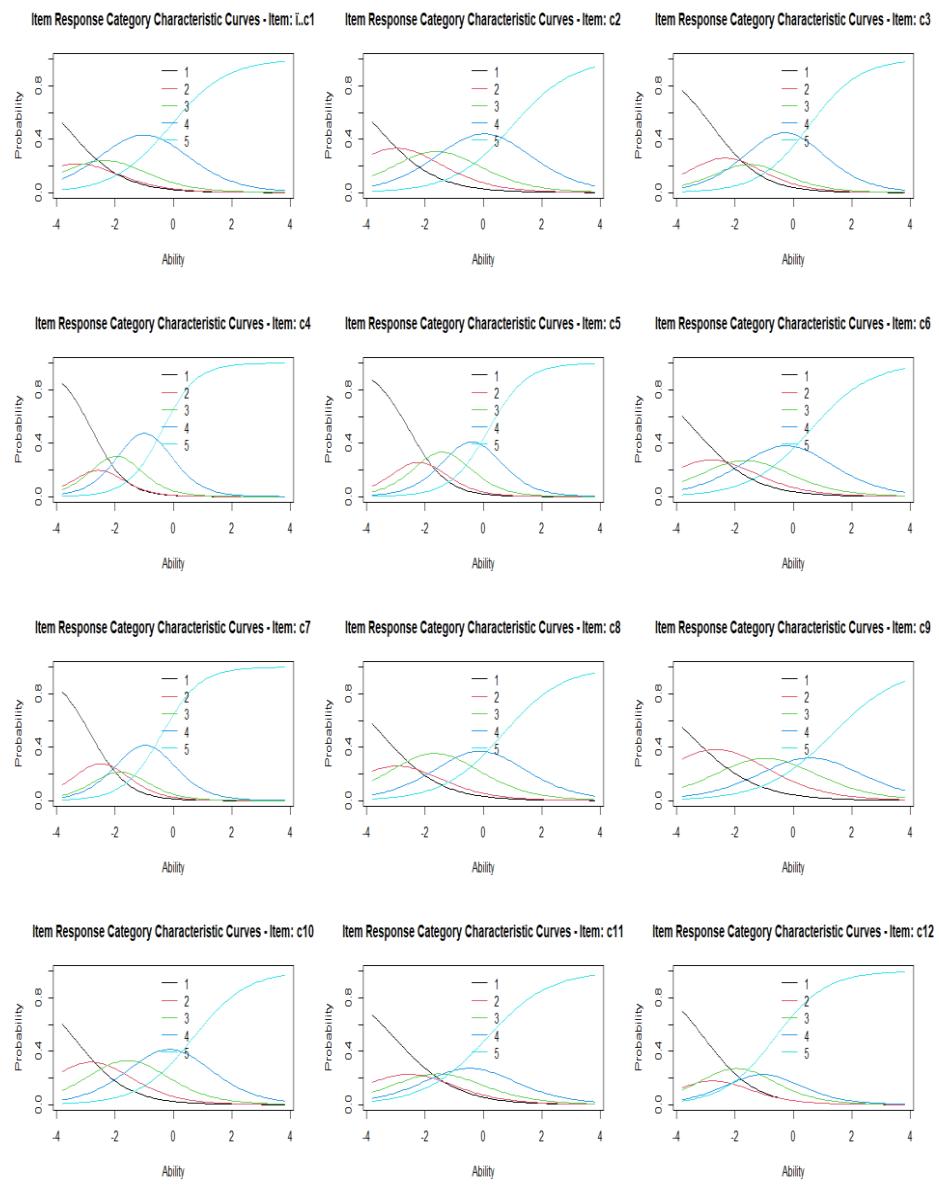
جدول ۷. ضریب تشخیص و آستانه‌های مربوط به هر سؤال

سؤال	ضریب تشخیص	آستانه ۱	آستانه ۲	آستانه ۳	آستانه ۴
۱	۱/۰۳۱	-۳/۷۰۱	-۲/۸۵۳	-۱/۹۰۱	-۰/۱۰۹
۲	۰/۹۷۴	-۳/۶۷۳	-۲/۲۵۷	-۰/۹۵۶	۰/۹۸۳
۳	۱/۱۵۸	-۲/۷۸۵	-۱/۸۷۲	-۱/۱۳۳	۰/۵۳۰
۴	۱/۷۰۷	-۲/۷۸۹	-۲/۳۲۲	-۱/۰۹۱	-۰/۳۸۴
۵	۱/۵۴۱	-۲/۵۴۲	-۱/۸۶۱	-۰/۹۶۳	۰/۱۶۷
۶	۰/۹۷۰	-۳/۳۷۳	-۲/۲۱۳	-۱/۰۷۱	۰/۵۸۱
۷	۱/۵۴۰	-۲/۸۴۰	-۲/۱۰۴	-۱/۰۴۰	-۰/۳۹۴
۸	۰/۹۸۳	-۳/۴۸۶	-۲/۴۱۰	-۰/۹۰۹	۰/۶۶۷
۹	۰/۸۶۶	-۳/۵۷۱	-۱/۷۰۹	-۰/۱۹۳	۱/۳۳۹
۱۰	۱/۰۹۰	-۳/۴۰۵	-۲/۱۹۶	-۰/۹۳۸	۰/۶۷۳
۱۱	۰/۹۴۱	-۳/۰۴۱	-۲/۰۶۱	-۱/۰۶۴	۰/۱۲۲
۱۲	۱/۱۳۷	-۳/۰۵۳	-۲/۴۲۳	-۱/۴۴۶	-۰/۶۴۰

با بررسی ستون مربوط به ضرایب تشخیص، مشاهده می‌شود که مطابق با نتیجه نظریه کلاسیک آزمون تمامی سؤالات دارای ضریب تشخیص مثبت هستند. سؤال ۴ دارای بالاترین ضریب تشخیص و سؤال ۹ دارای کمترین ضریب تشخیص در بین سؤالات هستند. در ستون‌های بعدی جدول، میزان آستانه گزارش شده است. سؤالات ۱، ۴، ۷ و ۱۲ هر چهار آستانه‌شان منفی شده است، یعنی حتی زمانی که فردی مسئولیت پذیری پایینی هم داشته باشد، احتمال انتخاب گزینه‌های انتهایی و با نمره بالا را در این سؤالات دارد و این سؤالات برای تفکیک افراد با مسئولیت بالا از افراد با مسئولیت متوسط چندان کارا نبوده و دارای اثر سقف هستند. ممکن است این ابهام ایجاد شود که چطور سؤال ۴ دارای ضریب تشخیص بالایی است؛ ولی در اینجا مطرح شده که در تفکیک بین افراد با سطوح صفت بالا ناتوان است؛ این مسئله را می‌شود این‌گونه توجیه کرد که گزینه‌های سؤال ۴ در همان محدوده صفتی که بیشترین احتمال انتخاب را دارند به خوبی عمل می‌کنند، برای مثال آستانه چهارم که مرز بین انتخاب گزینه آخر و گزینه‌های قبل از آن است در سطح صفت برابر با -۰/۳۸۴ دارای قدرت تشخیص بالایی است. با مراجعه به منحنی ویژه عملیاتی که در پیوست ارائه شده است، مشاهده می‌شود که منحنی‌های لوچیت تجمعی مربوط به سؤال ۴ دارای بیشترین

شیب نسبت به سایر گزینه‌ها هستند و همین امر باعث ضریب تشخیص بالای این سؤال شده است. در ادامه منحنی ویژه طبقات پاسخ مربوط به هر سؤال گزارش شده است.

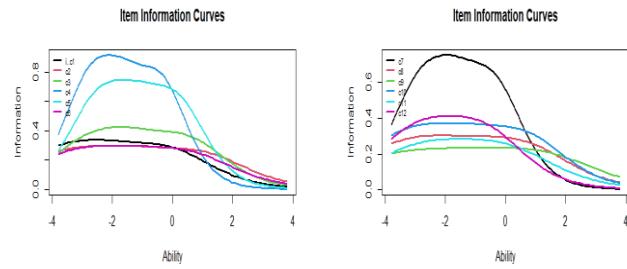
شکل ۶. منحنی ویژه طبقات سوالات مسئولیت‌پذیری



منحنی ویژه طبقات سؤالات ۲، ۹ و ۱۰ نشان می‌دهد که در این ۳ سؤال تمامی گزینه‌ها مؤثر بوده و هر کدام از گزینه‌ها در یک بازه‌ای از سطح صفت برآورد شده بیشترین احتمال انتخاب را نسبت به سایر گزینه‌ها دارند، ضمن اینکه توالی بین گزینه‌ها به خوبی حفظ شده است. گزینه ۲ در سؤالات ۴، ۵، ۶، ۷، ۸ و ۱۱ برای هیچ میزانی از مسئولیت‌پذیری گزینه محتمل نبوده و این نتیجه نشان می‌دهد که گزینه ۲ در برآورد صفت مسئولیت‌پذیری منفعل عمل کرده و تأثیر چندانی نداشته است.

درنهایت تابع آگاهی آزمون، محاسبه گردید. آگاهی کل آزمون برابر با $4/37$ است که در محدوده -4 تا 4 سطح صفت که در این تحلیل مدنظر بود، آگاهی برابر با $3/61$ است، یعنی آگاهی این دامنه از سطح صفت شامل $82/65$ درصد از آگاهی کل است. در شکل زیر منحنی آگاهی هر سؤال نمایش داده شده است. همان‌طور که در تصویر مشاهده می‌شود در بازه -4 تا صفر از صفت مکنون (مسئولیت‌پذیری) سؤال 4 بیشترین آگاهی را نشان داده است و بعداز آن سؤال 7 در بازه -4 تا -2 و سؤال 5 در بازه -2 تا صفر آگاهی بیشتری نشان دادند. هیچ سؤالی در این مجموعه، آگاهی نزدیک به صفر نداشت؛ ولی آگاهی همه سؤالات بعد از سطح صفت 2 به صفر میل می‌کند.

شکل ۷. منحنی آگاهی سؤالات مسئولیت‌پذیری



بحث و نتیجه‌گیری

بر اساس اهداف، در این پژوهش تلاش شد تا نتایج تحلیل سؤالات بر اساس دو نظریه کلاسیک و سؤال پاسخ در کنار یکدیگر قرار گرفته و تفاوت و تشابه آن‌ها مشخص شود. به همین منظور سه دسته سؤال با ضرایب همسانی متفاوت انتخاب و مورد تجزیه و تحلیل قرار گرفتند. نتایج ضریب آلفای کرونباخ که منطبق بر نظریه کلاسیک است با نتایج مربوط به

تابع آگاهی که مبتنی بر نظریه سؤال پاسخ است، همخوانی نشان داد؛ یعنی همان‌طور که سؤالات گشودگی کمترین ضریب آلفا را نشان داد، دارای کمترین آگاهی هم بود و سؤالات مسئولیت‌پذیری نیز دارای بالاترین میزان آلفا و آگاهی در بین این سه مجموعه سؤال بود و در هر دو مورد سؤالات برون‌گرایی حد وسط را نشان دادند. البته از طریق بررسی تابع آگاهی در نظریه سؤال پاسخ نتایج بیشتری قابل حصول است؛ مثلاً در نظریه سؤال پاسخ این امکان وجود دارد که علاوه بر تابع آگاهی کلی برای هر سؤال به‌طور جداگانه تابع آگاهی به دست آورده و همچنین مشخص کرد که در کدام سطوح توانایی هر سؤال آگاهی‌دهنده‌تر است؛ ولی در نظریه کلاسیک چنین امکانی وجود ندارد. علاوه بر این در بررسی توابع آگاهی مربوط به هر سؤال مشخص شد که سؤالات ۲، ۱۰ و ۱۲ در ویژگی برون‌گرایی و سؤالات ۱، ۶، ۷ و ۱۲ در ویژگی گشودگی در تمامی سطوح، آگاهی‌زنیدیک به صفر دارند و حذف این سؤالات از مجموعه سؤالات آسیبی به آگاهی آزمون نزده بلکه طول آزمون را کوتاه‌تر کرده و باعث صرفه‌جویی می‌شود؛ در تحلیل سؤالات با رویکرد کلاسیک، سؤالات ۲ و ۱۰ برون‌گرایی و سؤالات ۷ و ۱۲ گشودگی مشکل‌دار تشخیص داده نشدند. این یافته‌ها می‌تواند مهر تأییدی بر عقیده Baker and Kim (2004) باشد که نظریه سؤال پاسخ را بسط و توسعه‌ای از رویکرد کلاسیک با ریشه‌های ریاضی می‌دانست، درواقع IRT چیزی جدای از نظریه کلاسیک نبوده بلکه توسعه یافته و تکمیل شده آن است.

با اینکه در ضریب آلفا و آگاهی تناقضی مشاهده نشد؛ اما در بررسی ضرایب تشخیص از طریق دو رویکرد، تناقض آشکاری در تحلیل سؤالات گشودگی پدیدار شد. دقیقاً سه سؤالی که در رویکرد کلاسیک ضریب تشخیص منفی نشان دادند در نظریه سؤال پاسخ ضریب تشخیص مثبت داشتند و بالعکس که همین امر موجب شد تا منحنی ویژه طبقات سؤالات در ویژگی گشودگی دچار وارونگی شده و انتخاب گزینه با امتیاز بیشتر در سطح صفت پایین‌تر برای بیشتر سؤالات احتمال بالایی نشان دهد. با بررسی‌های انجام‌شده و با انجام تحلیل‌های مختلف مشخص شد که علت رخ دادن چنین اتفاقی، این بود که اولین سؤال مجموعه دارای همبستگی معکوس با نمره کل آزمون بود (نتیجه حاصل از تحلیل کلاسیک آزمون) و در تحلیل مبتنی بر IRT همان سؤال اول، مبنای قرار گرفته و صفت مکنون بر اساس سؤال اول برآورد شده و همین امر سبب منفی شدن ضرایب تشخیص ۹ سؤال دیگر

که با سؤال اول همبستگی منفی داشتند، شد و زمانی که جای سؤال اول و سؤال سوم در فایل داده‌ها تغییر کرد، علامت ضرایب تشخیص برآورد شده با IRT مشابه با علامت ضرایب تشخیص در نظریه کلاسیک آزمون شد. با بررسی‌های انجام شده توسط پژوهشگر در پژوهش یا کتابی به این نکته اشاره نشده؛ درصورتی که این می‌تواند یکی از ضعف‌های بزرگ مدل مدرج پاسخ بوده و اگر تحلیل کلاسیک آزمون انجام نشده بود، پژوهشگر را به اشتباه و گمراهی می‌کشاند.

با جمع‌بندی این یافته‌ها به این نتیجه می‌رسیم که در صورت وجود سؤالات ضعیف امکان به اشتباه افتادن و نتیجه‌گیری غلط از تحلیل‌های حاصل از نظریه سؤال پاسخ افزایش می‌یابد. همان‌طور که مشاهده شد در مورد سؤالات گشودگی که دارای ضریب آلفا بسیاری پایینی بودند و همبستگی بین سؤالات پایین و گاهی منفی بود، این اتفاق بیشتر نمایان شد. همچنین میزان آستانه در سؤالات این مجموعه به اعداد نامعقولی مثل ۱۱ و ۱۰ نیز می‌رسید؛ درصورتی که بر اساس نظر Baker and Kim (2004) نمرات صفت پنهان و پارامترهای آستانه معمولاً از ۲-تا ۲ متغیر است، حتی آستانه بین ۳- و ۳ نیز غیرمعقول نیست؛ ولی مقادیر آستانه خارج از این محدوده غیرمعمول هستند و به‌طور بالقوه نشانه‌ای از موارد مشکل‌ساز یا دسته‌های پاسخ کمتر مفید هستند؛ بنابراین تلاش برای استفاده از مقیاسی با ویژگی‌های روان‌سنجدی ضعیف (مانند دقت ضعیف در سراسر یا در مکان‌های خاص در امتداد زنجیره صفت پنهان موردنظر) می‌تواند استنتاج‌های تفسیر نمره بالقوه را به خطر بیندازد و اگر به عنوان متغیر برونداد در یک تحلیل آماری استفاده شود، می‌تواند منجر به کاهش روایی نتایج آماری شود (Kang & Waller, 2005). نتیجه پژوهش زمانپور و همکاران (۱۳۹۸) نیز نشان داد که اگر مفروضه تک‌بعدی بودن به‌طور سخت‌گیرانه‌ای رعایت شود، گویه‌هایی که مناسب تشخیص داده می‌شوند در هر دو تحلیل یکسان خواهد بود؛ بنابراین اگر مفروضه‌ها به درستی رعایت شده و سؤالات دارای ویژگی‌های روان‌سنجدی مناسبی باشند، تفاوت زیادی بین دو تحلیل مشاهده نمی‌شود؛ اگرچه تحلیل‌های IRT امکان ارائه اطلاعات جامع‌تری را دارند. برای مثال در تحلیل و واکاوی سؤالات مسئولیت‌پذیری، برتری مدل‌های IRT مشخص شد؛ زیرا اطلاعاتی که در مورد تابع آگاهی این سؤالات مشاهده شد از طریق رویکرد کلاسیک دست یافتنی نبود. در تحلیل سؤالات مسئولیت‌پذیری با اینکه در رویکرد کلاسیک همه

شرایط مناسب نشان داده می‌شد و ردی از مشکل نبود با تحلیل IRT مشخص شد که این سؤالات برای تشخیص افراد با مسئولیت بالاتر از ۲ ناتوان بوده و آگاهی دهنده نیستند. توصیه می‌شود که قبل از انجام هر تجزیه و تحلیل IRT، بررسی شود که آیا در هر دسته فراوانی به اندازه بوده و همه گزینه‌ها توسط افراد گروه نمونه به حد کفايت انتخاب شده‌اند؛ در واقع در این پژوهش مشاهده شد که در سؤالات مشکل دار بیشتر افراد گزینه‌های خاصی را انتخاب کرده و همین امر باعث نامعقول شدن منحنی ویژه طبقات شد. اگرچه هیچ دستورالعمل سخت و صریحی برای ملاک کافی بودن در نظر گرفته نشده، پاسخ‌های بیشتر در هر دسته به افزایش دقت برآورد پارامتر سؤال و ارزیابی سودمندی دسته‌های پاسخ کمک می‌کند. اگر از اعداد کافی در دسته‌های پاسخ استفاده نمی‌شود، ممکن است لازم باشد دسته‌های پاسخ با یکدیگر تجمعی و ادغام شوند تا یک سیستم دسته‌بندی پاسخ کاهش یافته تولید شود. انجام این کار باعث بهبود دقت و پایداری در برآورد پارامتر سؤال می‌شود (تولند، ۲۰۱۴). همچنین مشابه با این پژوهش بهتر است که در بررسی سؤالات هر آزمونی از روش‌های هر دو نظریه استفاده شده تا ضعف‌هایی که هر نظریه دارد و در این پژوهش به صورت عملی بررسی و گزارش شد توسط رویکرد دیگر پوشش داده شد و بهترین ارزیابی از آزمون موردنبررسی به عمل آید. همچنین پیشنهاد می‌شود که در مطالعات آتی سایر مدل‌های نظریه سؤال پاسخ با تحلیل‌ها نظریه کلاسیک آزمون مقایسه شود تا نقاط ضعف و قوت هر رویکرد به صورت عملی مشاهده و موردنبحث قرار گیرد.

تعارض منافع تعارض منافع ندارم.

منابع

- تیلور، کاترین، اس. (۱۳۹۸). روابی و رواسازی. (ترجمه یونسی، جلیل). تهران: دانشگاه علامه طباطبائی.
<https://book.atu.ac.ir/>
- زمانپور، عنایت‌اله، یونسی، جلیل، رستگار آگاه، مصطفی، و مهرابی، مهسا. (۱۳۹۸). تحلیل داده‌های نگرش‌سنگی: تفاوت نظریه کلاسیک و سؤال - پاسخ. پژوهش‌های ارتباطی. ۲۶، ۱۶۵-۱۳۹. <https://doi.org/10.22082/cr.2019.113772.1917>

References

- Baker, F. B., & Kim, S. H. (2004). *Item response theory: Parameter estimation techniques*. CRC press.
<https://doi.org/10.1201/9781482276725>
- Baker, F. B. (2001). *The basics of item response theory*. For full text:
<http://ericae.net/irt/baker>
- Courville, T. G. (2004). *An empirical comparison of item response theory and classical test theory item/person statistics*. Texas A&M University.
<https://www.proquest.com/openview/dc9dbe1471e8f2828066045a2396ea24/1?pq-origsite=gscholar&cbl=18750&diss=y>
- De Ayala, R. J. (2013). *The theory and practice of item response theory*. Guilford Publications.
https://cehs.unl.edu/EdPsych/RJSite/de_Ayala_Appendices_2ndEd.pdf
- Embretson, S. E., & Reise, P. E. (2000). *Item response theory for psychologists*. Psychology Press.
<https://doi.org/10.4324/9781410605269>
- Hambleton, R. K., & Jones, R. W. (1993). An NCME Instructional Module on Educational Measurement: issues and practice. *Comparison of Classical Test Theory and Item Response Theory and Their Applications to Test Development*, 12(3), 38-47.
<https://doi.org/10.1111/j.1745-3992.1993.tb00543.x>
- Hambleton, R. K., Swaminathan, H., & Rogers, H. J. (1985). *Principles and applications of item response theory*.
- Hambleton, R. K., & Swaminathan, H. (2013). *Item response theory: Principles and applications*. Springer Science & Business Media.
<https://link.springer.com/book/10.1007/978-94-017-1988-9>
- Jeong, H. J., & Lee, W. C. (2016). Item response theory-based evaluation of psychometric properties of the safety attitudes questionnaire-Korean version (SAQ-K). *Biometrics & Biostatistics International Journal*, 3(5), 1-15. <http://dx.doi.org/10.15406/bbij.2015.02.00020>
- Kang, S. M., & Waller, N. G. (2005). Moderated multiple regression, spurious interaction effects, and IRT. *Applied Psychological Measurement*, 29(2), 87-105. <https://doi.org/10.1177/0146621604272737>
- Lord, F.M., Novick, M.R., & Birnbaum, A. (1968). *Statistical theories of mental test scores*. Addison-Wesley.
<https://psycnet.apa.org/record/1968-35040-000>
- Ostini, R., & Nering, M. L. (2006). *Polytomous item response theory models* (No. 144). Sage.
https://scholar.archive.org/work/dbmqox2jvf6bl3ze75bobgxdq/aces/swayback/http://hbanaszak.mjr.uw.edu.pl/TempTxt/ebooksclub.org_Polytomous_Item_Response_Theory_Models__Quantitative_Applications_in_the_Social_Sciences_.pdf
- Reeve, B. B., & Fayers, P. (2005). Applying item response theory modeling for evaluating questionnaire item and scale properties. *Assessing quality of life in clinical trials: methods of practice*, 2, 55-73.
<http://dx.doi.org/10.1093/oso/9780198527695.003.0005>

- Sorrel, M. A., Olea, J., Abad, F. J., de la Torre, J., Aguado, D., & Lievens, F. (2016). Validity and reliability of situational judgement test scores: A new approach based on cognitive diagnosis models. *Organizational Research Methods*, 19(3), 506-532. <https://doi.org/10.1177/1094428116630065>
- Toland, M. D. (2014). Practical guide to conducting an item response theory analysis. *The Journal of Early Adolescence*, 34(1), 120-151. <http://dx.doi.org/10.1177/0272431613511332>
- Taylor, C. S. (2013). *Validity and validation*. Oxford University Press, USA. [In Persian] <https://doi.org/10.1093/acprof:osobl/9780199791040.001.0001>
- Zamanpour, E., Younesi, J., Rastegar Agah, M., & Mehrabi, M. (2019). Attitudinal Analysis: The Difference Between Classical Test Theory and Item Response Theory. *Communication Research*, 26(2), 139-165. [In Persian] <https://doi.org/10.22082/cr.2019.113772.1917>

پیوست

در جدول زیر سوالات مربوط به هر ویژگی همراه با شماره‌ای که در این تحلیل برای آن استفاده شده به علاوه نمادی که در نمودارها برای آن در نظر گرفته شده، آورده شده است.

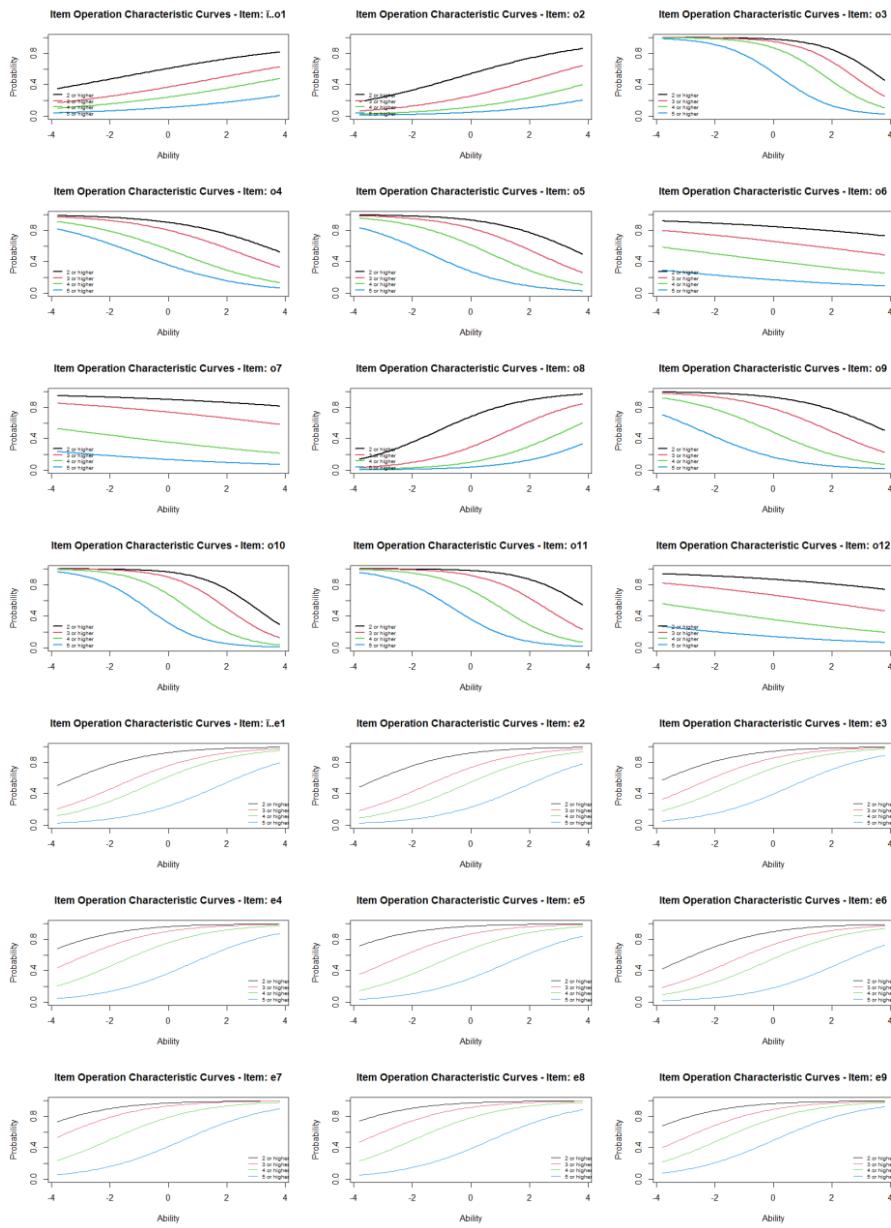
		سوالات گشودگی	
		صورت سؤال	شماره نماد
		شماره نماد	صورت سؤال
۰۱	۷	دوست ندارم وقتی را با خیال پردازی تلف کنم.	به احساسات و عواطفی که محیط‌های متفاوت به وجود می‌آورند، به ندرت توجه می‌کنم.
۰۲	۸	هنگامی که راه درست‌کاری را پیدا کنم، آن روش را همیشه در آن مورد تکرار می‌کنم.	معتقدم که هنگام تصمیم‌گیری درباره مسائل اخلاقی باید از مراجع مذهبی پیروی کنیم.
۰۳	۹	نقش‌های موجود در پدیده‌های هنری و طبیعت من را می‌بینم.	بعضی اوقات وقتی شعری را می‌خوانم یا یک کار هنری را تماشا می‌کنم، یک احساس لرزش و یک تکان هیجانی را حس می‌کنم.
۰۴	۱۰	فکر می‌کنم گوش دادن دانشجویان به مطالب متناقض فقط به سردگمی و گمراهمی آنها منجر خواهد شد.	علاقه‌ای به تأمل و تفکر جدی درباره سرنوشت و ماهیت جهان یا انسان ندارم.
۰۵	۱۱	شعر تقریباً اثربر من ندارد.	من کنیکاوی فکری فراوانی دارم.
۰۶	۱۲	اغلب غذاهای جدید و خارجی را امتحان می‌کنم.	غلب از کلنچار رفتن با نظریه‌ها یا مفاهیم انتزاعی لذت می‌برم.

مقایسه نتایج تحلیل سؤالات طیف لیکرت با نظریه ... | رحیمی و مجتبی | ۱۸۱

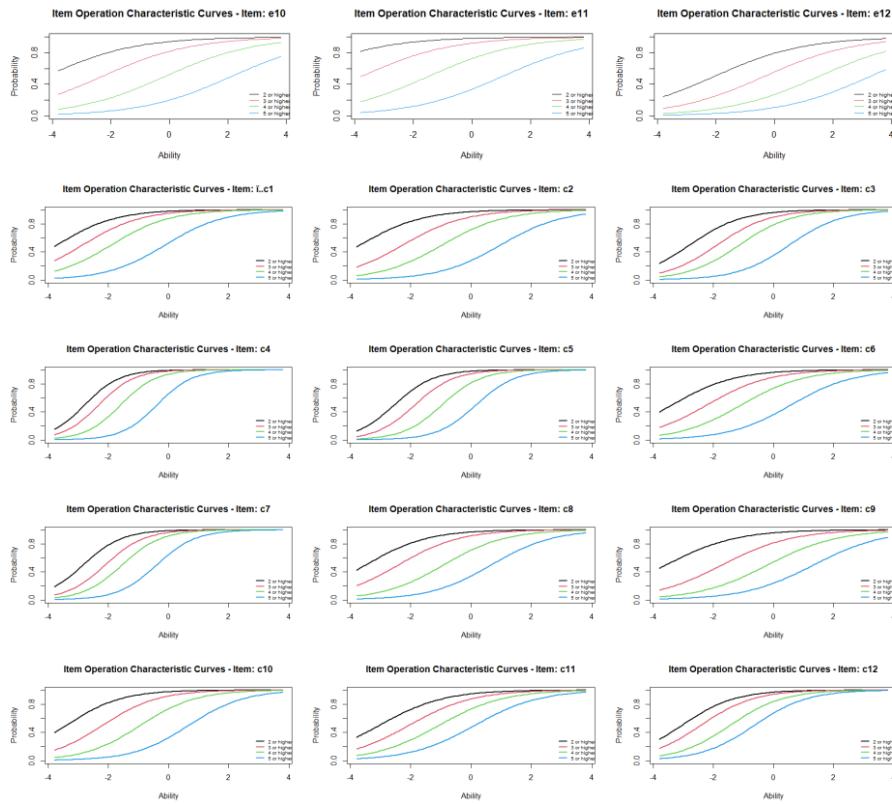
سؤالات برونگرایی			
شماره نماد	صورت سؤال	شماره نماد	صورت سؤال
E7 ۷	E1 اغلب احساس می‌کنم سرشار از انرژی هستم.	E8 ۸	E2 فردی خوشحال و بشاش و دارای روحیه خوبی هستم.
E9 ۹	E3 شخص باشاط و خوشبینی نیستم.	E10 ۱۰	E4 زندگی و رویدادهای آن برایم سریع می‌گذرند.
E11 ۱۱	E5 شخص بسیار فعالی هستم.	E12 ۱۲	E6 ترجیح می‌دهم کارها را به تنهایی انجام دهم.

سؤالات وظیفه‌شناسی			
شماره نماد	صورت سؤال	شماره نماد	صورت سؤال
C7 ۷	C1 برای رسیدن به اهدافم شدیداً تلاش می‌کنم.	C8 ۸	C2 وقتی قول یا تعهدی می‌دهم، همواره می‌توان برای کنم که درست سر زمان تعیین شده انجام عمل به آن روی من حساب کرد.
C9 ۹	C3 گاهی آن طور که باید شاید قابل اعتماد و اتکا نیستم.	C10 ۱۰	C4 فرد مولدی هستم که همیشه کارهایم را با احساس رسانم.
C11 ۱۱	C5 فکر نمی‌کنم که هیچ وقت بتوانم فردی منطقی بشوم.	C12 ۱۲	C6 قبل از شروع هر کاری وقت زیادی را تلف می‌کنم.

منحنی‌های ویژه عملیاتی مربوط به هر سؤال که در قسمت یافته‌ها به آن اشاره شده است در ادامه گزارش شده است.



۱۸۲ | مقایسه نتایج تحلیل سوالات طیف لیکرت با نظریه ... | رحیمی و مجتبی



کدهای دستوری استفاده شده در این پژوهش که در نرم افزار R و تحت پکیج "ltm" اجرا شده است، برای استفاده علاقه مندان و پژوهشگران در اینجا ارائه شده است.

```
library("ltm")
library("MASS")
library("msm")
library("polycor")
setwd("D:/ICC")
DATA<- read.table("data.dat", header = T)
Fit1 <- grm(DATA,, constrained = TRUE)
fit2 <- grm(DATA,, constrained = FALSE)
anova(fit1, fit2)
summary(fit2)
plot(fit2, legend = TRUE, cx = "topright", lwd =2, cex = 0.6))
plot(fit2, type = "IIC", items = (1: 12), legend = TRUE, cx = "topright", lwd =2, cex = 0.6)
plot(fit2, type = "OCCu", items = (1: 12), legend = TRUE, cx = "bottomright", lwd =2, cex = 0.6)
information(fit2, c(-4, 4), items = c(1, 12))
```