



The Effect of the Anchor Test with Total Test Correlation on Alignment of Results: A Systematic Review

Vahideh Asadi¹, Ali Moghadamzadeh², Keyvan Salehi³

1. PhD Student of Educational Measurement and Evaluation, Faculty of Psychology and Educational Sciences, University of Tehran, Tehran, Iran; (Corresponding Author), Email: vahideh.asadi@ut.ac.ir
2. Associate Professor, Department of Research and Assessment, Faculty of Psychology and Educational Sciences, University of Tehran, Tehran, Iran. Email: amoghadamzadeh@ut.ac.ir
3. Associate Professor, Department of Research and Assessment, Faculty of Psychology and Educational Sciences, University of Tehran, Tehran, Iran. Email: keyvansalehi@ut.ac.ir

Article Info

ABSTRACT

Article Type:

Research Article

Received:

2023.03.27

Received in revised form:

2023.06.26

Accepted:

2023.08.26

Published online:

2023.09.23

Objective: Correlation with the total test is the most important feature of the anchor test. This systematic review investigated the effects of this feature on the alignment process and the factors affecting it.

Methods: A systematic review was done based on the information available in PubMed, Medline, Eric Jstor and Wiley, Sage Ets Academia websites, as well as a review of the references included in some important articles. The search was done to English sources from 1950 to 2022.

Results: Based on the inclusion criteria, 18 studies out of the 167 searched sources were included in this review. The quality of researches was evaluated using the Quality Assessment Tool for Studies with Diverse Designs (QATSDD). The results showed that the test length, test reliability, statistical characteristics of the anchor, the content structure of the anchor test, and differences in the ability of examinee groups are the factors affecting the correlation of the anchor test and the total test. In addition, the results indicated that with the increase of this correlation, the quality and accuracy of parameter estimation in the alignment process improves and the standard error of alignment is reduced.

Conclusion: Considering the importance of the correlation between the anchor test and the total test, it is necessary to carefully examine and analyze the value of this correlation and the factors affecting it during the stages of the test construction and before performing the analyzes related to alignment in order to reduce the occurrence of alignment errors and bias in the results.

Keywords: Alignment, Anchor Test, Correlation, Systematic Review

Cite this article: Asadi, Vahideh; Moghadamzadeh, Ali; Salehi, Keyvan (2023). The Effect of the Anchor Test with Total Test Correlation on Alignment of Results: A Systematic Review. *Educational Measurement and Evaluation Studies*, 13 (43):7-38 pages. DOI: 10.22034/EMES.2023.1971260.2430



© The Author(s).

Publisher: National Organization of Educational Testing (NOET)



مطالعات اندازه‌گیری و ارزشیابی آموزشی

شایان الکترونیکی: ۰۹۴۲-۲۷۸۳-۲۴۷۶-۲۸۶۵

اثر همبستگی آزمون لنگر با آزمون کل بر نتایج همترازسازی: مرور سیستماتیک

وحیده اسدی^۱, علی مقدمزاده^۲, کیوان صالحی^۳

۱. دانشجوی دکتری سنجش و اندازه‌گیری، دانشکده روان‌شناسی و علوم تربیتی، دانشگاه تهران، تهران، ایران؛ (نویسنده مسئول)، رایانامه: amoghadamzadeh@ut.ac.ir
۲. دانشیار بخش تخصصی پژوهش و سنجش، دانشکده روان‌شناسی و علوم تربیتی، دانشگاه تهران، تهران، ایران.
۳. دانشیار بخش تخصصی پژوهش و سنجش، دانشکده روان‌شناسی و علوم تربیتی، دانشگاه تهران، تهران، ایران. رایانامه: keyvansalehi@ut.ac.ir

چکیده**اطلاعات مقاله**

هدف: یکی از ویژگی‌های آزمون لنگر که از مؤلفه‌های مهم همترازسازی است، همبستگی آن با آزمون کل است. در این مرور سیستماتیک، اثر این ویژگی بر فرایند همترازسازی و عوامل مؤثر بر آن بررسی شد.

روش پژوهش: یک مرور سیستماتیک بر اساس اطلاعات موجود در پایگاه‌های داده PubMed، ACADEMIA، SAGE، Wiley، JSTOR، ERIC، Medline و ETS، وبسایتهاي ETS، SAGE، Wiley، JSTOR، ERIC، Medline و ACADEMIA منابع مندرج در برخی مقاله‌های مهم اجرا شد. جستجو در بازه زمانی ۱۹۵۰ تا ۲۰۲۲ تنها برای منابع انگلیسی صورت پذیرفت. اصطلاحات جستجو شامل همترازسازی، لنگر و همبستگی بود که با ترکیب آنها راهبردهای جستجو به دست آمد.

یافته‌ها: با توجه به ملاک‌های ورود، ۱۸ مطالعه از ۱۶۷ منبع جستجو شده، برای بررسی به این مرور راه یافتند. کیفیت این پژوهش‌ها با استفاده از ابزار سنجش کیفیت مطالعه‌ها با طرح‌های مختلف (QATSD) مورد ارزیابی قرار گرفت. نتایج مطالعه نشان داد که طول آزمون، پایابی آزمون، نوع لنگر از نظر ویژگی‌های آماری، ساختار محتوایی آزمون لنگر و تفاوت در توانایی گروه‌ها، عواملی هستند که بر همبستگی آزمون لنگر و آزمون کل مؤثر است. علاوه بر این، نتایج حاکی از آن بود که با افزایش این همبستگی، کیفیت و دقیق‌تر پارامترها در فرایند همترازسازی بهبود می‌یابد و از خطای استاندارد همترازسازی کاسته می‌شود.

نتیجه‌گیری: به دلیل اهمیت همبستگی میان آزمون لنگر و آزمون کل، لازم است مقدار این همبستگی و عوامل مؤثر بر آن در مراحل ساخت آزمون و قبل از اجرای تحلیل‌های مرتبط با همترازسازی به دقت بررسی و تحلیل شود تا از بروز خطای همترازسازی و سوگیری در نتایج کاسته شود.

واژه‌های کلیدی: همترازسازی، آزمون لنگر، همبستگی، مرور سیستماتیک

نوع مقاله:

مقاله پژوهشی

دریافت: ۱۴۰۲/۰۱/۰۷

اصلاح: ۱۴۰۲/۰۴/۰۵

پذیرش: ۱۴۰۲/۰۶/۰۴

انتشار: ۱۴۰۲/۰۷/۰۱

استناد: اسدی، وحیده؛ مقدمزاده، علی؛ صالحی، کیوان (۱۴۰۲). اثر همبستگی آزمون لنگر با آزمون کل بر نتایج همترازسازی: مرور سیستماتیک. مطالعات اندازه‌گیری و ارزشیابی آموزشی، ۱۳ (شماره ۴۳)، ۷-۳۸ صفحه. DOI: 10.22034/EMES.2023.1971260.2430

ناشر: سازمان سنجش آموزش کشور حق مؤلف © نویسنده‌گان.



مقدمه

هنگامی که ویرایش‌های جدید یا فرم‌های جایگزین برای یک آزمون با هدف سنجش آزمودنی‌ها طراحی می‌شود، انتظار می‌رود که معنای نمره‌ها در این آزمون‌ها یکسان باشد. از دیدگاه شی و نورسینی^۱ (۱۹۹۵) سه دلیل برای کاربرد چند فرم از یک آزمون وجود دارد. اولین دلیل به حفظ امنیت آزمون مرتبط است که بر اساس آن تصمیم‌های سرنوشت‌سازی در حیطه‌های آموزشی و شغلی اتخاذ می‌شود؛ دلیل دیگر، امکان انتشار سؤال‌های آزمون است؛ دلیل سوم، تغییر در محتوا و سؤال‌های آزمون در طول زمان است. در چنین شرایطی، اطمینان از یکسان بودن معنای نمره‌ها در فرم‌های مختلف یک آزمون بسیار مهم و ضروری است تا نتایج به دست آمده برای همه آزمودنی‌ها منصفانه باشد. به همین منظور، طراحان آزمون یک برنامه مشترک برای ساخت آزمون‌هایی با سازه اندازه‌گیری یکسان در نظر می‌گیرند. با این حال، آزمون‌های طراحی‌شده دارای ویژگی‌های روان‌سنجدی متفاوتی هستند. برای مقایسه نمره‌ها در این فرم‌ها لازم است میان توابع برآورده نمره‌ها پیوند برقرار شود تا اثر تفاوت در فرم‌ها به‌ویژه اثر تفاوت در دشواری حذف شود. برای دستیابی به این هدف، می‌توان از فرایند همترازسازی^۲ که بین نمره‌های فرم‌های یک آزمون پیوند برقرار می‌کند، استفاده کرد. همترازسازی موجب می‌شود تا نمره‌های فرم‌های مختلف یک آزمون با سطح دشواری متفاوت، تعديل شوند (کولن و برنان^۳، ۲۰۱۴). به دلیل این فرایند، برای آزمودنی فرقی نمی‌کند که به کدام فرم پاسخ داده است؛ بنابراین، همترازسازی، تفاوت در دشواری فرم‌ها را تعديل می‌کند و هنگامی که فرم‌های آزمون با موفقیت همتراز شوند، تفاوت در نمره‌های آزمودنی‌ها به دلیل سختی یا آسانی آزمون نخواهد بود. دورانز و همکاران^۴ (۲۰۱۰) معتقدند که برای به دست آوردن بهترین و دقیق‌ترین برآورد تفاوت در دشواری فرم‌های آزمون، باید در تمام روش‌های همترازسازی، تفاوت گروه‌ها از نظر توانایی کنترل شود. دورویکرد متفاوت برای دستیابی به این هدف وجود دارد. یک رویکرد، استفاده از جامعه مشترک آزمودنی‌ها و یا دو نمونه معادل از یک جامعه مشترک است؛ رویکرد دوم، کاربرد سؤال‌های لنگر^۵ در دو فرم آزمون است که طرحی منعطف‌تر را برای گردآوری داده‌ها و اجرای همترازسازی فراهم می‌آورد. سؤال‌های لنگر، سؤال‌های مشترکی^۶ است که از نظر ویژگی‌های محتوایی و آماری مشابه آزمون اصلی است و از نمره‌های آن برای اندازه‌گیری و کنترل تفاوت‌های گروهی استفاده می‌شود (لیوینگستون^۷؛ ۲۰۰۴).

1. Shea & Norcini

2. equating

3. Kolen & Brennan

4. Dorans et al

5. anchor items

6. common

7. Livingston

گنزالس و ویبرگ^۱، ۲۰۱۷). با توجه به این تعریف، اصطلاح سؤال‌های لنگر و سؤال‌های مشترک را می‌توان به جای یکدیگر استفاده کرد (رايان و براكمان^۲، ۲۰۱۸) که اصطلاح سؤال‌های لنگر در مقاله حاضر به کار گرفته شد. دورانزو همکاران (۲۰۰۸) دریافتند نتایج همترازسازی زمانی قابل اطمینان است که محتوای آزمون لنگر با آزمون کل مطابقت داشته باشد. هابرمن و دورانز^۳ (۲۰۰۹) و وی^۴ (۲۰۱۰) گزارش کردند که آزمون لنگری که از آزمون کل محتوای متفاوتی دارد و مفروضه نمایندگی محتوایی آن نقض شده است، به رانش^۵ (انحراف) مقیاس منجر می‌شود. در کنار ویژگی‌های محتوایی، ویژگی‌های آماری آزمون لنگر نیز مهم است. به طوری که آزمون لنگر باید دارای ویژگی‌های آماری مشابهی نسبت به آزمون کل باشد. کولن و برنان (۲۰۱۴) اشاره نمودند که ویژگی‌های آماری، اغلب برآمارهای کلاسیک از جمله میانگین، انحراف استاندارد، توزیع دشواری و تشخیص سؤال‌ها مبنی است. هابرمن و دورانز (۲۰۰۹) و وی (۲۰۱۰) اظهار نمودند که هرگاه نمایندگی آماری آزمون لنگر نقض شود، رانش مقیاس رخ خواهد داد. وی (۲۰۱۰) بر این باور بود که از بین نمایندگی محتوایی و آماری آزمون لنگر، نمایندگی محتوایی تأثیر بیشتری بر نتایج همترازسازی دارد. علاوه بر موارد ذکر شده، هابرمن و دورانز (۲۰۰۹) بیان نمودند که انتخاب طرح نامناسب، گروه‌های دارای توانایی متفاوت، همبستگی ضعیف بین آزمون لنگر و آزمون کل و آزمون لنگر نامناسب می‌توانند منابع رانش مقیاس باشند. بررسی پیشینه پژوهش‌های ناشان داد که آزمون لنگر، نسخه‌ای کوتاه^۶ از آزمون اصلی است (کولن و برنان، ۲۰۱۴، ص ۱۸) و در بسیاری از برنامه‌های سنجش که از طرح گروه‌های نامعادل با آزمون لنگر^۷ (NEAT) (ون داویر و همکاران^۸، ۲۰۰۴) استفاده می‌کنند، به عنوان یک آزمون کوچک (minitest) شناخته و در نظر گرفته می‌شود (سینهارای و هالند^۹، ۲۰۰۶، ص ۱؛ لیو و همکاران^{۱۰}، ۲۰۱۱a؛ سینهارای، ۲۰۱۷). نتایج پژوهش‌های سینهارای و هالند (۲۰۰۷، b۲۰۰۶) و لیو و همکاران (۲۰۱۱b) در ارتباط با نوع آزمون لنگر ناشان داد که سؤال‌های آزمون لنگر با تغییرپذیری کم در دشواری، نتایج همترازسازی با ثباتی ایجاد می‌کند. آزمون لنگر در همترازسازی نمره‌های آزمون نقش کلیدی دارد و انتخاب آن در کیفیت همترازسازی، به ویژه هنگام استفاده از طرح NEAT بسیار مهم است (سینهارای و همکاران، ۲۰۱۲؛ سینهارای، ۲۰۱۷). یکی از عوامل تعیین‌کننده کارایی

1. Gonzalez & Wiberg

2. Ryan & Brockmann

3. Haberman & Dorans

4. Wei

5. drift

6. mini-version

7. non-equivalent groups with anchor test (NEAT)

8. von Davier et al

9. Sinharay & Holland

10. Liu et al

فرایند همترازسازی، همبستگی^۱ بین آزمون لنگر و آزمون کل است (بیدسکو^۲، ۱۹۸۵). پرسشی که مطرح می‌شود این است که همبستگی آزمون لنگر و آزمون کل چه تأثیری بر فرایند همترازسازی دارد؟ تاکنون هیچ پژوهشی به‌طور سیستماتیک بر اساس مطالعه‌های موجود برای پاسخ به این پرسش اجرا نشده است. با توجه به دانش موجود در زمینه ویژگی‌های آزمون لنگر، این مطالعه به‌منظور انجام یک مروز سیستماتیک برای بررسی اثر همبستگی آزمون لنگر با آزمون کل بر نتایج همترازسازی طراحی شد. اهمیت این مطالعه از آن‌جهت است که نتایج پژوهش‌های انجام‌گرفته در مورد اثر همبستگی با جزئیات بیشتری مورد بررسی قرار می‌گیرد و از ترکیب این نتایج مشخص می‌شود که وجود همبستگی بالا بین این دو آزمون چه تأثیری بر خطای همترازسازی دارد. همچنین از این مطالعه می‌توان به عواملی که بر میزان همبستگی این آزمون‌ها اثر می‌گذارد، پی‌برد. بر اساس نتایج این مروز، طراحان با شناخت و درک عوامل مؤثر بر همبستگی آزمون لنگر و آزمون کل می‌توانند در هنگام ساخت فرم‌های مختلف از یک آزمون، آنها را در نظر بگیرند تا نتایج همترازسازی بهبود یابد و حداقل خطأ رخ دهد.

روش‌ها پروتکل

قبل از نوشتمن مقاله، پروتکلی برای انجام این مروز سیستماتیک طراحی شد. در نگارش پروتکل، علاوه بر ارائه مقدمه‌ای در مورد چرایی انتخاب موضوع و اهمیت اجرای آن، هدف‌های پژوهش، سؤال‌های مروز سیستماتیک، ملاک‌های ورود منابع برای اجرای پژوهش، راهبردهای پژوهش، نحوه انتخاب مطالعه‌ها، فرم‌های ارزیابی انتقادی و سنجش کیفیت مطالعه‌ها، نحوه استخراج داده‌ها و روش ترکیب داده‌های به‌دست‌آمده به‌تفصیل در نظر گرفته شد. راهبردهای جستجو برای هر پایگاه داده و وبسایت در یک فایل جداگانه طراحی و نوشته شد. درنهایت برای ارزیابی پروتکل طراحی شده از فهرست وارسی^۳ پروتکل پریزما^۴ سال ۱۵۰۲ (شمیسر و همکاران^۵، ۱۵۰۲) استفاده شد.

هدف‌ها

هنگام همترازسازی آزمون‌ها با طرح NEAT، عموماً این باور وجود دارد که آزمون لنگر باید نسخه کوچک آزمون‌هایی باشد که همتراز می‌شوند (لیو و همکاران، ۱۱ ۲۰۱۱؛ کولن و برنان، ۱۴ ۲۰۱۴؛ سینهارای، ۱۷ ۲۰۱۷). در این طرح که یکی از منعطف‌ترین ابزارهای موجود برای همترازسازی آزمون‌ها است (انگاف^۶، ۷۱ ۱۹۷۱؛ پترسن و همکاران^۷، ۸۲ ۱۹۸۲؛ پترسن و همکاران، ۸۹ ۱۹۸۹؛ کولن و برنان، ۰۴ ۲۰۰۴؛

1. correlation

2. Budescu

3. checklist

4. preferred reporting items for systematic review and meta-analyses (PRISMA)

5. Shamseer et al

6. Angoff

7. Petersen et al

سینهارای و هالند، ۲۰۰۶b)، محاسبه تفاوت‌های گروهی مبتنی بر کاربرد یک آزمون لنگر است (بران و هالند^۱، ۱۹۸۲؛ کولن و برنان، ۲۰۰۴؛ ون داویر و همکاران، ۲۰۰۴؛ ماسز^۲ و همکاران، ۲۰۱۰). در طرح NEAT، داده‌ها از دو جامعه نامعادل (Q, P) که دو آزمون مختلف (X, Y) و یک آزمون لنگر (A) دریافت کردند، جمع‌آوری می‌شود (سینهارای و هالند، ۲۰۰۶b؛ ماسز و همکاران، ۲۰۱۰). هدف این همترازسازی، ایجاد یک تبدیل از نمره X به نمره Y است که تفاوت دشواری فرم‌های آزمون را حذف می‌کند (ماسز و همکاران، ۲۰۱۰). هدف از این مطالعه، انجام یک مرور سیستماتیک است برای تعیین اینکه چگونه همبستگی آزمون لنگر و آزمون کل بر نتایج همترازسازی تأثیر می‌گذارد و چه عواملی بر این همبستگی مؤثر هستند؛ بنابراین، در این پژوهش دو هدف ویژه مد نظر است؛ هدف اول، تعیین عوامل مؤثر بر همبستگی این دو آزمون و هدف دوم، بررسی اثر این همبستگی بر نتایج همترازسازی است.

سؤال‌های مرور

یکی از مراحل انجام یک مرور سیستماتیک، طراحی سؤال برای آن است. بررسی منابع مرتبط با مرور سیستماتیک نشان داد که برای طرح این سؤال‌ها باید چند مؤلفه را در نظر گرفت تا چرایی انجام مرور توضیح داده شود و واضح‌تر بیان گردد. یکی از اصطلاحاتی که این مؤلفه‌ها را به خوبی معرفی می‌کند، PICO است (سانتوس و همکاران^۳، ۲۰۰۷؛ لاسرسون و همکاران^۴، ۲۰۱۹؛ تای و همکاران^۵، ۲۰۲۰) که شامل چهار مؤلفه مسئله^۶ (جامعه)^۷ (P)، مداخله^۸ (I)، مقایسه^۹ (C) و پیامد^{۱۰} (O) است. بر این اساس، بخش‌های اصلی سؤال این مرور را می‌توان با اصطلاح PICO به صورت زیر بیان کرد: مسئله (P) مورد بررسی، همبستگی است. آنچه در معرض مداخله (I) قرار دارد، ویژگی‌های آزمون لنگر است. در بخش مقایسه (C)، همبستگی آزمون لنگر از نظر نوع، طول آزمون و پایایی با آزمون اصلی مورد نظر است. اثر همبستگی آزمون لنگر و آزمون کل بر فرایند همترازسازی و همچنین تعیین عوامل مؤثر بر همبستگی این دو آزمون، پیامد (O) این مطالعه است؛ بنابراین، پرسش اصلی پژوهش این است که کدام ویژگی‌های آزمون لنگر بر این همبستگی مؤثر است و این همبستگی چه تأثیری بر فرایند همترازسازی دارد؟ درنهایت دو پرسش این مرور به شرح زیر مطرح شد:

1. Braun & Holland
2. Moses et al
3. Santos et al
4. Lasserson et al
5. Tai et al
6. problem
7. population
8. intervention
9. comparison
10. outcome

۱. کدام عوامل بر همبستگی بین آزمون لنگر و آزمون کل مؤثر هستند؟
۲. همبستگی آزمون لنگر و آزمون کل چه اثری بر نتایج همترازسازی دارد؟

ملاک‌های ورودی

ملاک‌های مورد نظر برای ورود مطالعات بر اساس طرح ارائه شده، به شرح زیر است: (۱) مطالعه‌ای دارای شایستگی است که یافته‌های تجربی در مورد اثر همبستگی آزمون لنگر با آزمون کل بر فرایند همترازسازی را بیان نماید؛ (۲) مطالعه‌ای که یافته‌های تجربی را در مورد عوامل مؤثر بر همبستگی آزمون لنگر با آزمون کل گزارش می‌کند، شایسته انتخاب است؛ (۳) از آنجایی که این مطالعه بر آزمون لنگر مت مرکز است، تنها مطالعه‌هایی انتخاب می‌شوند که تحت طرح همترازسازی NEAT انجام گرفته باشند؛ (۴) مطالعه‌های منتخب، می‌توانند آزمون لنگر درونی و یا لنگر بیرونی داشته باشند؛ (۵) پژوهش‌هایی که انتخاب می‌شوند، از نظر نوع داده ممکن است دارای داده‌های واقعی^۱ و یا شبیه‌سازی^۲ باشند؛ (۶) از نظر روش تحلیل داده‌ها، مطالعه‌هایی با روش نظریه کلاسیک^۳ (CTT)، نظریه سؤال-پاسخ^۴ (IRT)، مدل راش^۵ و همترازسازی کرنل^۶ (KE) را می‌توان برای این مرور انتخاب کرد؛ (۷) پژوهش‌های منتخب می‌توانند تحلیلی از نوع اولیه و یا ثانویه^۷ داشته باشند؛ (۸) مطالعه‌های انتخاب شده باید دارای یک آزمون چندگزینه‌ای با سؤال‌هایی از نوع دو ارزشی باشند. علاوه بر موارد ذکر شده برای ورود مطالعه‌ها به این مرور، محدودیتی در مورد جامعه تحت بررسی پژوهش‌ها در نظر گرفته نشد. مقاله‌ها، پایان‌نامه‌ها، رساله‌ها و مطالب منتشر شده در کنفرانس‌های معتبر که دارای ملاک‌های مورد نظر بوده و تمام متن آن در دسترس بود، انتخاب شدند و مورد تحلیل قرار گرفتند.

راهبردهای جستجو

همان‌طور که اشاره شد، هنگام طراحی یک پروتکل برای راهبردهای جستجو، ابتدا اصطلاحاتی بر اساس عنوان و هدف‌های پژوهش در نظر گرفته شد. پس از آن، هر یک از این اصطلاحات جستجو^۸ با مترادف‌های خود با استفاده از عملگرهای بولی^۹ (AND/OR) برای تعریف مسیر جستجو ترکیب شدند. اصطلاحات جستجوی اولیه شامل "Effect"، "NEAT"، "Correlation" و "Equating" و "Anchor" و "Test" بود. علاوه بر جستجو در تمام زمینه‌ها^{۱۰}، فیلترهای جستجو شامل عنوان، چکیده و واژگان

1. real data
 2. simulation
 3. classical test theory (CTT)
 4. item response theory (IRT)
 5. Rasch model
 6. kernel equating (KE)
 7. secondary analysis
 8. search terms
 9. boolean operator
 10. all fields

کلیدی بود. این اطلاعات برای جستجو به صورت جدولی برای هر پایگاه داده و وبسایت مورد نظر طراحی شد. پایگاه‌های اطلاعاتی قابل دسترس برای پژوهشگر و اجرای این مرور سیستماتیک شامل Wiley و PubMed، Medline، ERIC، JSTOR و ACADEMIA بود. این جستجوها در بازه زمانی ۱۹۵۰ تا ۲۹ می ۲۰۲۲ (۱۴۰۱/۳/۸) صورت پذیرفت. ازانجایی که تاکنون پژوهشی در این زمینه به زبان فارسی اجرا نشده است، تمام جستجوها صرفاً در زبان انگلیسی انجام گرفت. علاوه بر جستجو در سطح پایگاه داده، برخی از وبسایتها مانند SAGE، ETS و ACADEMIA برای بررسی بیشتر جستجو شدند. برای برخی از مجله‌ها و کتاب‌های تخصصی، جستجوهای دستی انجام گرفت. منابع مقاله‌های مهم نیز برای مطالعه بیشتر و دقیق در جستجوی منابع مرتبط بررسی شدند. این اقدامات به منظور جستجوی همه اطلاعات مرتبط با موضوع این مرور صورت پذیرفت تا یک بررسی جامع و چندجانبه انجام شود و نتایج کامل‌تری به دست آید. در جدول (۱) برخی از اطلاعات مربوط به این جستجوها ارائه شده است.

جدول (۱) خلاصه‌ای از راهبردهای جستجو

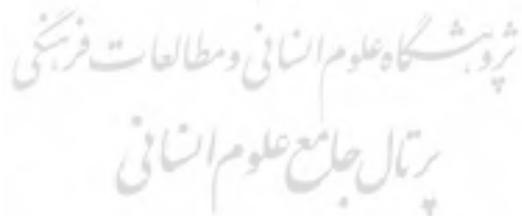
تعداد	اصطلاحات جستجو	جستجو	نوع
۱۰	Equating, Anchor, Correlation	PubMed	پایگاه داده
۵۰	Equating, Anchor, Correlation, NEAT, Effect, Test	Medline	
۲۱	Equating, Anchor, Correlation, NEAT, Effect, Test	ERIC	
۲۴	Equating, Anchor, Correlation, NEAT, Effect	JSTOR	
۱۱	Equating, Anchor, Correlation	Wiley	
۱۳	Equating, Anchor, Correlation, NEAT	SAGE	وبسایت
۶	Equating, Anchor, Correlation	ETS	
۱۹	Equating, Anchor, Correlation	ACADEMIA	
۱۳			موارد دیگر
زمان: از سال ۱۹۵۰ تا ۲۹ می ۲۰۲۲ (۱۴۰۱/۳/۸)			
فیلترها در سطح: همه حوزه‌ها، عنوان، چکیده و کلیدواژه‌ها			
زبان: انگلیسی			

در جدول (۱) دیده می‌شود که تعداد کل منابع یافت شده بر اساس مسیرهای جستجو ۱۶۷ مورد است. پس از اتمام جستجو، تمام این منابع، به نرمافزار EndNote (نسخه ۲۰.۵) برای حذف مطالعات تکراری^۱، منابع بی‌ارتباط و نامرتب منقل شد.

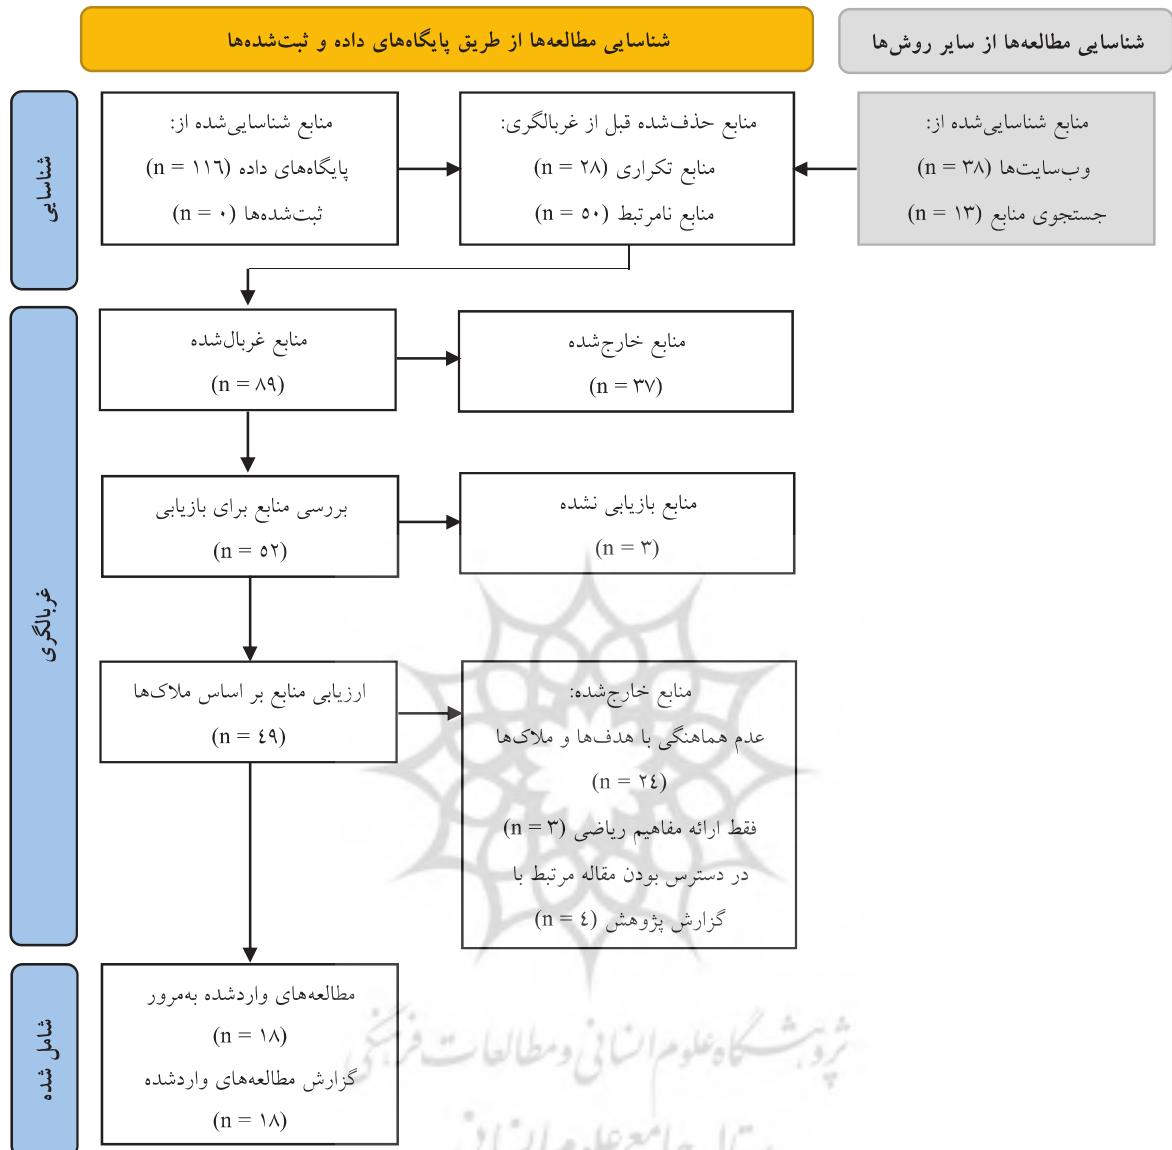
1. duplicate

انتخاب مطالعه

همه مطالعه‌ها (۱۶۷ مورد) به نرم افزار EndNote منتقل شدند تا منابع مناسب، انتخاب شوند. پس از شناسایی و حذف منابع تکراری (۲۸ مورد)، منابعی که عنوان آنها کاملاً نامرتبط به موضوع مرور بودند (۵۰ مورد) از منابع خارج شدند. در بین ۸۹ منبع باقیمانده، منابعی که عنوان آنها با موضوع پژوهش حاضر مطابق بود، حفظ شدند. از منابع نهایی (۵۲ مورد)، ۳ منبع دانلود نشد. ۴۹ منبع باقیمانده که فایل آنها به طور کامل در دسترس بود، با توجه به هدف‌های مرور بر اساس عنوان، چکیده و متن بررسی شدند و در نهایت ۲۴ منبع به دلیل نداشتن ملاک‌های اولیه حذف شدند. با توجه به ملاک‌های ورود، ۲۵ منبع باقیمانده به طور جداگانه مورد تحلیل قرار گرفت که منجر به حذف ۷ منبع شد. مقاله‌های ون‌داویر و همکاران (۲۰۰۴)، ون‌داویر (۲۰۰۸) و هابرمن و دورانز (۲۰۰۹) تنها به موضوع پژوهش خود از منظر نظری پرداختند و از آنجایی که امکان سنجش کیفیت این مقاله‌ها فراهم نبود، این سه مقاله حذف شدند؛ اما از نتایج آنها در پاسخ به سؤال‌های پژوهش استفاده شد. مطالعه‌های سینهارای و هالند (۲۰۰۶)، لیو و همکاران (۲۰۰۹)، پوهان^۱ (۲۰۱۰) و سینهارای و همکاران (۲۰۱۲)، گزارش‌های پژوهشی منتشرشده توسط شرکت خدمات سنجش آموزشی^۲ (ETS) هستند. جستجوی بیشتر نشان داد که مقاله‌هایی بر اساس این مطالعه‌ها ارائه شده است. از آنجایی که محتوای این گزارش‌ها مشابه مقاله‌های منتشرشده بود، این ۴ منبع حذف شدند. با توجه به منابع حذف شده، ۱۸ منبع برای ورود به این مرور و انجام بررسی‌های بیشتر باقی ماند. انتخاب مطالعه‌ها طی این مراحل با استفاده از نمودار پریزما^۳ (پیج و همکاران، ۲۰۲۱) در شکل (۱) گزارش شده است.



1. Puhan
2. Educational Testing Service (ETS)
3. Page et al



شکل (۱) نمودار پریزما (۲۰۲۰) برای انتخاب مطالعه‌ها

سنجش کیفیت مطالعه‌ها

برای ادامه روند مرور و قبل از ارائه نتایج، گام مهم، ارزیابی کیفیت روش‌شناختی منابع انتخاب شده است که نیازمند انتخاب ابزار مناسب برای سنجش کیفیت مطالعه‌های موردنظر است. بررسی کیفیت پژوهش‌های انجام گرفته به ایجاد اعتماد در نتایج این مطالعه‌ها کمک می‌کند. انواع مختلفی از ابزارهای سنجش کیفیت^۱ (QA) (مانند CONSORT، COSMIN، CASP و CEBM) و خطر سوگیری^۲

1. quality assessment (QA)
2. risk of bias assessment (ROB)

(مثلاً ROB و ROBINS-NRSI) (برای مطالعه بیشتر به پیج و همکاران (۲۰۱۸) مراجعه شود) توسعه یافته‌اند. برخی از پژوهشگران این دو اصطلاح را معادل هم می‌دانند و به جای یکدیگر به کار می‌برند. در حالی که کاناموری و همکاران^۱ (۲۰۲۱) در مقاله‌ای بیان کردند که این دو اصطلاح متفاوت‌اند و قابل معاوضه نیستند. علاوه بر معنای متفاوت این دو اصطلاح، ابزارهای متفاوتی برای آنها طراحی شده است. از آنجایی که ابزارهای سنجش خطر سوگیری اغلب برای کارآزمایی‌های بالینی، مطالعه‌های مداخله‌ای و مشاهده‌ای طراحی می‌شوند، برای این مرور که شامل مطالعه‌های کمی، همبستگی و توصیفی است، فاقد تناسب و کاربرد است؛ بنابراین، تنها سنجش کیفیت مطالعه‌های انتخاب‌شده، مدنظر قرار گرفت. یکی از ابزارهایی که می‌تواند برای سنجش کیفیت مطالعه‌های کمی مورد استفاده قرار گیرد، ابزار سنجش کیفیت مطالعه‌ها با طرح‌های مختلف^۲ (QATSDD) (فنتون و همکاران^۳، ۲۰۱۵) است. این ابزار دارای ۱۶ نشانگر^۴ بر اساس مقیاس لیکرت ۴ درجه‌ای (از ۰ تا ۳) است. قالب این ابزار دارای فرمی است که می‌توان از آن برای پژوهش‌های کمی، کیفی و ترکیبی استفاده کرد (سیریه و همکاران^۵، ۲۰۱۱). این نشانگرها شامل، چارچوب نظری روش، بیان هدف‌ها در متن اصلی گزارش، توصیف واضح زمینه پژوهش، شواهدی از اندازه نمونه در نظر گرفته‌شده، نماینده بودن نمونه گروه هدف، توصیف گردآوری داده‌ها، دلیل انتخاب ابزار گردآوری داده‌ها، اطلاعات دقیق به کار گرفته‌شده، ارزیابی آماری پایایی و روایی ابزار اندازه‌گیری، تناسب سؤال‌های پژوهش و روش گردآوری داده‌ها، تناسب سؤال‌های پژوهش و محتوای ابزار گردآوری داده‌ها، تناسب سؤال‌های پژوهش و روش تحلیل، توجیه روش‌های تحلیل انتخاب‌شده، ارزیابی پایایی فرایند تحلیل، شواهد مشارکت کاربران در طرح و بحث انتقادی درباره نقاط قوت و محدودیت‌ها است. از بین این نشانگرها، موارد ۹ و ۱۰ فقط برای پژوهش‌های کمی و موارد ۱۱ و ۱۴ تنها برای پژوهش‌های کیفی مورد استفاده قرار می‌گیرند. با توجه به نوع مطالعه‌های این مرور که از نوع کمی هستند، موارد ۱۱ و ۱۴ قابل اجرا نیستند^۶ و در جدول NA آمده است. ضمناً، مورد ۱۵ نیز برای این مطالعه‌ها قابل اجرا نبود و بررسی نشد. با توجه به آنچه بیان شد، برای هر مطالعه بر اساس ۱۳ نشانگر باقی‌مانده، بررسی‌هایی انجام گرفت. نتایج سنجش کیفیت برای هر یک از مطالعه‌ها در جدول (۲) ارائه شده است. همان‌طور که در جدول دیده می‌شود، همه مطالعه‌ها دارای نمره بالایی هستند (بالاتر از ۷۰ درصد) که نشان‌دهنده کیفیت مطلوب این مطالعه‌ها است.

1. Kanamori et al

2. quality assessment tool for studies with diverse design (QATSDD)

3. Fenton et al

4. indicator

5. Sirriyeh et al

6. not applicable (NA)

جدول (۲) سنجش کیفیت مطالعه‌های منتخب با QATSDD و نمره‌گذاری آنها

درصد	نمره	نشانگرها																	منبع
		۱۶	۱۵	۱۴	۱۳	۱۲	۱۱	۱۰	۹	۸	۷	۶	۵	۴	۳	۲	۱	سال	
۷۶/۹۲	۳۰	۲	NA	NA	۳	۳	NA	۳	۳	۳	۳	۰	۰	۲	۲	۳	۱۹۸۵	بیدسکو	
۸۹/۷۴	۳۵	۲	NA	NA	۳	۳	NA	۳	۰	۳	۳	۳	۳	۳	۳	۳	۱۹۸۸	بالا	
۸۹/۷۴	۳۵	۲	NA	NA	۳	۳	NA	۳	۱	۳	۲	۳	۳	۳	۳	۳	۱۹۹۶	یانگ و هوانگ	
۹۲/۳۰	۳۶	۲	NA	NA	۳	۳	NA	۳	۱	۳	۳	۳	۳	۳	۳	۳	a۲۰۰۶	سینهارای و هلند	
۸۷/۱۷	۳۴	۳	NA	NA	۳	۳	NA	۳	۰	۳	۳	۳	۳	۳	۲	۲	۲۰۰۷	سینهارای و هلند	
۹۲/۳۰	۳۶	۲	NA	NA	۳	۳	NA	۳	۳	۳	۳	۳	۳	۳	۲	۲	۲۰۰۷	ماسز و کیم	
۷۶/۹۲	۳۰	۰	NA	NA	۳	۳	NA	۳	۳	۳	۱	۳	۳	۱	۲	۲	۳	۲۰۰۷	ریکر وون داویر
۷۶/۹۲	۳۰	۰	NA	NA	۱	۳	NA	۳	۳	۳	۳	۳	۳	۳	۱	۱	۳	۲۰۰۹	سو و همکاران
۸۴/۶۱	۳۳	۲	NA	NA	۳	۳	NA	۳	۰	۲	۳	۳	۳	۲	۳	۳	۲۰۰۹	بی	
۹۷/۴۳	۳۸	۳	NA	NA	۳	۳	NA	۳	۳	۳	۲	۳	۳	۳	۳	۳	۲۰۱۰	پوهان	
۹۴/۸۷	۳۷	۳	NA	NA	۲	۲	NA	۳	۳	۳	۳	۳	۳	۳	۳	۳	۲۰۱۱	سان ناسی	
۸۹/۷۴	۳۵	۲	NA	NA	۳	۳	NA	۳	۳	۳	۳	۳	۳	۱	۳	۲	a۲۰۱۱	لیو و همکاران	
۹۲/۳۰	۳۶	۳	NA	NA	۳	۳	NA	۳	۳	۳	۳	۳	۳	۱	۲	۳	b۲۰۱۱	لیو و همکاران	
۹۴/۸۷	۳۷	۲	NA	NA	۳	۳	NA	۳	۳	۳	۳	۳	۳	۳	۲	۳	۲۰۱۳	ژانگ و کولن	
۹۲/۳۰	۳۶	۲	NA	NA	۳	۳	NA	۳	۳	۳	۳	۳	۳	۱	۳	۳	۲۰۱۶	تری ویلر و همکاران	
۷۶/۹۲	۳۰	۱	NA	NA	۳	۳	NA	۳	۰	۲	۳	۳	۳	۱	۳	۳	۲۰۱۶	لین و همکاران	
۸۰/۵۵	۲۹	۲	NA	NA	۳	۳	NA	۳	NA	۲	۳	۳	۰	۱	۳	۳	۲۰۱۷	سینهارای	
۹۴/۸۷	۳۷	۳	NA	NA	۳	۳	NA	۳	۳	۳	۳	۳	۳	۲	۲	۳	۲۰۱۸	مارنگو و همکاران	

(قابل اجرا نیست (not applicable, NA))

نتایج

در میان تمام مطالعه‌هایی که در طول فرایند جستجوی این مرور یافت شد، ۱۸ منبع که ملاک‌های ورود به مرور را داشتند، دقیق‌تر بررسی شدند. جزئیات این اطلاعات در جدول (۳) ارائه شده است. در همه این مطالعه‌ها، تابع همترازسازی تحت طرح گروه‌های نامعادل با آزمون لنگر (NEAT) برای داده‌های دو ارزشی به کاررفته و تحلیل شده‌اند. نحوه قرار گرفتن سؤال‌های آزمون لنگر در هر دو

آزمون می‌تواند درونی^۱ یا بیرونی^۲ باشد (پترسن، ۲۰۰۷؛ دورانز و همکاران، ۲۰۱۱، ۲۰۱۰؛ رایان و برآکمن، ۲۰۱۸). آزمون لنگر به کاررفته در مطالعه‌های این مرور، از نظر جایگاه و موقعیت، شامل آزمون لنگر درونی (۵ مورد، ۲۷٪/۷۷)، بیرونی (۹ مورد، ۵٪) و یا هر دونوع (۴ مورد، ۲٪/۲۲) است. از نظر ویژگی‌های آماری (میانگین و واریانس دشواری سؤال‌ها)، سه نوع لنگر midi، mini و semi-^۳ midi معرفی شده است (سینه‌های و هلند، ۲۰۰۶). لازم به ذکر است که در این مقاله به منظور حفظ مفهوم اولیه این سه نوع لنگر و سهولت استفاده از آنها در هنگام گزارش نتایج، نام آنها بدون ترجمه و بر اساس همان اصطلاحات اصلی در متن پژوهش ذکر شده است. در این مطالعه‌ها، آزمون لنگر بر اساس ویژگی‌های آماری از نوع mini (۱۱ مورد، ۱۱٪/۶۱)، mini و midi (۳ مورد، ۶۶٪/۱۶) و یا هر سه نوع (۴ مورد، ۲۲٪/۲۲) بود. کولن (۲۰۲۰) اظهار داشت که استفاده از داده‌های واقعی دارای مزایایی است که از جمله آن می‌توان به کنترل خطای تصادفی و واقع‌گرایی مطالعه و نتایج آن اشاره کرد. از میان این مطالعه‌ها، ۵ مورد (۷۷٪/۲۷) از داده‌های واقعی، ۱۰ مورد (۵۵٪/۵۵) از داده‌های شبیه‌سازی شده و ۳ مورد (۶۶٪/۱۶) از هر دونوع داده استفاده کرده بودند. از نظر نوع توزیع داده‌ها، ۱۳ مورد (۲۲٪/۷۲) آنها دارای توزیع نرمال، ۱ مورد (۵٪/۵۵) توزیع با کجی منفی، ۱ مورد (۵٪/۵۵) دارای توزیع شرطی، ۱ مورد (۵٪/۵۵) با توزیع حاشیه‌ای و دو مطالعه (۱۱٪/۱۱) بدون ذکر نوع توزیع بودند. یانگ و هوانگ^۴ (۱۹۹۶) در پژوهش خود تأثیر طول آزمون لنگر بر دقت نتایج روش‌های مختلف همترازسازی را با استفاده از طرح NEAT بررسی کردند. برای انجام این مطالعه از داده‌های واقعی استفاده شد که دارای توزیعی با کجی منفی بود. با توجه به نوع توزیع، در تحلیل‌ها، پارامتر حدس را به کار بردند. نتایج نشان داد که همترازسازی آزمون با در نظر گرفتن پارامتر حدس در توزیعی با کجی منفی از کفايت و تناسب لازم برخوردار است. از دیدگاه لرد^۵ (۱۹۷۷)، «اگر و فقط اگر تفاوتی نکند که آزمودنی به فرم X یا Y پاسخ دهد، تبدیل نمره X به Y همترازسازی به حساب می‌آید» (ص ۱۲۸).

حال اگر دو فرم آزمون از نظر توانایی، پایایی و دشواری متفاوت باشند، این تعریف نقض می‌شود و نمی‌توان دو فرم آزمون را همتراز کرد. رویکردهای همترازسازی آزمون مبتنی بر CTT، IRT و راش برای ایجاد نمره‌های قابل مقایسه در آزمون‌هایی که با حداقل تفاوت در دشواری طراحی شده‌اند، استفاده می‌شود. همترازسازی کرنل یک رویکرد یکپارچه برای همتراز کردن دو فرم آزمون است و شامل مجموعه‌ای از توابع همترازسازی مشابه همترازسازی همصدک است (ون‌داویر و همکاران، ۲۰۰۴). در این روش از هموارسازی کرنل برای ایجاد پیوستگی توزیع نمره‌های گستته استفاده

1. internal

2. external

3. Yang & Houang

4. Lord

می‌شود (والین و همکاران^۱، ۲۰۲۱). روش‌های تحلیل در نظر گرفته شده در این مطالعه‌ها شامل CTT (۷ مورد، ۸۸/۸۸٪)، IRT (۳ مورد، ۶۶/۱۶٪)، راش (۱ مورد، ۵۵/۵٪) و بیشتر از یک روش (۶ مورد، ۳۳/۳٪) بود. همان‌طور که در ملاک‌های ورود به مطالعه ذکر شد، محدودیتی برای جامعه و نمونه‌ها در نظر گرفته نشد تا بتوان طیف وسیع‌تری از مطالعه‌ها و نتایج آنها را بررسی کرد. دامنه نمونه‌های این مطالعه‌ها از ۲۵ تا ۲۰۰۰۰ نفر متغیر بود. برخی از این مطالعه‌ها از داده‌های آزمون‌هایی مانند^۲ SAT و^۳ MBE استفاده کردند. تعدادی از مطالعه‌ها، داده‌های پژوهش‌های پیشین را به کار برداشتند، مانند پژوهش تریویلر و همکاران^۴ (۲۰۱۶) (داده‌های مطالعه سینهارای و هالند (۲۰۰۶) a) و سینهارای (۲۰۱۷) (بررسی داده‌های پژوهش تریویلر و همکاران (۲۰۱۶) که نام آن را TLS16 گذاشتند). ممکن است این سؤال پیش بیاید که چرا ملاک‌های ورود به این پژوهش، متنوع بوده و تنها بر یک نوع خاص متمرکز نشده است؟ دلیل این مورد این است که مشخص شود آیا پاسخ به سؤال‌های پژوهش در شرایط مختلف، یکسان است یا اینکه نتایج مرور به دلیل تفاوت در ملاک‌های ورود به مطالعه، متفاوت خواهد بود؟

جدول (۳) مشخصات مطالعه‌های واردشده به مرور سیستماتیک

نمونه	روش تحلیل	توزيع	سؤال‌ها	داده‌ها	لنگر	لنگر	طرح	تابع	سال	منبع
SAT	CTT	نرمال	دو ارزشی	واقعی	mini	درونی	NEAT	همترازسازی	۱۹۸۵	بیدسکو
۱۰۰۰	CTT/ IRT	نرمال	دو ارزشی	شبیه‌سازی	mini	بیرونی	NEAT	همترازسازی	۱۹۸۸	بالا
۲۲۴۱	CTT IRT	کجی منفی	دو ارزشی	واقعی	mini	درونی بیرونی	NEAT	همترازسازی	۱۹۹۶	یانگ و هوانگ
۱۰۰۰ ۲۰۰۰ ۶۴۸۹	IRT Rasch	نرمال	دو ارزشی	شبیه‌سازی مثال واقعی	mini midi semi	درونی بیرونی	NEAT	همترازسازی	a۲۰۰۶	سینهارای و هالند
۱۰۰ ۵۰۰ ۵۰۰۰	IRT	نرمال	دو ارزشی	شبیه‌سازی مثال واقعی	mini midi semi	بیرونی	NEAT	همترازسازی	۲۰۰۷	سینهارای و هالند

1. Wallin et al

2. Scholastic Aptitude Test (SAT)

3. Multistate Bar Examination (MBE)

4. Trierweiler et al

نمونه	روش تحلیل	توزيع	سؤال‌ها	داده‌ها	لنگر	لنگر	طرح	تابع	سال	منع
۵۰۰ ۱۰۰۰ ۵۰۰۰	CTT CM GT	نرم‌ال	دو ارزشی	شبیه‌سازی	mini	بیرونی	NEAT	همترازسازی	۲۰۰۷	ماسز و کیم
۴۲۳۷ ۶۱۶۸ ۱۰۴۰۵	CTT KE	نرم‌ال	دو ارزشی	شبیه‌سازی	mini	بیرونی	NEAT	همترازسازی	۲۰۰۷	ریکرو ون داویر
MBE ۲۰۰۰۰ ۲۰۰۰۰	CTT	نرم‌ال	دو ارزشی	شبیه‌سازی	mini	دروندی	NEAT	همترازسازی	۲۰۰۹	سو و همکاران
۵۰۰۰	IRT	نرم‌ال	دو ارزشی	شبیه‌سازی مثال واقعی	mini midi	دروندی	NEAT	همترازسازی	۲۰۰۹	بی
۱۰۰۰	CTT	-	دو ارزشی	شبیه‌سازی	mini	دروندی	NEAT	همترازسازی	۲۰۱۰	پوهان
۲۵، ۵۰ ۱۰۰، ۲۰۰ ۴۰۰	CTT	نرم‌ال	دو ارزشی	شبیه‌سازی	mini	دروندی	NEAT	همترازسازی	۲۰۱۱	سان‌ناسی
SAT	CTT IRT	شرطی	دو ارزشی	واقعی	mini midi	بیرونی	NEAT	همترازسازی	a۲۰۱۱	لیو و همکاران
SAT	CTT	حاشیه‌ای	دو ارزشی	واقعی	mini midi	بیرونی	NEAT	همترازسازی	b۲۰۱۱	لیو و همکاران
۲۰۰۰	CTT	نرم‌ال	دو ارزشی	شبیه‌سازی	mini	دروندی بیرونی	NEAT	همترازسازی	۲۰۱۳	ژانگ و کولن
۱۰۰۰	IRT	نرم‌ال	دو ارزشی	شبیه‌سازی	mini midi semi	بیرونی	NEAT	همترازسازی	۲۰۱۶	تری‌ویلر و همکاران
-	CTT	نرم‌ال	دو ارزشی	شبیه‌سازی	mini	بیرونی	NEAT	همترازسازی	۲۰۱۶	لین و همکاران
TLS16	-	-	دو ارزشی	شبیه‌سازی	mini midi semi	دروندی بیرونی	NEAT	همترازسازی	۲۰۱۷	سینه‌های
۱۸۱۳	Rasch	نرم‌ال	دو ارزشی	واقعی	mini	بیرونی	NEAT	همترازسازی	۲۰۱۸	مارنگو و همکاران

(minitest)؛ (non-equivalent groups with anchor test, NEAT)؛ (classical test theory, midi)؛ (semi-miditest) نظریه کلاسیک آزمون (semi)؛ (miditest) نظریه سؤال-پاسخ (IRT)؛ (item-response theory, Rasch)؛ (CTT) مدل راش؛ (generalizability theory, GT)؛ (congeneric model, CM) نظریه تعمیم‌پذیری؛ (Scholastic Aptitude Test, SAT) آزمون استعداد تحصیلی؛ (kernel equating, KE) آزمون وکالت چند ایالتی (Multistate Bar Examination, MBE).

طول آزمون لنگر

یکی از عوامل کلیدی در دستیابی به نتایج دقیق همترازسازی، طول آزمون لنگر است (مارنگو و همکاران^۱، ۲۰۱۸) که به هدف سنجش، ناهمگنی محتوای اندازه‌گیری شده و ویژگی‌های آزمون وابسته است (کولن و برنان، ۲۰۱۴). بسیاری از متخصصان با موضوع طول آزمون لنگر به منظور انتخاب حداقل طول آزمون برای دستیابی به هدف‌های آماری و حداقل طول آزمون برای ملاحظاتی مانند امنیت آزمون مواجه شده‌اند (ریکر و ندانوییر^۲، ۲۰۰۷). از دیدگاه یانگ و هوانگ (۱۹۹۶) یکی از عوامل تعیین‌کننده اهمیت همبستگی آزمون لنگر و آزمون کل، طول آزمون لنگر است؛ به‌طوری‌که با افزایش طول آزمون، همبستگی این دو آزمون افزایش می‌یابد و موجب بهبود همترازسازی می‌شود. همچنین، بیدسکو (۱۹۸۵) اظهار نمود که طول نسبی آزمون لنگر، عاملی است که بر همبستگی آزمون لنگر و آزمون کل اثر می‌گذارد. سان‌ناسی^۳ (۲۰۱۱، ص ۹۰) در پژوهش خود بیان نمود که استفاده از آزمونی با سؤال‌های بیشتر، دقت برآوردهای همترازسازی را بهبود می‌بخشد زیرا پایایی و همبستگی بین دو آزمون افزایش می‌یابد. کاهش تعداد سؤال‌ها در یک آزمون لنگر، همبستگی این دو آزمون را کاهش می‌دهد و درنتیجه خطای همترازسازی افزایش می‌یابد (ریکر و ندانوییر، ۲۰۰۷؛ یی^۴، ۲۰۰۹؛ پوهان، ۲۰۱۰؛ ژانگ^۵ و کولن، ۲۰۱۳، لین و همکاران^۶، ۲۰۱۶).

نوع آزمون لنگر (ویژگی‌های آماری)

کولن و برنان (۲۰۰۴) معتقد بودند که آزمون لنگر باید به‌گونه‌ای طراحی شود که بتواند به دقت تفاوت‌های دو گروه را منعکس کند. انتظار می‌رود این آزمون که اغلب از آن به عنوان minitest یاد می‌شود، از نظر ویژگی‌های آماری و محتوایی مشابه آزمون کل باشد (سینهارای، ۲۰۱۷). سینهارای و هالند (۲۰۰۶) بیان کردند که وقتی میانگین و پراکندگی دشواری سؤال‌های آزمون لنگر تقریباً

1. Marengo et al
2. Ricker & Von Davier
3. Sunnassee
4. Yi
5. Zhang
6. Lin et al

برابر با آزمون کل باشد، می‌توان گفت این آزمون نماینده آماری آزمون کل است. از طرفی، در طراحی آزمون لنگر mini لازم است، سؤال‌های بسیار آسان و بسیار دشوار به کار رود تا از کفایت پراکندگی دشواری سؤال‌های این آزمون اطمینان حاصل شود. این انتخاب می‌تواند چالش‌هایی برای طراحان آزمون به دلیل فراوانی پایین‌تر آنها ایجاد کند؛ بنابراین، برای پرداختن به این موضوع و به دلیل اهمیت انتخاب آزمون لنگر در طرح همترازسازی NEAT، سینهارای و هالند (a2006) یک آزمون لنگر را پیشنهاد کردند که نماینده محتوای آزمون کل است و میانگین دشواری سؤال‌های آن با آزمون کل مشابه است؛ اما به دلیل استفاده از سؤال‌هایی با دشواری متوسط، پراکندگی دشواری سؤال‌های آن کمتر از آزمون کل است. سینهارای و هالند (a2006, b2007) این نوع آزمون لنگر را miditest نامیدند. حال اگر مقدار پراکندگی دشواری سؤال‌های لنگر بین miditest و minitest باشد (کمتر از miditest و بیشتر از minitest)، از آن به عنوان semi-miditest نام برندند. نتایج پژوهش‌های سینهارای و هالند (a2006, a2007, b2009)، لیو و همکاران (a2011, b2011) و سینهارای (2017) نشان می‌دهد که همبستگی آزمون لنگر midi با آزمون کل از همبستگی آزمون لنگر mini با آزمون کل بیشتر است و مقدار همبستگی آزمون لنگر semi-midi بین این دونوع آزمون قرار دارد؛ به عبارت دیگر، عملکرد آزمون لنگر midi نسبت به دیگر آزمون‌های لنگر بهتر است. این لنگر، دارای بالاترین مقدار همبستگی با آزمون کل است و نتایج همترازسازی آن دقیق‌تر گزارش شده است. پژوهش تری‌ویلر و همکاران (2016) نشان داد که آزمون لنگر midi همیشه بالاترین مقدار همبستگی را بین این سه نوع آزمون لنگر ندارد. با توجه به وجود این مطالعه که یافته‌های آن برخلاف پژوهش‌های ذکرشده است، سینهارای (2017) تصمیم گرفت این تفاوت را در پژوهشی بررسی کند. او به دنبال پاسخ به این سؤال بود که آیا آزمون لنگر midi باید استفاده شود و در عمل ادامه باید؟ یافته‌های این مطالعه نشان داد که برخلاف دیدگاه تری‌ویلر و همکارانش، لنگر midi همبستگی بین آزمون لنگر و آزمون کل را افزایش می‌دهد و عملکرد آن بهتر از آزمون mini است و باید از آن در همترازسازی آزمون‌ها استفاده کرد.

پایابی و آزمون لنگر

از آنجایی که همترازسازی شکل قوی‌تر پیوند است (لیو و واکر¹، ۲۰۰۷)، شرایطی برای همترازسازی باید در نظر گرفته شود تا بتوان پیوند بین دو آزمون را همترازسازی نماید. یکی از این شرایط، برابری پایابی است (لرد، ۱۹۸۰؛ انگاف، ۱۹۸۴؛ شی و نورسینی، ۱۹۹۵؛ دورانز و همکاران، ۲۰۱۰). این شرط برای همترازسازی دو فرم آزمون، ضروری و مهم تلقی می‌شود. یانگ و هوانگ (1996) بیان نمودند که همبستگی قوی بین آزمون لنگر و آزمون کل، نشانه‌ای از پایا و روابودن آزمون لنگر است.

1. Liu & Walker

ماسز و کیم (۲۰۰۷) در پژوهشی تأثیر نابرابری پایایی بر روش‌های همترازسازی با طرح NEAT را بررسی کردند. نتایج نشان داد که تفاوت در پایایی بین دو فرم آزمون، به بیش برآورده تابع همترازسازی منجر می‌شود. اگر توانایی افراد در گروه‌ها متفاوت و آزمون‌ها ناپایا باشند، نتایج همترازسازی در هر روشی با خطا همراه خواهد بود. همچنین، نتایج بیانگر آن بود که در روش تاکر، همبستگی آزمون لنگر و آزمون کل، از نظر پایایی آزمون لنگر قابل بررسی است. از دیدگاه بیدسکو (۱۹۸۵)، ژانگ و کولن (۲۰۱۳) و تری‌ویلر و همکاران (۲۰۱۶) یکی از عواملی که بر همبستگی این دو آزمون تأثیر می‌گذارد، پایایی آزمون کل است و بین این همبستگی و پایایی یک اثر متقابل وجود دارد. سینهارای و هالند (۲۰۰۶) در مطالعه خود نشان دادند که پایایی آزمون لنگر midi بالاتر از لنگر mini است که عاملی برای بالاتر بودن همبستگی آزمون لنگر midi نسبت به لنگر mini است. از طرفی، نتایج پژوهش ریکر وون‌داویر (۲۰۰۷) نشان می‌دهد که کاهش تعداد سؤال‌های لنگر باعث کاهش پایایی آن و درنتیجه کاهش همبستگی آزمون لنگر با آزمون کل می‌شود؛ بنابراین، از دیدگاه آنها، یکی از عوامل کنترل خطای همترازسازی دو فرم آزمون، پایایی آزمون لنگر است.

محتوای آزمون لنگر

آزمون لنگر باید تا حد امکان ویژگی‌های محتوایی مشابه آزمون کل داشته باشد و سؤال‌های آن معرف محتوای آزمون باشد، چراکه به گفته کلاین و جارجورا^۱ (۱۹۸۵) عدم تناسب محتوایی در آزمون لنگر، همترازسازی را تحت تأثیر قرار می‌دهد و موجب ایجاد خطای همترازسازی می‌شود. از دیدگاه یانگ و هوانگ (۱۹۹۶) و تری‌ویلر و همکاران (۲۰۱۶) یک عامل مهم در همبستگی آزمون لنگر و آزمون کل این است که آزمون لنگر نماینده‌ای از محتوای آزمون کل باشد. اگر دو فرم آزمون، سازه مشابهی را اندازه‌بگیرند و محتوای مشابهی داشته باشند، همبستگی بین آزمون لنگر و آزمون کل افزایش می‌یابد (لین و همکاران، ۲۰۱۶؛ مارنگو و همکاران، ۲۰۱۸؛ بنابراین، یکی از راه‌های دستیابی به همبستگی بالاتر بین این دو آزمون، دقت در انتخاب محتوای آزمون لنگر و تشابه محتوای آن با آزمون کل است (بیدسکو، ۱۹۸۵؛ سینهارای، ۲۰۱۷). بالا^۲ (۱۹۸۸)، سینهارای و هالند (۲۰۰۶) و لین و همکاران (۲۰۱۶) معتقدند که اگر آزمون لنگر نماینده محتوای آزمون کل نباشد، توانایی متفاوتی اندازه‌گیری می‌شود. درنتیجه همبستگی بین دو آزمون کاهش می‌یابد و به سوگیری در نتایج همترازسازی منجر می‌شود.

توانایی گروه‌های آزمودنی

هنگام استفاده از طرح NEAT برای فرایند همترازسازی، اگر دو گروه از آزمودنی‌ها از نظر توانایی

1. Klein & Jarjoura
2. Balla

بسیار متفاوت باشند، نتایج همترازسازی با سوگیری همراه خواهد شد (لیو و همکاران، ۲۰۰۹؛ ماسز و همکاران، ۲۰۱۰؛ وندر لیندن^۱ و ویبرگ، ۲۰۱۰؛ هگ^۲، ۲۰۱۰؛ لیو و همکاران، ۲۰۱۱؛ a^۳، b^۴، ۲۰۱۱؛ آریکان و جلبال^۵، ۲۰۱۸). سوو همکاران^۶ (۲۰۰۹) گزارش نمودند که اگر بر تفاوت توانایی دو گروه از آزمودنی‌ها افزوده شود، همبستگی بین آزمون لنگر با آزمون کل کاهش می‌یابد. تحت این شرایط نتایج روش همترازسازی poststratification نسبت به روش همترازسازی زنجیره‌ای دارای سوگیری بیشتری است (پوهان، ۲۰۱۰). از دیدگاه یی (۲۰۰۹)، اگر تفاوت توانایی آزمودنی‌ها در دو گروه زیاد باشد، همبستگی بین آزمون لنگر و آزمون کل برای سه نوع لنگر (mini، midi، semi-midi) تفاوت چندانی ندارد. سینه‌هارای (۲۰۱۷) در مطالعه خود دریافت که اگر تفاوت توانایی آزمودنی‌ها کم باشد، نتایج تمام روش‌های همترازسازی رضایت‌بخش است و شرایط لنگر خیلی مهم نیست؛ اما اگر تفاوت در توانایی افراد زیاد باشد، ویژگی‌های مختلف آزمون لنگر اهمیت ویژه‌ای پیدا می‌کند.

روش‌های همترازسازی

با توجه به مدل‌های روان‌سنجدی، رویکردهای همترازسازی مختلفی توسعه یافته است که به‌طورکلی می‌توان آنها را به دو طبقه رویکردهای همترازسازی مبتنی بر نظریه کلاسیک آزمون و نظریه سؤال-پاسخ تقسیم کرد. هنگام استفاده از طرح NEAT برای همترازسازی بر اساس CTT، رویکردهای همترازسازی شامل همترازسازی خطی (همترازسازی خطی زنجیره‌ای^۷، همترازسازی تاکر^۸، همترازسازی لوین^۹) و همترازسازی همصدک (همترازسازی همصدک زنجیره‌ای، همترازسازی بران-هالند و برآورد فراوانی^{۱۰}) است (برنان و همکاران^{۱۱}، ۲۰۰۹؛ کولن و برنان، ۲۰۱۴؛ گنزالس و ویبرگ، ۲۰۱۷). ون‌داویر (۲۰۰۸) در پژوهشی نشان داد که هرگاه میانگین و انحراف استاندارد هر دو نمونه در آزمون لنگر برابر باشد، نتایج همه روش‌های همترازسازی یکسان است. از طرفی، اگر همبستگی آزمون لنگر و آزمون کل خیلی پایین باشد، نمره‌های همتراز شده قابل معاوضه نیستند. به همین ترتیب، اگر همبستگی آزمون لنگر با آزمون کل بالا باشد، نتایج روش‌های همترازسازی تاکر با افزایش مشابه است. در پژوهش ماسز و کیم (۲۰۰۷) اشاره شده است که در روش همترازسازی تاکر با افزایش همبستگی آزمون لنگر با آزمون کل، میزان خطای استاندارد همترازسازی کاهش می‌یابد. از دیدگاه ریکر و ون‌داویر (۲۰۰۷) نتایج روش‌های همترازسازی کرنل و برآورد فراوانی به همبستگی بین آزمون

1. Van der Linden & Wiberg

2. Hagge

3. Arıkan & Gelbal

4. Suh et al

5. chained

6. Tucker

7. Levine

8. frequency estimation

9. Brennan et al

لنگر و آزمون کل بستگی دارد. بالا (۱۹۸۸) بیان نمود که کاهش همبستگی آزمون لنگر و آزمون کل به کاهش عملکرد همترازسازی منجر می‌شود. علاوه بر این، با کاهش مقدار این همبستگی، تفاوت بین نتایج روش‌های همترازسازی همصدک و خطی افزایش پیدا می‌کند. پوهان (۲۰۱۰) در پژوهشی روشن‌های همترازسازی تاکر، لوین و زنجیره‌ای را تحت شرایط مختلف مقایسه کرد. نتایج نشان داد که اگر همبستگی بین آزمون لنگر و آزمون کل بسیار کم باشد، هیچ‌یک از روش‌های همترازسازی نتیجه مناسبی ارائه نمی‌دهد. این سه روش زمانی قابل استفاده هستند که تفاوت در توانایی آزمودنی‌ها کم و مقدار همبستگی آزمون لنگر و آزمون کل نسبتاً بالا (۷/۰ به بالا) باشد. اگر گروه‌ها متفاوت و مقدار همبستگی آزمون لنگر و آزمون کل بالای ۹/۰ باشد، روش همترازسازی تاکر مناسب است. نتایج پژوهش سو و همکاران (۲۰۰۹) در ارزیابی عملکرد روش‌های مختلف همترازسازی نشان داد که افزایش تفاوت بین توانایی آزمودنی‌ها در دو فرم به کاهش همبستگی آزمون لنگر و آزمون کل منجر می‌شود. به گفته آنها تأثیر تفاوت توانایی آزمودنی‌ها بر نتایج همترازسازی بیشتر از تفاوت بین فرم‌های آزمون است. اگر تشابه بین گروه‌ها زیاد و بین آزمون‌ها کم باشد، روش همترازسازی تاکر مناسب‌ترین روش است و در صورت معکوس شدن شرایط، روش همترازسازی لوین مناسب‌تر است.

بحث

این مقاله، اولین مطالعه در حوزه سنجش بهویژه در موضوع همترازسازی است که از روش‌های مرور سیستماتیک برای پرداختن به سؤال‌های پژوهش جهت بررسی اثر همبستگی آزمون لنگر و آزمون کل بر نتایج همترازسازی تحت طرح گروه‌های نامعادل با آزمون لنگر استفاده شد. راهبردهای جستجوی جامعی برای یافتن مطالعه‌هایی که ملاک‌های در نظر گرفته شده را داشته باشند، به کار گرفته شد. به کمک این مرور، ۱۸ مطالعه منتشرشده از اجرای همترازسازی تحت طرح NEAT به تفصیل تحلیل شد تا تأثیر همبستگی بر یافته‌های همترازسازی تعیین شود.

پرسش اول: کدام عوامل بر همبستگی بین آزمون لنگر و آزمون کل مؤثر هستند؟

هوانگ و یانگ (۱۹۹۶) بیان کردند دو عاملی که اهمیت همبستگی آزمون لنگر با آزمون کل را تعیین می‌کند، نمایندگی محتوای آزمون لنگر و طول آن است. همبستگی بالا بین این دو آزمون نشانهٔ پایایی و روایی آزمون لنگر است و طول بیشتر آن به افزایش این همبستگی و درنتیجه بهبود همترازسازی منجر می‌شود. طبق نظر بیدسکو (۱۹۸۵)، پایایی آزمون کل و طول نسبی هر دو آزمون، دو عامل مؤثر بر همبستگی آزمون لنگر و آزمون کل است. علاوه بر این، دقیقت در انتخاب محتوای آزمون لنگر باعث می‌شود تا همبستگی بالاتری به دست آید. با توجه به اهمیت همبستگی این دو آزمون، هابرمن و دورانز (۲۰۰۹) گزارش نمودند که سه عامل بر رانش مقیاس تحت طرح NEAT تأثیر

می‌گذارد. این سه عامل، تفاوت زیاد در توانایی گروه‌ها، محتوای متفاوت آزمون لنگر و آزمون کل و فقدان همبستگی بالا بین این دو آزمون است. ژانگ و کولن (۲۰۱۳) معتقدند که دقیقت همترازسازی مستقیماً با همبستگی بین آزمون لنگر و آزمون کل مرتبط است و این همبستگی از پایایی آزمون کل، طول آزمون لنگر و طول آزمون کل تأثیر می‌پذیرد و این عوامل، خطای همترازسازی را تحت تأثیر قرار می‌دهند. تری‌ویلر و همکاران (۲۰۱۶) بیان کردند که همبستگی آزمون لنگر با آزمون کل، نه تنها به پراکندگی دشواری سؤال‌های آزمون، بلکه به عوامل مستقلی مانند پایایی آزمون لنگر و همبستگی بین نمره واقعی آزمون لنگر و آزمون کل نیز وابسته است. مستقل بودن این دو عامل به این معناست که اگر چند سؤال با ویژگی‌های مشابه به آزمون اضافه شود، پایایی آزمون بهبود می‌باید، ولی همبستگی تغییری نمی‌کند. علاوه بر این عوامل، نوع لنگر نیز بر این رابطه اثر می‌گذارد. به طوری که آزمون لنگر midi نسبت به آزمون لنگر mini همبستگی بالاتری با آزمون کل دارد (سینهارای و هالند، ۲۰۰۶؛ a^{۲۰۰۷}؛ b^{۲۰۱۱}؛ a^{۲۰۱۱}؛ b^{۲۰۰۹}؛ یی، ۲۰۰۷؛ لیو و همکاران، ۱۹۸۵؛ سینهارای، ۱۹۹۶؛ سینهارای و هالند، ۲۰۰۶؛ تری‌ویلر و همکاران، ۲۰۱۶؛ سینهارای، ۲۰۱۷؛ مارنگو و همکاران، ۲۰۱۸). تفاوت محتوایی بین آزمون لنگر و آزمون کل به کاهش همبستگی و بروز سوگیری در نتایج همترازسازی منجر می‌شود (بالا، ۱۹۸۸؛ لین و همکاران، ۲۰۱۶). از سوی دیگر، زمانی که سازه‌های دوفرم آزمون از نظر محتوا مشابه، همبستگی بین دو فرم بالا و تابع پیوند آنها تغییرناپذیر باشد، شرایطی ایجاد می‌شود که می‌توان نمره‌های همتراز شده را معاوضه کرد (دورانز، ۲۰۰۴؛ به نقل از لین و همکاران، ۲۰۱۶، ص. ۲). هرگاه تفاوت در توانایی دو گروه زیاد باشد، همبستگی آزمون لنگر و آزمون کل کاهش می‌یابد (سو و همکاران، ۲۰۰۹؛ یی، ۲۰۰۹؛ پوهان، ۲۰۱۰؛ سینهارای، ۲۰۱۷). با توجه به آنچه ذکر شد، می‌توان گفت پنج عامل بر همبستگی بین آزمون لنگر و آزمون کل مؤثر است. این عوامل که در شکل (۲) نشان داده شده است عبارت‌انداز: طول آزمون (لنگر، کل)، پایایی آزمون (لنگر، کل)، نوع لنگر از نظر ویژگی‌های آماری، ساختار محتوایی آزمون لنگر (نمایندگی محتوایی) و تفاوت در توانایی هر دو گروه.



شکل (۲) عوامل مؤثر بر همبستگی آزمون لنگر و آزمون کل

پرسش دوم: همبستگی آزمون لنگر و آزمون کل چه اثری بر نتایج همترازسازی دارد؟
 یکی از مهمترین عوامل مؤثر بر کارایی همترازسازی دوفرم آزمون، همبستگی آزمون لنگر با آزمون کل است (بیدسکو، ۱۹۸۵؛ ون داویر، ۲۰۰۸؛ سینهارای و هالند، a۲۰۰۶). از نظر لرد (۱۹۷۵) این همبستگی در حذف سوگیری مؤثر است (به نقل از بالا، ۱۹۸۸، ص. ۴۱۰). یانگ و هوانگ (۱۹۹۶) بیان نمودند اگر مقدار همبستگی این دو آزمون $0.999/0$ باشد، فرایند همترازسازی دارای نتایج یکسانی است. البته به گفته سینهارای و هالند (a۲۰۰۶) این مقدار همبستگی در عمل اتفاق نمی‌افتد. از دیدگاه سان ناسی (۲۰۱۱)، وجود همبستگی $0.8/0$ یا بیشتر، بین آزمون لنگر و آزمون کل، عامل مهمی در موفقیت فرایند همترازسازی است. کاهش این همبستگی باعث کاهش عملکرد روش‌های همترازسازی و عدم معاوضه نمره‌ها می‌شود (بالا، ۱۹۸۸؛ ون داویر، ۲۰۰۸؛ لین و همکاران، ۲۰۱۶). نتایج روش‌های همترازسازی خطی، همصدک، زنجیره‌ای، تاکر، لوین و کرنل تحت طرح گروه‌های نامعادل با آزمون لنگر، تحت تأثیر مقدار این همبستگی قرار دارد (بالا، ۱۹۸۸؛ ریکر و ون داویر، ۲۰۰۷؛ ماسزو کیم، ۲۰۰۷؛ ون داویر، ۲۰۰۸؛ پوهان، ۲۰۱۰). اگر همبستگی آزمون لنگر و آزمون کل بالا باشد، نتایج همترازسازی روش‌های لوین، تاکر و زنجیره‌ای مشابه است (ون داویر، ۲۰۰۸؛ پوهان، ۲۰۱۰). پوهان (۲۰۱۰) همچنین خاطرنشان کرد که اگر تفاوت بین گروه‌ها کم باشد، برای به دست آوردن یک فرایند همترازسازی دقیق در این سه روش، به همبستگی بالاتر از $0.7/0$ نیاز است. اگر توانایی گروه‌ها متفاوت باشد، روش زنجیره‌ای مقدار خطای همترازسازی کمتری ایجاد

می‌کند؛ اما اگر توانایی گروه‌ها با یکدیگر بسیار متفاوت و همبستگی آزمون لنگر و آزمون کل ۰/۹ یا بیشتر باشد، در بین این سه روش، روش تاکر مناسب‌ترین روش همترازسازی است. علاوه بر نوع روش همترازسازی، نوع آزمون لنگر از نظر ویژگی‌های آماری بر صحت نتایج همترازسازی مؤثر است. یافته‌هایی برخی از مطالعه‌هانشان می‌دهد که همبستگی آزمون لنگر midi با آزمون کل بیشتر از آزمون لنگر mini است و این عامل باعث می‌شود که نتایج همترازسازی با آزمون لنگر midi معمولاً دقیق‌تر از آزمون لنگر mini باشد (سینهارای و هالند، ۲۰۰۶؛ a؛ لیو و همکاران، ۲۰۰۹؛ b؛ لیو و همکاران، ۱۹۸۸؛ a؛ سینهارای و همکاران، ۲۰۱۱؛ b؛ سینهارای و همکاران، ۲۰۱۲؛ c؛ سینهارای، ۲۰۱۷). بالا (۲۰۰۷) معتقد بود که کاهش همبستگی آزمون لنگر و آزمون کل باعث می‌شود تا عملکرد روش‌های همترازسازی نیز کاهش یابد. در این شرایط، افرادی که به آزمون دشوارتر پاسخ داده‌اند، متضرر می‌شوند. از دیدگاه ریکر و ون‌داویر (۲۰۰۷) همبستگی این دو آزمون و پایایی آزمون لنگر، دو عاملی هستند که خطای همترازسازی را مدیریت می‌کند. افزایش همبستگی آزمون لنگر و آزمون کل باعث کاهش خطای همترازسازی و افزایش دقت در نتایج می‌شود، زیرا بین همبستگی این دو آزمون و خطای استاندارد همترازسازی رابطه معکوس وجود دارد (سینهارای و هالند، ۲۰۰۶؛ a؛ ماسز و کیم، ۲۰۰۷؛ چانگ و کولن، ۲۰۱۳؛ تری‌ویلر و همکاران، ۲۰۱۶؛ مارنگو و همکاران، ۲۰۱۸). بر اساس این مطالب، دقت نتایج همترازسازی تحت طرح NEAT مستقیماً به همبستگی آزمون لنگر و آزمون کل مرتبط است. به‌طوری که افزایش این همبستگی، به کاهش خطای استاندارد همترازسازی و درنتیجه افزایش دقت در نمره‌های همتراز شده منجر می‌شود؛ بنابراین، یکی از مؤلفه‌های کلیدی و مهم برای اجرای یک همترازسازی موفق تحت این طرح، وجود همبستگی بالا بین آزمون لنگر و آزمون کل است. از طرفی، با توجه به مطالعه‌های بررسی‌شده در این مرور، مقدار این همبستگی بر روش‌های مختلف همترازسازی و نتایج آنها مؤثر است.

با توجه به ملاک‌های مورد استفاده برای ورود مطالعه‌ها، دو محدودیت برای این مرور ایجاد شد. یک محدودیت این است که فقط مطالعه‌هایی که از دو فرم آزمون برای فرایند همترازسازی استفاده کرده بودند، در نظر گرفته شد؛ به عبارت دیگر، مطالعه‌هایی که شامل آزمون‌های چندگانه، آزمونچه و آزمون‌های چندوجهی بودند، بررسی نشدند. از سوی دیگر، سوال‌های مورد تحلیل در مطالعه‌ها از نوع دو ارزشی بود و داده‌های چندارزشی در این مرور لحاظ نشد؛ بنابراین، یافته‌های این مطالعه به پژوهش‌هایی محدود شد که شرایط مختلف فرایند اجرای همترازسازی برای دو فرم آزمون را تحت طرح NEAT و داده‌های دو ارزشی بررسی کردند. در پژوهش‌های آتی، آزمون‌های چندگانه و آزمون‌هایی با داده‌های چند ارزشی را می‌توان برای بررسی اثر همبستگی بین آزمون لنگر و آزمون کل در نظر گرفت.

طبق نظر ریکر و ون داویر (۲۰۰۷) یکی از چالش‌های طراحان آزمون، آزمون لنگر طولانی برای دست یافتن به ویژگی‌های آماری و آزمون لنگر کوتاه برای حفظ ملاحظاتی مانند امنیت و زمان آزمون است. با توجه به یافته‌های این مرور، یکی از عوامل مؤثر بر همبستگی آزمون لنگر و آزمون کل، طول آزمون لنگر است. برخی از مطالعه‌ها این دو مؤلفه را باهم بررسی کردند که نتایج نشان داد با افزایش طول آزمون لنگر، مقدار همبستگی نیز افزایش می‌یابد. بر این اساس، در مطالعه‌های آینده لازم است طول بهینه آزمون لنگر برای حفظ تناسب محتوا و همبستگی آن با آزمون کل بررسی شود. همان‌طور که در این مرور نشان داده شد، این مطالعه‌ها بر اساس ملاک‌های ورود دارای ویژگی‌های متفاوتی بودند. همین امر باعث شد تا در پاسخ به سؤال‌ها، شرایط متفاوتی در نظر گرفته شود. این موضوع یکی از نقاط قوت این مرور محسوب می‌شود، چراکه به شناسایی عوامل مربوط به همبستگی آزمون لنگر و آزمون کل و تأثیر آن بر همترازسازی از جنبه‌های مختلف کمک کرد.

نتیجه‌گیری

در این مرور، اثر همبستگی آزمون لنگر و آزمون کل بر نتایج همترازسازی تحت طرح گروه‌های نامعادل با آزمون لنگر، بررسی و عواملی که بر این همبستگی تأثیر می‌گذارند، شناسایی شد. برای دستیابی به این هدف‌ها، ۱۸ مطالعه در زمینه همترازسازی با طرح NEAT مورود شد. مطالعه‌های واردشده به این مرور بر اساس جایگاه و موقعیت سؤال‌های لنگر، ویژگی‌های آماری آزمون لنگر، نوع داده‌ها (واقعی، شبیه‌سازی)، نوع توزیع داده‌ها (نرمال، دارای کجی منفی)، روش تحلیل داده‌ها (CTT، IRT، Rasch) و کرنل) و اندازه نمونه (از ۲۵ تا ۲۰۰۰۰ آزمودنی) دارای شرایط متفاوتی بودند. بررسی‌ها نشان‌دهنده آن بود که با وجود شرایط متفاوت بین مطالعه‌های این مرور، از نظر اهمیت همبستگی آزمون لنگر و آزمون کل بر بهبود فرایند همترازسازی و عوامل مؤثر بر این همبستگی، نتایج مشابهی برقرار است. از میان این مطالعه‌ها، پژوهش بالا (۱۹۸۸) و سینهارای و هالند (۱۹۹۶) به‌طور خاص همبستگی بین آزمون لنگر و آزمون کل و تأثیر آن بر فرایند همترازسازی را بررسی کرده‌اند. در سایر مطالعه‌ها، موضوع همبستگی آزمون لنگر و آزمون کل در کنار مؤلفه‌های دیگر (طول لنگر، نوع لنگر، پایابی آزمون‌ها، مقایسه روش‌ها) بررسی شده است. در این مطالعه‌ها مشاهده شد که همبستگی بالا بین آزمون لنگر و آزمون کل، یکی از شرط‌های اجرای همترازسازی کارآمد است. در مطالعه‌های بررسی شده، مقدار این همبستگی اغلب در دامنه ۰/۷ تا ۰/۹ در نظر گرفته و برآورد شده است؛ بنابراین، برای آنکه فرایند همترازسازی در برآورد پارامترها و نمره‌ها از دقت کافی برخوردار باشد، لازم است مقدار همبستگی آزمون لنگر و آزمون کل ۰/۷ یا بیشتر باشد. مقدار این همبستگی، شاخصی از صحت نتایج همترازسازی است که با افزایش مقدار آن، کیفیت و دقت برآورد پارامترها در گروه‌ها

افزایش و خطای استاندارد همترازسازی کاهش می‌یابد. علاوه بر این، نتایج بیانگر آن است که مقدار همبستگی بر روش‌های همترازسازی تأثیر دارد. هنگامی که آزمون لنگر و آزمون کل، همبستگی بسیار کمی داشته باشند، هیچ‌یک از روش‌های همترازسازی نتایج خوبی ایجاد نمی‌کند و نمره‌های همتراز شده قابل معاوضه نیستند. اجرای همترازسازی در این شرایط توصیه نمی‌شود، زیرا عملکرد روش‌های همترازسازی با کاهش همبستگی کاهش می‌یابد و نتایج به نفع آزمودنی‌های شرکت‌کننده در آزمون آسان‌تر خواهد بود. همچنین، با توجه به اهمیت همبستگی بین آزمون لنگر و آزمون کل بر فرایند همترازسازی وجود ارتباط مستقیم بین مقدار این همبستگی و دقت در همترازسازی، در این مروز، عوامل مؤثر بر این همبستگی مورد بررسی قرار گرفت. یکی از عواملی که در صحت فرایند همترازسازی نقش بسزایی دارد، طول آزمون لنگر است. یافته‌های این مروز نشان داد که با افزایش طول آزمون لنگر، مقدار همبستگی این دو آزمون افزایش می‌یابد و به دنبال آن نتایج همترازسازی بهبود می‌یابد. یکی از شروط لازم برای اجرای فرایند همترازسازی، برابری پایایی دو آزمون است. نتایج مروز نشان داد که بین پایایی آزمون (لنگر و کل) و همبستگی این دو آزمون تقابل وجود دارد. به گونه‌ای که با افزایش پایایی، همبستگی آزمون لنگر و آزمون کل افزایش می‌یابد. با توجه به ویژگی‌های آماری آزمون لنگر، شواهد گویای آن بود که نوع لنگر (semi-midi, midi, mini) بر همبستگی این دو آزمون و دستیابی به نتایج دقیق‌تر مؤثر است. یک‌راه برای دستیابی به همبستگی بالا بین آزمون لنگر و آزمون کل، وجود تشابه محتوایی بین این دو آزمون است؛ بنابراین، با دقت در انتخاب سؤال‌های آزمون لنگر از نظر محتوا می‌توان به نتایج دقیق‌تری در فرایند همترازسازی دست یافت. در کنار این عوامل، هنگامی که توانایی آزمودنی‌ها در دو گروه متفاوت باشد، یافته‌های حاصل از فرایند همترازسازی با سوگیری همراه خواهد شد، زیرا این تفاوت بر همبستگی آزمون لنگر با آزمون کل اثر گذاشته و به کاهش مقدار آن منجر می‌شود. بر این اساس، لازم است پیش از اجرای فرایند همترازسازی، توانایی گروه‌های آزمودنی ارزیابی شود تا فرایند همترازسازی با حداقل سوگیری اجرا شود. بنا بر آنچه مطرح شد، می‌توان گفت که تعداد سؤال‌های آزمون (لنگر، کل)، پایایی آزمون (لنگر، کل)، پراکندگی دشواری سؤال‌های آزمون لنگر، تشابه محتوای آزمون لنگر با آزمون کل و تفاوت در توانایی آزمودنی‌های دو گروه، مجموعه عواملی هستند که بر همبستگی آزمون لنگر با آزمون کل تأثیر می‌گذارند. شناسایی این عوامل، راه را برای طراحان آزمون، تحلیلگران آزمون و افرادی که قصد اجرای فرایند همترازسازی دارند، تسهیل می‌کند. از سوی دیگر، بستر بسیار مناسبی را برای سیاست‌گذاران و مدیران سازمان سنجش آموزش کشور برای طراحی انواع آزمون‌ها و اجرای همترازسازی فراهم می‌آورد. با توجه به نتایج مروز، طراحان با شناخت و درک عوامل مؤثر بر همبستگی آزمون لنگر و آزمون کل می‌توانند هنگام طراحی فرم‌های

مختلف از یک آزمون، آنها را مدنظر قرار دهند تا در فرایند همترازسازی به نتایج بهتری دست یابند و با حداقل خطا مواجه شوند. یافته‌های مرور بیانگر آن است که لنگر midi از لنگر mini و semi-midi با آزمون کل همبستگی بالاتری دارد و عملکرد آن در بهبود نتایج همترازسازی بهتر از دونوع لنگر دیگر است. این شواهد به طراحان آزمون کمک می‌کند تا آزمون لنگر midi و یا semi-midi را انتخاب کنند و با اطمینان از کیفیت و دقت کافی در برآورد پارامترها و نمره‌های آزمون‌های همتراز شده، در زمان و هزینه ساخت آزمون لنگر نیز صرفه‌جویی کنند. با این‌همه، انتخاب نوع لنگر به هدف‌ها و شرایط اجرای آزمون بستگی دارد. علاوه بر شناسایی عوامل مؤثر بر همبستگی بین آزمون‌نگر و آزمون کل که در مرور به آن پرداخته شد، اثر این همبستگی بر نتایج همترازسازی نیز مورد بررسی قرار گرفت. یافته‌ها بیانگر آن بود که نتایج فرایند همترازسازی تحت طرح NEAT برای روش‌های خطی (لوین، تاکر، زنجیره‌ای)، همصدک (برآورد فراوانی، زنجیره‌ای) و کرنل به مقدار همبستگی این دو آزمون وابسته است. به‌طوری که در مقادیر بالای همبستگی، این روش‌ها از نتایج مشابهی برخوردار هستند. حال اگر مقدار این همبستگی با توجه عوامل ذکرشده، کم شود، عملکرد روش‌های همترازسازی نیز کاهش می‌یابد و در پی آن امکان معاوضه نمره‌ها فراهم نخواهد بود. از طرفی، بین همبستگی این دو آزمون و خطای همترازسازی رابطه معکوسی برقرار است. به‌گونه‌ای که با افزایش مقدار همبستگی آزمون لنگر با آزمون کل، خطای همترازسازی کاهش می‌یابد و نتایج حاصل از فرایند همترازسازی دقیق‌تر می‌شود. با توجه به اهمیت تأثیر این همبستگی بر فرایند همترازسازی که در مرور به آن اشاره شد، لازم است طراحان آزمون و مجریان برگزارکننده، مقدار این همبستگی و عوامل مؤثر بر آن را در مراحل ساخت آزمون و قبل از انجام تحلیل‌های مرتبط با همترازسازی به دقت بررسی و تحلیل کنند تا از بروز خطای همترازسازی و سوگیری در نتایج کاسته شود.

References

- Angoff, W. H. (1971). Scales, norms, and equivalent scores. In R. L. Thorndike (Ed.), *Educational measurement* (2nd ed.). American Council on Education.
- Angoff, W. H. (1984). *Scales, norms, and equivalent scores*. Educational Testing Service.
- Arikan, C. A., & Gelbal, S. (2018). The effect of mini and midi anchor tests on test equating. *The International Journal of Progressive Education*, 14(2), 148-160. [Doi.org/10.29329/ijpe.2018.1.39.11](https://doi.org/10.29329/ijpe.2018.1.39.11)
- Balla, J. (1988). The effects of reducing correlation of external anchors on test equating methods for the equivalent groups and non-equivalent groups designs. *International Journal of Educational Research*, 12(4), 409-425. [https://doi.org/10.1016/0883-0355\(88\)90034-1](https://doi.org/10.1016/0883-0355(88)90034-1)

- Braun, H. I., & Holland, P. W. (1982). Observed score test equating: A mathematical analysis of some ETS equating procedures. In P. W. Holland & D. B. Rubin (Eds.), *Test equating* (pp. 9-49). Academic.
- Brennan, R. L., Wang, T., Kim, S., & Seol, J. (2009). *Equating recipes*. CASMA. <https://education.uiowa.edu/sites/education.uiowa.edu/files/2021-11/casma-monograph-1.pdf>
- Budescu, D. (1985). Efficiency of linear equating as a function of the length of the anchor test. *Educational Measurement*, 22(1), 13–20. <https://www.jstor.org/stable/1434562>
- Dorans, N. J. (2004). Equating, concordance, and expectation. *Applied Psychological Measurement*, 28(4), 227–246. <https://doi.org/10.1177/0146621604265031>
- Dorans, N. J., Liu, J., & Hammond, S. (2008). Anchor test type and population invariance: An exploration across subpopulations and test administrations. *Applied Psychological Measurement*, 32(1), 81–97. <https://doi.org/10.1177/0146621607311580>
- Dorans, N. J., Moses, T. P., & Eignor, D. R. (2010). *Principles and practices of test score equating* (RR-10-29). ETS. <https://files.eric.ed.gov/fulltext/ED523737.pdf>
- Dorans, N. J., Moses, T. P., & Eignor, D. R. (2011). Equating test scores: toward best practices. In A. A. von Davier (Ed.), *Statistical models for test equating, scaling and linking* (pp. 21-42). Springer.
- Fenton, L., Lauckner, H., & Gilbert, R. (2015). The QATSDD critical appraisal tool: comments and critiques. *Evaluation in Clinical Practice*, 21, 1125-1128. <https://doi.org/10.1111/jep.12487>
- Gonzalez, J., & Wiberg, M. (2017). *Applying test equating method using R*. Springer.
- Haberman, S., & Dorans, N. J. (2009, April). *Scale consistency, drift, stability: Definitions, distinctions, and principles* [Paper presentation]. National Council on Measurement in Education, San Diego, CA. <http://www.ets.org/legal/index.html>
- Hagge, S. L. (2010). *The impact of equating method and format representation of common items on the adequacy of mixed-format test equating using nonequivalent groups* (Doctoral Dissertation, University of Iowa). <https://doi.org/10.17077/etd.bc5ticit>
- Kanamori, L. F., Xu, C., Hasan, S. S., & Doi, S. A. (2021). Quality versus risk of bias assessment in clinical research. *Clinical Epidemiology*, 129, 172-175. <https://doi.org/10.1016/j.jclinepi.2020.09.044>

- Klein, L. W., & Jarjoura, D. (1985). The importance of content representation for common-item equating with nonrandom groups. *Educational Measurement, 22*(3), 197–206. <http://www.jstor.org/stable/1435033>
- Kolen, M. J. (2020). Equating with small samples (Commentary). *Applied Measurement in Education, 33*(1), 77-82. <https://doi.org/10.1080/08957347.2019.1674308>
- Kolen, M. J., & Brennan, R. L. (2004). *Test equating, scaling, and linking: Methods and practices* (2nd ed.). Springer.
- Kolen, M. J. & Brennan, R. L. (2014). *Test equating, scaling, and linking* (3rd ed.). Springer.
- Lasserson, T. J., Thomas, J., & Higgins, J. P. T. (2019). Starting a review. In J. P. T. Higgins, J. Thomas, J. Chandler, M. Cumpston, T. Li, M. J. Page & V. A. Welch (Eds.), *Cochrane Handbook for systematic review of interventions* (2nd ed., pp. 1-12). Wiley-Blackwell.
- Lin, P., Dorans, N., & Weeks, J. (2016). *Linking composite scores: Effects of anchor test length and content representativeness* (Research Report No. RR-16-36). Educational Testing Service. <https://doi.org/10.1002/ets2.12122>
- Liu, J., Sinharay, S., Holland, P. W., Feigenbaum, M., & Curley, E. (2009). *The effects of different types of anchor tests on observed score equating*. ETS. <https://www.ets.org/research/contact.html>
- Liu, J., Sinharay, S., Holland, P. W., Feigenbaum, M., & Curley, E. (2011a). Test score equating using a mini-version anchor and a midi anchor: A case study using SAT data. *Educational Measurement, 48*(4), 361-379. <https://doi.org/10.1111/j.1745-3984.2011.00150.x>
- Liu, J., Sinharay, S., Holland, P. W., Feigenbaum, M., & Curley, E. (2011b). Observed score equating using a mini-version anchor and an anchor with less spread of difficulty: A comparison study. *Educational & Psychological Measurement, 71*, 346–361. <https://doi.org/10.1177/0013164410375571>
- Liu, J., & Walker, M. E. (2007). Score linking issues related to test content changes. In N. J. Dorans, M. Pommerich & P. W. Holland (Eds.), *Linking and aligning scores and scales* (pp. 109-134). Springer.
- Livingston, S. A. (2004). *Equating test scores (without IRT)*. ETS. <https://www.ets.org/Media/Research/pdf/LIVINGSTON.pdf>
- Lord, F. M. (1975). *A survey of equating methods based on item characteristic curve theory* (RB 75-13).

- Educational Testing Service. <https://doi.org/10.1002/j.2333-8504.1975.tb01052.x>
- Lord, F. M. (1977). Practical applications of item characteristic curve theory. *Educational Measurement, 14*(2), 117-138. <http://doi.org/10.2307/1434011>
- Lord, F. M. (1980). *Applications of item response theory to practical testing problems*. Lawrence Erlbaum.
- Marengo, D., Miceli, R., Rosato, R., & Settanni, M. (2018). Placing multiple tests on a common scale using a post-test anchor design: Effects of item position and order on the stability of parameter estimates. *Applied Mathematics & Statistics, 4*, 1-14. <http://doi.org/10.3389/fams.2018.00050>
- Moses, T., Deng, W., & Zhang, Y. L. (2010). *The use of two anchors in nonequivalent groups with anchor test (NEAT) equating*. ETS. <http://doi.org/10.1002/j.2333-8504.2010.tb02230.x>
- Moses, T., & Kim, S. (2007). *Reliability and the nonequivalent groups with anchor test design* (RR-07-16). ETS. <https://doi.org/10.1002/j.2333-8504.2007.tb02058.x>
- Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S.,... Moher, D. (2021). The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. *BMJ, 372*, n71. <https://doi.org/10.1136/bmj.n71>
- Page, M. J., McKenzie, J. E., & Higgins, J. P. T. (2018). Tools for assessing risk of reporting biases in studies and syntheses of studies: A systematic review. *BMJ open, 8*(3), 1-16. <https://doi.org/10.1136/bmjopen-2017-019703>
- Petersen, N. S. (2007). Equating: best practices and challenges to best practices. In N. J. Dorans, M. Pommerich & P. W. Holland (Eds.), *Linking and aligning scores and scales* (pp. 59-72). Springer.
- Petersen, N. S., Kolen, M. J., & Hoover, H. D. (1989). Scaling, norming, and equating. In R. L. Linn (Ed.), *Educational measurement* (3rd ed., pp. 221–262). Macmillan.
- Petersen, N. S., Marco, G. L., & Stewart, E. E. (1982). A test of the adequacy of linear score equating models. In P. W. Holland & D. B. Rubin (Eds.), *Test equating* (pp. 71–135). Academic.
- Puhan, G. (2010). A comparison of chained linear and poststratification linear equating

- under different testing conditions. *Educational Measurement*, 47(1), 54-75. <https://doi.org/10.1111/j.1745-3984.2009.00099.x>
- Ricker, K. L., & Von Davier, A. A. (2007). *The Impact of anchor test length on equating results in a nonequivalent groups design*. ETS. <https://www.ets.org/research/contact.html>
- Ryan, J., & Brockmann, F. (2018). *A practitioner's introduction to equating with primers on classical test theory and item response theory*. The Council of Chief State School Officers. https://ccss.o.org/sites/de_fault/files/201806/A%20Practitioners%20Introduction%20to%20Equating%20revised%20edition.pdf
- Santos, C. M. C., Pimenta, C. A. M., & Nobre, M. R. C. (2007). The PICO strategy for the research question construction and evidence search. *Rev Latino-am Enfermagem*, 15(3), 508–5011. <https://doi.org/10.1590/s0104-11692007000300023>
- Shamseer, L., Moher, D., Clarke, M., Ghersi, D., Liberati, A., Petticrew, M., Shekelle, P., & Stewart, L. (2015). Preferred reporting items for systematic review and meta-analysis protocols (PRISMA-P): elaboration and explanation. *BMJ*, 349:g7647. <https://doi.org/10.1136/bmj.g7647>
- Shea, J. A., & Norcini, J. J. (1995). *Licensure testing: Purposes, procedures, and practices*. University of Nebraska-Lincoln. <https://digitalcommons.unl.edu/buroslicensure/16/>
- Sinharay, S. (2017). On the choice of anchor test in equating. *Educational Measurement: Issues and Practice*, 37(4), 1-6. <https://doi.org/10.1111/emip.12175>
- Sinharay, S., Haberman, S., Holland, P., & Lewis, C. (2012). *A note on the choice of an anchor test in equating*. ETS. <https://doi.org/10.1002/j.2333-8504.2012.tb02296.x>
- Sinharay, S., & Holland, P. W. (2006a). *The correlation between the scores of a test and an anchor test*. ETS. <https://doi.org/10.1002/j.2333-8504.2006.tb02010.x>
- Sinharay, S., & Holland, P. W. (2006b). *Choice of anchor test in equating*. ETS. <https://doi.org/10.1002/j.2333-8504.2006.tb02040.x>
- Sinharay, S., & Holland, P. W. (2007). Is it necessary to make anchor tests mini-versions of the tests being equated or can some restrictions be relaxed? *Educational Measurement*, 44, 249–275. <https://doi.org/10.1111/j.1745-3984.2007.00037.x>
- Sirriyeh, R., Lawton, R., Gardner, P., & Armitage, G. (2011). Reviewing studies with diverse designs: the development and evaluation of a new tool. *Evaluation in Clinical Practice*, 18(4), 746-752. <https://doi.org/10.1111/j.1365-2753.2011.01662.x>
- Suh, Y., Morch, A. A., Kane, M. T., & Ripkey, D. R. (2009). An empirical comparison of five

- linear equating methods for the NEAT design. *Measurement: Interdisciplinary Research & Perspectives*, 7(3), 147-173. <https://doi.org/10.1080/15366360903418048>
- Sunnassee, D. (2011). *Conditions affecting the accuracy of classical equating methods for small sample under the NEAT design: A simulation study* (Doctoral Dissertation, University of North Carolina). <https://libres.uncg.edu/ir/uncg/listing.aspx?id=8164>
- Tai, J., Ajjawi, R., Bearman, M., & Wiseman, P. (2020). Conceptualizations and measures of student engagement: A worked example of systematic review. In O. Zawacki-Richter, M. Kerres, S. Bendenlier, M. Bond & K. Buntins (Eds.), *Systematic reviews in educational research* (pp. 91-110). Springer. <https://doi.org/10.1007/978-3-658-27602-7>
- Trierweiler, T. J., Lewis, C., & Smith, R. L. (2016). Further study of the choice of anchor tests in equating. *Educational Measurement*, 53, 498–518. <https://doi.org/10.1111/jedm.12128>
- Van der Linden, W. J., & Wiberg, M. (2010). Local observed-score equating with anchor-test designs. *Applied Psychological Measurement*, 34(8), 620-640. <https://doi.org/10.1177/0146621609349803>
- Von Davier, A. A. (2008). New results on the linear equating methods for the non-equivalent-groups design. *Educational & Behavioral Statistics*, 33(2), 186-203. <https://doi.org/10.3102/1076998608302633>
- Von Davier, A. A., Holland, P. W., & Thayer, D. T. (2004). *The kernel method of test equating*. Springer.
- Wallin, G., Haggstrom, J., & Wiberg, M. (2021). How important is the choice of bandwidth in kernel equating? *Applied Psychology Measurement*, 45(7-8), 518-535. <https://doi.org/10.1177/01466216211040486>
- Wei, H. (2010, May). *Impact of non-representative anchor items on scale stability* [Paper presentation]. National Council on Measurement in Education, Denver, Pearson.
- Yang, W. L., & Houang, R. T. (1996, April). *The effect of anchor length and equating method on the accuracy of test equating: comparison of linear and IRT-based equating using an anchor-item design* [Paper presentation]. American Educational Research Association, New York, NY. <https://eric.ed.gov/?id=ED401308>
- Yi, H. S. (2009). Evaluating the performance of non-equivalent groups anchor test equating under various conditions of anchor test construction. *Educational Evaluation*, 22(3), 847-869. <https://www.kci.go.kr/kciportal/ci/sereArticleSearch/ciSereArtiView.kci?sereArticleSearchBean.artiId=ART001378603>

Zhang, M., & Kolen, M. J. (2013). *Effect of the number of common items on equating precision and estimation of the lower bound to the number of common items needed*. Center for Advanced Studies in Measurement and Assessment (CASMA). <https://www.education.uiowa.edu/casma>

