

ارزیابی کارکرد افتراقی جنسیتی سوال‌های آزمون ریاضی با استفاده از دو روش مانتل-هنزل و نظریه سوال-پاسخ

نگار شریفی یگانه*

چکیده

آزمون‌ها می‌بایست برای تمام افراد جامعه از هر جنس، نژاد، سن، موقعیت اجتماعی و اقتصادی عادلانه باشد. بر این اساس ارزیابی وجود سوگیری و کارکرد افتراقی در سوال‌های آزمون‌ها بسیار حائز اهمیت است. در مطالعه حاضر کارکرد افتراقی جنسیتی با استفاده از روش مانتل-هنزل و روش مبتنی بر نظریه سوال-پاسخ مورد بررسی قرار گرفته است. در ابتدا مبانی نظری و روش‌های ارزیابی کارکرد افتراقی معرفی شده است و در ادامه به منظور ارائه نمونه عملی، پاسخ‌های یک نمونه تصافی طبقه‌ای ۴۰۰۰ نفری مشتمل بر ۲۲۰۰ آزمودنی مرد و ۱۸۰۰ زن به ۵۵ سوال آزمون ریاضی کنکور سراسری مورد تحلیل قرار گرفته است. نتایج تحلیل بیانگر آن است که سوال‌های آزمون دارای کارکرد افتراقی است. در بررسی کارکرد افتراقی با استفاده از روش مانتل هنزل ۲۳ سوال دارای شاخص مانتل هنزل معنادار بودند. بر اساس رویکرد سوال-پاسخ نیز ۹ سوال دارای کارکرد افتراقی جنسیتی بودند که همگی به نفع دختران بودند. سوال‌های دارای کارکرد افتراقی به نفع دختران بیشتر در حوزه محتوایی توابع و معادلات و سوال‌های دارای کارکرد افتراقی به نفع پسران بیشتر در حوزه محتوایی مثلثات، هندسه و احتمال هستند.

واژگان کلیدی: نظریه سوال-پاسخ، سوگیری سوال، کارکرد افتراقی سوال، روش مانتل-

هنزل

* دانشجوی دکتری سنجش و اندازه‌گیری دانشگاه علامه طباطبائی و کارشناس سازمان سنجش آموزش کشور
مسئول مکاتبات: (nsh-yeganeh@yahoo.com)

مقدمه

روش‌های مختلف سنجش به ویژه آزمون‌ها نقش مهمی در سرنوشت افراد ایفا می‌کنند، از این رو، عادلانه^۱ و منصفانه بودن شیوه‌های سنجش اهمیت بسیاری دارد. در واقع روش‌های سنجش از جمله آزمون‌ها می‌بایست برای تمام افراد جامعه از هر جنس، نژاد، سن، موقعیت اجتماعی و اقتصادی منصفانه باشد و آزمودنی‌های متعلق به گروه‌های مختلف با توانایی‌های مشابه، امکان توفیق یکسانی در آزمون داشته باشند. هدف از اجرای آزمون‌ها، تفکیک و تمایز افراد است، اما آزمون‌ها نبایستی منجر به تبعیض میان آزمودنی‌ها شود (ناسستروم^۲، ۲۰۰۳).

در سال‌های اخیر، با توجه به افزایش کاربرد آزمون‌ها در موقعیت‌های مختلف، نگرانی فزاینده‌ای در باره امکان عملکرد متفاوت سئوال‌های آزمون و به عبارت دیگر سوگیری سئوال‌های آزمون در زیرگروه‌های آزمودنی (به طور مثال زنان و مردان) ایجاد شده است. به دلیل تأثیر سوگیری سئوال‌ها در انحراف نتایج آزمون و بالطبع تصمیم‌های اتخاذ شده بر مبنای این آزمون‌ها، دامنه این نگرانی حتی به سیاست‌گذاران آموزشی هم منتقل شده است. به اعتقاد متقدان آزمون‌ها، سوگیری سئوال‌های آزمون ممکن است منجر به از دست رفتن فرصت‌های آموزشی و شغلی شود (کونولی^۳، ۲۰۰۳).

سوگیری زمانی مطرح می‌شود که احتمال پاسخ‌گویی درست گروهی از آزمودنی‌ها به دلیل مشخصات سئوال‌ها و شرایط آزمون، از گروه دیگری از آزمودنی‌ها کمتر یا بیشتر باشد (زومبو^۴، ۱۹۹۹). در واقع سئوال زمانی سوگیری دارد که ویژگی‌های غیرمرتبط با سازه مورد سنجش را بسنجد. سوگیری سئوال ممکن است به علت ابهام در متن، گزینه‌ها و راهنمای آزمون باشد (همبلتون^۵ و راجرز^۶، ۱۹۹۵). کارکرد افتراقی سئوال‌ها^۷ (DIF) روش آماری تعیین وجود سوگیری در سئوال‌های آزمون است. این اصطلاح توسط هالند^۸ و واینر^۹ (۱۹۹۳) ارائه شده است (اینگ^{۱۰} و هوی^{۱۱}، ۲۰۰۵).

-
1. Fair
 2. Näsström
 3. Item Bias
 4. Conoley
 5. Zumbo
 6. Hambleton
 7. Rodgers
 8. Differential Item Function
 9. Holland
 10. Wainer
 11. Eng
 12. Hoe

کارکرد افتراقی سوال، زمانی مطرح می‌شود که آزمودنی‌ها با توانایی یکسان، متعلق به گروههای مختلف، احتمال پاسخ‌گویی درست اما متفاوتی داشته باشند. به عبارت دیگر سوال در صورتی دارای کارکرد افتراقی است که در زیر گروههای مختلف جامعه عملکرد متفاوت داشته باشد. وجود کارکرد افتراقی بیانگر آن است که عوامل مربوط به عضویت در گروه، احتمال پاسخ‌گویی درست را تحت تأثیر قرار می‌دهد. در صورتی که سوال، کارکرد افتراقی نداشته باشد، فاقد سوگیری نیز هست، ولی با وجود کارکرد افتراقی، وجود سوگیری سوال نیز، باید به روش‌های مختلفی چون تحلیل محتوا و ارزشیابی تجربی مورد بررسی قرار گیرد (دانکن، ۲۰۰۶).

تاریخچه و رویکردهای ارزیابی کارکرد افتراقی سوال

چالش اساسی در خصوص آزمون عادلانه، نگرانی در خصوص سوگیری سوالهای آزمون و ضرورت بررسی آن به عنوان بخشی از فرایند آزمونسازی، در اواخر دهه ۱۹۷۰ و اوایل دهه ۱۹۸۰ در راستای انتظارات مبنی بر یکسانی نتایج آزمون‌ها و هم‌زمان با آغاز عصر حقوق مدنی مطرح شد (دانکن، ۲۰۰۶). در چهل سال اخیر، نگرانی‌های مربوط به عادلانه بودن آزمون‌ها، منجر به ایجاد روش‌های مختلفی برای ارزیابی کارکرد افتراقی سوال‌ها شده است. به عنوان مثال هیلز^۱ بیش از چهل روش را را مشخص کرده است. روش‌های مختلف ارزیابی کارکرد افتراقی از لحاظ مفروضه‌ها، شرایط کاربرد و نتایج حاصل با یکدیگر تفاوت دارند و همین مسئله زمینه‌ای را برای پژوهشگران، به منظور مقایسه روش‌های مختلف ارزیابی کارکرد افتراقی سوال‌ها، با هدف دستیابی به مناسب‌ترین روش برای هر موقعیت ایجاد کرده است (زومبو، ۱۹۹۹). پژوهشگران روش‌های ارزیابی کارکرد افتراقی را بر اساس الگوها و آمارهای به کار رفته طبقه‌بندی کرده‌اند که این موجب درک بهتری از روش‌های مختلف می‌شود.

در طبقه‌بندی کلی می‌توان روش‌های تحلیل کارکرد افتراقی را در چارچوب نظریه کلاسیک و یا نظریه سوال - پاسخ^۲ طبقه‌بندی کرد. در نظریه کلاسیک، تفاوت مشخصه‌های کلاسیک سوال، در بین گروههای مختلف آزمودنی با نمره‌های مشابه مورد مقایسه قرار می‌گیرد. سادگی اجرا و کاربرد نمونه‌های کوچک از مزیت‌های روش‌های مبتنی بر رویکرد کلاسیک است (امبرتسون^۳ و رایس^۴، ترجمه شریفی و همکاران، ۱۳۸۸). برخی از متداول‌ترین روش‌های بررسی کارکرد افتراقی عبارتند از:

1. Hills
2. Item response theory
3. Embreston
4. Reise

- ۱- روش‌های دشواری سؤال تبدیل شده^۱: این روش توسط انگاف^۲ و فورد^۳ پیشنهاد شده است و به آن طرح دلتا نیز گفته می‌شود. در این روش پارامتر دشواری سؤال در هر یک از زیر گروه‌های جامعه به طور جداگانه محاسبه می‌شود، سپس مقادیر دشواری سؤال به مقیاس دلتا (میانگین ۱۳ و انحراف استاندارد ۴) تبدیل می‌شوند (باقی^۴ و فرارا^۵، ۱۹۸۹). همبستگی مقادیر دلتا مربوط به دو گروه محاسبه می‌شود، به علاوه برای تمام سؤال‌ها نمودار مقادیر دلتا مربوط به هر زوج رسم می‌شود و با داده‌ها خط مستقیمی برآذش داده می‌شود. سؤال‌هایی که مقادیر دلتا در آنها با فاصله زیادی از این خط قرار گرفته‌اند دارای سوگیری هستند (أُنیل، ۱۹۹۱). این روش به علت سادگی مورد توجه بسیار واقع شده است، اما نسبت به عدم یکسانی قدرت تشخیص سؤال‌ها حساس است.
- ۲- روش مانتل - هنزل^۶: این روش توسط مانتل و هنزل (۱۹۵۹) به عنوان روشی برای مطالعه گروه‌های جور شده معرفی شده است. هالند و تایر (۱۹۸۸) این روش را در بررسی کارکرد افتراقی سؤال مورد استفاده قرار دادند (دورانس^۷ و هالند، ۱۹۹۲). روش مانتل - هنزل، روشی ناپارامتریک برای ارزیابی کارکرد افتراقی است. سؤال‌ها به صورت دوارزشی نمره‌دهی می‌شوند و برای تعیین آزمودنی‌ها با سطوح توانایی یکسان در دو گروه مرجع^۸ و کانونی^۹ نمره کل مورد استفاده قرار می‌گیرد (گروه مرجع گروهی از آزمودنی‌ها است که عملکرد آنها به عنوان نقطه مرجع محسوب می‌شود. گروه کانونی گروهی از آزمودنی‌ها است که انتظار می‌رود سؤال‌های آزمون به نفع آنان نباشد). این روش به دلیل ارائه آزمون آماری، برآورد اندازه اثر و کارآمدی آن در نمونه‌های با حجم کم، به عنوان یکی از رایج‌ترین روش‌های ارزیابی کارکرد افتراقی سؤال‌ها مطرح است. البته این روش فقط در تشخیص کارکرد افتراقی یکنواخت^{۱۰} مناسب است و همین موضوع یکی از محدودیت‌های روش مانتل هنزل است. کارکرد افتراقی به دو صورت یکنواخت و غیریکنواخت^{۱۱} است. در کارکرد

-
1. Transformed Item Difficulty
 2. Angoff
 3. Ford
 4. Baghi
 5. ferrara
 6. Mantel- Haenszel
 7. Dorans
 8. Reference
 9. Focal
 10. Uniform
 11. Non -Uniform

افتراقی یکنواخت تفاوت احتمال پاسخ‌گویی درست گروه کانونی و گروه مرجع در تمام سطوح توانایی یکسان است یا به عبارت دیگر در کارکرد افتراقی یکنواخت تعامل بین سطح توانایی و عضویت در گروه وجود ندارد (دریانا^۱، ۲۰۰۷). در کارکرد افتراقی یکنواخت سوالهای از لحاظ سطوح دشواری در دو گروه متفاوت هستند، اما از لحاظ قدرت تشخیص تفاوتی ندارند (شولتز^۲ و ویتنی^۳، ۲۰۰۵). در کارکرد افتراقی غیریکنواخت احتمال پاسخ‌گویی درست گروه کانونی و گروه مرجع در تمام سطوح توانایی یکسان نیست و در واقع بین سطح توانایی و عضویت در گروه تعامل وجود دارد (دریانا، ۲۰۰۷) و سوالهای از لحاظ سطح دشواری و قدرت تشخیص در دو گروه متفاوت قرار می‌گیرند (شولتز و ویتنی، ۲۰۰۵).

-۳- روش رگرسیون لجستیک: این روش توسط سوامیناثان^۴ و راجرز^۵ معرفی شده است. در این روش پاسخ سوالهای، به عنوان متغیری وابسته در نظر گرفته می‌شود. رگرسیون لجستیک مبتنی بر مدل‌سازی آماری احتمال پاسخ صحیح به سوال، بر اساس عضویت در گروه و ملاک است که در آن ملاک معمولاً نمره کل آزمون است. وجود کارکرد افتراقی با بررسی بهبود ایجاد شده در برآش مدل رگرسیون، پس از اضافه کردن عضویت در گروه و تعامل بین نمره آزمون و عضویت در گروه در مدل رگرسیون تعیین می‌شود (روسسو^۶، برتراند^۷ و بیتو^۸، ۲۰۰۴). روش رگرسیون لجستیک لجستیک مانند روش مانتل هنزل، آزمون معناداری آماری و اندازه اثر ارائه می‌کند. از جمله مزایای این روش می‌توان به توانایی بررسی کارکرد افتراقی یکنواخت و غیریکنواخت اشاره کرد.

بررسی کارکرد افتراقی بر اساس نظریه سوال - پاسخ به ابتدای دهه شصت میلادی و کاربرد مدل راش بر می‌گردد. لرد^۹ و نوایک^{۱۰} ظرفیت بالای رویکرد سوال - پاسخ را در ارزیابی کارکرد افتراقی سوال مورد تأکید قرار دادند (دانکن، ۲۰۰۶). از لحاظ نظری رویکرد سوال - پاسخ روش مناسبی برای ارزیابی کارکرد افتراقی سوالها

1. Driana

2. Shultz

3. Whitney

4. Swaminathan

5. Rogers

6. Rousseau

7. Bertrand

8. Boiteau

9. Lord

10. Novick

است. ویژگی نامتغير بودن پارامترها در این رویکرد، چارچوبی نظری برای تعریف و تعیین کارکرد افتراقی سوالهای آزمون فراهم می‌سازد. اگر سوال، در زیرگروههای جامعه یکسان عمل کند، در این حالت احتمال پاسخ‌گویی درست آزمودنی‌ها با سطح توانایی یکسان می‌باشد. به این ترتیب بر اساس نظریه سوال - پاسخ، سوال زمانی دارای کارکرد افتراقی است که منحنی ویژگی سوال یا به عبارت دیگر احتمال شرطی پاسخ درست به سوال در سطوح توانایی یکسان در گروه مرجع و کانونی متفاوت باشند (امبرتسون و رایس، ترجمه شریفی و همکاران، ۱۳۸۸). رویکرد سوال - پاسخ قادر به تشخیص کارکرد افتراقی یکنواخت و غیریکنواخت است. یکی از محدودیت‌های روش‌های مبتنی بر رویکرد سوال - پاسخ ضرورت وجود گروههای نمونه بزرگ است. زیکی^۱ (۱۹۹۳)، روسو و ستوات^۲ کاربرد گروه نمونه با حجم بالای بالای صد نفر را برای گروه کانونی و بین دویست تا هزار نفر را برای گروه مرجع در ارزیابی کارکرد افتراقی توصیه کردند. از سویی کاربرد نمونه‌های بزرگ منجر به افزایش موارد مثبت کاذب می‌شود (دانکن، ۲۰۰۶).

در چارچوب رویکرد سوال - پاسخ چندین روش برای ارزیابی کارکرد افتراقی مطرح شده است که این روش‌ها در دو گروه کلی مساحت میان منحنی ویژگی سوال^۳ گروه مرجع و کانونی و روش آزمون‌های آماری یکسانی پارامترهای سوال طبقه‌بندی می‌شوند (شولتز و ویتنی، ۲۰۰۵). روش آزمون‌های آماری، شامل آزمون چند متغیره و آزمون t بر روی مقادیر پارامتر دشواری می‌شود. در رویکرد مساحت میان دو منحنی ویژگی سوال، منحنی ویژگی و نه پارامتر سوال‌ها مورد توجه قرار می‌گیرد. هر چند که مساحت بین دو منحنی ویژگی سوال‌ها بر اساس پارامترهای سوال‌ها ترسیم می‌شوند، اما روش بررسی مساحت بین دو منحنی ویژگی سوال، مستلزم نگاه دقیق‌تری به تفاوت بین پارامتر سوال‌ها است. در این روش منطقه بین دو منحنی ویژگی سوال مورد توجه قرار می‌گیرد. پس از برآوردهای پارامتر سوال‌ها و قرار دادن آنها روی مقیاس مشترک، مساحت سوال در دو گروه ترسیم می‌شود. در صورتی که فاصله بین دو منحنی ویژگی سوال صفر باشد و در واقع دو منحنی بر هم منطبق باشند، کارکرد افتراقی وجود ندارد. بر عکس هنگامی که مساحت بین دو منحنی سوال صفر نیست کارکرد افتراقی با درجاتی وجود دارد. هر چه

1. Zieky

2. Stout

3. Item Characteristic Curve

این مساحت بیشتر باشد، کارکرد افتراقی نیز بیشتر است. همبلتون و راجو^۱ فرمولهایی برای محاسبه مساحت ارائه کرده‌اند (همبلتون، سوامیناتان و راجرز، ترجمه فلسفی نژاد، ۱۳۸۹). راجو نارسايی رویکرد محاسبه مساحت بین دو منحنی ويژگی سوال را درک کرده و روش‌های مبتنی بر چارچوب کارکرد افتراقی سوال‌ها و آزمون^۲ (DFIT) را برای ارزیابی کارکرد افتراقی ارائه کرد. شاخص DFIT ويژگی‌هایی دارد که آن را توانمند و منعطف می‌سازد. این ويژگی‌ها عبارتند از: ۱- امکان کاربرد این شاخص برای سوال‌های دو ارزشی و چندارزشی ۲- امکان کاربرد این شاخص در مدل‌های تک بعدی و چند بعدی ۳- توانایی ارزیابی کارکرد افتراقی سوال و آزمون (أشیما و موریس، ۲۰۰۸).

مقایسه روش‌های مختلف تعیین کارکرد افتراقی سوال‌ها

به منظور مقایسه روش‌های مختلف ارزیابی کارکرد افتراقی، مطالعات متعددی با استفاده از داده‌های حقیقی و یا شبیه‌سازی شده انجام شده است که در برخی موارد نتایج متناقضی به همراه داشته‌اند. دو روش رگرسیون لجستیک و روش مانتل هنzel به عنوان رایج‌ترین روش‌های ارزیابی کارکرد افتراقی در بسیاری از مطالعات مورد مقایسه قرار گرفته‌اند. به عنوان مثال هیدالگو^۳ و لوپز^۴ در مطالعه‌ای به بررسی این دو رویکرد در ارزیابی کارکرد افتراقی سوال‌های آزمون پرداختند. نتایج مطالعه آنان بیانگر آن بود که روش رگرسیون لجستیک سوال‌های بیشتری را با کارکرد افتراقی مشخص می‌سازد. سوامی ناتان و راجرز (۱۹۹۰) نیز با استفاده از مطالعات شبیه‌سازی شده به نتیجه مشابه دست یافتند (دانکن، ۲۰۰۶). گیرل^۵ و همکاران (۱۹۹۹) در مطالعه‌ای کارکرد افتراقی جنسیتی سوال‌های آزمون ریاضی و علوم را با استفاده از دو روش مانتل هنzel و رگرسیون لجستیک مورد بررسی قرار دادند. در حالی که نتایج این دو روش در بررسی کارکرد افتراقی یکنواخت در آزمون ریاضی مشابه بود، نتایج آزمون علوم ثبات کمتری داشت. روش مانتل هنzel در مقایسه با روش رگرسیون لجستیک تعداد کمتری از سوال‌ها را دارای کارکرد افتراقی تشخیص داد و بنابر این روشهای محافظه‌کارانه‌تر می‌باشد. با توجه به مطالعات ارائه شده می‌توان نتیجه گرفت

1. Raju

2. Differential Functioning of Items and Tests

3. Hidalgo

4. Lopez

5. Gierl

که تعداد سوال‌های دارای کارکرد افتراقی، به روش به کار رفته وابسته است و از این رو سازندگان آزمون‌ها و سیاست‌گذاران آموزشی می‌بایست تفاوت‌های روش‌های مختلف ارزیابی کارکرد افتراقی سوال‌ها را همواره در نظر بگیرند (احمدی، ۱۳۸۷).

باقی و فرارا (۱۹۸۹) در مطالعه‌ای سه روش نمودار دلتا، روش مانتل هنzel و رویکرد مبتنی بر نظریه سوال - پاسخ را با استفاده از نمونه‌هایی با حجم متفاوت مورد مقایسه قرار دادند. روش‌ها از لحاظ ثبات (مطابقت نتایج هر روش در نمونه‌ها با حجم‌های متفاوت)، توافق (مطابقت نتایج روش‌های مختلف ارزیابی کارکرد افتراقی با نتایج روش مبتنی بر رویکرد سوال - پاسخ) و عملی بودن (نرم‌افزارهای مورد نیاز، حجم گروه نمونه مورد نیاز) با یکدیگر مقایسه شدند. ثبات روش نمودار دلتا و رویکرد سوال - پاسخ کم تا متوسط بود. در نمونه‌های بزرگ ثبات روش سوال - پاسخ، نمودار دلتا و روش مانتل هنzel در حد متوسط بود. توافق روش‌ها با محاسبه همبستگی رتبه‌ای اسپیرمن میان شاخص‌های کارکرد افتراقی روش‌ها و مشخص کردن تعداد سوال‌ها دارای کارکرد افتراقی و قادر کارکرد افتراقی در هر یک از روش‌ها تعیین شد. بر اساس ضرایب همبستگی رتبه‌ای اسپیرمن، توافق میان روش راش و نمودار دلتا در تمام نمونه‌ها در حد بسیار بالا بود، توافق روش راش با مدل سه پارامتری در حد متوسط بود و توافق سایر روش‌ها با روش سه پارامتری کم بود. هریس^۱ و کولن^۲ (۱۹۸۶)، هریس و هوور^۳ (۱۹۸۶) و اسکاگر^۴ و لیسیتزر^۵ (۱۹۸۶) اظهار داشتند که میزان توافق بین روش‌های مختلف ارزیابی کارکرد افتراقی خیلی زیاد نیست (باقی و فرارا، ۱۹۸۹).

عبدالعزیز^۶ (۲۰۱۰) کارکرد افتراقی جنسیتی سوال‌ها را در آزمون ریاضی با استفاده از روش مانتل هنzel، تفاوت پارامتر دشواری سوال‌های آزمون و روش پارامتر دشواری تبدیل شده (TID) را بررسی و میزان توافق این سه روش را تعیین کرد. نتایج تحقیق وی بیانگر آن بود که میزان توافق بین این سه روش پایین است. بیشترین توافق، بین روش مانتل هنzel و روش پارامتر دشواری تبدیل شده (TID) به دست آمد که این مسئله ممکن است به این دلیل باشد که هر دو این روش‌ها در چارچوب

1. Harris

2. Kolen

3. Hoover

4. Skaggs

5. Lissitz

6. Abedalaziz

نظریه کلاسیک هستند. کمترین توافق میان روش پارامتر دشواری تبدیل شده (TID) و تفاوت پارامتر دشواری سوالها است.

دوراند^۱ و پارک^۲ (۲۰۰۶) کارکرد افتراقی را در سوالهای آزمون زبان با استفاده از سه روش SIBTEST، مانتل هنزل و رویکرد سوال - پاسخ بررسی کردند. نتایج نشان داد که دو روش SIBTEST و مانتل هنزل تعداد زیادی سوال دارای کارکرد افتراقی را مشخص ساختند، در حالی که روش سوال - پاسخ تعداد سوالهای کمتری را به عنوان سوالهای دارای کارکرد افتراقی مشخص کرده است. بر اساس این نتایج آنان مطالعات بیشتر و دقیق‌تری را در باره روش‌های مختلف ارزیابی کارکرد افتراقی توصیه کردند.

یکی از مسایل مهم در مطالعات کارکرد افتراقی تعیین عوامل به وجود آورنده آن است. در باره سوالهای دو ارزشی مطالعاتی صورت گرفته است که از آن جمله می‌توان به مطالعه اونیل و مکپیک^۳ اشاره کرد که تأثیر عواملی چون محظوظ و شکل سوال را در آزمون استعداد تحصیلی^۴ (SAT)، آزمون‌های ورودی تحصیلات تكمیلی^۵ (GRE) و سایر آزمون‌های پذیرش مورد بررسی قرار دادند. نتایج مطالعه آنان بیانگر آن بود که در آزمون ریاضی آزمودنی‌های دختر در مقایسه با آزمودنی‌های پسر در سوالهای جبر عملکرد بهتری دارند، در حالی که آزمودنی‌های پسر در حل مسایل، عملکرد بهتری دارند (وانگ و لان، ۱۹۹۴). پژوهشگران هم‌چنین نشان دادند که کارکرد افتراقی جنسیتی به میزان شباهت سوال با سوالهای کتاب‌های درسی نیز بستگی دارد. آزمودنی‌های دختر در مقایسه با پسران در سوالهایی که مشابه سوالهای کتاب‌های درسی هستند، عملکرد بهتری دارند (ویلینگهام و کول، ۱۹۹۷). در مورد عوامل به وجود آورنده کارکرد افتراقی در سوالهای چند ارزشی مطالعات اندکی انجام شده است (وانگ و لان، ۱۹۹۴). دودین^۶ و الدرابی^۷ (۲۰۰۳) نیز کارکرد افتراقی سوالهای آزمون ریاضی را با استفاده از روش مانتل هنزل مورد بررسی قرار دادند. آزمون متشکل از پنجاه سوال چندگزینه‌ای بود که با نمونه چهارصد نفری از دانش‌آموzan اجرا شد (۲۰۰ دانش‌آموzan دختر و ۲۰۰ دانش‌آموzan پسر). از این پنجاه

1. Durand

2. Park

3. McPeek

4. Scholastic Aptitude Test

5. Graduate Record Examinations (GRE)

6. Doudin

7. Al-Darabee

سؤال ۱۷ سوال (۳۴ درصد) کارکرد افتراقی داشتند که هشت سوال به نفع دانشآموزان پسر و نه سوال به نفع دانشآموزان دختر بود. نتایج مطالعه آنان بیانگر برتری دانشآموزان پسر در سوال‌های حساب و حل مسئله و همچنین برتری دانشآموزان دختر در سوال‌ها جبر و هندسه بود. بربر اوغلو^۱ (۱۹۹۶) وجود کارکرد افتراقی جنسیتی در سوال‌های ریاضی آزمون سراسری ورود به دانشگاه را با استفاده از مدل دو پارامتری مورد بررسی قرار داد. نتایج تحلیل مبین آن بود که از ۳۲ سوال چندگرینه‌ای آزمون، ۵۳ درصد سوال‌ها به نفع مردان و ۴۷ درصد به نفع زنان بوده است (دریانا، ۲۰۰۷).

مندز^۲، بارنت^۳ و ارکیکان^۴ (۲۰۰۶) منابع کارکرد افتراقی سوال‌ها با توجه به عامل عامل جنسیت را مورد بررسی قرار دادند. بر اساس فرضیه آنان، محتوا، سطوح شناختی و متن سوال، منابع احتمالی کارکرد افتراقی سوال محسوب می‌شوند. آنان دریافتند که در حوزه محتوایی، مجموعه سوال‌های حل مسئله و مجموعه سوال‌های مربوط به حوزه‌های لگاریتم و توان به نفع دانشآموزان پسر و مجموعه سوال‌های چندجمله‌ای‌ها و روابط درجه دوم به نفع دانشآموزان دختر است. بر اساس سطوح شناختی سوال‌ها، دانشآموزان پسر در مقایسه با دختران در سوال‌های سطوح بالای شناختی عملکرد بهتری داشتند. در سوال‌های مربوط به سطوح پایین شناختی تفاوتی مشاهده نشد. مطالعه آنان در باره متن سوال‌ها نشان داد سوال‌هایی که شامل شکل و نمودار هستند به نفع پسران است. نتایج این پژوهش موافق با نتایج سایر مطالعات انجام شده در این زمینه است (دریانا، ۲۰۰۷).

اهداف مطالعه

اتخاذ تصمیمات درست و منطقی برپایه نتایج آزمون‌ها مستلزم کسب اطمینان از عادلانه بودن آزمون‌ها است. بنابراین ارزیابی کارکرد افتراقی سوال‌های آزمون‌ها اهمیت فراوانی دارد و می‌بایست به عنوان بخشی از فرایند تحلیل آزمون در نظر

1. Berberoglu

2. Mendes

3. Barnett

4. Ercikan

گرفته شود. با توجه به اهمیت آزمون‌های ورودی دانشگاه‌ها و نقش آنها در سرنوشت تحصیلی و شغلی داوطلبان، لازم است سوالهای آزمون‌های ریاضی گروه آزمایشی ریاضی و کارکرد مورد بررسی دقیق و موشکافانه قرار گیرد. در این راستا مطالعه حاضر به ارزیابی کارکرد افتراقی جنسیتی در سوالهای آزمون ریاضی گروه آزمایشی ریاضی و فنی با استفاده از روش مانتل - هنzel و روش مبتنی بر نظریه سوال - پاسخ پرداخته است. به علاوه میزان توافق بین این دو روش در تعیین کارکرد افتراقی نیز مورد بررسی قرار گرفته است. در مطالعه حاضر آزمودنی‌های دختر به عنوان گروه کانونی آزمودنی‌های پسر به عنوان گروه مرجع در نظر گرفته شده‌اند.

سوال تحقیق

آیا عملکرد آزمودنی‌های دختر و پسر با سطوح توانایی مشابه در آزمون ریاضی کنکور سراسری گروه آزمایشی ریاضی و فنی متفاوت است؟

داده‌های تحلیل

تفاوت عملکرد در آزمون‌های ریاضی با توجه به ویژگی‌ها نظیر وضعیت اقتصادی - اجتماعی، جنسیت و نژاد از جمله مسایلی است که مورد توجه و پژوهش فراوان قرار گرفته است. در مورد آزمون‌های ریاضی، کارکرد افتراقی دغدغه‌ای اساسی است. در مطالعه حاضر کارکرد افتراقی جنسیتی سوالهای آزمون ریاضی مورد بررسی قرار گرفته است. در تحلیل حاضر از پاسخ‌های آزمودنی‌های شرکت کننده در کنکور سراسری گروه آزمایشی علوم ریاضی و فنی سال ۱۳۸۲ استفاده شده است. ۳۹۹۱۹۹ آزمودنی در این آزمون شرکت کرده‌اند که ۷۸۷۵ آزمودنی به تمام سوالهای آزمون ریاضی پاسخ خلط داده‌اند و در نتیجه از روند تحلیل کنار گذاشته شدن. به این ترتیب تحلیل براساس پاسخ‌های ۳۹۱۳۲۴ آزمودنی انجام شده است. ۲۱۳۶۲۵ آزمودنی پسر و ۱۷۷۶۹۹ نفر دختر بودند. با استفاده از روش نمونه‌گیری تصادفی طبقه‌ای گروه نمونه چهارهزار نفری از آزمودنی‌ها انتخاب شد که شامل ۲۲۰۰ آزمودنی مرد و ۱۸۰۰ آزمودنی بود. آزمون شامل ۵۵ سوال چهارگزینه‌ای بود که برای پاسخ‌های نادرست نمره منفی لحاظ شده است.

روش تحلیل

در مطالعه حاضر بررسی کارکرد افتراقی سوالات براساس دو روش سوال - پاسخ و مانتل - هنزل صورت گرفته است. اولین گام در تحلیل مبتنی بر نظریه سوال - پاسخ بررسی برقراری مفروضه‌های مدل است، چون کاربرد این نظریه و کسب نتایج دقیق از آن مستلزم برقراری مفروضه بنیادی آن است. هر چند برخی شواهد بیانگر مقاوم بودن نظریه سوال - پاسخ به تخطی از مفروضه‌های بنیادی اش است (همبلتون، ۱۹۸۹). یکی از مفروضه‌های مدل، تکبعدي بودن^۱ است، به این معنا که یک خصیصه مکنون با مجموعه سوالات آزمون اندازه‌گیری شود. برقراری مطلق این مفروضه به دلیل دخالت عوامل گوناگون (اضطراب، انگیزش، مهارت‌ها و فرایندهای شناختی و وضعیت جسمانی و روانی آزمودنی‌ها) بر عملکرد آزمودنی‌ها غیرممکن است، اما آن چه اهمیت دارد وجود عاملی باز در آزمون است که معرف عملکرد آزمودنی‌ها در آزمون باشد. روش‌های مختلفی برای بررسی برقراری مفروضه تکبعدي هست که یکی از مناسب‌ترین آنها تحلیل عاملی^۲ است. در مطالعه حاضر تحلیل عاملی سوالات با استفاده از نرم‌افزار TESTFACT و بر اساس کل داده‌ها انجام شده است. ارزش ویژه نخستین عامل استخراج شده در تحلیل عاملی برابر با ۰/۶۳ است و ۰/۳۶ درصد واریانس را تبیین می‌کند. دومین ارزش ویژه برابر با ۰/۰۱ است که ۰/۰۵ درصد واریانس را تبیین می‌کند. طبق اظهار ریکازی^۳ هنگامی که عامل نخست حداقل ۰/۰۸ درصد واریانس کل را تبیین کند، می‌توان نتیجه گرفت آزمون تکبعدي است (احمدی، ۲۰۰۸). بر این اساس در مطالعه حاضر آزمون تکبعدي است و تحلیل آزمون بر اساس نظریه سوال - پاسخ تکبعدي امکان پذير است.

جدول (۱) عامل‌های استخراج شده آزمون ریاضی

عامل	ارزش ویژه	درصد واریانس تبیین شده
۱	۰/۰۱	۰/۳۶
۲	۰/۰۰۱	۰/۰۵
۳	۰/۰۰۵	۰/۰۴۴
۴	۰/۰۰۷	۰/۰۱۱
۵	۰/۰۰۹	۰/۰۹۸

1. Unidimensionality

2. Factor analysis

3. Reakase

بررسی وجود کارکرد افتراقی سوالها با استفاده از نرم‌افزار BILOG-MG صورت گرفته است. این نرم‌افزار توانایی مدل‌سازی چندگروهی نظریه سوال - پاسخ را دارد. بنابراین می‌توان از آن برای ارزیابی کارکرد افتراقی سوال استفاده کرد. نرم‌افزار BILOG-MG، کارکرد افتراقی سوال را از نظر پارامترهای دشواری سوال بررسی می‌کند و قادر به بررسی تفاوت‌های گروهی در پارامتر تشخیص نیست (امبرتسون و رایس، ترجمه شریفی و همکاران، ۱۳۸۸). نکته قابل تأمل در کاربرد روش سوال-پاسخ، برازش مدل با داده‌ها است. در واقع، برتری‌های رویکرد سوال-پاسخ تنها در صورت برازش داده‌ها با مدل برقرار است. برازش مدل انتخابی با استفاده از شاخص لگاریتم درستنمایی صورت گرفت. تفاوت مقدار این شاخص در مدل‌های مختلف دارای توزیع مجذور کای با درجه آزادی برابر با تعداد پارامترهای افزوده برای مدل پیچیده‌تر است (امبرتسون و رایس، ترجمه شریفی و همکاران، ۱۳۸۸). مقادیر این شاخص در جدول (۲) ارائه شده است. با توجه به جدول، مدل دو پارامتری با داده‌ها برازش دارد.

جدول (۲) مقادیر شاخص برازش لگاریتم درستنمایی مدل‌های مختلف

لگاریتم درستنمایی	مدل سوال - پاسخ
۴۷۵۲۵/۴۸۹	تک پارامتری
۴۶۸۰۶/۸۷۷۹	دو پارامتری
۴۶۸۱۱/۱۴۳۹	سه پارامتری

پس از کسب اطمینان از برقراری مفروضه‌های مدل و برازش مدل با داده‌ها، در گام اول به منظور تعیین وجود کارکرد افتراقی در سوال‌ها، داده‌ها دوبار تحلیل می‌شوند. در نوبت اول داده‌ها به طور کلی تحلیل می‌شوند به گونه‌ای که از جامعه یکسانی انتخاب شده‌اند. در نوبت دوم داده‌ها در زیرگروه‌ها با استفاده از تحلیل کارکرد افتراقی با فرض صفر عدم وجود کارکرد افتراقی، تحلیل می‌شوند. تفاوت لگاریتم درستنمایی دو مرحله دارای توزیع مجذور کای با درجه آزادی $(n-1)(m-1)$ است که n معرف تعداد سوال‌ها و m معرف تعداد گروه‌ها است. هنگامی که مجذور کای معنادار است، شواهدی از کارکرد افتراقی وجود دارد. بر این اساس در مطالعه حاضر داده‌ها یکبار به طور کلی و یکبار در دو گروه داوطلبان دختر و پسر با استفاده از تحلیل کارکرد افتراقی تحت فرضیه صفر مبنی بر عدم وجود کارکرد افتراقی

تحلیل شدند. مقدار لگاریتم درستنمایی در مرحله اول برابر با $1880^{34}/86$ و در مرحله دوم $1877^{84}/02$ است که تفاوت آن $250/84$ است و در سطح $0/05$ با درجه آزادی ۵۴ معنادار است که این نتیجه بیانگر وجود اثرات کارکرد افتراقی در آزمون ریاضی است.

پس از تأیید وجود کارکرد افتراقی در آزمون، در گام بعدی تحلیل کارکرد افتراقی سوال‌ها انجام شد. نرمافزار کارکرد افتراقی را فقط بر اساس پارامتر دشواری بررسی می‌کند. کارکرد افتراقی در سه مرحله مورد بررسی قرار می‌گیرد. در مرحله نخست پارامتر سوال‌ها برای هر یک از دو گروه آزمودنی به طور جداگانه برآورده شود. البته پارامتر تشخیص سوال‌ها برای دو گروه یکسان در نظر گرفته می‌شود. برنامه BILOG- MG میانگین و انحراف استاندارد گروه‌ها را یکسان فرض نمی‌کند. میانگین و انحراف استاندارد گروه کانونی پارامترهایی هستند که برآورده می‌شوند. در مرحله دوم میانگین دشواری سوال‌ها برای گروه مرجع و کانونی محاسبه می‌شود و تفاوت میانگین دشواری سوال‌های دو گروه کانونی و مرجع محاسبه می‌شود. پارامتر دشواری سوال‌های گروه کانونی با کم کردن تفاوت میانگین دشواری دو گروه از پارامتر دشواری سوال‌های گروه کانونی، تعدیل می‌شوند. در مرحله سوم تفاوت میان پارامترهای دشواری سوال‌های مربوط به گروه مرجع و کانونی و خطای استاندارد محاسبه می‌شود، تفاوت زیاد نشان‌دهنده کارکرد افتراقی سوال می‌باشد. در واقع سوال‌هایی که تفاوت میان پارامتر دشواری آنها در دو گروه تقریباً بیش از دو برابر خطای استاندارد ($S_{Ex1/96}$) است به عنوان سوال‌هایی با کارکرد افتراقی در نظر گرفته می‌شوند. در تحلیل حاضر با توجه به این‌که داوطلبان دختر گروه کانونی و داوطلبان پسر، گروه مرجع را تشکیل می‌دهند، مقادیر منفی تفاوت میان پارامترهای دشواری سوال‌ها در گروه مرجع و کانونی بیانگر آن است که سوال به نفع داوطلبان دختر است و بر عکس. نتایج تحلیل سوال‌ها آزمون در جدول (۳) ارائه شده است. همان گونه که در جدول مشخص شده است نه سوال آزمون ($16/4$ درصد سوال‌ها) کارکرد افتراقی دارند که تمام این سوال‌ها به نفع آزمودنی‌های دختر سوگیری دارند (سؤال‌های شماره ۵، ۷، ۹، ۱۸، ۲۷، ۳۲، ۳۶ و ۴۱ و ۴۹).

جدول (۳) نتایج تحلیل مبتنی بر رویکرد سوال - پاسخ

DIF	تفاوت دشواری گروه‌ها داوطلبان پسر - داوطلبان دختر	سوال	DIF	تفاوت دشواری گروه‌ها داوطلبان پسر - داوطلبان دختر	سوال
	۰/۰۵۴ *۰/۱۵۹	۲۹		-۰/۰۳ *۰/۰۵۴	۱
	۰/۰۷۱ *۰/۲۹۷	۳۰		۰/۰۵۴ *۰/۲۰۸	۲
	-۰/۰۲۴ *۰/۱۹۶	۳۱		-۰/۰۴۲ *۰/۶۵	۳
+	-۰/۳۴۶ *۰/۰۶۴	۳۲		۰/۰۱۲ *۰/۳۳۷	۴
	۰/۳۱ *۰/۴۲۱	۳۳	+	-۰/۲۱۳ *۰/۰۶	۵
	۰/۲۵۱ *۰/۲۵۸	۳۴		-۰/۰۳۲ *۰/۰۶۹	۶
	۰/۱۵۹ *۰/۰۹۸	۳۵	+	-۰/۲۸۵ *۰/۱۱۱	۷
+	-۰/۱۸۸ *۰/۰۹۴	۳۶		۰/۱۵۲ *۰/۰۹۱	۸
	-۰/۲۰۱ *۰/۱۱۶	۳۷	+	-۰/۱۸ *۰/۰۵۲	۹
	۰/۰۱ *۰/۲۰۵	۳۸		۰/۶۲۲ *۰/۴۲	۱۰
	-۰/۰۱۸ *۰/۲۷۲	۳۹		-۰/۱۴۵ *۰/۱۰۷	۱۱
	-۰/۸ *۰/۱۸۴	۴۰		۰/۲۰۸ *۰/۰۵۸۸	۱۲
+	-۰/۲۰۲ *۰/۰۷۷	۴۱		۰/۲۸۴ *۰/۳۳۳	۱۳
	-۰/۰۲۹ *۰/۰۹۹	۴۲		۰/۳۱۱ *۰/۳۴۸	۱۴
	۰/۲۸۱ *۰/۳۲۲	۴۳		-۰/۲۴۴ *۰/۲۸۹	۱۵
	۰/۳۹۴ *۰/۳۰۶	۴۴		۰/۳۷۴ *۰/۰۵۲	۱۶

DIF	تفاوت دشواری گروه‌ها داوطلبان پسر - داوطلبان دختر	سوال	DIF	تفاوت دشواری گروه‌ها داوطلبان پسر - داوطلبان دختر	سوال
				داوطلبان پسر - داوطلبان دختر	
	-۰/۳۰۹ *۰/۱۶۵	۴۵		۰/۰۳۸ *۰/۱۲۴	۱۷
	۰/۰۶۳ *۰/۱۰۹	۴۶	+	-۰/۰۳۸ *۰/۰۷۶	۱۸
	۰/۰۰۵ *۰/۱۰۰	۴۷		۰/۱۱۶ *۰/۲۴۸	۱۹
	-۰/۰۲۲۵ *۰/۱۴۶	۴۸		۰/۱۲۷ *۰/۴۵۳	۲۰
+	-۲/۱۲۶ *۰/۶۸۴	۴۹		۰/۰۰۷ *۰/۱۱۲	۲۱
	۰/۰۸۵ *۰/۳۳۹	۵۰		-۰/۰۰۴ *۰/۱۱	۲۲
	۰/۰۲۳ *۱/۱۰۸	۵۱		-۰/۱۸۷ *۰/۱۹۷	۲۳
	۰/۰۰۶ *۰/۳۱۸	۵۲		-۰/۱۳۸ *۰/۰۷۲	۲۴
	۰/۰۵۴ *۰/۱۷۱	۵۳		۰/۰۵۲ *۰/۱۶	۲۵
	-۰/۰۰۲۹ *۰/۱۷۱	۵۴		-۰/۱۱۷ *۰/۰۸۲	۲۶
	۱/۰۰۶ *۱/۰۳۹	۵۵	+	-۰/۱۹۷ *۰/۰۷۵	۲۷
				۰/۱۸۸ *۰/۱۳۱	۲۸

(*) خطای استاندارد (+) وجود کارکرد افتراقی

در ادامه تحلیل کارکرد افتراقی سوال‌ها با استفاده از روش مانتل هنzel مورد ارزیابی قرار گرفت. در مطالعه حاضر تحلیل مانتل هنzel با استفاده از نرم‌افزار Leartap انجام شده است. برای هر سوال در هر سطح نمره، تعداد و نسبت افراد هریک از گروه‌های مرجع و کانونی که به سوال، پاسخ درست داده‌اند، شاخص مجدولهای مانتل هنzel،

آلفای مانتل هنzel^۱، دلتای مانتل هنzel^۲، نسبت بختها، معناداری و اندازه اثر محاسبه می‌شود. نسبت بخت، اندازه‌ای نسبی است که احتمال این‌که فردی از گروه مرجع در مقایسه با گروه کانونی به سوال پاسخ درست بدهد را نشان می‌دهد. مقادیر بزرگ‌تر از یک نشان‌دهنده این است که احتمال پاسخ‌گویی درست بیشتر به نفع گروه مرجع است و مقادیر کم‌تر از یک بیانگر آن است که احتمال پاسخ‌گویی درست بیشتر به نفع گروه کانونی است. آلفای مانتل هنzel عبارت است از میانگین نسبت بخت‌ها در تمام سطوح نمره که براساس تعداد افراد هر یک از گروه‌ها در هر سطح نمره وزن‌دهی شده‌اند. بخت، به عنوان شاخصی از احتمال وقوع یک حادثه، با این محدودیت همراه است که دامنه آن همواره بین صفر تا مثبت بی‌نهایت است یا به عبارتی ناقرینه^۳ است. به همین علت از آن لگاریتم گرفته و به این ترتیب لگاریتم آلفای مانتل هنzel به دست می‌آید که دامنه آن در بازه منفی بی‌نهایت تا مثبت بی‌نهایت است. سوالات با مقادیر مثبت به سود گروه مرجع و سوالات با مقادیر منفی به نفع گروه کانونی سوگیری دارند. هالند و تایر برای نشان دادن مقدار کارکرد افتراقی شاخص دیگری را پیشنهاد کردند که در واقع تبدیل آلفای مانتل هنzel به مقیاسی دیگر است که دلتای مانتل هنzel نامیده می‌شود و از رابطه زیر به دست می‌آید:

$$MH\ D-DIF = -2.35 * \ln MH\ alpha$$

سوالات با مقادیر دلتای مانتل هنzel مثبت به نفع گروه کانونی و سوالات با مقادیر منفی به نفع گروه مرجع هستند. خدمات سنجش آموزشی^۴ طبقه‌بندی سه سطحی را برای کارکرد افتراقی سوال ارائه کرده است (زویک^۵، ۲۰۱۲) که عبارتند از:

- سطح A : قدر مطلق دلتای مانتل هنzel سوالات این طبقه کم‌تر از ۱ است. سوالات این طبقه فاقد کارکرد افتراقی یا کارکرد افتراقی ناچیزی دارند.
- سطح B : سوالات با قدر مطلق دلتای مانتل هنzel بین ۱ تا ۱/۵ در این طبقه قرار می‌گیرند. این سوالات کارکرد افتراقی متوسطی دارند.

1. MH alpha

2. MH D-DIF

3. Asymmetry

4. Educational Testing Service (ETS)

5. Zwick

-۳ سطح C : سوال‌های این طبقه با شاخص مجدور کای مانتل هنzel معنادار و قدر مطلق دلتای مانتل هنzel بیش از ۱/۵ مشخص می‌شوند. کارکرد افتراقی سوال‌ها زیاد است و چنین سوال‌هایی از آزمون حذف می‌شوند (زویک، ۲۰۱۲). نتایج تحلیل مانتل هنzel سوال‌های آزمون در جدول (۵) ارائه شده است.

جدول (۵) نتایج تحلیل مانتل هنzel

سوال	شاخص مانتل هنzel	معناداری	آلفای مانتل هنzel	دلتای مانتل هنzel	طبقه‌بندی ETS
۱	۰/۶۱	۰/۴۴	۱/۰۶	-۰/۱۳	A
۲	۰/۶۵	۰/۴۲	۱/۱۰	-۰/۲۲	A
۳	۰/۲	۰/۶۶	۱/۰۳	-۰/۰۸	A
۴	۰/۱۴	۰/۷۱	۱/۰۴	-۰/۱۰	A
۵	۷/۸۱	*۰/۰۱	۰/۸۰	۰/۵۲	A
۶	۰/۲۹	۰/۵۹	۱/۰۴	-۰/۱۰	A
۷	۷/۷۲	*۰/۰۱	۰/۸۱	۰/۵۰	A
۸	۹/۲۴	*۰/۰۰	۱/۳۱	-۰/۶۳	A
۹	۴/۲۲	*۰/۰۴	۰/۸۶	۰/۳۶	A
۱۰	۱۴/۳۶	*۰/۰۰	۱/۰۹	-۱/۰۹	B
۱۱	۰/۷۷	۰/۳۸	۰/۹۴	۰/۱۵	A
۱۲	۲/۱۶	۰/۱۴	۱/۱۳	-۰/۲۸	A
۱۳	۴/۵۹	*۰/۰۳	۱/۲۴	-۰/۵۰	A
۱۴	۵/۲۶	*۰/۰۲	۱/۳۶	-۰/۷۲	A
۱۵	۱/۴۹	۰/۲۲	۰/۹۱	۰/۲۱	A
۱۶	۴/۵۷	*۰/۰۳	۱/۳۲	-۰/۶۵	A
۱۷	۰/۰۱	۰/۹۳	۰/۹۹	۰/۰۲	A
۱۸	۲۳/۵۵	*۰/۰۰	۰/۷۰	۰/۸۵	A
۱۹	۱/۰۴	۰/۳۱	۱/۱۳	-۰/۲۹	A
۲۰	۱/۰۷	۰/۳۰	۱/۱۱	-۰/۲۵	A
۲۱	۰/۴۴	۰/۵۱	۱/۰۶	-۰/۱۴	A
۲۲	۰/۲۳	۰/۶۳	۱/۰۴	-۰/۰۹	A
۲۳	۱/۰۶	۰/۲۱	۰/۸۸	۰/۳۱	A
۲۴	۱/۳۷	۰/۲۴	۰/۹۱	۰/۲۳	A
۲۵	۱/۴۹	۰/۲۲	۱/۱۴	-۰/۳۰	A
۲۶	۱/۱۴	۰/۲۹	۰/۹۰	۰/۲۵	A

سوال	شاخص مانتل هنzel	معناداری	آلفای مانتل هنzel	دلتای مانتل هنzel	طبقه‌بندی ETS
۲۷	۶/۱۲	*۰/۰۱	۰/۷۵	۰/۶۷	A
۲۸	۵/۶۲	*۰/۰۲	۱/۲۰	-۰/۴۳	A
۲۹	۰/۵۶	۰/۴۵	۱/۰۸	-۰/۱۸	A
۳۰	۰/۳۹	۰/۰۳	۱/۰۸	-۰/۱۷	A
۳۱	۰/۰۲	۰/۹۰	۱/۰۱	-۰/۰۳	A
۳۲	۲۳/۰۹	*۰/۰۰	۰/۶۹	۰/۸۶	A
۳۳	۴/۳۲	*۰/۰۴	۱/۳۷	-۰/۷۴	A
۳۴	۴/۰۶	*۰/۰۴	۱/۳۰	-۰/۶۲	A
۳۵	۶/۲۸	*۰/۰۱	۱/۱۹	-۰/۴۲	A
۳۶	۳/۴۱	۰/۰۶	۰/۸۶	۰/۳۴	A
۳۷	۲/۵۳	۰/۱۱	۰/۸۸	۰/۳۰	A
۳۸	۰/۰۶	۰/۸۱	۱/۰۳	-۰/۰۸	A
۳۹	۰/۰۲	۰/۹۰	۰/۹۸	۰/۰۵	A
۴۰	۰/۰	۰/۹۵	۰/۹۹	۰/۰۲	A
۴۱	۰/۰۶	*۰/۰۲	۰/۸۱	۰/۵۱	A
۴۲	۰/۱۱	۰/۷۴	۱/۰۳	۰/۰۷	A
۴۳	۵/۰	*۰/۰۳	۱/۳۸	-۰/۷۵	A
۴۴	۹/۰۶	*۰/۰۰	۱/۳۶	-۰/۷۳	A
۴۵	۴/۷۹	*۰/۰۳	۰/۸۶	۰/۳۶	A
۴۶	۱/۲۷	۰/۲۳	۱/۱۰	-۰/۲۳	A
۴۷	۲/۰۹	۰/۱۵	۱/۱۴	-۰/۳۰	A
۴۸	۴/۴۲	*۰/۰۴	۰/۸۴	۰/۴۰	A
۴۹	۲۱/۶۴	*۰/۰۰	۰/۷۴	۰/۷۱	A
۵۰	۰/۳۰	۰/۵۸	۱/۰۵	-۰/۱۳	A
۵۱	۰/۰۵	۰/۸۲	۱/۰۳	-۰/۰۸	A
۵۲	۲/۴۷	۰/۱۲	۱/۲۷	-۰/۵۷	A
۵۳	۶/۸۴	*۰/۰۱	۱/۳۲	-۰/۶۶	A
۵۴	۰/۰۴	۰/۸۴	۱/۰۲	-۰/۰۴	A
۵۵	۱۸/۸۸	*۰/۰۰	۱/۴۰	-۰/۷۸	A

همانگونه که در جدول مشخص شده است، شاخص مانتل هنzel ۲۳ سوال (۴۱/۸) درصد سوالهای (۰/۰۵) در سطح معنادار است. از این ۲۳ سوال با توجه به مقادیر دلتای مانتل هنzel ۲۲ سوال در سطح A هستند، به این معنا که مقدار دلتای مانتل هنzel آنها

کمتر از یک است و در واقع با وجود معنادار بودن شاخص مانتل هنzel، کارکرد افتراقی ناچیزی دارند و می‌توان این سوال‌ها را در آزمون حفظ کرد. سوال شماره ۱۰ در سطح B است و دارای کارکرد افتراقی متوسط است. هیچ یک از سوال‌های آزمون کارکرد افتراقی زیاد از خود نشان نداده‌اند (سطح C). از این ۲۳ سوال که شاخص مانتل هنzel معنادار دارند، ۱۰ سوال به نفع داوطلبان دختر (سوال‌های شماره ۵، ۷، ۹، ۱۰، ۱۳، ۱۴، ۱۶، ۲۷، ۳۲، ۴۱، ۴۵، ۴۸ و ۴۹) و ۱۳ سوال (سوال‌های شماره ۸، ۱۰، ۱۳، ۱۴، ۱۶، ۲۷، ۳۳، ۳۴، ۴۲، ۴۴، ۴۵ و ۵۵) به نفع داوطلبان پسر است.

همان‌گونه که مشاهده می‌شود روش مبتنی بر نظریه سوال – پاسخ تعداد سوال‌های کمتری را به عنوان سوال‌های دارای کارکرد افتراقی مشخص کرده است (۹ سوال در مقابل ۲۳ سوال) که این یافته با نتایج مطالعه دوراند و پارک همسو است. یک دلیل تفاوت حساسیت روش‌های مختلف تعیین کارکرد افتراقی ممکن است مربوط به تعدیلات ریاضی خطای نوع اول باشد که در هر برنامه‌ای به گونه متفاوتی اجرا می‌شود. بررسی سوال‌هایی که دارای کارکرد افتراقی هستند بیانگر آن است که سوال‌هایی که به نفع دختران کارکرد افتراقی دارند در حوزه محتوایی توابع و معادلات هستند و سوال‌هایی که به نفع پسران کارکرد افتراقی دارند بیشتر در حوزه محتوایی مثلثات، هندسه و احتمال می‌باشند. البته بررسی دقیق‌تر سوال‌های آزمون توسط کارشناسان موضوعی به منظور روشن ساختن منبع و دلیل کارکرد افتراقی ضروری می‌باشد.

به منظور بررسی توافق و هم‌خوانی میان دو روش مانتل هنzel و روش مبتنی بر رویکرد سوال – پاسخ در تشخیص کارکرد افتراقی، ضریب کاپا^۱ محاسبه شد و به این ترتیب میزان هم‌خوانی روش‌ها در تعیین سوال‌های دارای کارکرد افتراقی مشخص شد. در جدول (۶) فراوانی سوال‌های دارای کارکرد افتراقی و فاقد کارکرد افتراقی براساس دو رویکرد ارائه شده است. همان‌گونه که در جدول مشخص شده است، دو روش در تعیین هشت سوال دارای کارکرد افتراقی و در ۳۱ سوال فاقد کارکرد افتراقی مطابقت داشتند. مقادیر ضریب کاپا در مطالعه حاضر برابر با 0.346 ^۲ و $p=0.002$ و فاصله اطمینان 95 درصد (0.565 ، 0.126) است. پیشنهاد لاندیس^۳ و کخ^۳ (۱۹۹۷) این است که کاپای بیش از 0.75 حاکی از توافق عالی، کاپای کمتر از

1. Kappa coefficient
2. Landis
3. Kokh

۴/۰ نشاندهنده توافق ضعیف و بالاخره کاپای بین ۰/۴ تا ۰/۷۵ نشان از توافق نسبی خوب دارد. در مطالعه حاضر میزان توافق میان دو روش، ضعیف است. بیشتر مطالعات انجام شده در خصوص توافق روش‌های مختلف ارزیابی کارکرد افتراقی بیانگر توافق کم میان روش‌های مختلف است. همگرایی روش‌های بررسی کارکرد افتراقی به شدت تحت تأثیر ناپایابی شاخص‌های ارزیابی کارکرد افتراقی است (عبدالعزیز، ۲۰۱۰).

جدول (۶) فراوانی سوالهای دارای کارکرد افتراقی و فاقد کارکرد افتراقی

تعداد کل	رویکرد سوال - پاسخ			مانتل هنzel
	دارای کارکرد افتراقی	فاقد کارکرد افتراقی	دارای کارکرد افتراقی	
۲۳	۱۵	۸	دارای کارکرد افتراقی	
۳۲	۳۱	۱	فاقد کارکرد افتراقی	
۵۵	۴۶	۹	تعداد کل	

نتیجه‌گیری

مطالعه حاضر به ارزیابی کارکرد افتراقی سوالهای آزمون ریاضی با استفاده از دو روش مانتل هنzel و روش مبتنی بر نظریه سوال - پاسخ پرداخته است. تحلیل مبتنی بر رویکرد سوال - پاسخ با استفاده از نرم افزار BILOG-MG انجام شده است. این برنامه کارکرد افتراقی را صرفاً براساس پارامتر دشواری بررسی می‌کند. نظریه سوال - پاسخ روش مناسبی برای ارزیابی کارکرد افتراقی سوالها محسوب می‌شود که این به واسطه ویژگی نامتغیر بودن پارامترها در این رویکرد است. نتایج تحلیل، بیانگر وجود کارکرد افتراقی در سوالهای آزمون ریاضی است. براساس رویکرد سوال - پاسخ، نه سوال کارکرد افتراقی دارند که تمامی آنها نیز به نفع آزمودنی‌های دختر هستند. در تحلیل آزمون براساس روش مانتل هنzel، شاخص مانتل هنzel ۲۳ سوال آزمون در سطح ۰/۰۵ معنادار بود که ده سوال به نفع آزمودنی‌های دختر و ۱۳ سوال به نفع آزمودنی‌های پسر است. با توجه به طبقه‌بندی خدمات سنجش آموزشی ۲۲ سوال دارای کارکرد افتراقی ناچیز می‌باشند (سطح A) و یک سوال کارکرد افتراقی متوسط دارد (سطح B). شایان ذکر است که از نه سوالی که بر اساس رویکرد سوال - پاسخ دارای کارکرد افتراقی هستند، هشت مورد آن نیز در روش مانتل هنzel دارای کارکرد

افترافقی می‌باشدند. تنها سؤال شماره ۳۶ است که براساس روش مبتنی بر رویکرد سؤال - پاسخ دارای کارکرد افترافقی است، اما در روش مانتل هنزل فاقد کارکرد افترافقی است. میزان توافق و همخوانی میان دو روش مانتل هنزل و روش مبتنی بر رویکرد سؤال - پاسخ در تشخیص کارکرد افترافقی با توجه به ضریب کاپا 0.346 ضعیف است. رویکرد سؤال - پاسخ در مقایسه با روش مانتل هنزل تعداد کمتری از سؤال‌ها را دارای کارکرد افترافقی تشخیص داده است، این یافته مشابه نتایج مطالعه دوراند و پارک (۲۰۰۶) است. بر این اساس سازندگان آزمون‌ها می‌بایست همواره به تفاوت‌های روش‌های مختلف ارزیابی کارکرد افترافقی سؤال‌ها توجه داشته باشند و سؤال‌هایی را که بر اساس یک روش دارای کارکرد افترافقی هستند با سایر روش‌های معتبر نیز مورد بررسی قرار دهند.

بررسی سؤال‌های دارای کارکرد افترافقی در آزمون ریاضی بیانگر آن است که سؤال‌های دارای کارکرد افترافقی به نفع دختران بیشتر در حوزه محتوای توابع و معادلات و سؤال‌های دارای کارکرد افترافقی به نفع پسران در حوزه محتوای مثلثات، هندسه و احتمال هستند. پس از تعیین کارکرد افترافقی، کارشناسان موضوعی می‌بایست محتوای سؤال‌ها را به منظور روش ساختن منبع و دلیل کارکرد افترافقی مورد بازبینی کامل قرار دهند. از این رو لازم است در مطالعات بعدی سؤال‌های آزمون که دارای کارکرد افترافقی بودند از لحاظ محتوای توسط کارشناسان موضوعی مورد بررسی قرار گیرند. وجود سؤال‌های دارای کارکرد افترافقی در آزمون، ضرورت بررسی و توجه بیشتر به فرایند طراحی سؤال‌های آزمون و آموزش جامع طراحان سؤال را به منظور تهیه آزمون‌های عادلانه و منصفانه مطرح می‌سازد.

منابع

- امپرسون، سوزان ای و رایس، استیون پی (۲۰۰۰). نظریه‌های جدید روانسنجی برای روانشناسان (IRT). ترجمه: دکتر حسن پاشا شریفی، دکتر ولی‌الله فرزاد، مجتبی حبیبی عسگرآباد و بلال ایزانلو (۱۳۸۸). تهران: انتشارات رشد.
- همبلتون، رونالد ک، سوامینانان، اچ و راجرز، جین. (۱۹۹۱). مبانی نظریه پرسش-پاسخ. ترجمه: دکتر محمدرضا فلسفی نژاد (۱۳۸۹). تهران: انتشارات دانشگاه علامه طباطبائی.

- Abedalaziz, Nabeel. (2010). A gender - related differential item functioning of mathematics test item. *The International Journal of Educational and Psychological Assessment*, 5,101-116 .
- Ahmadi, Alireza. (2008). *Differential Item Functioning in High-stakes Tests: the Effect of Gender and Field of Study*. Doctoral dissertation, University of Isfahan, Faculty of Foreign Languages, Department of English .
- Baghi, Heibatollah & Ferrara, Steven. (1989). *A comparison of IRT, Delta Plot and Mantel- Haenszel techniques for detecting differential item functioning across subpopulations in the Maryland test of citizenship skills*. Paper presented at the annual meeting of the American Educational Research Association. San Francisco, CA: March 27-31 (Eric database, Report: ED324364) .
- Conoley, C. Adele (2003). *Differential item functioning in the Peabody picture vocabulary test - third edition: partial correlation versus expert judgment*. Doctoral dissertation. Texas A&M University .
- Dorans, Neil J. & Holland,Paul W. (1992). *DIF Detection and Description: Maentel - Haenszel and Standardization*. Paper presented at the Educational Testing Service/AFHRL Conference (Princeton. NJ. October)
- Driana, Elin. (2007). *Gender item functioning on a ninth- grade mathematics proficiency test in Appalachian Ohio*. Doctoral dissertation, Ohio University, Ohio .
- Duncan, Cromwell, Susan. (2006). *improving the prediction of differential item functioning: A comparison of the use of an effect size for logistic regression DIF and Mantel- Haenszel DIF methods*. Doctoral dissertation, Texas A&M University .
- Durand, Jeffrey & Park, Siwo. (2006). A Study of Gender and Academic Major - Based Differential Item Functioning (DIF) In KEPT 2006, Mexico .

-
- Eng, L. S., & Hoe, L. S. (2005). Detecting Differential Item Functioning (DIF) in Standardized Multiple-Choice Test: An Application of Item Response Theory (IRT). [ONLINE] Available at:<http://www.ipbl.edu.my/inter/penyelidikan/seminarpapers/2005/linguitm.pdf>.
 - Hambleton, R. , & Rodgers, J. (1995). Item bias review. Practical Assessment, Research, and valuation, 4(6). Retrieved November 18, 2006, from <http://PAREonline.net/getvn.asp?v=4&n=6>
 - Hambleton 'R. K. (1989). Principles and selected applications of item response theory. In R. L. Linn (Ed.) 'Educational measurement (3rd ed ,pp. 147-200). New York NY: American Council on Education & Macmillan Publishing .
 - Landis, J. R. , Koch, G. G. (1977). The measurement of observer agreement for categorical data. Biometrics 33:159-174.
 - Näsström, Gunilla. (2003). *Differential item functioning for items in the Swedish National test in mathematics, course B*. Paper presented at the Pre-ICME Conference in Växjö .
 - O'Neal, Marcia R. (1991). A Comparison of Method for Detecting Item Bias. Paper presented at the annual meeting of the Mid-South Educational Research Association (20th, Lexington, KY, November 12-15 .
 - Oshima, T. C. and Morris, S. B. (2008), Raju's Differential Functioning of Items and Tests (DFIT). Educational Measurement: Issues and Practice, 27: 43–50. doi: 10.1111/j.1745-3992.2008.00127 .
 - Rousseau, M. , Bertrand, R. , & Boiteau, N. (2004). *Impact of missing data on robustness of DIF IRT-based and Non-IRT-based methods*. Paper presented at the 2004 AERA annual meeting .
 - Shultz, S. Kenneth & Whitney, David. (2005). Measurement Theory in Action. Case Studies and Exercises. Sage publication .
 - Willingham, W. W. & Cole, N. S; (1997). Gender and fair assessment. New Jersey, U. S. A: Lawrence Erbaum associate
 - Zumbo, B. D. (1999). A handbook on the theory and methods of differential item functioning (DIF): Logistic regression modeling as a unitary framework for binary and Likert-like (ordinal) item scores. Ottawa, Canada: Directorate of Human Resources Research and Evaluation .
 - Zwick .Rebecca (2012). A Review of ETS Differential Item Functioning Assessment Procedures: Flagging Rules, Minimum Sample Size Requirements, and Criterion Refinement. [ONLINE] Available at: <http://www.ets.org/Media/Research/pdf/RR-12-08.pdf>.