

سنچش مقایسه‌پذیری سازه و تحلیل کارکرد افتراقی سؤال‌ها و بلوک‌های (DTF) آزمون علوم پایه هشتم تیمز ۲۰۰۷ در بین دانشآموزان ایران و آمریکا

اصغر مینایی^۱

چکیده

در سنچش‌های بین‌المللی مانند تیمز و پرلز لازم است تا آزمون‌های مورد استفاده از همارزی سازه که به مقایسه‌پذیری سازه معروف است برخوردار بوده و سؤال‌ها تا حد ممکن برای تمام کشورها و گروه‌های مشارکت کننده، یکسان عمل نمایند. در پژوهش حاضر تلاش شد تا مقایسه‌پذیری سازه‌ای آزمون علوم پایه هشتم (سوم راهنمایی) تیمز ۲۰۰۷ و کارکرد افتراقی بر عملکرد دانشآموزان ایران و آمریکا و همچنین میزان تأثیر سؤال‌های دارای کارکرد افتراقی بر عملکرد دانشآموزان ایرانی مورد بررسی قرار گیرد. برای تحلیل داده‌ها و پاسخگویی به سؤال‌های پژوهش از ترکیبی از رویکردهای تحلیل عاملی تأییدی و نظریه سؤال - پاسخ استفاده شد. نتایج حاصل از تحلیل عاملی تأییدی نشان می‌دهد که آزمون علوم از مقایسه‌پذیری سازه در بین دو گروه مورد مطالعه برخوردار است. این یافته بدان معناست که دانشآموزان دو کشور ایران و آمریکا برای دادن پاسخ به سؤال‌های علوم از چارچوب مفهومی یکسانی استفاده می‌کنند. با این حال، نتایج حاصل از تحلیل کارکرد افتراقی سؤال‌ها نشان می‌دهد ۶۲٪ سؤال‌های درس علوم تیمز ۲۰۰۷ علیه دانشآموزان ایران از کارکرد افتراقی برخوردارند. به طور خلاصه، به ظرفی رسید که عملکرد ضعیف دانشآموزان ایران در درس علوم تیمز ۲۰۰۷ را نمی‌توان به کارکرد افتراقی سؤال‌ها نسبت داد و بایستی علل آن را جایی دیگر جستجو کرد. مسئولان وزارت آموزش و پرورش و متولیان امور آموزش در کشور بایستی تلاش کنند تا با تهیه محتواهای آموزشی مناسب، مفاهیم مهم هر حوزه را به صورت زنجیره‌وار و در ارتباط با یکدیگر آموزش دهند و تلاش کنند تا توانایی و مهارت تفکر واگرا و چند‌بعدی را در دانشآموزان پرورش دهند. همچنین بایستی تلاش شود تا از روش سنتی آموزش که به شکل سختنای و عدم تائیدی صورت می‌گیرد فاصله گرفت و دانشآموزان را در گیر فعالیتهای عملی و آزمایشگاهی نمود.

وازگان کلیدی: تحلیل عاملی تأییدی، تغییرناپذیری عاملی، تیمز، کارکرد افتراقی سؤال، نظریه سؤال - پاسخ.

۱. هیأت علمی پژوهشگاه آموزش و پرورش. Email: as_minaei@yahoo.com.

تاریخ پذیرش: ۱۳۹۲/۳/۲۵

تاریخ دریافت: ۱۳۹۲/۱/۱۸

مقدمه

سنجهای بین‌المللی، مانند TIMSS و PIRLS، به طور فزاینده‌ای مورد توجه وزارتخانه‌ها و سیاست‌گذاران آموزشی کشورهای مختلف قرار دارند. چنین سنجهای این امکان را فراهم می‌آورد تا دروندادها، فرایندها و پیشرفت تحصیلی کشورهای مختلف را مقایسه و چشم‌انداز وسیعی را برای ارزیابی و بهبود آموزش فراهم نمود (ارسی کان^۱، ۱۹۹۸). نمره‌های حاصل از این سنجهای ارزیابی اصلی مقایسه عملکردهای کشورها، تصمیم‌گیری‌های مربوط به سیاست‌های آموزشی و پژوهش در زمینه نتایج ارزیابی را تشکیل می‌دهند.

معادل‌بودن یا همارزی^۲ سازه در میان گروه‌های مورد مطالعه، که به مقایسه‌پذیری سازه معروف است، شرط اصلی برای مطالعه تفاوت‌های گروهی است و روایی استباطهایی که بر اساس نتایج سنجهای بین‌المللی به عمل می‌آید اساساً به مقایسه‌پذیری نمره‌ها در میان کشورها بستگی دارد.

آزمون تیمز یکی از مهم‌ترین سنجهای بین‌المللی است که توسط انجمن بین‌المللی ارزشیابی پیشرفت تحصیلی^۳ (IEA) برگزار می‌گردد. کشور جمهوری اسلامی ایران به منظور ارزیابی و بهبود نظام آموزشی خود از سال ۱۳۷۰ برابر با ۱۹۹۱ میلادی رسماً همکاری خود را با انجمن IEA آغاز کرد و تا کنون در ۵ مطالعه در فاصله سال‌های ۱۹۹۵، ۱۹۹۹، ۲۰۰۳، ۲۰۰۷، ۲۰۱۱ و تیمز پیشرفته ۲۰۰۸ شرکت کرده است (کریمی، ۱۳۸۸).

در سنجهای بین‌المللی، ایده‌آل این است که صرفاً از یک فرم مشترک و یکسان آزمون استفاده شود. با این حال، از آنجا که آزمون در کشورهای مختلف اجرا می‌شود، لازم است به زبان کشورهای مشارکت کننده ترجمه شود. اگر ترجمه، به طور نامناسبی صورت گیرد ویژگی‌های روان‌سنجی آزمون‌ها ممکن است تحت تأثیر قرار گیرد (ارسی کان، ۱۹۹۸).

در خصوص کارکرد افتراقی سؤال‌های تیمز مطالعات متعددی صورت گرفته است. از

1. Ercikan

2. Equivalence

3. International Association for the Evaluation of Educational Achievement

جمله این مطالعات می‌توان به ارسی کان (۱۹۹۸)، ارسی کان و کاه (۲۰۰۵)، ارسی کان و مک کریس (۲۰۰۲)، بیتون (۱۹۹۸)، وو، لی، و زامبو^۱ (۲۰۰۷) اشاره کرد. به عنوان مثال، ارسی کان (۱۹۹۸) دریافت که تعداد ۱۸ سؤال (٪۲۶) از ۷۰ سؤال مورد مطالعه در درس علوم TIMSS سال ۱۹۹۵ دارای DIF هستند. از این ۱۸ سؤال تعداد ۱۰ سؤال به نفع گروه مرجع^۲، که دانش آموزان انگلیسی زبان بودند، و تعداد ۸ سؤال به نفع گروه هدف^۳، که دانش آموزان فرانسوی زبان کشور کانادا بودند، عمل می‌کنند. پژوهش ارسی کان و کاه (۲۰۰۵) نیز نتایج مشابهی به دست داد. آن‌ها دریافتند که سؤال‌های هر دو بخش ریاضی و علوم TIMSS بر علیه دانش آموزان فرانسوی زبان عمل می‌کنند.

ارسی کان و مک کریس (۲۰۰۲) نیز دریافتند که در درس ریاضی تیمز ۱۹۹۵، از ۱۵۶ سؤال مورد مطالعه، ۲۲ سؤال در بین دانش آموزان فرانسوی و انگلیسی زبان کشور کانادا، ۶۱ سؤال در بین دانش آموزان کشور فرانسه و انگلستان، و از بین ۱۵۴ سؤال، ۹۱ سؤال در بین دانش آموزان کشور فرانسه و آمریکا دارای DIF هستند. تقریباً ۴۵٪ سؤال‌های دارای DIF به نفع دانش آموزان فرانسوی زبان عمل می‌کردند. در درس علوم در مقایسه با درس ریاضی نسبت بیشتری از سؤال‌ها دارای DIF بودند. از ۱۴۰ سؤال مورد مطالعه، تعداد ۵۲ سؤال در بین دانش آموزان فرانسوی و انگلیسی زبان کانادا، تعداد ۵۴ سؤال در بین دانش آموزان کشور فرانسه و انگلستان، و ۹۱ سؤال در بین دانش آموزان کشور فرانسه و آمریکا دارای DIF بودند. در واقع، بین ۵۴ تا ۶۵ درصد سؤال‌های دارای DIF به نفع دانش آموزان فرانسوی زبان عمل می‌کردند. این پژوهشگران دریافتند که در ۶۴ سؤال از ۲۹۶ سؤال تیمز، مشکلات مرتبط با ترجمه و انطباق وجود دارد. ارسی کان و مک کریس به این نتیجه رسیدند که در حدود ۳۵ تا ۴۰ درصد سؤال‌های دارای DIF ناشی از مشکلات ترجمه و انطباق سؤال‌ها و تفاوت‌ها در برنامه‌های درسی کشورها است.

1. Wu, Li & Zumbo
2. reference group
3. focal group

وو، لی، و زامبو(۲۰۰۷) تغییرناپذیری اندازه‌گیری یکی از دفترچه‌های آزمون ریاضی پایه هشتم تیمز ۱۹۹۹ را در میان ۷ کشور استرالیا، نیوزیلند، آمریکا، کانادا، کره، ژاپن، و تایوان مورد بررسی قرار دادند. یافته‌های حاصل از پژوهش آنها نشان داد که در تمام ۲۱ مقایسه جفتی که بین کشورها صورت گرفت، آزمون ریاضیات از تغییرناپذیری شکلی^۱ که ابتدایی ترین حالت و اولین گام در اثبات تغییرناپذیری اندازه‌گیری^۲ یک ابراز است (وان دن برگ و لانس^۳، ۲۰۰۰) برخوردار است. پژوهشگران مذکور، به طور کلی به این نتیجه رسیدند که در مقایسه‌های بین فرهنگی، تغییرناپذیری اندازه‌گیری تنها در سطح ضعیف (تغییرناپذیری متريک)^۴ برقرار است. اين نتیجه حاکی از اين است که در هیچ یک از مقایسه‌های بین فرهنگی، تغییرناپذیری عرض از مبدأ (تغییرناپذیری قوی^۵)، که شرط کافی برای تغییرناپذیری اندازه‌گیری و مقایسه‌پذیری نمره‌ها محسوب می‌شود، برقرار نیست و از اینرو آزمون ریاضی به صورت یک کل، همواره بر علیه یکی از کشورهای مورد مقایسه، دارای سوگیری است.

با در نظر گرفتن مطالبی که در خصوص کاربردهای نتایج مطالعات TIMSS و لزوم معادل‌بودن و مقایسه‌پذیری سوال‌ها و نتایج آزمون‌ها گفته شد و با توجه به تفاوت‌های موجود بین نظام آموزشی ایران با نظام آموزشی کشورهای مبدع این پرروزه، و با در نظر گرفتن تأثیر ترجمه بر ویژگی مورد اندازه‌گیری و کارکرد سوال، پژوهش حاضر تلاش می‌کند تا به سوال‌های زیر پاسخ دهد:

۱- آیا ساختار عاملی/سازه‌ای آزمون علوم تیمز ۲۰۰۷ در بین دانشآموزان ایران و آمریکا یکسان و قابل مقایسه است؟

۲- آیا سوال‌های آزمون علوم تیمز ۲۰۰۷ بر له یا علیه دانشآموزان ایرانی دارای DIF

1. configural invariance
2. measurement invariance
3. Vandenberg & Lance
4. metric invariance
5. strong invariance

است و به چه میزان؟

۳- تأثیر سوالات DIF بر عملکرد دانشآموزان ایرانی در آزمون علوم پایه

هشتم تیمز ۲۰۰۷، چگونه و به چه میزان است؟

روش

جامعه آماری و گروه نمونه پژوهش حاضر همان جامعه آماری و گروه نمونه پایه هشتم (جمعیت ۲) در آزمون علوم تیمز ۲۰۰۷ است که در سال تحصیلی ۱۳۸۵-۱۳۸۶ به اجرا درآمد. حجم نمونه دانشآموزان ایرانی ۳۹۸۱ نفر و حجم نمونه دانشآموزان آمریکایی ۷۳۷۷ نفر است (السن، مارتین و مولیس^۱، ۲۰۰۸).

چارچوب نمونه‌گیری در تیمز ۲۰۰۷، از طرح نمونه‌گیری خوش‌های طبقه‌ای دو مرحله‌ای مناسب با حجم نمونه استفاده شده است. در گام اول، مدارس و در گام دوم، کلاس در پایه هدف، نمونه‌گیری شده‌اند. طرح به روش «احتمال مناسب با حجم (PPS)» سهم هریک از خوش‌های نمونه را مناسب با حجم آن در جامعه تعیین می‌کند و با بهره‌گیری از وزن‌های نمونه‌گیری، شامل وزن کلاس، مدرسه، دانشآموز، وزن کل و وزن نهایی، اطمینان حاصل می‌شود که شاخص‌های آماری به دست آمده از نمونه مورد مطالعه، معرف جامعه است (السن، مارتین و مولیس، ۲۰۰۸). استفاده از این روش باعث می‌شود تا حجم مدارس، عاملی در افزایش احتمال انتخاب مدرسه باشد. بطوریکه احتمال انتخاب شدن مدرسه‌ای با ۴۰ دانشآموز، ۲ برابر مدرسه‌ای با ۲۰ دانشآموز است.

ابزار مورد استفاده در این پژوهش، آزمون علوم پایه هشتم (سوم راهنمایی) تیمز ۲۰۰۷ است. این آزمون دارای ۲۱۴ سوال اصلی و ۱۴ زیر سوال است که مجموعاً ۲۲۸ سوال را تشکیل می‌دهند که در ۱۴ دفترچه ارائه شده‌اند. این دفترچه‌ها به صورت تصادفی در بین دانشآموزان توزیع شدند. از بین ۲۲۸ سوال، تعداد نیمی از آن‌ها دو یا چند گزینه‌ای است که به صورت دو ارزشی ۰ یا ۱ نمره گذاری می‌شوند و نیم دیگر، سوالات‌های باز پاسخ

1. Olson, Martin & Mullis

هستند که به صورت چند ارزشی از ۰ تا حداقل ۳ نمره گذاری می‌شوند. در پژوهش حاضر به منظور ایجاد سهولت در تحلیل داده‌ها و به پیروی از لی، پارک و تایلان(۲۰۱۱) سوال‌های چند ارزشی از طریق کد گذاری مجدد به سوال‌های دو ارزشی تبدیل گردید. برای این منظور، اگر فردی در یک سوال چند ارزشی بالاترین نمره را بدست آورده بود، نمره ۱ و چنانچه نمره کامل را نگرفته بود نمره صفر تعلق گرفت. همچنین به پیروی از ارسی کان(۱۹۹۸) سوال‌هایی که فرد آن‌ها را خالی گذاشته بود، که در چارچوب تیمز آن‌ها را سوال‌های بدون پاسخ^۱ می‌نامند، و همچنین سوال‌هایی که بدلیل کمبود زمان فرصت پاسخ‌دهی به آن‌ها نبوده است، که در چارچوب تیمز آن‌ها را سوال‌های جامانده^۲ می‌نامند، نمره صفر داده شد.

همانطور که ذکر شد آزمون علوم تیمز ۲۰۰۷ دارای ۱۴ دفترچه است که از ۱ تا ۱۶ شماره گذاری شده‌اند. سوال‌های هر دفترچه در قالب دو بلوک تقسیم‌بندی شده است و یکی از بلوک‌ها با دفترچه ماقبل و بلوک دیگر با دفترچه بعد، مشترک و یکسان است. به عنوان مثال، دفترچه ۱ شامل بلوک ۱ و ۲، دفترچه ۲ شامل بلوک ۲ و ۳، دفترچه ۳ شامل بلوک ۳ و ۴ است و الی آخر. به منظور افزایش حجم نمونه و برآورد دقیق پارامترها بلوک‌های مشترک بین دفترچه‌ها با یکدیگر ترکیب شدند و ۱۴ بلوک سوال شکل گرفت و تحلیل‌ها بر اساس بلوک‌ها انجام شد.

روش تحلیل داده‌ها

در پژوهش‌های مربوط به همارزی/تغییرناپذیری اندازه‌گیری آزمون‌های تیمز به صورتهای مختلفی عمل شده است. ارسی کان(۱۹۹۸) از روش^۳ متنل-هانسز استفاده کرد، در حالیکه ارسی کان و کاه(۲۰۰۵) از ترکیبی از روش‌های CFA و IRT استفاده نمودند. آن‌ها در تحلیل‌های خود از داده‌های سطح سوال استفاده کردند. به این معنا که در هر دو رویکرد

1. omitted

2. not reached

CFA و IRT تحلیل‌ها در سطح سئوال صورت گرفته است و سئوال‌ها به صورت مستقیم مدل‌پردازی شدند. وو، لی، و زامبو(۲۰۰۷) از تحلیل عاملی تأییدی چند‌گروهی (MG-CFA) استفاده کردند. در پژوهش حاضر با به ۲ دلیل زیر از ترکیبی از روش‌های مبتنی بر IRT و CFA استفاده شد. ۱- محدودیت کاربرد مدل‌های CFA برای داده‌های گسسته (مانند داده‌های مربوط به سئوال‌های آزمون‌های تیمز)؛ و ۲- روش‌های تحلیل DIF بر مفروضه‌هایی استوار نند که در موقعیت‌هایی که در آن‌ها آزمونی به زبانهای مختلف ترجمه و اجرا می‌شود ممکن است برقرار نباشند....در چنین مواردی رویکردهای دیگری که کمتر، سئوال-محور^۱ هستند ارجحیت دارند (دورانز و کولیک، ۲۰۰۶). به عبارت دقیق‌تر، روش‌های تحلیل DIF (از جمله روش‌های مبتنی بر IRT) بر این فرض استوارند که گروه‌های مورد مطالعه به یک جامعه مربوط می‌شوند، یعنی اینکه آزمون، در گروه‌های مورد مطالعه، سازه یا سازه‌های یکسانی را می‌سنجد. بنابراین لازم است قبل از کاربرد این روش‌ها با استفاده از روش‌های مناسب نشان داد که ساختار عاملی آزمون در گروه‌های مورد مطالعه یکسان است.

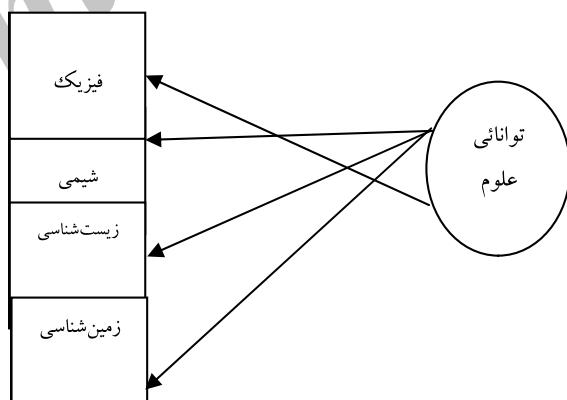
تریزی (۲۰۰۶) معتقد است که یک رویکرد عملی برای استفاده ترکیبی از روش‌های CFA و IRT این است که ابتدا اولین سطح تغییرناپذیری عاملی، یعنی تغییرناپذیری شکلی با استفاده از رویکرد CFA مورد آزمون قرار گیرد و سپس با استفاده از روش‌های تحلیل DIF، وجود، نوع و بزرگی DIF مورد مطالعه قرار گیرد. به همین دلیل در پژوهش حاضر برای پاسخگویی به سئوال‌های پژوهش، از ترکیبی از روش‌های مبتنی بر IRT و CFA استفاده گردید.

مجموعه تحلیل‌های اول (تحلیل عاملی تأییدی چند‌گروهی): با توجه به مطالبی که در خصوص کاربرد ترکیبی مدل‌های CFA و IRT گفته شد، در مجموعه تحلیل‌های اول، اولین سطح همارزی/تغییرناپذیری عاملی، یعنی تغییرناپذیری شکلی در سطح حیطه‌های محتوایی مورد بررسی قرار گرفت. همانطور که ذکر شد، به منظور انجام تحلیل‌ها بلوک‌های

1. item-centered

سؤال شکل گرفت که هر کدام از ۴ حیطه محتوایی زیست‌شناسی، فیزیک، شیمی و زمین‌شناسی تشکیل یافته است. در پژوهش حاضر هر یک از بلوک‌ها به صورت جداگانه یکبار به داده‌های هر یک از دو کشور ایران و آمریکا و یکبار به صورت همزمان به داده‌های هر دو کشور برآش داده شدند. به عبارت دقیق‌تر، در مجموع ۲۸ تحلیل عاملی تأییدی تک گروهی و ۱۴ تحلیل عاملی تأییدی دو گروهی انجام پذیرفت. برای انجام تحلیل‌های مربوط به CFA از نسخه ۱۱/۶ نرم‌افزار Mplus (موتن و موتن، ۲۰۱۰) استفاده شد.

ابتدا برای هریک از بلوک‌ها یک مدل تک عاملی که هر یک از حیطه‌های محتوایی به عنوان نشانگرهای آن عمل می‌کنند، به صورت جداگانه به داده‌های هریک از دو گروه دانش‌آموزان ایرانی و آمریکایی برآش داده شد. این مدل که مدل پایه اولیه نامیده می‌شود و در شکل زیر نشان داده شده است مدل ۱ را تشکیل می‌دهد. دلیل استفاده از حیطه‌های محتوایی به عنوان نشانگر این است که زمانی که آزمون، طولانی است به گونه‌ای که تعداد ۵ الی ۸ سوال روی هر عامل بار می‌شود غیرممکن است که مدل مورد نظر برآش رضایت‌بخشی با داده‌ها داشته باشد و مورد تأیید قرار گیرد. در اینگونه موارد، استفاده از بسته‌های سؤال^۱، مناسب خواهد بود (فلوید، و ویدامن^۲، ۱۹۹۵).



شکل ۱: مدل عاملی مفروض

1. Item Parcel
2. Floyd & Widaman

چنانچه نتایج آماره‌ها و شاخص‌های برازش نشان می‌داد که مدل ارائه شده در شکل ۱ از برازش مطلوبی با داده‌ها برخوردار است این مدل به عنوان مدل پایه در نظر گرفته می‌شد و تغییرناپذیری شکلی آن مورد آزمون قرار می‌گرفت. لکن چنانچه یافته‌ها نشان می‌داد که مدل با داده‌ها برازش ندارد، در اینصورت با استفاده از آزمون‌های لاگرانژ و شاخص‌های اصلاح، تغییرات لازم در مدل صورت می‌گرفت تا مدلی با بهترین برازش برای هر یک از گروه‌ها بدست آید. بدین صورت، مدل پایه نهایی بدست می‌آمد. پس از تدوین و فرمولبندی مدل پایه نهایی، تغییرناپذیری شکلی آن درین دو گروه مورد آزمون قرار می‌گرفت.

مجموعه تحلیل‌های دوم (تحلیل‌های مبتنی بر IRT): هدف دومین مجموعه تحلیل‌ها بررسی کارکرد افتراقی سئوال‌های هر یک از بلوک‌ها است. در این بخش علاوه بر تحلیل‌های مربوط به مفروضه ابعاد و برآورد پارامترهای سئوال‌ها، به تعداد سئوال‌های آزمون علوم (یعنی ۲۲۸ سوال) تحلیل‌های مربوط به DIF تکرار گردید. همچنین برای هر یک از سئوال‌ها و بلوک‌ها شاخص اندازه اثر برآورد گردید. در ادامه نحوه انجام این تحلیل‌ها توضیح داده می‌شود.

۱- بررسی مفروضه تک بعدی بودن سئوال‌های هر یک از حوزه‌های محتوایی و تعیین مدل یا مدل‌هایی که بهترین برازش را با داده‌ها دارد. جهت بررسی تک بعدی بودن سئوال‌های هر یک از بلوک‌ها از روش NOHARM (فریزر، ۱۹۸۸) استفاده شد.

۲- شناسایی سئوال‌های لنگر. پس از اتمام مرحله فوق، ابتدا یک مدل که در آن، کلیه پارامترهای تمام سئوال‌های بلوک مورد نظر بین دو گروه (گروه مرجع^۱ و گروه هدف^۲) محدود^۳ شده بودند، فرمولبندی^۴ و مورد آزمون قرار گرفت.

۳- شناسایی نهایی سئوال‌های دارای DIF. پس از تعیین مجموعه سئوال‌های نهایی لنگر، بقیه سئوال‌های بلوک مورد نظر از لحاظ دارا بودن DIF مورد آزمون قرار گرفتند.

1. reference
2. focal
3. constrained
4. specification

در این مرحله سوال‌های لنگر به عنوان متغیر همتاسازی بکار رفته و دیگر از نظر DIF مورد مطالعه قرار نگرفتند.

۴- برآوردهای پارامترهای سوال و توانایی. پس از شناسایی سوال‌های دارای DIF و تعیین نوع DIF (یکنواخت یا غیریکنواخت)، یکبار دیگر، پارامترهای کلیه سوال‌ها براساس یک مدل دو گروهی برآورد شد. در این مدل، سوال‌های لنگر و همچنین آن دسته از سوال‌هایی که فاقد DIF تشخیص داده شدند، بین دو گروه محدود شدند و برای سایر سوال‌هایی که واجد DIF تشخیص داده شدند، آن پارامتری که باعث شده بود تا سوال دارای DIF تشخیص داده شود بین گروه‌ها آزاد گذاشته می‌شد و پارامتر دیگر سوال محدود می‌شد. به عبارت دقیق‌تر، اگر سوال براساس پارامتر a دارای DIF بود هر دو پارامتر a و b بین دو گروه آزاد گذاشته می‌شد و برای هر گروه به صورت جداگانه برآوردهای شدنده، اما اگر سوالی دارای DIF یکنواخت بود صرفاً پارامتر b بین دو گروه آزاد گذاشته می‌شد و به صورت جداگانه برآوردهای می‌گردد.

۵- ارزشیابی بزرگی DIF. بزرگی DIF به میزان تفاوت در عملکرد افراد گروه مرجع و هدف در سوال اشاره دارد که از لحاظ توانایی همتا شده‌اند (تریزی و همکاران، ۲۰۰۷). به عبارت دیگر، بزرگی DIF به شدت یا درجه کارکرد افتراقی سوال اشاره می‌کند. از نمره‌های مورد انتظار سوال به عنوان شاخص بزرگی DIF استفاده شد. در سوال‌های دو ارزشی، نمره مورد انتظار سوال، همان احتمال پاسخ درست به سوال است.

یک راه برای کمی کردن تفاوت‌های بین متوسط نمره مورد انتظار گروه‌ها در سوال، شاخص NCDIF است که توسط کمیلی و شپارد (۱۹۹۶، نقل از اورلاندو-ادلن و همکاران، ۲۰۰۶) برای سوال‌های دو ارزشی ارائه گردید و راجو و همکارانش (۱۹۹۵) آن را برای سوال‌های چند ارزشی بسط و گسترش دادند. برای بدست آوردن این شاخص، نمره مورد انتظار تک تک افراد گروه هدف یکبار به عنوان عضوی از همان گروه و یکبار به عنوان عضو گروه مرجع به دست آمد. میانگین مجدورات این تفاوت‌ها برای کل گروه

هدف بدست آمد که به عنوان شاخص بزرگی DIF تفسیر می‌شود.

۶- ارزشیابی تأثیر DIF تأثیر^۱ به اثرگذاری DIF روی نمره کل آزمون اشاره دارد. در پژوهش حاضر منظور از نمره کل آزمون، نمره کل در بلوک است. برای ارزشیابی تأثیر DIF، بسته به روش مورد استفاده برای شناسایی DIF، روش‌های گوناگونی ارائه شده است. در بافت IRTLR تأثیر DIF از طریق تابع‌های پاسخ-آزمون^۲ (TRF) مورد بررسی قرار می‌گیرد. در واقع TRF، یک منحنی شیوه منحنی ویژگی سؤال^۳ است که نمره مورد انتظار در کل آزمون را برای هر سطح از توانایی نشان می‌دهد. برای بدست آوردن نمره مورد انتظار کل آزمون (بلوک)، نمره‌های مورد انتظار سؤال‌ها برای هر سطح از توانایی، جمع شدند. پس از بدست آوردن نمره‌های مورد انتظار کل آزمون، TRF‌های هر دو گروه هدف و مرجع روی یک نمودار رسم گردید. تفاوت‌های موجود بین این دو منحنی، تأثیر نسبی DIF را نشان می‌دهد. برای برآورد و ارزشیابی تأثیر DIF در سطح بلوک‌ها از نرم‌افزار DFIT5 (راجو، ۱۹۹۹) استفاده شد.

برای تحلیل داده‌ها از نسخه ۱۱/۶ نرم‌افزار Mplus (موتن و موتن، ۲۰۱۰)، نسخه ۷/۰۳ نرم‌افزار MULTILOG (تیسن، چن، و باک، ۲۰۰۳)، نرم‌افزار DFIT5 (راجو، ۱۹۹۹) نرم‌افزار IRTLRDIF (تیسن، ۲۰۰۱)، SPSS15 و برای رسم نمودارها از Excel استفاده گردید.

نتایج

جدول ۱ اطلاعات جمعیت‌شناسختی دانش‌آموزان شرکت کننده در تیمز ۲۰۰۷ را به تفکیک کشور و بلوک نشان می‌دهد. در ستون مربوط به جنسیت، اعداد داخل پرانتز، درصد و اعداد خارج پرانتز، تعداد دانش‌آموزان است. در ستون مربوط به سن نیز اعداد خارج پرانتز، بیانگر میانگین و اعداد داخل پرانتز، بیانگر انحراف استاندارد است.

1. DIF impact
2. Test-response function
3. Item-response function

جدول ۱: اطلاعات جمعیت‌سناختی نمونه

آمریکا				ایران					
بلوک	سن	دختر	پسر	جنسيت	بلوک	سن	دختر	پسر	جنسيت
		دختر	پسر	تعداد کل			دختر	پسر	جنسيت
۱	۱۴/۱۴	(۵۵/۲)۳۱۶	(۴۴/۸)۲۵۶	۵۷۲	(۰/۷۳)۱۴/۲۸	(۰/۷۹)	(۵۱/۸)۵۵۶	(۴۸/۲)۵۱۸	دختر
۲	۱۴/۱۰	(۵۴/۱)۳۱۰	(۴۵/۹)۲۶۳	۵۷۳	(۰/۶۸)	(۵۰/۶)۵۳۹	(۴۹/۴)۵۲۶	(۴۹/۴)۵۲۶	دختر
۳	۱۴/۰۹	(۴۵/۸)۲۵۹	(۰/۶۴)	۵۶۵	(۴۴/۹)۲۵۶	(۰/۶۴)	(۵۱/۹)۵۲۴	(۵۰/۱)۵۲۶	دختر
۴	۱۴/۱۳	(۴۴/۹)۲۵۶	(۰/۶۴)	۵۷۰	(۰/۶۴)	(۵۵/۱)۳۱۴	(۴۸/۵)۵۱۶	(۴۸/۵)۵۱۶	دختر
۵	۱۴/۱۹	(۴۴/۱)۲۵۵	(۰/۶۹)	۵۶۷	(۰/۶۹)	(۵۵/۹)۳۱۷	(۴۷/۹)۵۰۶	(۴۷/۹)۵۰۶	دختر
۶	۱۴/۱۸	(۴۳/۷)۲۴۵	(۰/۷۱)	۵۶۱	(۰/۷۱)	(۵۶/۴)۳۱۶	(۵۰/۷)۵۳۲	(۴۹/۳)۵۱۷	دختر
۷	۱۴/۱۶	(۴۴/۳)۲۴۷	(۰/۶۵)	۵۵۸	(۰/۶۵)	(۴۴/۳)۳۱۱	(۵۱/۶)۵۴۱	(۴۸/۴)۵۰۸	دختر
۸	۱۴/۱۷	(۴۴/۸)۲۵۵	(۰/۶۷)	۵۶۹	(۰/۶۷)	(۵۵/۲)۳۱۴	(۰/۵۱)۵۳۵	(۰/۴۹)۵۱۴	دختر
۹	۱۴/۱۷	(۴۴/۷)۲۵۸	(۰/۶۸)	۵۷۷	(۰/۶۸)	(۴۴/۳)۳۱۹	(۵۰/۶)۵۲۴	(۴۹/۴)۵۱۱	دختر
۱۰	۱۴/۱۷	(۴۴/۹)۲۵۸	(۰/۷۲)	۵۷۵	(۰/۷۲)	(۴۴/۹)۳۱۷	(۵۰/۴)۵۲۴	(۴۹/۶)۵۱۵	دختر
۱۱	۱۴/۱۶	(۴۴/۷)۲۵۹	(۰/۷۲)	۵۸۰	(۰/۷۲)	(۴۴/۳)۳۲۱	(۵۰/۳)۵۳۲	(۴۹/۷)۵۲۵	دختر
۱۲	۱۴/۱۵	(۴۴/۶)۲۵۱	(۰/۶۹)	۵۶۳	(۰/۶۹)	(۴۴/۳)۳۱۲	(۵۰/۲)۵۲۶	(۴۹/۸)۵۲۲	دختر
۱۳	۱۴/۱۸	(۴۵/۷)۲۵۷	(۰/۷۰)	۵۶۲	(۰/۷۰)	(۴۵/۳)۳۰۵	(۴۸/۲)۵۰۹	(۵۱/۸)۵۴۶	دختر
۱۴	۱۴/۱۸	(۴۵/۳)۲۵۸	(۰/۷۲)	۵۷۰	(۰/۷۲)	(۴۵/۳)۳۱۲	(۴۶/۷)۴۹۷	(۵۲/۳)۵۶۷	دختر

در ادامه نتایج حاصل از تحلیل‌های مربوط به تغییرناظدی‌شکلی و کارکرد افتراقی سوال (DIF) و کارکرد افتراقی آزمون (DTF) در دو بخش جداگانه ارائه می‌شود.

نتایج مربوط به تغییرناظدی‌شکلی: انجام آزمون تغییرناظدی‌شکلی و برآورد پارامترها در مدل CFA مستلزم انتخاب یک تابع یا برآورده کننده مناسب است. تابع ییشینه درستنمایی (ML) پرکاربردترین روش برای برآورده کننده پارامترها و آزمون برآش مدل با داده‌ها است. یکی از مفروضه‌های این تابع، نرمالبودن چند متغیری توزیع داده‌های نشانگرها است. بررسی شاخص‌های چولگی و کشیدگی نشان داد که نمره‌های هیچ یک از حیطه‌های محتوایی بلوک‌ها دارای توزیع نرمال نیست. علاوه بر این، دامنه آماره Q_3 (اسمال، ۱۹۸۰، نقل از دی کارلو، ۱۹۹۷)، که نرمال بودن چندمتغیری را آزمون می‌کند، برای داده‌های کشور ایران از ۱۰/۱/۶۶ برای بلوک شماره ۱۲ تا ۴۰/۹/۳۳ برای بلوک شماره

۱ است. دامنه این آماره برای داده‌های کشور آمریکا از ۳۸۰/۰۵ برای بلوک شماره ۲ تا ۲۶۵۱/۰۸ برای بلوک شماره ۵ متغیر است. آماره Q_3 بر توزیع χ^2 استوار است و برای آزمون معناداری از مقادیر این توزیع استفاده می‌شود. نتایج بدست آمده نشان داد که کلیه مقادیر مشاهده شده آماره Q_3 در سطح آلفای ۰/۰۰۱ به لحاظ آماری معنادار است. معنای این مطلب آن است توزیع داده‌های هیچ کدام از بلوک‌ها نرمال چندمتغیری نیست. از این‌رو برای برآورد پارامترها و برآش مدل با داده‌ها از برآورد کننده پارامترهای مدل به مقاوم یا MLM (براون، ۲۰۰۶) استفاده گردید. در این برآورد کننده، پارامترهای مدل با شیوه ML برآورد می‌شوند، اما برای آزمون معناداری پارامترها و آزمون برآش مدل با داده‌ها از خطاهای استاندارد مقاوم و آماره χ^2 اصلاح شده که به آماره χ^2 ساتورا-بنتلر (SB) نیز معروف است استفاده می‌شود (کلاین، ۲۰۱۱).

برای سنجدش برآش مدل، معمولاً از چندین شاخص استفاده می‌شود. آماره χ^2 بدلیل حساسیتی که به حجم نمونه دارد، در گذشته بر استفاده از این آماره برای بررسی برآش مدل با داده‌ها تأکید زیادی نمی‌شد. اما امروزه پژوهشگران زیادی از جمله (بارت، ۲۰۰۷) معتقدند که برای بررسی برآش مدل با داده‌ها بایستی بر این آماره توجه زیادی شود.

در پژوهش حاضر برای سنجدش برآش مدل، از آماره‌های χ^2 ساتورا-بنتلر، ریشه دوم برآورد واریانس خطای تقریب (RMSEA)، شاخص برآش تطبیقی^{۱۷} (CFI) و ریشه دوم میانگین مجذورات پس‌مانده‌های استاندارد شده^{۱۸} (SRMR) و شاخص تاکر-لویز^{۱۹} (TLI) استفاده گردید.

در تفسیر شاخص‌های برآزنده‌گی، از قواعد پیشنهادی زیر استفاده شد. برآونی و کادک (۱۹۹۳) معتقدند که مقادیر بالاتر از ۹۰٪ برای شاخص‌های TLI و CFI حاکی از برآش خوب مدل است. در مورد شاخص RMSEA نیز از ملاک پیشنهادی هیو و بنتلر (۱۹۹۹) استفاده شد. آن‌ها معتقدند اگر مقدار این شاخص کمتر از ۰/۰۶ باشد می‌توان نتیجه گرفت که برآش مدل با داده‌ها خوب است. در ارتباط با شاخص SRMR نیز مقادیر کمتر از ۰/۱۰

به طور کلی به صورت مقادیر مطلوب در نظر گرفته می‌شود (کلاین، ۲۰۰۵). برای آزمون تغییرناپذیری شکلی، ابتدا برای هریک از بلوک‌ها یک مدل تک عاملی که هر یک از حیطه‌های محتوایی به عنوان نشانگرهای آن عمل می‌کنند، به صورت جداگانه به داده‌های دو گروه دانش‌آموzan ایرانی و آمریکایی برآراش داده شد. این مدل که مدل پایه اولیه نامیده می‌شود در شکل ۱ نشان داده شده است.

نتایج حاصل از تحلیل‌ها نشان داد که مدل پایه اولیه با داده‌های برخی از بلوک‌ها از برآراش مطلوبی برخوردار نیست. بررسی شاخص‌های اصلاح^۱ (MI) نشان داد که واریانس یا عبارت خطای نشانگرها با یکدیگر همبسته هستند. لذا پس از اعمال تغییرات لازم در مدل و همبسته کردن عبارت‌های خطای نشانگرها، مدل پایه نهایی، به صورت جداگانه به داده‌های دانش‌آموzan ایران و آمریکا برآراش داده شد و شاخص‌های برآراش مورد بررسی قرار گرفت. در مرحله بعد، مدل پایه نهایی، به طور همزمان به داده‌های دو گروه برآراش داده شد و میزان برآراش مدل با داده‌ها با استفاده از آماره‌های برآراش مورد بررسی قرار گرفت.

تحلیل عاملی تأییدی و تغییرناپذیری شکلی برای تمام ۱۴ بلوک صورت گرفت. لکن به دلیل محدودیت جا از ارائه مفصل نتایج مربوط به این بخش از تحلیل‌ها خودداری و صرف نتیجه مربوط به بلوک ۷ به عنوان نمونه ارائه می‌شود.

جدول ۳ نتایج مربوط به برآراش مدل و تغییرناپذیری شکلی را برای بلوک ۷ نشان می‌دهد. نتایج آماره χ^2 و سایر شاخص‌های برآراش نشان داد که مدل پایه اولیه (مدل ۱) با داده‌های هیچ یک از دو گروه از برآراش مناسبی برخوردار نیست. بررسی شاخص‌های اصلاح در گروه ایران نشان داد که کوواریانس بین عبارت‌های خطای دو درس زمین‌شناسی و فیزیک به لحاظ آماری معنادار است ($MI = ۴۵/۲۶$). بنابراین کوواریانس بین عبارت‌های خطای این دو درس، آزاد گذاشته شد و برآراش مدل با داده‌های ایران، مجدداً مورد آزمون قرار گرفت. نتایج آماره χ^2 و سایر شاخص‌ها نشان داد که مدل از

1. modification index

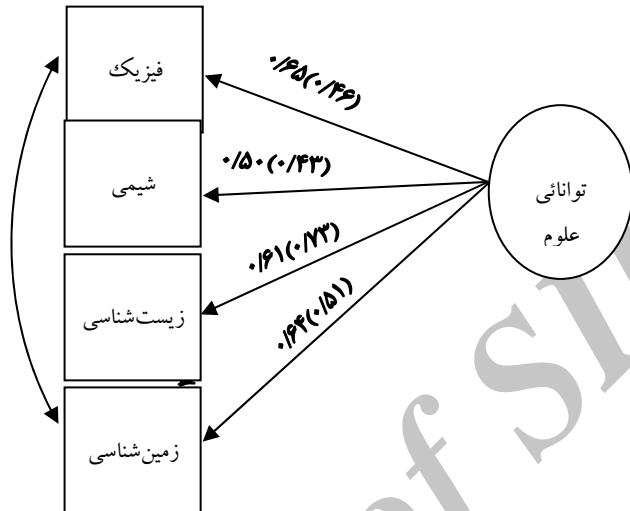
برازش مطلوبی با داده‌ها بروخوردار است. این مدل (مدل ۲) به عنوان مدل پایه نهایی برای ایران در نظر گرفته شد.

بررسی شاخص‌های اصلاح در گروه آمریکا نیز نشان داد که کوواریانس بین عبارت خطای درس زمین‌شناسی و فیزیک به لحاظ آماری معنادار است ($MI = 7/16$). بنابراین، کوواریانس بین عبارت‌های خطای این دو درس، آزاد گذاشته شد و مدل مجدد به داده‌های آمریکا برازش داده شد. همانطور که در جدول ۳ مشاهده می‌کنید، مدل از برازش مطلوبی با داده‌های آمریکا بروخوردار است. این مدل (مدل ۲) به عنوان مدل پایه نهایی برای کشور آمریکا در نظر گرفته شد. در گام بعد، مدل‌های پایه نهایی (مدل‌های ۲) به صورت همزمان به داده‌های دو گروه ایران و آمریکا برازش داده شد. هدف این مرحله، آزمون تغییرناپذیری شکلی است. نتایج مربوط به این مرحله نشان می‌دهد که مدل از تغییرناپذیری شکلی مطلوبی بین دو گروه بروخوردار است.

جدول ۳: آزمون برازش مدل و تغییرناپذیری شکلی بلوک ۷ در بین دو گروه ایران و آمریکا

فاصله اطمینان ۹۰٪ برای		RMSEA	RMSEA	SRMR	TLI	CFI	p	df	کشور	مدل
حد بالا	حد پایین									
ایران	.۱۹۸	.۰۹۹	.۱۴۵	.۰۴۲	.۸۰۹	.۹۳۶	.۰۰۰	۲	۲۵/۶۰۳	مدل ۱
	.۰۶۲	.۰۰۰	.۰۰۰	.۰۰۱	.۰۱۶	.۸۵۶	.۰۳۳	۱	.۰۳۳	مدل ۲
	.۰۹۵	.۰۱۹	.۰۵۴	.۰۱۷	.۹۷۹	.۹۹۳	.۰۱۷	۲	۸/۱۴۱	مدل ۱
	.۰۸۳	.۰۰۰	.۰۰۸	.۰۰۵	.۰۱۷	.۹۳۰	.۰۶۶	۱	.۰۶۶	مدل ۲
تغییرناپذیری										
شکلی		.۰۵۹	.۰۰۰	.۰۰۰	.۰۰۴	.۰۰۴	.۰۵۷۷	۲	.۰۹۸	۱/۰۹۸

شکل ۲ ضرایب استاندارد شده پارامترهای مدل (بارهای عاملی) را برای دو کشور ایران و آمریکا نشان می‌دهد. ضرایب داخل پرانتز مربوط به ایران و ضرایب خارج پرانتز مربوط به آمریکا است. همه این ضرایب در سطح آلفای ۰/۰۱ معنادار است.



شکل ۲: نمودار مدل عاملی بلوک ۷ همراه با برآوردهای استاندارد شده پارامترها

به طور کلی نتایج حاصل از تحلیل عاملی تأییدی نشان داد که تمام ۱۴ بلوک، از تغییرناپذیری شکلی در بین دو گروه ایران و آمریکا برخوردارند. برقرار بودن تغییرناپذیری شکلی بدان معنا است که دانش آموزان دو کشور ایران و آمریکا برای دادن پاسخ به سوال‌های علوم از چارچوب مفهومی یکسانی استفاده می‌کنند (چونگ و رنسولد، ۲۰۰۲؛ هورن و مک آردل، ۱۹۹۲) ولذا می‌توان از روش‌های DIF مبتنی بر نظریه سوال - پاسخ برای بررسی کارکرد افتراقی تک تک سوال‌ها استفاده نمود.

انجام تحلیل‌های DIF مستلزم انتخاب یکی از مدل‌های دو ارزشی IRT به عنوان مدل پایه است. مهم‌ترین مفروضه مدل‌های دو ارزشی IRT، مفروضه تک بعدی بودن سوال‌ها است. یکی از مناسب‌ترین روش‌های آزمون این مفروضه، انجام تحلیل عاملی در سطح سوال است. بنابراین، پیش از انتخاب یکی از مدل‌های ۱، ۲، و ۳ پارامتری به عنوان مدل پایه، سوال‌های هر یک از بلوک‌ها با استفاده از تحلیل عاملی غیرخطی که از طریق برنامه NOHARM (فریزر، ۱۹۸۸) قابل اجرا است برای دو کشور ایران و آمریکا به صورت

جداگانه مورد تحلیل قرار گرفت. نتایج حاصل از این تحلیل، که به دلیل محدودیت جا و جلوگیری از حجم شدن مقاله در اینجا ارائه نشده است، نشان داد که شواهد کافی برای رد فرضیه تک بعدی بودن بلوک‌های درس علوم تیمز ۲۰۰۷ وجود ندارد. این یافته حاکی از این است که سوالات تمام ۱۴ بلوک در دو گروه ایران و آمریکا صرفاً یک سازه یا عامل مکنون را می‌سنجدند و مفروضه تک بعدی بودن در مورد تمام آن‌ها صادق است.

به منظور انتخاب مدل پایه، مدل‌های لوچستیک ۱، ۲ و ۳ پارامتری به هر یک از بلوک‌ها و به صورت جداگانه به داده‌های ایران و آمریکا برآراش داده شد و با استفاده از آماره نسبت درستنمایی (G^2 -LL) که با G^2 نشان داده می‌شود، میزان برآراش این مدل‌ها با یکدیگر مورد مقایسه قرار گرفت. نتایج حاصل از این تحلیل‌ها که با بهره‌گیری از نرم‌افزار MULTILOG صورت گرفت نشان داد که مدل لوچستیک دو پارامتری در مقایسه با دو مدل دیگر، از برآراش بهتری با داده‌ها برخوردار است. بنابراین، این مدل به عنوان مدل پایه در نظر گرفته شد.

پس از تعیین مدل پایه، به منظور شناسایی سوالاتی دارای DIF، هر یک از بلوک‌ها با استفاده از نرم‌افزار IRTLRDIF به صورت جداگانه مورد تحلیل قرار گرفتند. شناسایی سوالاتی دارای DIF در دو مرحله صورت گرفت. در واقع، برنامه IRTLRDIF در مورد هر بلوک، دو بار اجرا گردید. در مرحله اول که هدف آن شناسایی سوالاتی لنگر اولیه است، برنامه IRTLRDIF هر یک از سوالات را به عنوان سوال مورد مطالعه و بقیه سوالات را به عنوان سوال لنگر در نظر می‌گیرد و بر این اساس تعیین می‌کند که آیا سوال مورد مطالعه، دارای DIF است یا نه. با اجرای این مرحله، سوالاتی لنگر اولیه شناسایی گردید. آنگاه سایر سوالات که دارای DIF تشخیص داده شدند از فایل داده‌ها حذف گردیدند. به عبارت دقیق‌تر، پس از اجرای مرحله اول، برای هر یک از بلوک‌ها فایل جدیدی تشکیل گردید که صرفاً سوالاتی لنگر اولیه را شامل می‌شد. آنگاه این فایلهای داده مجدداً با برنامه IRTLRDIF مورد تحلیل قرار گرفتند. هدف از این کار،

خالص سازی متغیر همتاسازی به منظور شناسایی سوالاتی لنگر نهایی بود. پس از شناسایی سوالاتی لنگر نهایی، برنامه IRTLRDIF یکبار دیگر در مورد فایل اولیه داده‌های هر یک از بلوک‌ها اجرا گردید. در این اجراء، سوالاتی که به عنوان سوال لنگر نهایی شناسایی شده بودند، به عنوان سوال لنگر به برنامه معرفی شدند. پس از اجرای این مرحله، سوالاتی دارای DIF شناسایی گردیدند. به منظور کنترل نرخ خطای نوع اول از اصلاح به روش بنجامینی - هاچبرگ (B-H؛ تیسن، استنبرگ، و کوانگ، ۲۰۰۲) که از طریق برنامه EXCELL صورت گرفت استفاده گردید. پس از اجرای روش B-H سوالاتی نهایی واجد DIF شناسایی گردید. پس از شناسایی سوالاتی لنگر و سوالاتی دارای DIF، سوالاتی هر یک از بلوک‌ها به صورت جداگانه و از طریق برنامه MULTLOG مورد تحلیل قرار گرفتند. در اجرای این تحلیل که به شیوه چند گروهی صورت گرفت، پارامترهای سوالاتی لنگر بین دو گروه ایران و آمریکا یکسان قرار داده شدند، در حالیکه پارامترهای سوالاتی واجد DIF برای دو گروه به صورت جداگانه برآورد گردیدند. البته، پارامتر a سوالاتی که دارای DIF یکنواخت بودند نیز بین دو گروه یکسان قرار داده شدند. به عبارت دقیق، در مرحله برآورد نهایی پارامترهای سوال و توانایی، پارامتر a و b سوالاتی لنگر و همچنین پارامتر a سوالاتی دارای DIF یکنواخت بین دو گروه یکسان قرار داده شد و پارامتر a و b سوالاتی دارای DIF غیریکنواخت و همچنین پارامتر a سوالاتی دارای DIF یکنواخت بین دو گروه آزاد گذاشته شد و برای هر گروه به صورت جداگانه برآورد گردیدند. نتایج حاصل از این تحلیل در جدول ۴ ارائه شده است. در این جدول علاوه بر برآوردهای نهایی پارامترهای سوالاتی لنگر یا DIF بودن سوالاتی، نوع DIF و همچنین شاخص اندازه اثر و جهت DIF که به ترتیب با NCDIF و CDIF نشان داده می‌شوند، ارائه شده است.

شاخص NCDIF همانند یک شاخص اندازه اثر تفسیر می‌شود. این شاخص برای شناسایی سوالاتی دارای DIF در چارچوب رویکرد DFIT بکار می‌رود. برای آزمون

معناداری این شاخص و همچنین برای شاخص‌های DTF و CDIF آماره‌های χ^2 ارائه شده است. اما بدليل حساسیت زیاد آماره χ^2 به حجم نمونه، بر اساس داده‌های شبیه‌سازی، برای شاخص DTF و NCDIF نقاط برش ارائه شده است.

فلر(۱۹۹۳) و فلاورز، اوشیما و راجو(۱۹۹۵) براساس داده‌های شبیه‌سازی نقاط برش را برای آماره NCDIF ارائه کردند. مقدار نقطه برش، بسته به تعداد گزینه‌های پاسخ متفاوت است. برای سؤال‌های دو ارزشی نقطه برش 0.006 ٪ پیشنهاد شده است. نقطه برش برای شاخص DTF که بیانگر بزرگی کارکرد افتراقی آزمون است از جمع نقاط برش سؤال‌های دارای DIF بدست می‌آید. به عنوان مثال، نقطه برش شاخص DTF برای یک آزمون ۴۰ سؤالی دو ارزشی که فرضا ۲۵ سؤال آن دارای DIF است برابر با 0.15 ٪ (0.006×25) خواهد بود.

اگر علامت شاخص CDIF مثبت باشد بیانگر این است که سؤال به نفع گروه مرجع (آمریکا) دارای DIF است و اگر علامت آن منفی باشد حاکی از این است که سؤال به نفع گروه هدف (ایران) دارای کارکرد افتراقی است.

جدول ۴: برآوردهای نهایی پارامترهای سوالات لنگر و دارای DIF همراه با شاخص اندازه اثر

کد سوال	آمریکا	ایران		کد سوال				
		b	a					
شاخص اندازه اثر	DIF	نوع	DIF یا لنگر	CDIF				
.۰/۳۴	.۰/۰۶	یکنواخت	DIF	.۰/۰۲	.۰/۹۹	-.۰/۵۶	.۰/۹۹	S032115
-.۰/۱۶	.۰/۰۲	یکنواخت	DIF	.۰/۳۷	.۰/۹۱	۱/۱۰	.۰/۹۱	S032565
.۰/۲۶	.۰/۰۴	یکنواخت	DIF	.۰/۵۱	.۰/۰۲	-.۰/۹۸	.۰/۵۲	S032403
.۰/۶۱	.۰/۱۹	یکنواخت	DIF	.۲/۴۶	.۰/۳۷	-.۲/۷۱	.۰/۳۷	S032273
.۰/۳۳	.۰/۰۶	یکنواخت	DIF	.۰/۷۷	.۱/۴۷	-.۰/۲۵	.۱/۴۷	S032019A
.۰/۰۳	.۰/۰۰۴	غیر یکنواخت	DIF	.۱/۶۸	.۱/۱۴	.۰/۹۳	.۱/۹۵	S032019B
.۰/۴۹	.۰/۱۳	یکنواخت	DIF	.	.۱/۱۴	-.۱/۹۰	.۰/۶۸	S032516
.۰/۱۴	.۰/۰۱	یکنواخت	DIF	.۰/۹۶	.۰/۶۸	.۱/۰۴	.۰/۳۳	S032620
-	-	-	لنگر	-.۰/۱۱	.۱/۰۶	-.۰/۱۱	.۱/۰۶	S032693A
-.۰/۰۵	.۰/۰۰۲	یکنواخت	DIF	-.۱/۰۴	.۱/۲۸	-.۰/۹۸	.۱/۳۸	S032693B
-.۰/۱۳	.۰/۰۱	یکنواخت	DIF	.۰/۴۰	.۱/۱۳	.۰/۹۳	.۱/۱۳	S032695
.۰/۱۰	.۰/۰۰۷	غیر یکنواخت	DIF	-.۰/۰۲	.۳/۵۲	-.۰/۱۲	.۲/۳۶	S032697A
.۰/۰۶	.۰/۰۰۳	غیر یکنواخت	DIF	.۰/۰۸	.۴/۲۰	.۰/۰۳	۳	S032697B
-	-	-	لنگر	.۰/۱۵	.۴/۴۲	.۰/۲۵	.۴/۴۲	S032697D
-.۰/۰۱	.۰/۰۳	یکنواخت	DIF	.۰/۸۵	.۰/۵۶	.۰/۴۵	.۰/۵۶	S042009
-	-	-	لنگر	-.۱/۷۵	.۰/۹۹	-.۱/۷۵	.۰/۹۹	S042313
-.۰/۰۲	.۰/۰۵	یکنواخت	DIF	.۱/۷۳	.۰/۷۸	.۰/۵۱	.۰/۷۸	S042059
-	-	-	لنگر	.۱/۲۳	.۱/۱۶	.۱/۲۳	.۱/۱۶	S042011
.۰/۰۱	.۰/۰۳	غیر یکنواخت	DIF	.۱/۶۹	.۰/۷۲	.۲/۷۷	.۰/۱۷	S042028
-.۰/۰۲	.۰/۰۵	یکنواخت	DIF	.۰/۵۹	.۰/۶۲	.۲/۶۹	.۰/۶۲	S042001
-.۰/۰۰۸	.۰/۰۱	غیر یکنواخت	DIF	-.۰/۲۸	.۰/۳۸	.۰/۲۴	.۰/۶۳	S042276
.۰/۰۰	.۰/۰۰۴	غیر یکنواخت	DIF	-.۰/۸۴	.۰/۷۱	-.۱/۱۱	.۰/۲۷	S042279
.۰/۰۰۱	.۰/۰۰۱	یکنواخت	DIF	.۲/۴۳	.۱/۶۴	.۱/۷۴	.۱/۶۴	S042083
-	-	-	لنگر	.۱/۰۲	.۱/۴۸	.۱/۰۲	.۱/۴۸	S042106
.۰/۰۳	.۰/۱۴	غیر یکنواخت	DIF	.۰/۶۰	.۰/۶۵	-.۱/۲۷	.۱/۳۰	S042071
.۰/۰۲	.۰/۰۶	یکنواخت	DIF	.۱/۲۴	.۱/۰۸	-.۰/۰۵	.۱/۰۸	S042101
.۰/۰۲	.۰/۰۴	یکنواخت	DIF	-.۰/۲۹	.۱/۲۵	-.۰/۹۸	.۱/۲۵	S042307
-	-	-	لنگر	-.۰/۴۰	.۰/۷۲	-.۰/۴۰	.۰/۷۲	S042405
-.۰/۰۰۴	.۰/۰۰۹	یکنواخت	DIF	.۰/۷۳	.۱/۷۶	.۱/۳۱	.۱/۷۶	S042244A
-	-	-	لنگر	.۱/۵۲	.۱/۱۹	.۱/۵۲	.۱/۱۹	S042244B
-.۰/۰۱	.۰/۰۱	غیر یکنواخت	DIF	.۰/۳۶	.۰/۸۸	.۰/۴۴	.۰/۵۴	S042153
.۰/۲۵	.۰/۲۳	یکنواخت	DIF	.۱/۰۳	.۰/۹۴	-.۱/۳۸	.۰/۹۴	S022183
-.۰/۱۵	.۰/۰۸	یکنواخت	DIF	-.۱/۱۹	.۱/۱۸	-.۰/۰۸	.۱/۱۸	S022276
-	-	-	لنگر	-.۰/۶۵	.۱/۱۱	-.۰/۶۵	.۱/۱۱	S022115
-.۰/۰۴	.۰/۰۰۵	یکنواخت	DIF	.۰/۲۵	.۱/۱۳	-.۰/۰۴	.۱/۱۳	S022022

کد سؤال	ایران								
	آمریکا	b	a	b	a				
CDIF	شاخص اندازه اثر	DIF نوع	لنگر	لنگر	-	-	-	-	-
-	-	-	لنگر	-	۱/۰۴	۱/۰۱	-۱/۰۴	۱/۰۱	S022019
-	-	-	لنگر	-	-۰/۳۸	.۹۴	-۰/۳۸	.۹۴	S022002
.۰/۰۳	.۰/۰۴	یکنواخت	DIF	-	-۰/۶۳	.۸۳	-۰/۹۶	.۸۳	S022294
-	-	-	لنگر	۵/۸۵	۳/۸۴	۵/۸۵	۳/۸۴	S022106	
.۰/۰۳	.۰/۰۴	یکنواخت	DIF	۵/۶۹	.۷۲	۲/۱۴	.۷۲	S022244	
.۰/۰۴	.۰/۰۶	یکنواخت	DIF	-۰/۲۳	۱/۰۹	-۰/۵۴	۱/۰۹	S022150	
-۰/۰۹	.۰/۰۴	غیر یکنواخت	DIF	-	-۰/۳۰	۱/۴۳	۱/۶۲	.۴۶	S022042
-	-	-	لنگر	۲/۰۶	.۹۶	۲/۰۶	.۹۶	S022289	
.۰/۱۲	.۰/۰۶	غیر یکنواخت	DIF	۲/۵۳	.۸۱	.۲۲	۱/۲۶	S022069	
-	-	-	لنگر	-	-۰/۲۶	.۹۲	-۰/۲۶	.۹۲	S022268
-۰/۰۱	.۰/۰۱	یکنواخت	DIF	-۲/۳۰	۱/۳۲	-۲/۱۱	۱/۳۲	S042013	
-	-	-	لنگر	-	-۰/۲۸	.۶۰	-۰/۲۸	.۶۰	S042006
.۰/۰۶	.۰/۰۲	یکنواخت	DIF	.۳۱	۱/۰۹	-۰/۲۵	۱/۰۹	S042310	
-۰/۰۲	.۰/۰۱	یکنواخت	DIF	.۷۲	.۷۵	.۹۷	.۷۵	S042052	
.۰/۱۲	.۰/۰۷	یکنواخت	DIF	.۴۳	.۵۳	-۱/۶۲	.۵۳	S042054	
-۰/۰۴	.۰/۰۱	یکنواخت	DIF	۱/۱۸	.۷۵	۲/۰۹	.۷۵	S042043	
-	-	-	لنگر	۱/۷۷	۱/۱۵	۱/۷۷	۱/۱۵	S042196	
-	-	-	لنگر	۱/۱۵	.۴۵	۱/۱۵	.۴۵	S042061	
.۰/۱۰	.۰/۰۸	یکنواخت	DIF	۱/۶۰	۱/۳۶	.۲۳	۱/۳۶	S042292	
.۰/۰۵	.۰/۰۲	غیر یکنواخت	DIF	-	-۰/۳۵	۱/۸۰	-۰/۷۷	.۷۱	S042109
-۰/۰۸	.۰/۰۳	یکنواخت	DIF	-	-۰/۱۸	.۸۴	.۷۶	.۸۴	S042232A
-	-	-	لنگر	۲/۵۵	۲/۲۳	۲/۵۵	۲/۲۳	S042232B	
-۰/۰۲	.۰/۰۳	یکنواخت	DIF	۴/۹۹	.۰۸	۲/۸۹	.۰۸	S042232C	
-۰/۰۴	.۰/۰۳	غیر یکنواخت	DIF	-	-۰/۲۹	۱/۱۸	۱/۶۵	.۳۰	S042294
.۰/۱۳	.۰/۰۸	یکنواخت	DIF	.۱۹	۱/۱۸	-۰/۸۵	۱/۱۸	S042149	
.۰/۰۷	.۰/۰۲	غیر یکنواخت	DIF	.۵۵	۱/۷۵	.۳۲	۱/۰۳	S042155	
-۰/۰۶	.۰/۰۲	یکنواخت	DIF	-	-۰/۴۵	.۷۳	.۲۷	.۷۴	S042150
.۰/۱۰	.۰/۰۲	یکنواخت	DIF	-	-۰/۶۰	۱/۱۲	۱/۱۵	۱/۱۲	S022290
-	-	-	لنگر	.۸۳	.۹۱	.۸۳	.۹۱	S022292	
-	-	-	لنگر	-	-۱/۱۰	.۸۹	-۱/۱۰	.۸۹	S022054
-	-	-	لنگر	.۵۰	۱/۱۰	.۵۰	۱/۱۰	S022181	
.۰/۲۷	.۰/۱۵	یکنواخت	DIF	.۱۶	۱/۱۶	-۱/۳۸	۱/۱۶	S022208	
.۰/۰۸	.۰/۰۱	غیر یکنواخت	DIF	-	-۰/۴۴	۱/۷۱	-۰/۷۳	۱/۸۷	S022078
-۰/۱۰	.۰/۰۲	یکنواخت	DIF	-	-۰/۵۲	.۷۰	.۳۱	.۷۰	S022126
-	-	-	لنگر	.۹۷	.۸۳	.۹۷	.۸۳	S022281	

کد سوال	ایران				آمریکا				کد سوال
	b	a	b	a	DIF	نوع	DIF	لنگر	
CDIF	شاخص اندازه اثر	DIF	یکنواخت	DIF	-۰/۱۱	۱/۲۳	-۱/۴۰	۱/۲۸	S032385
-	-	-	لنگر	-۰/۸۸	۱/۰۲	-۰/۸۸	۱/۰۲	۱/۰۲	S032035
-۰/۰۲	.۰/۰۱	یکنواخت	DIF	-۰/۷۶	.۰/۹۸	-۰/۶۴	.۰/۹۸	S032519	
.۰/۱۸	.۰/۰۶	یکنواخت	DIF	.۰/۸۵	.۰/۹۰	-۰/۴۵	.۰/۹۰	S032683	
-۰/۱۸	.۰/۰۶	یکنواخت	DIF	-۰/۱۷	.۰/۷۳	.۰/۳۲	.۰/۷۳	S032258	
-۰/۰۳	.۰/۰۱	یکنواخت	DIF	.۰/۱۶	.۰/۰۵	۱/۴۳	.۰/۰۵	S032120A	
-۰/۰۲	.۰/۰۴	غیر یکنواخت	DIF	۱	۱/۲۱	.۰/۶۴	.۰/۱۹	S032120B	
.۰/۰۴	.۰/۰۷	غیر یکنواخت	DIF	-۰/۸۸	.۰/۱۵	-۰/۶۲	.۰/۷۲	S042304	
-۰/۰۰۷	.۰/۰۲	غیر یکنواخت	DIF	-۰/۳۹	.۰/۹۰	-۰/۸۰	.۰/۶۸	S042038	
-	-	-	لنگر	.۰/۰۳	۱/۲۶	.۰/۰۳	۱/۲۶	S042298	
-۰/۰۰۶	.۰/۰۳	یکنواخت	DIF	.۰/۲۷	۱/۱۱	.۰/۲۶	.۰/۱۱	S042261	
.۰/۰۰۸	.۰/۰۹	یکنواخت	DIF	-۰/۹۶	.۰/۰۷	.۰/۳۲	.۰/۰۷	S042051A	
.۰/۰۰۴	.۰/۰۹	یکنواخت	DIF	.۰/۶۰	.۰/۵۰	۱/۱۱	.۰/۵۰	S042051B	
-۰/۰۰۴	.۰/۰۱	یکنواخت	DIF	.۰/۲۷	.۰/۵۴	-۰/۱۵	.۰/۵۴	S042076	
-۰/۰۰۲	.۰/۰۳	یکنواخت	DIF	.۰/۲۱	.۰/۰۷	۱/۳۴	.۰/۰۷	S042404	
.۰/۰۰۲	.۰/۰۵	یکنواخت	DIF	.۰/۵۶	.۰/۷۰	.۰/۰۷	.۰/۷۰	S042306	
-۰/۰۰۷	.۰/۰۳	غیر یکنواخت	DIF	.۰/۸۰	.۰/۲۰	-۰/۰۵	.۰/۰۷	S042403	
-	-	-	لنگر	-۰/۰۱	.۰/۰۵	-۰/۰۱	.۰/۰۵	S042272	
.۰/۰۰۴	.۰/۰۲	غیر یکنواخت	DIF	.۰/۴۷	.۰/۷۸	.۰/۸۷	.۰/۲۹	S042100	
-	-	-	لنگر	.۰/۷۹	.۰/۶۴	.۰/۷۹	.۰/۶۴	S042238A	
.۰/۰۰۹	.۰/۰۴	غیر یکنواخت	DIF	.۰/۵۱	.۰/۰۴	.۰/۲۷	.۰/۲۹	S042238B	
.۰/۰۰۹	.۰/۰۲	غیر یکنواخت	DIF	-۰/۰۱	.۰/۳۷	-۰/۳۶	.۰/۳۰	S042141	
-۰/۰۰۸	.۰/۱۱	یکنواخت	DIF	.۰/۸۲	.۰/۸۰	-۰/۰۴	.۰/۸۰	S042215	
-۰/۱۲	.۰/۰۳	یکنواخت	DIF	-۰/۴۳	.۰/۰۳	-۰/۶۸	.۰/۰۳	S032606	
.۰/۲۳	.۰/۰۵	یکنواخت	DIF	.۰/۲۲	.۰/۷۳	.۰/۷۹	.۰/۷۳	S032015	
.۰/۴۹	.۰/۲۲	یکنواخت	DIF	.۰/۶۴	.۰/۱۰	.۰/۴۰	.۰/۱۰	S032310A	
.۰/۳۸	.۰/۱۲	غیر یکنواخت	DIF	.۰/۱۸	.۰/۰۹	.۰/۵۵	.۰/۴۵	S032310B	
.۰/۱۲	.۰/۰۳	غیر یکنواخت	DIF	-۰/۰۰۷	.۰/۰۲	.۰/۷۴	.۰/۷۶	S032310D	
-۰/۰۰۵	.	یکنواخت	DIF	.۰/۳۶	.۰/۷۹	.۰/۳۴	.۰/۷۹	S032680	
-۰/۱۵	.۰/۰۳	یکنواخت	DIF	.۰/۹۷	.۰/۲۵	-۰/۶۰	.۰/۲۵	S032672	
-	-	-	لنگر	-۰/۲۸	.۰/۷۴	-۰/۲۸	.۰/۷۴	S032392	
-۰/۰۷	.۰/۰۵	یکنواخت	DIF	.۰/۱۵	.۰/۴۸	.۰/۴۹	.۰/۴۸	S032425	
.۰/۱۴	.۰/۰۲	غیر یکنواخت	DIF	.۰/۱۳	.۰/۵۸	.۰/۹۳	.۰/۱۰	S032257	
.۰/۲۹	.۰/۱۰	یکنواخت	DIF	-۰/۳۶	.۰/۴۹	.۰/۳۱	.۰/۴۹	S032663	

کد سؤال	ایران						کد سؤال	
	آمریکا			ایران				
CDIF	شاخص اندازه اثر	DIF نوع	DIF یا لنگر	b	a	b	a	
-0.09	.008	یکنواخت	DIF	.27	.54	-.43	.53	S032660
.07	.004	یکنواخت	DIF	.68	.86	1.07	.86	S032555
.03	.001	یکنواخت	DIF	1.46	.86	1.70	.86	S032122
.06	.009	یکنواخت	DIF	-.90	.95	-1.37	.95	S042053
.05	.007	یکنواخت	DIF	.07	.93	-.031	.93	S042408
.06	.008	یکنواخت	DIF	.12	.74	-.042	.74	S042015
-	-	-	لنگر	-.24	.42	-.024	.42	S042309
-.14	.07	غیر یکنواخت	DIF	-.21	.84	-.059	1.47	S042049A
-.05	.007	یکنواخت	DIF	.32	1.60	-.07	1.60	S042049B
.10	.03	یکنواخت	DIF	-.15	1.33	-.207	1.33	S042182
.09	.02	یکنواخت	DIF	2.21	.98	1.07	.98	S042402
.03	.004	یکنواخت	DIF	.10	1.64	.07	1.64	S042228A
-	-	-	لنگر	-.05	.85	-.056	.85	S042228B
-.12	.04	یکنواخت	DIF	-.13	2.43	.45	2.21	S042228C
-.06	.01	یکنواخت	DIF	-.48	.68	-.096	.51	S042126
.06	.01	غیر یکنواخت	DIF	.67	.35	.15	.65	S042210
.24	.15	یکنواخت	DIF	.74	1.44	-.07	1.44	S042176
-.07	.02	غیر یکنواخت	DIF	-.68	1.32	-.026	.80	S042211
.15	.06	یکنواخت	DIF	-.28	1.49	-.113	1.49	S042135
-	-	-	لنگر	-.31	.68	.31	.68	S042257
-.003	.004	یکنواخت	DIF	.54	.58	1.08	.58	S032542
-.007	.05	یکنواخت	DIF	-.38	.97	.68	.97	S032645
-	-	-	لنگر	.81	.64	.81	.64	S032530A
.06	.03	یکنواخت	DIF	.91	.57	.49	.57	S032530B
.001	.004	یکنواخت	DIF	2.77	.92	1.91	.92	S032530D
-	-	-	لنگر	.08	1.27	.08	1.27	S032007
.004	.009	یکنواخت	DIF	-.06	.89	-.052	.89	S032502
-.002	.006	غیر یکنواخت	DIF	1.88	.68	.70	1.39	S032679
-	-	-	لنگر	.74	.28	.74	.28	S032184
.008	.03	یکنواخت	DIF	.98	.58	-.043	.58	S032394
-	-	-	لنگر	-.23	1.37	-.023	1.37	S032151
.004	.05	غیر یکنواخت	DIF	-.20	2.64	.77	1.30	S032651A
-.001	.002	یکنواخت	DIF	1.03	1.15	1.31	1.15	S032651B
-	-	-	لنگر	.36	1.48	.36	1.48	S032665A

کد سوال	ایران				آمریکا				لنگر	نوع DIF	شناخت	اندازه اثر	CDIF	
	b	a	b	a										
S032665B	.78	.95	.78	.95	-	-	-	-	یکنواخت	DIF	.81	.83	.68	.83
S032665C	.11	.05	.11	.05	-	-	-	-	یکنواخت	DIF	-2.87	.58	-.88	.58
S042073	.04	.02	.04	.02	-	-	-	-	غیر یکنواخت	DIF	.47	.83	.49	.23
S042007	-.03	.005	-.03	.005	-	-	-	-	یکنواخت	DIF	.85	.94	.47	.94
S042024	-	-	-	-	-	-	-	-	لنگر	4.54	.12	.54	.12	
S042095	-	-	-	-	-	-	-	-	لنگر	-1.22	.11	-1.22	.11	
S042022	.13	.08	.13	.08	-	-	-	-	یکنواخت	DIF	-.40	.97	.92	.97
S042063	-	-	-	-	-	-	-	-	لنگر	-2.26	.28	-2.26	.28	
S042197	.06	.03	.06	.03	-	-	-	-	غیر یکنواخت	DIF	-.40	.94	.85	.42
S042297	.08	.04	.08	.04	-	-	-	-	یکنواخت	DIF	.21	.96	.69	.95
S042305	-	-	-	-	-	-	-	-	لنگر	2.60	.07	.60	.07	
S042112	.18	.15	.18	.15	-	-	-	-	یکنواخت	DIF	-1.20	.92	.69	.92
S042173A	.03	.004	.03	.004	-	-	-	-	یکنواخت	DIF	-1.20	.85	-.83	.85
S042173B	-.08	.03	-.08	.03	-	-	-	-	یکنواخت	DIF	.01	.60	-.19	.60
S042173C	-.02	.01	-.02	.01	-	-	-	-	غیر یکنواخت	DIF	-.13	.48	-.86	.28
S042173D	.03	.008	.03	.008	-	-	-	-	غیر یکنواخت	DIF	-.63	.93	-.34	.69
S042173E	-.04	.007	-.04	.007	-	-	-	-	غیر یکنواخت	DIF	-.16	.10	-.15	.59
S042173	-.02	.03	-.02	.03	-	-	-	-	غیر یکنواخت	DIF	.059	.61	.11	.54
S042407	-.10	.05	-.10	.05	-	-	-	-	یکنواخت	DIF	2.14	.44	-.06	.44
S042278	-.02	.001	-.02	.001	-	-	-	-	یکنواخت	DIF	.72	.14	.56	.14
S042274	-.07	.03	-.07	.03	-	-	-	-	یکنواخت	DIF	3.04	.64	1.33	.64
S042311	-	-	-	-	-	-	-	-	لنگر	4.26	3.80	.26	3.80	
S042317	-.04	.008	-.04	.008	-	-	-	-	یکنواخت	DIF	-.37	.96	-.78	.96
S032465	-	-	-	-	-	-	-	-	لنگر	-1.52	1.11	-1.52	1.11	
S032315	.05	.02	.05	.02	-	-	-	-	غیر یکنواخت	DIF	-.40	.08	-.14	.35
S032306	-	-	-	-	-	-	-	-	لنگر	.42	.98	.42	.98	
S032640	-.02	.004	-.02	.004	-	-	-	-	غیر یکنواخت	DIF	.43	.59	-.95	.92
S032579	.06	.007	.06	.007	-	-	-	-	یکنواخت	DIF	.62	.42	-.23	.42
S032570	.09	.02	.09	.02	-	-	-	-	غیر یکنواخت	DIF	.14	.82	-.53	.27
S032024	.15	.05	.15	.05	-	-	-	-	غیر یکنواخت	DIF	1.90	.37	-.45	.76
S032272	.09	.02	.09	.02	-	-	-	-	یکنواخت	DIF	2.54	1	1.20	1
S032141	-	-	-	-	-	-	-	-	لنگر	.80	.86	.80	.86	
S032060	-	-	-	-	-	-	-	-	لنگر	-.85	1.32	-.85	1.32	

کد سؤال	ایران						آمریکا	
	b	a	b	a	b	a		
CDIF	شاخص اندازه اثر	DIF نوع	یا DIF لنگر					
./۱۱	./۰۲	یکنواخت	DIF	- .۰۴۰	۱/۲۶	- .۰۹۷	۱/۲۶	S032463
-	-	-	لنگر	- .۰۵۲	۲/۵۴	- .۰۵۲	۲/۵۴	S032650A
-	-	-	لنگر	- .۰۱۶	۴/۵۶	- .۰۱۶	۴/۵۶	S032650B
-	-	-	لنگر	.۰۰۳	۳/۶۰	.۰۰۳	۳/۶۰	S032650D
./۰۰۵	./۰۰۶	غیر یکنواخت	DIF	.۰۰۷	.۰۶۲	۱/۰۹	.۰۱۸	S032514
- .۰۰۵	./۰۳	یکنواخت	DIF	- ۱/۶۴	.۰۸۸	- .۰۷۱	.۰۸۸	S042042
- .۰۰۴	./۰۳	یکنواخت	DIF	.۰۳۸	۱/۲۸	۱/۱۴	۱/۲۸	S042030
./۰۳	./۰۲	غیر یکنواخت	DIF	.۰۴۷	.۰۴۶	- .۰۴۶	.۰۸۳	S042003
./۰۳	./۰۰۹	یکنواخت	DIF	- ۱/۷۰	.۰۶۷	- ۲/۵۰	.۰۶۷	S042110
-	-	-	لنگر	.۰۶۲	۱/۲۹	.۰۶۲	۱/۲۹	S042222A
-	-	-	لنگر	.۰۱۲	۱/۵۰	.۰۱۲	۱/۵۰	S042222B
- .۰۰۶	./۰۵	یکنواخت	DIF	- ۱/۵۵	.۰۸۶	- .۰۴۰	.۰۸۶	S042222C
./۰۵	./۰۴	غیر یکنواخت	DIF	- ۱/۲۶	.۰۹۴	- ۱/۷۳	۱/۷۴	S042065
-	-	-	لنگر	- .۰۴۴	۱/۳۵	- .۰۴۴	۱/۳۵	S042280
-	-	-	لنگر	.۰۹۵	.۰۵۹	.۰۹۵	.۰۵۹	S042088
./۰۴	./۰۳	غیر یکنواخت	DIF	- .۰۵۰	۱/۳۳	- .۱۵۶	.۰۶۳	S042218
./۰۲	./۰۱	غیر یکنواخت	DIF	.۱۳۹	۱/۰۶	.۰۶۲	۱/۴۷	S042104
- .۰۰۸	./۰۹	یکنواخت	DIF	.۰۱۵	۱/۴۵	۱/۶۰	۱/۴۵	S042064
./۰۰۷	./۰۰۴	غیر یکنواخت	DIF	.۰۱۵	۱/۳۱	- .۰۰۵	۱/۸۲	S042273
./۰۰۲	./۰۰۱	غیر یکنواخت	DIF	- .۰۵۶	۱/۲۷	- .۰۵۹	۱/۱۱	S042301
./۰۵	./۰۳	یکنواخت	DIF	- .۰۳۴	.۰۳۴	- ۲/۳۵	.۰۳۴	S042312
./۰۶	./۰۴	یکنواخت	DIF	.۰۲۵	.۰۹۶	- .۰۶۲	.۰۹۶	S042217
./۰۳	./۰۲	غیر یکنواخت	DIF	.۰۷۶۵	۱/۱۷	.۰۱۳	۱/۵۶	S042406
-	-	-	لنگر	.۲/۲۰	.۰۲۹	.۲/۲۰	.۰۲۹	S032611
-	-	-	لنگر	- .۰۸۵	۱/۱۱	- .۰۸۵	۱/۱۱	S032614
- .۰۱۰	./۰۹	یکنواخت	DIF	- .۰۸۹	۱/۲۳	.۰۲۲	۱/۲۳	S032451
- .۰۰۷	./۰۵	یکنواخت	DIF	- .۰۲۲	.۰۷۳	۱/۱۶	.۰۷۳	S032156
./۰۵	./۰۲	یکنواخت	DIF	.۰۳۷	۱/۱۲	- .۰۲۱	۱/۱۲	S032056
./۱۱	./۱۰	غیر یکنواخت	DIF	.۰۰۷	۱/۱۹	- .۱۸۵	.۰۶۸	S032087
./۰۳	./۰۰۶	یکنواخت	DIF	.۱/۱۳	.۰۵۹	.۰۵۱	.۰۵۹	S032279
./۰۷	./۰۴	یکنواخت	DIF	.۱/۲۰	.۱/۰۲	.۰۱۳	.۱/۰۲	S032238
./۰۲	./۰۱	یکنواخت	DIF	.۱/۵۰	.۱/۷۸	.۰۹۸	.۱/۷۸	S032369
- .۰۰۳	./۰۰۸	یکنواخت	DIF	.۱/۲۱	.۰۷۰	- .۰۶۵	.۰۷۰	S032160
./۰۵	./۰۲	یکنواخت	DIF	- .۰۲۸	.۰۹۱	- .۰۹۳	.۰۹۲	S032654

کد سوال	ایران				آمریکا				لنگر	نوع	DIF	شناخت	اندازه اثر	CDIF
	b	a	b	a										
S032126	.79	.40	.79	.40	-	-	-	-	-	غیر یکنواخت	DIF	-	.003	.
S032510	.83	.18	.83	.18	-	-	-	-	-	لنگر	DIF	-	.003	.
S032158	.16	.91	.16	.91	-	-	-	-	-	لنگر	DIF	-	.11	.06
S042258	.74	.46	.74	.46	-	-	-	-	-	یکنواخت	DIF	-	.004	.
S042005	.50	.76	.50	.76	-	-	-	-	-	یکنواخت	DIF	-	.004	.009
S042016	.89	.68	.89	.68	-	-	-	-	-	یکنواخت	DIF	-	.004	.009
S042300A	.92	.16	.92	.16	-	-	-	-	-	لنگر	DIF	-	-	-
S042300B	.47	.05	.47	.05	-	-	-	-	-	لنگر	DIF	-	-	-
S042300C	.47	.51	.47	.51	-	-	-	-	-	یکنواخت	DIF	-	.05	.04
S042319	.98	.99	.98	.99	-	-	-	-	-	یکنواخت	DIF	-	.05	.03
S042068	.45	.34	.45	.34	-	-	-	-	-	یکنواخت	DIF	-	.11	.07
S042216	.80	.08	.80	.08	-	-	-	-	-	یکنواخت	DIF	-	.06	.01
S042249	.13	.99	.13	.99	-	-	-	-	-	یکنواخت	DIF	-	.06	.01
S042094	.15	.99	.15	.99	-	-	-	-	-	یکنواخت	DIF	-	.05	.02
S042293A	.48	.18	.48	.18	-	-	-	-	-	لنگر	DIF	-	-	-
S042293B	.92	.71	.92	.71	-	-	-	-	-	غیر یکنواخت	DIF	-	.02	.02
S042195	.82	.17	.82	.17	-	-	-	-	-	یکنواخت	DIF	-	.02	.004
S042400	.25	.49	.25	.49	-	-	-	-	-	یکنواخت	DIF	-	.007	.001
S042401	.33	.44	.33	.44	-	-	-	-	-	لنگر	DIF	-	-	-
S042164	.05	.66	.05	.66	-	-	-	-	-	غیر یکنواخت	DIF	-	.06	.02

بررسی یافته‌های جدول ۴ نشان می‌دهد که از ۲۲۸ سوال مورد مطالعه، ۵۹ سوال لنگر و ۱۶۹ سوال دارای DIF است که ۵۱ سوال دارای DIF غیر یکنواخت و ۱۱۸ سوال دارای DIF یکنواخت است.

از ۱۶۹ سوال دارای DIF، ۶۴ سوال (۳۸%) به نفع گروه دانش آموزان ایران و ۱۰۵ سوال (۶۲%) به نفع گروه دانش آموزان آمریکا از کار کرد افتراقی برخوردارند. در جدول ۵ تعداد سوال‌هایی که به نفع هر کدام از گروه‌ها دارای DIF یکنواخت یا غیر یکنواخت است ارائه شده است.

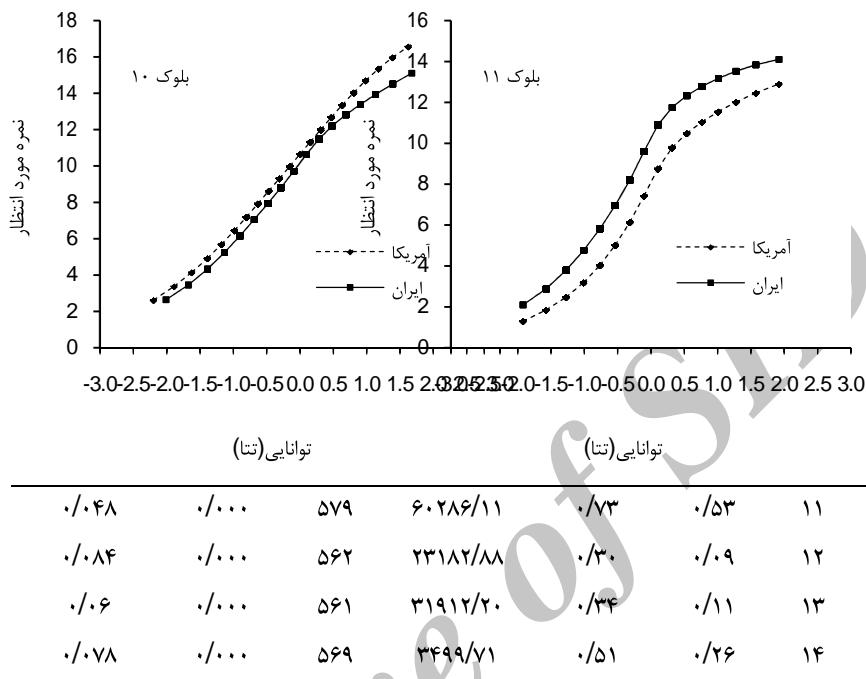
جدول ۵: فراوانی و درصد سئوال‌های دارای DIF

نوع DIF		کشور
غیریکنواخت	یکنواخت	
(%)۱۴	(%)۳۰(۵۰	ایران
(%)۲۲(۳۷	(%)۴۰(۶۸	آمریکا

در جدول ۶ شاخص DTF که کارکرد افتراقی آزمون (کل سئوال‌های یک مجموعه) را نشان می‌دهد به تفکیک بلوک ارائه شده است. آزمون χ^2 بدلیل حساسیت به حجم نمونه، روش مناسبی برای آزمون معناداری شاخص DTF نیست، بنابراین از نقاط برش که در اولین ستون سمت چپ جدول ارائه شده است برای این منظور استفاده می‌شود. بررسی یافته‌های جدول ۶ نشان می‌دهد که به غیر از بلوک‌های ۲، ۶ و ۹، سایر بلوک‌ها از کارکرد افتراقی برخوردارند. به عبارت دیگر، ۱۱ بلوک از ۱۴ بلوک دارای کارکرد افتراقی است. در واقع، ۷۹٪ بلوک‌ها بر له یا علیه گروه دانش آموزان ایران دارای کارکرد افتراقی هستند.

جدول ۶: شاخص DTF همراه با نقاط برش به تفکیک بلوک

نقطه برش DTF	P	df	χ^2	مقدار DFT	ریشه دوم DFT	DTF	بلوک
./.۰۷۲	./.۰۰۰	۵۷۱	۴۶۰۰۲/۰۲	۱/۴۱	۱/۹۹	۱	
./.۰۷۲	./.۰۰۰	۵۷۲	۳۱۲۶	۰/۰۸۴	۰/۰۰۷	۲	
./.۰۴۸	./.۰۰۰	۵۶۴	۵۴۷۴۵	۰/۵۳	۰/۲۸	۳	
./.۰۷۸	./.۰۰۰	۵۶۹	۳۱۱۰/۱۲	۰/۵۰	۰/۲۵	۴	
./.۰۶	./.۰۰۰	۵۶۶	۳۱۶۹۵/۸۴	۰/۷۲	۰/۰۵۱	۵	
./.۰۷۸	./.۰۴	۵۶۰	۶۱۹/۶۱	۰/۰۶	۰/۰۰۴	۶	
./.۰۷۸	./.۰۰۰	۵۵۷	۱۶۶۹/۱۵	۱/۴۵	۱/۳۲	۷	
./.۰۸۴	./.۰۰۰	۵۶۸	۶۶۴۹۵/۸۵	۰/۶۲	۰/۰۳۹	۸	
./.۰۶	./.۰۰۰	۵۷۶	۷۵۲/۷۴	۰/۱۰	۰/۰۱	۹	
./.۱۰۲	./.۰۰۰	۵۷۴	۴۴۶۶/۱۶	۰/۵۰	۰/۰۲۵	۱۰	



شکل ۳: نمودار تابع پاسخ آزمون (بلوک)، TRF، برای دو گروه ایران و آمریکا

شکل ۳ نیز کار کرد افتراقی آزمون یا بلوک ها (DTF) را به صورت نموداری برای ۵ بلوک که ۴ بلوک آن بر له یا علیه دانش آموzan ایران از کار کرد افتراقی یکنواخت و ۱ بلوک نیز دارای کار کرد افتراقی غیر یکنواخت است نشان می دهد. به طور کلی، ۳۷٪ از ۱۴ بلوک به نفع گروه هدف (دانش آموzan ایران) و ۲۱٪ بلوک ها به نفع گروه مرجع (دانش آموzan آمریکا) از کار کرد افتراقی یکنواخت برخوردارند. ۲۱٪ بلوک ها دارای کار کرد افتراقی غیر یکنواخت و ۲۱٪ مابقی فاقد کار کرد افتراقی هستند.

بحث و نتیجه گیری

در مباحث مربوط به روش شناسی سنجش های بین المللی، معادل بودن و مقایسه پذیری از اهمیت اساسی برخوردار است (ارسی کان، ۱۹۹۸). با توجه به اهمیت و ضرورت

تغییرناپذیری سازه‌ای آزمون‌هایی که در مطالعات بین فرهنگی و بین‌المللی بکار می‌رond (به عنوان مثال برن و استوارت، ۲۰۰۶؛ لیتل، ۱۹۹۷) و با توجه به یافته‌های مربوط به تغییرناپذیری سازه‌ای و کارکرد افتراقی سوالات ریاضیات و علوم تیمز (به عنوان مثال به ارسی کان، ۱۹۹۸؛ ارسی کان و کام، ۲۰۰۵؛ وو، لی، و زامبو، ۲۰۰۷) پژوهش حاضر تلاش کرد تا به سوالات زیر پاسخ دهد:

۱- آیا ساختار عاملی/سازه‌ای آزمون علوم تیمز ۲۰۰۷ در بین دانش‌آموزان ایران و آمریکا یکسان و قابل مقایسه است؟

۲- آیا سوالات‌ای آزمون علوم تیمز ۲۰۰۷ بر له یا علیه دانش‌آموزان ایرانی دارای DIF است و به چه میزان؟

۳- تأثیر سوالات‌ای دارای DIF بر عملکرد دانش‌آموزان ایرانی در آزمون علوم پایه هشتم تیمز ۲۰۰۷، چگونه و به چه میزان است؟

به طور کلی نتایج حاصل از تحلیل‌های مربوط به سوال نشان می‌دهد که تمام ۱۴ بلوک، از تغییرناپذیری شکلی در بین دو گروه ایران و آمریکا برخوردارند. برقرار بودن تغییرناپذیری شکلی بدان معنا است که دانش‌آموزان دو کشور ایران و آمریکا برای دادن پاسخ به سوالات‌ای علوم تیمز ۲۰۰۷ از چارچوب مفهومی یکسانی استفاده می‌کنند (چیونگ و رنسولد، ۲۰۰۲؛ هورن و مک آردل، ۱۹۹۲) و این آزمون در هر دو جامعه، سازه واحد و یکسانی را اندازه می‌گیرد. این یافته، هر چند که به درس علوم تیمز ۲۰۰۷ مربوط می‌شود، لیکن با نتایج حاصل از پژوهش وو، لی و زامبو (۲۰۰۷) که درس ریاضی تیمز ۱۹۹۹ را مورد مطالعه قرار دادند، از همخوانی برخوردار است. آن‌ها نیز در پژوهش خود به این نتیجه رسیدند که سوالات‌ای ریاضی تیمز ۱۹۹۹ از تغییرناپذیری شکلی در بین کشورهای مورد مطالعه برخوردارند.

یافته‌های حاصل از تحلیل‌های مربوط به سوال دوم نشان داد که از ۲۲۸ سوال مورد مطالعه، ۵۹ سوال لنگر و ۱۶۹ سوال دارای DIF است که ۵۱ سوال دارای DIF غیریکنواخت و ۱۱۸ سوال دارای DIF یکنواخت است. از ۱۶۹ سوال دارای ۶۴ DIF

سؤال (۳۸%) به نفع گروه دانش آموزان ایران و ۱۰۵ سؤال (۶۲%) به نفع گروه دانش آموزان آمریکا، یا به عبارت دیگر علیه دانش آموزان ایران از کار کرد افتراقی برخوردارند. این یافته با نتایج حاصل از پژوهش ارسی کان و کاه (۲۰۰۵) و ارسی کان و مک کریس (۲۰۰۲) از همخوانی برخوردار است. ارسی کان و کاه (۲۰۰۵) در پژوهش خود دریافتند که ۳۷٪ از سؤال‌های علوم تیمز ۱۹۹۵ در بین دانش آموزان انگلیسی زبان و فرانسوی زبان کانادا از DIF برخوردارند، در حالیکه درصد سؤال‌های دارای DIF در بین دانش آموزان آمریکایی و فرانسوی ۷۹٪ بود. همچنین آنها دریافتند که ۳۹٪ سؤال‌ها در بین دانش آموزان کشور انگلیس و فرانسه از DIF برخوردارند. در واقع، آنها دریافتند که از بین سؤال‌های مورد مطالعه در درس علوم، تعداد ۵۲ سؤال در بین دانش آموزان انگلیسی و فرانسوی زبان کانادا، تعداد ۵۴ سؤال در بین دانش آموزان کشور انگلیس و فرانسه و تعداد ۱۱۰ سؤال در بین دانش آموزان کشور فرانسه و آمریکا از DIF برخوردارند. در تمام این مقایسه‌ای که این پژوهشگران انجام دادند، بیش از نیمی از سؤال‌های دارای DIF، به نفع گروه هدف، یعنی دانش آموزان فرانسوی زبان عمل می‌کردند. زیاد بودن تعداد سؤال‌های دارای DIF در بین دانش آموزان آمریکا و فرانسه بیانگر این است که هم عامل زبان و هم عوامل فرهنگی، اجتماعی و آموزشی بر نحوه عملکرد سؤال تأثیر مهمی دارند. تعداد سؤال‌های دارای DIF در بین دانش آموزان انگلیسی و فرانسوی زبان کانادا که از شرایط فرهنگی، اجتماعی و آموزشی مشابهی برخوردارند در مقایسه با تعداد سؤال‌های دارای DIF در بین دانش آموزان کشور آمریکا و فرانسه، بسیار کمتر است. در پژوهش حاضر نیز درصد بالایی از سؤال‌ها (۷۴٪) از DIF برخودار بودند که می‌تواند همانند مورد فوق ناشی از تفاوت‌های عمیق فرهنگی، زبان‌ناختی، اجتماعی، اقتصادی، آموزشی و حتی سیاسی باشد.

در پژوهش ارسی کان و کاه (۲۰۰۵) در درس ریاضی نیز وضعیت و الگوی سؤال‌های دارای DIF مشابه درس علوم بود. در این درس نیز تعداد سؤال‌های دارای DIF در بین دانش آموزان کشور آمریکا و فرانسه بیشتر از تعداد این سؤال‌ها در بین دانش آموزان

انگلیسی زبان و فرانسوی زبان کانادا و همچنین بیشتر از تعداد این سوالات در بین دانشآموزان کشور انگلیس و فرانسه بود.

ارسی کان و مک کریس (۲۰۰۲) نیز دریافتند که در درس ریاضی تیمز ۱۹۹۵، از ۱۵۶ سوال مورد مطالعه، ۲۲ سوال در بین دانشآموزان فرانسوی و انگلیسی زبان کشور کانادا، ۶۱ سوال در بین دانشآموزان کشور فرانسه و انگلستان، و از بین ۱۵۴ سوال، ۹۱ سوال در بین دانشآموزان کشور فرانسه و آمریکا دارای DIF هستند. تقریباً ۴۵٪ سوالات دارای DIF به نفع دانشآموزان فرانسوی زبان عمل می‌کردند. در درس علوم در مقایسه با درس ریاضی نسبت بیشتری از سوالات دارای DIF بودند. از ۱۴۰ سوال مورد مطالعه، تعداد ۵۲ سوال در بین دانشآموزان فرانسوی و انگلیسی زبان کانادا، تعداد ۵۴ سوال در بین دانشآموزان کشور فرانسه و انگلستان، و ۹۱ سوال در بین دانشآموزان کشور فرانسه و آمریکا دارای DIF بودند. در واقع، بین ۵۴ تا ۶۵ درصد سوالات دارای DIF به نفع دانشآموزان فرانسوی زبان عمل می‌کردند. این پژوهشگران دریافتند که در ۶۴ سوال از ۲۹۶ سوال تیمز، مشکلات مرتبط با ترجمه و انصباق وجود دارد. ارسی کان و مک کریس به این نتیجه رسیدند که در حدود ۳۵ تا ۴۰ درصد سوالات دارای DIF ناشی از مشکلات ترجمه و انصباق سوالات و تفاوت‌ها در برنامه‌های درسی کشورها است.

وجود DIF ناشی از ترجمه و انصباق سوالات، تفاوت‌های فرهنگی، اجتماعی، زبانشناختی و آموزشی در یک سوال، به آن معناست که سوال، ویژگی مورد نظر را که برای اندازه‌گیری آن تهیه شده است اندازه نمی‌گیرد و از این رو، بر روایی آزمون و استبطاطهایی که از نمره‌های آن به عمل می‌آید تأثیر منفی می‌گذارد. یکی از راههای بهبود کیفیت آزمون و کاهش DIF این است که تعدادی از سوالات از همان ابتدا به زبان مادری دانشآموزان کشورهای مشارکت کننده طراحی و اجرا شوند. علاوه بر این، برای اجتناب از مشکلات مرتبط با ترجمه، انجام تحلیل‌های DIF در مرحله مقدماتی پرورش آزمون یا حتی پس از اجرای آزمون می‌تواند سودمند باشد. در مرحله مقدماتی، سوالات‌هایی که دارای DIF تشخیص داده می‌شوند را می‌توان حذف یا اصلاح کرد. از نتایج حاصل از

تحلیل‌های DIF پس از اجرای آزمون نیز می‌توان برای شناسایی سوال‌های دارای DIF و حذف آنها به هنگام انجام مقایسه‌های بین‌المللی استفاده نمود.

برای پاسخگویی به سوال سوم از شاخص DTF که تأثیر DIF را برابر عملکرد دانش‌آموزان در آزمون نشان می‌دهد، استفاده گردید. یافته‌های حاصل از این تحلیل نشان داد که به غیر از بلوک‌های ۲، ۶ و ۹ سایر بلوک‌ها از کار کرد افتراقی برخوردارند. به عبارت دیگر، ۱۱ بلوک از ۱۴ بلوک دارای کار کرد افتراقی است. در واقع، ۷۹٪ بلوک‌ها دارای کار کرد افتراقی هستند که ۳۷٪ به نفع گروه هدف (دانش‌آموزان ایران) و ۲۱٪ به نفع گروه مرجع (دانش‌آموزان آمریکا) عمل می‌کنند. ۲۱٪ بلوک‌ها نیز دارای کار کرد افتراقی غیریکنواخت و ۲۱٪ مابقی قادر به کار کرد افتراقی هستند.

در زیر محتوای دو سوال S042173 و S032310 که از DIF یکنواخت علیه دانش‌آموزان ایران برخوردارند ارائه شده است. سوال S032310 که در دفترچه شماره ۷ به عنوان سوال شماره ۳۲ آمده است به این شکل است. "گیاهان سبز هنگام فتوستتر، اکسیژن و غذا تولید می‌کنند. کلروفیل یکی از چیزهایی است که برای فتوستتر لازم است. نام دو عامل دیگر که برای انجام فتوستتر لازم هستند را بنویسید". سوال S042173 نیز که در دفترچه شماره ۹ به عنوان سوال شماره ۴۹ آمده است به این شکل است. "وقتی که یک مایع به گاز تبدیل می‌شود، چه ویژگی‌ها یا خصیت‌هایی تغییر می‌کند و چه ویژگی‌ها یا خصیت‌هایی ثابت می‌مانند؟" در ستون مناسب در جدول زیر علامت (X) بگذارید.

جگالی	تغییر می‌کند	ثابت می‌ماند
جرم		
حجم		
اندازه‌ی مولکول‌ها		
سرعت مولکول‌ها		

به منظور شناسایی علل احتمالی کار کرد افتراقی دو سوال فوق، از تعدادی از معلمات درس علوم پایه هشتم و همچنین از تعدادی از دیبران زیست‌شناسی، نظر خواهی به عمل

آمد. به طور خلاصه، به نظر این افراد شاید بتوان گفت که عدم تسلط خود معلمان بر مفاهیم مطرح شده در این سوال‌ها و نداشتن توانایی در برقراری ارتباط بین این مفاهیم، عدم آموزش عملی و آزمایشگاهی این مفاهیم و اکتفا کردن به آموزش‌های صرفاً نظری، ضعف محتوای دروس در آموزش و ایجاد مهارت تفکر واگرا و چند‌بعدی در دانش آموزان و همچنین گسترش فرهنگ آپارتمان‌نشینی که باعث ضعیف شدن ارتباط و تعامل دانش آموزان با طبیعت شده است را می‌توان از جمله علل احتمالی عملکرد ضعیف دانش آموزان ایرانی در این نوع سوال‌ها محسوب کرد.

به طور کلی نتایج این پژوهش نشان می‌دهد، اگرچه ۶۲٪ سوال‌های درس علوم تیمز ۲۰۰۷ علیه دانش آموزان ایران از کارکرد افتراقی برخوردارند، لیکن این کارکرد افتراقی تأثیر چندانی بر عملکرد دانش آموزان ایران و رتبه ایران در تیمز ندارد، زیرا از ۱۱ بلوک دارای کارکرد افتراقی، تعداد ۶ بلوک به نفع دانش آموزان ایران و ۳ بلوک به نفع دانش آموزان آمریکا از کارکرد افتراقی یکنواخت و ۲ بلوک دیگر نیز از کارکرد افتراقی غیر یکنواخت برخوردارند. این یافته با نتیجه حاصل از پژوهش بیتون (۱۹۹۸)، و ارسی کان و مک کریس (۲۰۰۲) هماهنگی دارد. بیتون در پژوهش خود که بر اساس داده‌های تیمز ۱۹۹۵ صورت گرفت به این نتیجه رسید که عادلانه بودن یا نبودن سوال‌ها، هر چند ممکن است جایگاه یک کشور را به میزان چند رتبه تغییر دهد اما باعث نمی‌شود که رتبه یک کشور از ضعیف به متوسط یا از متوسط به قوی تغییر یابد. او به طور کلی به این نتیجه رسید که استفاده از عدم استفاده از سوال‌هایی که مناسب یک کشور هستند تأثیر بسیار اندکی بر جایگاه نسبی یا رتبه کشورها دارد و تأثیر اساسی بر تصویر کلی و عملکرد کلی کشورها نمی‌گذارد.

ارسی کان و مک کریس (۲۰۰۲) نیز به این نتیجه رسیدند که تأثیر سوال‌های دارای DIF بر عملکرد دانش آموزان کشورهای مورد مقایسه به اندازه کافی بزرگ نیست که بتواند جایگاه یک کشور را به شکل اساسی تغییر بدهد.

به طور خلاصه، چنین به نظر می‌رسد که بر اساس یافته‌های پژوهش حاضر می‌توان

نتیجه گرفت که عملکرد ضعیف دانشآموزان ایران در درس علوم تیمز ۲۰۰۷ را نمی‌توان به کار کرد افتراقی سوال‌ها نسبت داد و بایستی علل آن را جایی دیگر جستجو کرد. با این حال، وجود سوال‌های دارای DIF می‌تواند مقایسه‌پذیری نمره‌ها را به شیوه‌های پیچیده‌تری تحت تأثیر قرار دهد. برای مثال، سوال‌های دارای DIF ممکن است تأثیر یکنواختی بر عملکرد دانشآموزان نداشته باشند. در واقع، ممکن است مقایسه‌پذیری نمره‌های برخی از دانشآموزان، مانند دانشآموزان ضعیف، به میزان بیشتری تحت تأثیر قرار گیرد. از اینرو، به منظور افزایش روایی و صحت و درستی استنباطهایی که از داده‌های مطالعات تیمز در پژوهش‌ها به عمل می‌آید، پیشنهاد می‌شود که در مراحل مقدماتی تهیه آزمون‌های تیمز با انجام تحلیل‌های DIF سوال‌های دارای DIF شناسایی شده و اصلاح یا حذف شوند. همچنین پیشنهاد می‌شود که دست‌اندکاران و مسئولان ملی پروژه تیمز بایستی تلاش کنند تا برگزارکنندگان بین‌المللی تیمز را مقاعده کنند، تا به جای ترجمه سوال‌ها از زبان انگلیسی به فارسی، اجازه دهند تعدادی از سوال‌های نسخه فارسی آزمون‌های تیمز از همان ابتدا به زبان فارسی تهیه و اجرا شوند.

یافته‌ضمنی پژوهش حاضر این است که مسئولان وزارت آموزش و پرورش و متولیان امر آموزش در کشور بایستی تلاش کنند تا به تهیه محتواهای آموزشی مناسب، مفاهیم مهم هر حوزه را به صورت زنجیره‌وار و در ارتباط با یکدیگر آموزش دهند و تلاش کنند تا توانایی و مهارت تفکر واگرا و چند بعدی را در دانشآموزان پرورش دهند. همچنین بایستی تلاش شود تا از روش سنتی آموزش که به شکل سخنرانی و عمدتاً نظری صورت می‌گیرد فاصله گرفت و دانشآموزان را در گیر فعالیتهای عملی و آزمایشگاهی نمود. در ارتباط با معلمان و دیبران نیز بایستی تلاش شود تا برگزاری دوره‌های آموزشی، توانایی و مهارت معلمان را در حوزه‌ها و موضوعات مرتبط با دروسی که تدریس می‌کنند، افزایش داد تا بتوانند با برقراری ارتباط درست و دقیق بین مفاهیم و موضوعات مورد تدریس، آموخته‌های قبلی و یادگیریهای جدید دانشآموزان، یا به عبارت دیگر آموخته‌های جزیره‌وار و از هم گسیخته دانشآموزان، را به شکل شبکه‌ای نظاممند به یکدیگر متصل نمایند.

منابع

- کریمی، عبدالعظیم. (۱۳۸۸). مجموعه سوالات علمی ریاضیات تیمز TIMSS (پایه سوم راهنمایی). تهران: پژوهشگاه مطالعات آموزش و پژوهش.
- Barrett, P. (2007). Structural Equation Modeling: Adjusting model fit. *Personality and Individual Differences*, 42, 815-824.
- Beaton, A. E.(1998). Comparing cross-national student performance on TIMSS using different test items. *International Journal of Educational Research*, 29, 529-542.
- Brown, T. A.(2006). *Confirmatory factor analysis for applied research*. NY: The Guilford Press.
- Byrne, B. M., & Stewart, S., M. (2003). The MACS approach to testing for multigroup invariance of a second-order factor structure: A walk through the process. *Structural Equatiopn Modeling*, 13, 287-321.
- Campbell, H. L., Barry, C. L., Joe, J. N. & Finney, S. J. (2008). Configural, metric and scalar invarince of the modified achievement goal questinnnaire across africanamerican and white university studenys. *Educational and Psychological Measurement*, 68, 988-1007.
- Cheung, G. W., & Rensvold, R. B. (2002). Evaluating goodness-of-fit indexes for testing measurement invariance. *Structural Equation Modeling*, 9, 233–255.
- DeCarlo, L. T.(1997). On the meaning and use of kurtosis. *Psychological Methods*, 2, 292-307.
- Dorans, N. J., & Kulick, E. (1986). Demonstrating the utility of the standardization approach to assessing unexpected differential item performance on the Scholastic Aptitude Test. *Journal of Educational Measurement*, 23, 355-368.
- Dorans, N. J., & Kulick, E. (2006). Differential item functioning on the Mini-Mental State Examination : An application of the Mantel-Haenszel and standardization pricedures. *Medical Care*, 44(Suppl 3),S107-S114.

- Ercikan, K.(1998). Translation effects in international assessments. *International Journal of Educational Research*, 29, 543-553.
- Ercikan, K., & Koh, K. (2005). Examining the construct comparability of the English and French versions of TIMSS. *International Journal of Testing*, 5, 23-35.
- Ercikan, K., & McCreith, T. (2002). Effects of adaptations on comparability of test items and test scores. In D. F. Robitaille & A. E. Beaton. (Eds.), Secondary Analysis of the TIMSS Data(391-405). Kluwer Academic Publishers.
- Fleer, P.F.(1993) A Monte Carlo assessment of a new measure of item and test bias. Illinois Institute of Technology. *Dissertation Abstracts International*. 54(04B):2266.
- Flowers, C. P., Oshima, T. C., & Raju, N.S.(1999). A description and demonstration of the polytomous DFIT framework. *Applied Psychological Measurement*. 23,309–32.
- Frase, C.(1988). NOHARM: An IBM PC program for fitting both unidimensional and multidimensional normal ogive models of latent trait theory. Armidale, Australia:The University of New England.
- Floyd; F.J. , & Widaman, K. F. (1995). Factor analysis in development and refinement of clinical assessment instrument . *Psychological Assessment*, 3, 286-299.
- Horn, J. L., & McArdle, J. J. (1992). A practical and theoretical guide in measurement invariance in aging research. *Experimental Aging Research*, 18, 117-144.
- Kline, P. (2005). Principles and practice of structural equation modeling (2nd ed.). New York: Guilford Press.
- Kline, P. (2011). Principles and practice of structural equation modeling (3rd ed.). New York: Guilford Press.
- Lee, Y-S., Park, Y-S., & Tayalan, D. (2011). A cognitive diagnostic modeling of attribute mastery in Massachusetts, Minnesota, and U.S national sample using TIMSS 2007. *International Journal of testing*, 11, 144-177.
- Little, T. D.(1997). Mean and covariance structures(MACS) analysis of cross-cultural data: Practical and theoretical issues. *Multivariate Behavioral Research*, 32, 53-76.
- Muthén, L. K., & Muthén, B. O. (1998–2010). *Mplus user's guide* (6th ed.). Los Angeles: Muthén & Muthén.
- Olson, J.F., Martin, M.O., & Mullis, I.V.S. (Eds.) (2008). Chestnut Hill, MA: TIMSS & PIRLS International Study Center, Boston College. Available in PDF format at: <http://timss.bc.edu/timss2007/techreport.html>
- Orlando-Edelen, M., Thissen, D., Teresi, J. A., Kleinman, M., & Ocepek-

- Welikson, K. (2006). Identification of differential item functioning using item response theory and the likelihood-based model comparison approach: Application to the Mini-mental status examination. *Medical Care, 44*, S134–S142.
- Raju, N. S.(1999). DFIT5P: A fortran program for calculating dichotomous DIF/DTF[computer program]. Chicago, Il: Illinois Institute of Technology.
- Raju, N. S., Van der Linden, W., & Fleer, P.(1995). An IRT-based internal measure of test bias with applications for differential item functioning. *Applied Psychological Measurement, 19*, 353-368.
- Reise, S. P., Widaman, K. F., & Pugh, R. H. (1993). Confirmatory factor analysis and item response theory: Two Approaches for exploring measurement invariance, *Psychological Bulletin, 114*, 552-566.
- Teresi, J. A.(2006). Overview of quantitative measurement methods: Equivalence, invariance and differential item functioning in health applications. *Medical Care,(Suppl 3)*, 44, S39-S49.
- Teresi, J. A., Kleinman, M. & Ocepek-Welikson, K. (2000). Modern psychometric methods for detection of differential item functioning: Application to cognitive assessment measures. *Statistics in Medicine, 19*, 1651-1683.
- Teresi, J. A., Ocepek-Welikson, K., Kleinman, M., Cook, K. F., et al. (2007). Evaluation measurement equivalence using the item response theory log-likelihood ratio (IRTLR) method to assess differential item functioning(DIF): Applications (with illustration) to measure physical functioning ability and general distress. *Quality Life Research, 16(Suppl 1)*, 43-68.
- Teresi, J. A., Ocepek-Welikson, K., Kleinman, M., Eimicke, J. P., et al. (2009). Analysis of differential item functioning in the depression item bank from the Patient Reported Outcome Measurement Information System (PROMIS): An item response approach. *Psychology Science Quarterly, 51*, 148-180.
- Thissen, D. (2001). *IRTLRDIF*(version 2.02b): Software for the computation of the statistics involved in item response theory likelihood-ratio tests for differential item functioning [Computer program]. Chapel Hill, NC: L. L. Thurstone Psychometric Laboratory.
- Thissen, D., Chen, W., & Bock, D.(2003). MULTIOLOG: multiple category item analysis and test scoring using item response theory (Version 7.03). Lincolnwood, IL: Scientific Software International.
- Thissen, D., Steinberg, L., & Kuang, D.(2002). Quick and easy implementation of the Benjamini-Hochberg procedure for controlling the false positive

- rate in multiple comparisions. *Journal of Educational and Behavioral Statistics*, 24, 77-83.
- Vandenberg, R. J., & Lance, C. E. (2000). A review and synthesis of the Measurement invariance literature: Suggestions, practices, and recommendations for organizational research. *Organizational Research Methods*, 3, 4-70.
- Wu, A. D., Li, Z. & Zumbo, B. D. (2007). Decoding the meaning of factorial invariance and updating the practice of multi-group confirmatory factor analysis: A demonstration with TIMSS data. *Practical assessment Research & Evaluation*, 12, 1-26. Available Online: <http://pareonline.net/pdf/v12n2.pdf>