

## کاربرد جای گذاری چندگانه در تحقیقات پزشکی و اپیدمیولوژی

مجید میرمحمدخانی: دستیار تخصصی، گروه اپیدمیولوژی و آمارزیستی، دانشکده علوم پزشکی تهران، ایران  
کورش هلاکوبی نائینی: استاد، گروه اپیدمیولوژی و آمارزیستی، دانشکده بهداشت، دانشگاه علوم پزشکی تهران، تهران، ایران - نویسنده رابط:  
holakoin@sina.tums.ac.ir  
تاریخ دریافت: ۱۳۸۹/۱۱/۹ تاریخ پذیرش: ۱۳۹۰/۵/۲۵

### چکیده

گم شدن داده ها در اکثر مطالعات اپیدمیولوژیک امری اجتناب ناپذیر است و با مکانیسم ها و دلایل مختلفی رخ می دهد. به دلیل ماهیت فراغیر آن، بسیاری از روش شناسان از مشکل داده های گم شده به عنوان یکی از مهمترین معضلات طراحی و تحلیلی در پژوهش یاد می کنند. اگرچه در اکثر مطالعات، تحلیل بر اساس موارد کامل انجام می شود، اما این رویکرد ممکن است منجر به برآوردها و استنتاج هایی گردد که به دلیل سوگیرایی ناشی از داده های گم شده دور از واقعیت باشد. این در حالی است که با ترمیم داده های گم شده ممکن است بتوان به نتایج دقیق تری دست یافت. روش های معمولی و ساده مانند جای گذاری منفرد، دارای ضعف هایی هستند که استفاده از آنها را در عمل بسیار محدود می کنند. اما نشان داده شده که روش های جدید جای گذاری در کنار پیچیدگی نسبی خود، اگر درست و بجا استفاده شوند، می توانند در بسیاری از موارد باعث تقلیل چشمگیر سوگیری گردد. در مقاله حاضر کاربرد جای گذاری چندگانه به عنوان یک شیوه مدرن در برخورد با مشکل فقدان داده ها در تحقیقات پزشکی و سلامت به طور خلاصه بررسی شده است.

واژگان کلیدی: جای گذاری چندگانه، اپیدمیولوژی، داده های گمشده

### مقدمه

(2004). گرچه این رویکرد که تحلیل موارد کامل (Complete-Case Analysis) نام دارد، در برخی از شرایط به نتایج قابل قبولی منتهی می گردد، اما پژوهشگران میدانند که در بسیاری از موقعیت ها با ترمیم داده ها به نتایج بهتری دست خواهند یافت. برای انجام این ترمیم لازم است با استفاده از یک روش قابل قبول، بجای هر داده گم شده مقداری مناسب برآورد و جایگزین گردد (Ghosh and Pahwa 2008). تا به حال روش های مختلفی برای جای گذاری داده های گم شده معرفی و به کار رفته است. روش های ساده و معمولی جای گذاری، دارای ضعف هایی هستند که استفاده از آنها را سوال برانگیز و در عمل بسیار محدود می کنند. اما نشان داده شده که روش های جدید جای گذاری در کنار پیچیدگی نسبی خود، اگر درست و بجا استفاده شوند، می توانند در بسیاری از موارد باعث تقلیل چشمگیر خطأ و افزایش دقت مطالعه گردد (Horton and Kleinman 2007). در این مقاله سعی

وجود داده های گم شده (Missing data) در بیشتر مطالعات امری اجتناب ناپذیر است و به دلیل ماهیت فراغیر تاثیر گذاری که دارد، از آن به عنوان یکی از مهمترین معضلات طراحی و آماری در پژوهش یاد می کنند (Little and Rubin 2002). داده های مطالعات اپیدمیولوژیک نیز بدلایل مختلف از این مشکل مصون نمی باشند (Barnard and Meng 1999). هدف اصلی و بدیهی انجام یک تحقیق و تحلیل های آماری آن، دستیابی به برآورد و استنتاجی درست درخصوص جمعیت مورد نظر می باشد. اما وجود نقص در داده ها در صورت عدم چاره اندیشه مناسب، می تواند لطمات جدی به نتایج پژوهش وارد نماید. با پیروی از یک عادت دیرینه محقق می تواند از موارد ناقص چشم پوشی کند و تنها بر اساس داده های کامل Joseph et al. (2007) اقدام به تحلیل ونتیجه گیری نماید.

بدون این که اقدامی در جهت ترمیم داده‌ها صورت گیرد، امکان پذیر می‌باشد. گرچه این فرض در بسیاری از موقعیت‌ها پذیرفتنی نیست، اما حتی در این شرایط نیز داده‌های گم شده می‌توانند تاثیر نامطلوبی بر نتایج تحقیق بگذارند. چرا که به دلیل کمتر شدن حجم نمونه، خطای معیار (Standard Error) برآورد های مورد نظر نیز افزایش می‌یابد و در نتیجه دقت (Precision) مطالعه کاهش پیدا می‌کند. اگر گم شدن داده‌ها به طور تصادفی (MAR) یا غیرتصادفی (MNAR) روی دهد، علاوه بر کم شدن دقت مطالعه خطر وجود اریبی نیز در انجام برآورد های مورد نظر، نتایج مطالعه را تهدید خواهد کرد، به خصوص در شرایطی که گم شدن داده‌ها با مکانیسم غیر تصادفی (MNAR) اتفاق می‌افتد. بنابراین روش‌های جای گذاری چنانچه درست و بجا مورد استفاده قرار گیرند، می‌توانند تحت هریک از شرایط پیش گفت به کم کردن مشکلات تحلیلی ناشی از داده‌های گم شده کمک نمایند (He 2010; Little and Rubin 2002).

جای گذاری داده‌ها: ایده اصلی در جای گذاری این است که با استفاده از روابط موجود میان داده‌ها، مقداری مناسب برای داده‌های گم شده برآورد و جایگزین گردد. در گروهی از روش‌های جایگذاری، این کار در یک مرحله انجام می‌شود. در این صورت به آن جای گذاری منفرد (Single Imputation) می‌گویند (Ghosh and Pahwa 2008). به عنوان مثال، یکی از ساده‌ترین شیوه‌ها در این گروه، محاسبه میانگین مقادیر مشاهدات موجود و جای گذاری آن بجای مقادیر گم شده (Mean Imputation) می‌باشد که البته در بسیاری از موارد نتایج مطالعه را با خطای زیادی همراه می‌نماید (Little and Rubin 2002).

رویکردهای بهتر و پیچیده‌تری نیز در میان روش‌های جای گذاری منفرد وجود دارد. انواع برآورد های رگرسیونی جزء آنها محسوب می‌شوند که گاهی به نام جای گذاری میانگین شرطی (Conditional Mean Imputation) نیز خوانده می‌شوند. در این روش با استفاده از مدل رگرسیونی

شده است که به طور خلاصه به معرفی روش جای گذاری چندگانه (Multiple Imputation) به عنوان یک روش نوین مقابله با داده‌های گم شده پرداخته و مروری بر کاربردهای آن در مطالعات بهداشتی و اپیدمیولوژی انجام شود. گم شدن داده‌ها با سه مکانیسم متفاوت رخ می‌دهد (Little and Rubin 2002):

۱- گم شدن کاملاً "Missing Completely At Random (MCAR)": این حالت زمانی اتفاق می‌افتد که در آن فقدان داده‌ها با متغیرهای مورد مطالعه بی ارتباط باشد. مثلاً وقتی که تعدادی لوله آزمایش حاوی نمونه یا چند برگ از پرسشنامه‌های تکمیل شده به طور کاملاً تصادفی - مثلاً "حین حمل و نقل" - گم یا خراب شوند، به طوری که دیگر نتوان از آنها داده‌ای را استخراج نمود.

۲- گم شدن تصادفی (Missing At Random (MAR)): در این حالت رویه گم شدن داده‌ها به طور مشروط تصادفی است و این به این معناست که فقدان داده‌ها با متغیری که در آن نقص رخ داده بی ارتباط است، اما به دیگر متغیرهای مطالعه مربوط می‌شود. به عنوان مثال فرض کنید در یک تحقیق، جنسیت افراد، یکی از متغیرهای مورد مطالعه باشد. حال اگر به طور کاملاً تصادفی تعدادی از مشاهدات متعلق به افراد مذکور از دست برود، گم شدن داده‌ها از نوع تصادفی خواهد بود.

۳- گم شدن داده‌ها بطور غیرتصادفی (Missing Not At Random (MNAR)): این وضعیت زمانی روی می‌دهد که فقدان داده‌های یک متغیر با مقادیر همان متغیر ارتباط داشته باشد. یک مثال خوب، بی پاسخی افراد دارای درآمد بالا در جواب به سوال در مورد سطح درآمدشان می‌باشد. از دیدگاه عملی مکانیسم رویداد نقصان در داده نقش تعیین کننده‌ای در کاربرد و انتخاب روش جای گذاری دارد. اگر بتوان فرض کرد مکانیسم گم شدن داده‌ها از نوع کاملاً تصادفی (MCAR) باشد و تحلیل در مطالعه بدون جایگذاری و صرفاً بر اساس داده‌های کامل انجام شود، انتظار نداریم نتایج دچار اریبی (Bias) قابل توجهی گردد و دست یابی به برآورد های قابل قبول

عرصه پزشکی و بهداشت هم از این امر مستثنی نبوده است.). Harel and Zhou 2007b; He 2010; Kenward and Carpenter 2007; Klebanoff and Cole 2008; Newgard and Haukoos (2007; Yu et al. 2007

این تکنیک اولین بار توسط روبین (Rubin) در سال ۱۹۷۸ توصیف و در سالهای بعد توسط خود او و دیگران کاملتر گردید و همچنان جنبه های نظری و عملی بیشتری از آن در حال معرفی می باشد (Barnard and Meng 1999). در جایگذاری متعدد نیز مقادیر گمشده ، با استفاده از یک مدل مناسب رگرسیونی و بر اساس داده های مشاهده شده برآورده می گردد. اما تفاوت اصلی این روش با روش های جایگذاری منفرد این است که در جایگذاری چندگانه برای مقدار برآورده شده پراکنده گرفته می شود و با انجام تکرار در جایگذاری به آن اجازه تغییر داده می شود (Graham et al. 2007). روش جای گذاری چندگانه به طور خلاصه دارای سه مرحله است. در مرحله اول  $M$  بار جای گذاری مستقل انجام و  $M$  سری داده کامل بدست می آید. در مرحله بعد برای هریک از این  $M$  سری داده کامل، آنالیز استاندارد جداگانه ای انجام و برآورده های مورد نظر محاسبه می گردد. در مرحله آخر نتایج بدست آمده طبق قوانینی با یکدیگر ترکیب و یک نتیجه منفرد حاصل می گردد (Little and Rubin 2002). از نظر تئوری هرچه تعداد جایگذاری بیشتر باشد نتایج بهتری حاصل می شود و هرچه میزان گم شدگی داده ها کمتر باشد تعداد کمتری از جایگذاری کفايت می کند، اما در عمل  $M$  معمولاً بین ۳ تا ۱۰ بار می باشد(Ghosh and Pahwa 2008). روش جای گذاری متعدد تنها روش جدید موجود و مورد قبول نمی باشد. انعطاف پذیری و کارآیی و قابلیت استفاده برای انواع داده ها خصوصاً داده های حجمی، شاخص ترین مزایایی هستند که به روش جای گذاری چندگانه مقبولیت پخشیده است (Horton and Kleinman 2007).

کاربرد جایگذاری متعدد در تحقیقات پزشکی و اپیدمیولوژی: در عرصه اپیدمیولوژی و تحقیقات بهداشتی،

و بر اساس مقادیر موجود، هر یک از مقادیر گم شده در یک مرحله برآورده و جایگزین می گردد. این رویکردها گرچه دقیقتر به نظر می رستند، اما هرگز عاری از خطای نیستند و تنها در صورتی قابل استفاده اند که مکانیسم گم شدن داده ها از نوع MCAR باشد. اما در عمل این شرط در اغلب موقعیتها برآورده نمی شود. مشکل دیگری نیز وجود دارد و آن این است که در جای گذاری منفرد، چون هر یک از مقادیر جایگزین، صحیح ترین مقدار ممکن فرض شده و برای آن پراکنده گرفته نمی شود، لذا برآورده های مورد نظر به غلط با اطمینانی بیشتر از مقدار واقعی به دست می آیند. این بدان معنی است که دقت مطالعه به طور کاذب بالا نشان داده می شود. لذا روش های فوق در عمل دارای ضعف و اشکال هستند (Baccini 2008; Little and Rubin 2002).

در دهه های اخیر و در راستای غلبه بر محدودیتهای فوق، تلاشهای زیادی جهت معرفی و بکار گیری برخی شیوه های جدید (Modern Techniques) برای جایگذاری صورت گرفته است (Ghosh and Pahwa 2008). مهمترین وجه تمایز و برتری این روشها نسبت به روش های مرسوم این است که در صورتی که با آگاهی و به درستی به کار گرفته شوند، هم در مواردی که مکانیسم گم شدن داده ها از نوع کاملاً تصادفی (MCAR) است و هم در حالی که فقدان داده ها با مکانیسم تصادفی (MAR) رخ می دهد، می توانند نتایج ناریب داشته باشند (Little and Rubin 2002; Patrician 2002 چندگانه - به علت کارآیی نسبتاً "بالای خود" - بیشتر مورد توجه و استفاده پژوهشگران قرار گرفته است Freedman and Wolf 1995; Schafer 1999; ) (Sinhary et al. 2001; Zhou et al. 2004 سال های اخیر، با ورود برنامه های نرم افزاری کاربردی برای جای گذاری متعدد، استفاده عملی از آن در فعالیتهای پژوهشی باز هم رواج و مقبولیت بیشتری یافته است (Horton and Kleinman 2007). تحقیقات در

است (Soullier et al. 2008). در تعدادی از مقالات نشان داده شده است، استفاده از روش جای گذاری چندگانه در مطالعات تحلیل بقا، دقت برآوردها را نسبت به تحلیل بر اساس داده‌های کامل افزایش می‌دهد. به عنوان نمونه می‌توان به موردی اشاره کرد که این تحلیل برای مطالعه بقای بیماران مبتلا به سرطان پستان انجام شده است (Baneshi and Talei 2010).

مشکل فقدان داده‌ها در سایر مطالعات اپیدمیولوژیک نیز مهم و قابل توجه است. به عنوان نمونه می‌توان به داده‌های ارزشمند سیستم مراقبت‌های بهداشتی اشاره کرد. این داده‌ها به دلیل ماهیت ذاتی خود ممکن است دارای نقصان باشند. بنابراین استفاده از متدهای نوین در ترمیم آنها Faris et al. (2002) ایده سودمند و کارساز به نظر می‌رسد (Rubin and Rubin 2002). اهمیت این مطلب باعث شد Rubin خود از اولین کسانی باشد که روش جای گذاری چندگانه را در بستر داده‌های Rubin and Schenker (1991) مراقبت‌های بهداشتی پیشنهاد می‌نمایند (Schenker 1991).

روش جای گذاری چندگانه در مطالعات مقطعی (Cross-Sectional) و بررسی (Survey) نیز کاربرد داشته و بهره‌گیری از آن در عرصه بهداشت عمومی (Public Health) مورد پیشنهاد و بحث قرار گرفته است (Zhou et al. 2001).

در این گونه مطالعات مهمترین دلیل گم شدن داده‌ها بی‌پاسخی (Non-response) است که می‌تواند یافته‌ها را دچار اربیبی نماید (Powers et al. 2005). به عنوان مثال در یک طرح پژوهشی با استفاده از جای گذاری چندگانه نسبت به برآورد میزانهای ابتلا به بیماری اوستئوپروز در جامعه اقدام شده است (Kmetic et al. 2002). همچنین تاکنون از این روش، به منظور بررسی وضعیت سلامت قلب و عروق (Arnold and Kang et al. 2003)، اندازه فشارخون (Kronmal 2003)، شکایات اورولوژیک (Taylor et al. 2002)، (Taylor et al. 2003)، برشی وضع سلامت زنان و شاخص توده بدنی آنها (Mishra and Dobson 2004)، مطالعه سلامت مادران

استفاده از جای گذاری چندگانه بیشتر به منظور تقلیل سوگیری ناشی از فقدان داده‌ها بوده است. این روش به منظور مدل سازی (Ferguson et al. 2008; Gelman et al. 2005; Yu and Tiwari 2006 Greenland) (Bias analysis) و تحلیل سوگیری (Fraser and Yan 2007) نیز پیشنهاد شده یا به کار رفته است. همچنین نشان داده اند که با رویکرد جایگذاری چندگانه، می‌توان مکانیسم گم شدن داده‌ها را نیز تعیین و بررسی نمود.

فقدان داده‌ها و تاثیری که نبود این مقادیر روی صحت و دقت نتایج می‌گذارد، در پژوهش‌های طولی (Longitudinal) Survival Analysis) دارای اهمیت مضاعفی است و به همین دلیل تاکنون حجم نسبتاً زیادی از متنوں و مقالات مربوط به تحلیل داده‌های گمشده و روش‌های مقابله با آنها با این نوع مطالعات ارتباط دارد. از میان آنها در چندین مقاله متند جای گذاری چندگانه به عنوان یک روش مناسب جهت تقلیل آثار نامطلوب فقدان داده‌ها معروفی و به کار رفته است. یکی از اولین موارد استفاده از روش جایگذاری چندگانه در مطالعات اپیدمیولوژیک، به کار گیری آن در یک مطالعه همگروهی (cohort) برای بررسی توزیع فاصله زمانی میان تشخیص سرمی عفونت HIV و شروع بیماری ایدز بوده است (Taylor et al. 1990). از این شیوه برای برآورد بروز بیماری ایدز نیز استفاده کرده اند (Brancato et al. 1997). در یک مطالعه جالب نشان داده اند که با استفاده از روش جای گذاری چندگانه می‌توان به برآورد دقیقتری از میزان موفقیت باروری مصنوعی (IVF) In Vitro Fertilization دست یافت. بسیاری از زوجها پس از ناکامی در اولین اقدام ممکن است از انجام مجدد آن منصرف شوند و لذا نتیجه کار نامشخص و جزء داده‌های گم شده خواهد بود. در این مطالعه محقق پس از به کار گیری روش جای گذاری چندگانه برای مقابله با مشکل فقدان این داده‌ها اقدام به برآورد صحیح تری از میزان موفقیت عمل مذکور نموده

داده های ناشی از بی پاسخی و عدم همکاری افراد نیز استفاده کرده اند.(Taylor and Zhou 2009)

بررسی متون نشان از حضور جای گذاری چندگانه در مطالعات مورد شاهدی (Case-Control) نیز دارد، Cordell گرچه این حضور نسبتاً چشمگیر نبوده است (Cordell 2006; Schroeder and Weinberg 2001).

ترمیم داده های گم شده در حوزه مراقبتها ویژه و طب اورژانس بسیار حائز اهمیت می باشد. از چالشهای مهم در این عرصه، نقصان داده های مربوط به عوامل موثر بر پیش آگهی بیماران می باشد. به عنوان نمونه در یک مطالعه جالب نشان داده شد استفاده از روش جای گذاری چندگانه در تحقیقات ترومما، می تواند مناسبترین راه حل برای رفع مشکل نقصان اطلاعات در خصوص نمره گلاسکو برای ارزیابی کما (GCS) باشد (Moore et al. 2005). در این راستا محققین روش جای گذاری چندگانه را با موفقیت به کار برده اند و آن را توصیه نموده اند (Moore et al. 2009a; Moore et al. 2009b; Perez et al. 2002). از روش مورد بحث برای ترمیم داده های مراکز ثبت حوادث (Trauma Registry Data Hayes and Groner 2008).

برخورد با مشکل گم شدن داده ها در مطالعات سرطان نیز اهمیت زیادی دارد. با مرور متون و مقالات منتشر شده می بینیم جای گذاری چندگانه در جنبه های مختلفی از مطالعات انکولوژی مورد استفاده قرار گرفته است. برای مثال در یک مطالعه با هدف بررسی هزینه-اثربخشی شیمی درمانی در مقایسه با روش های معمول درمان تسکینی در بیماران مبتلا به سرطان سلول کوچک ریه، اجزای ناکامل داده های مربوط به هزینه ها با استفاده از رویکرد جایگذاری متعدد ترمیم گردیده است (Burton et al. 2007). اخیراً، جای گذاری چندگانه به عنوان یک ابزار سودمند برای افزایش صحت داده های مربوط به Cancer Bankهای اطلاعاتی مراکز ثبت بیماران سرطانی (He et al. 2006) معرفی شده است (Registry Databases).

و کودکان (Mao and Li 2005)، بررسی پوشش واکسیناسیون (Santibanez et al. 2005)، افسردگی در افراد طلاق گرفته (Sbarra and Emery 2005) و برآورد شیوع دیابت (Heidarian Miri 2010) استفاده شده است. در یک مطالعه با هدف بررسی میزان مناسب بودن انجام عمل جراحی کاتاراكت، از روش جای گذاری چندگانه برای اصلاح داده ها استفاده شده است (Choi et al. 2004). نشان داده اند با بهره گیری از روش مذکور می توان نسبت به ترمیم داده های ناقص مربوط به درآمد افراد نیز در تحقیقات مربوط به health surveillance (Zeng 2009) اقدام نمود (Population-based Didiگاه نظری، وقتی اندازه حجم یا پیچیدگی یک مجموعه از داده ها افزایش می یابد، استفاده از روش های جایگذاری دچار محدودیت می شوند. یکی دیگر از موارد کاربرد این روش در مطالعات اپیدمیولوژیک، استفاده از آن در ترمیم داده های بزرگ (large data sets) و پیچیده می باشد (He et al. 2009; Stuart et al. 2009).

از جای گذاری چندگانه در مطالعات کارآزمایی بالینی (Clinical Trials) نیز استفاده کرده اند. به دلایل چالشها و محدودیت های اخلاقی، یکی از مهمترین مشکلات در کارآزماییهای بالینی، نیاز به انجام مطالعه روی کمترین حجم نمونه یا در کوتاه ترین زمان ممکن می باشد. یکی از موارد کاربرد جایگذاری چندگانه، متوقف کردن زود هنگام کارآزماییهای بالینی دشوار و پر چالش بوده است (Betensky 1998). به این ترتیب که در مراحلی از انجام مطالعه که بدلایل اخلاقی یا تکنیکی امکان اندازه گیری اثر مداخله وجود ندارد، نتیجه اندازه گیری مشاهده نشده به عنوان داده گمشده در نظر گرفته می شود و با استفاده از جایگذاری چندگانه مقدار مناسب برآورد می گردد. جایگذاری متعدد در انجام کارآزماییهای بالینی با حجم نمونه کم نیز سودمندی خود را نشان داده است(Barnes et al. 2006).

برخی شرایط ممکن است بررسی نمونه موجود متبهی به نتایج قاطع نگردد و این در حالی است که اخذ مجدد نمونه نا ممکن، دشوار و یا غیر اخلاقی است. در این حالت نتیجه بررسی نمونه می تواند یک داده گم شده تلقی گردد و در تحلیل با آن مانند یک داده گم شده رفتار شود. با عنایت به این که در بررسی آزمون ها همیشه نتیجه آزمون استاندارد طلایی در دسترس نیست، محققان نشان داده اند که می توان با کمک رویکرد جایگذاری چندگانه، ابتدا نتایج نامعلوم و گم شده برآورد و سپس اقدام به ارزیابی صحت (Accuracy) روش های تشخیصی نظیر تست های آزمایشگاهی Albert 2007; Harel et al. 2007; Harel and Zhou 2007a).

نقش تحلیل داده های گمشده در مطالعات ژنتیک نیز بسیار قابل توجه است. در سالهای اخیر به موازات پیشرفت بشر در عرصه بیولوژی سلولی- مولکولی و افزایش توانایی در تعریف و تعیین مارکرهای ژنی قابل اندازه گیری، بسیاری از مطالعات در حوزه ژنتیک پژوهشی به سمت بررسی ارتباط میان این مارکرهای پیامدهای سلامت معطوف گردیده است. اما همواره حجم متراکم اطلاعات مربوط به مارکرهای جایگاهها ی ژنی، کامل نیستند و این در حالی است که هنوز تعیین و بررسی مارکرهای ژنتیکی نیازمند روش های "نسبتاً" پژوهیه می باشد. لذا ژنتیک حیطه ای است که استفاده از تکنیک های کار آمد جایگزینی داده ها در آن دارای اهمیت و ضرورت بوده و از روش جای گذاری چندگانه برای ترمیم داده ها به طور فزاینده ای در مطالعات مربوط استفاده شده است. به عنوان نمونه، از جای گذاری چندگانه در مطالعاتی که بر اساس نقشه های High-density (Single-Nucleotide Polymorphism, SNP Maps Croiseau et al. 2007) این شیوه به عنوان یک ابزار کار آمد برای تقلیل خطای اندازه گیری (Measurement Error) در برخی مطالعات ژنتیکی نیز معرفی گردیده است (Padilla et al. 2009).

علاوه بر مطالعات مربوط به تصویر برداری، بررسی متون نشان می دهد روش جای گذاری چندگانه در ترمیم داده های گمشده آزمایشگاهی نیز مفید بوده است. به عنوان مثال در یک مطالعه در حیطه اپیدمیولوژی بیماریهای عفونی با بهره گیری از روش مذکور مقادیر گم شده آلبومین سرم بیماران به طور موفق ترمیم گردید (Mulla et al. 2009). در مطالعه ای دیگر، به منظور ترمیم داده های گم شده در خصوص سطح سرمی فاکتور نکروز تومور در بیماران مبتلا به آرتربیت روماتوئید از Schiattino et al. 2005).

تعیین حساسیت و ویژگی روشها و تست های نوین تشخیصی در دامنه تحقیقات بهداشتی و بالینی نیازمند در اختیار داشتن روش های استاندارد طلایی معتبر و قابل اتكابی است که عموماً "پر هزینه" یا تهاجمی هستند. به عنوان مثال می توان به روش های نوین یا غیرتهاجمی تشخیص بیماریهای سرطانی اشاره کرد. برای تعیین حساسیت و ویژگی این آزمون ها اغلب نیاز به اطلاع از نتیجه بررسی نمونه آسیب شناسی افراد وجود دارد. اما در

آموزش دادن باشد و یا الگوریتم های عملیاتی برای آن تعریف نگردد، عملاً جایگاهی در حل مشکلات نخواهد داشت. بسیاری از پژوهشگران، به دلیل عدم شناخت کافی از مبانی تئوریک آن و نیز کمبود نمونه های عملی و کاربردی، به روش های مدرن جای گذاری به دیده ابزاری برای داده پردازی (Data makeup) نگاه می کنند. اما در واقع هدف از به کار گیری روش جای گذاری چندگانه، نه داده پردازی، بلکه استفاده هر چه بیشتر از مشاهدات واقعی است. تحلیل بر اساس داده های کامل تنها در صورتی دارای وجاهت علمی خواهد بود که مکانیسم فقدان داده ها MCAR باشد. اما حقیقت این است که اگر نتوان برآورده شدن این شرط مهم را نشان داد بی اعتمایی به مشاهدات مفقود شده و تحلیل بر اساس داده های کامل، مصدق قابل قبول تری از داده پردازی به نظر می رسد و به تبع آن بروز سوگیری بیشتری در نتایج قابل انتظار خواهد بود. البته این بدان معنا نیست که در همه شرایط روش های جدید جای گذاری مناسب و کافی هستند. بلکه این روش ها نیز در صورت استفاده نابجا و غلط می توانند منجر به نتایج نادرست و دارای سوگیری گرددند و اگر به اندازه کافی در این خصوص دقت و احتیاط نشود به کارگیری آنها می تواند خطرونک باشد(Ghosh and Pahwa 2008).

مسئله در حال حاضر یک چالش مهم محاسب می گردد و بایستی وجاهت استفاده از این روش در شرایط مختلف با انجام برخی مطالعات تخصصی ارزیابی شود. در تعدادی از مطالعات که در سالهای اخیر منتشر شده اند، نقاط قوت و ضعف و نیز کاربرد این روش در مطالعات پزشکی و اپیدمیولوژیک در مقایسه با سایر روشها خصوصاً "روش تحلیل داده های کامل، مورد بررسی قرار گرفته است (Horton et al. 2010; Sterne et al. 2009)".

مطالعات تحلیل حساسیت (Sensitivity Analysis) نیز برای نشان دادن کارآیی متدهای جای گذاری چندگانه، استفاده از (Carpenter et al. 2007) گردیده است. در این مطالعات محقق شرایط مختلف گمشدگی را روی داده های واقعی یا تولید شده شبیه سازی می کند و سپس با استفاده از روش

مطالعات بررسی رابطه بر اساس وابستگی های خانوادگی (Family-based Association Studies) نیز کاربرد داشته است. هدف از انجام این مطالعات بررسی خطر افزایش یافته بیماری در وابستگان و خویشاوندان می باشد (Croiseau et al. 2007).

## بحث

با بررسی مقالات و اقدامات پژوهشی صورت گرفته در عرصه پزشکی و اپیدمیولوژی در ارتباط با روش جایگذاری چندگانه ملاحظه می گردد عمدتاً سه هدف اساسی برای محققین مطرح بوده است: معرفی و آشنایی با تکنیک جایگذاری متعدد و جنبه های مختلف نظری آن به عنوان یک شیوه نوین در برخورد با داده های گمشده، نشان دادن سودمندی این روش به عنوان یک شیوه موثر در مقابله با مشکلات و چالش های ناشی از نقصان داده ها و استفاده کاربردی از آن به عنوان یک ابزار تحلیلی در بستر های مختلف مطالعاتی. نمونه هایی از این مقالات را می توان در جدول ۱، مشاهده نمود.

گرچه اهداف مذکور در بسیاری از موارد از یکدیگر قابل تفکیک نیستند، اما مرور مقالات منتشر شده نشان از این واقعیت دارد که رویکرد جایگزینی چندگانه، علی رغم کارآیی و انعطاف پذیری که دارد، آن طور که باید و شاید در حوزه های مختلف تحقیقات بهداشتی و اپیدمیولوژی مورد توجه و استفاده پژوهشگران قرار نگرفته است. در واقع، هنوز اغلب محققین ترجیح می دهند به جای استفاده از روش های مدرن جای گذاری، از روش تحلیل بر اساس داده های کامل استفاده نمایند. شاید مهمترین عاملی که در متون برای این امر ذکر شده، این باشد که در حوزه مطالعات بهداشتی مواردی که بتوانند به عنوان راهنمای عملیاتی برای انجام این متدهای استفاده محققین قرار بگیرد نسبتاً کم تعداد هستند (Stuart et al. 2009). در توضیح این مطلب باید گفت اگر یک شیوه خواص بسیار عالی داشته باشد اما به دلایلی نظیر پیچیدگی یا کمبود افراد آشنا یا متخصص غیر قابل

### نتیجه گیری

علی رغم همه چالش ها و دشواری ها، به نظر می تواند نشان دهد که استفاده از روش جایگذاری چندگانه در چه شرایطی نتایج خوب و قابل قبول دارد و در کدام حالات قابل استفاده نیست.

(Kenward and Carpenter 2007)

**جدول ۱- نمونه هایی از کاربرد روش جای گذاری چندگانه در مطالعات انجام شده در عرصه تحقیقات پزشکی و اپیدمیولوژی**

نویسنده و سال انتشار مقاله*	شرح مختصر کاربرد
Albert 2007	ارزیابی صحت روش‌های رادیوگرافیک تشخیصی سرطان معده
Arnold and Kronmal 2003	ترمیم داده ها در بررسی وضعیت ابتلا به بیماری های قلب و عروق
Baneshi and Talei 2010	در تحلیل بقای بیماران سرطان پستان
Barnes et al. 2006	انجام کارآزمایی بالینی با حجم نمونه کم
Betensky 1998	متوقف کردن زود هنگام مطالعات کارآزمایی بالینی
Croiseau et al. 2007	ترمیم داده ها در مطالعه روی پایی مورفیسمهای تک نوکلئوتیدی
Emerson et al. 2009	ترمیم موارد نقص بیومارکرها در سرطان پستان
Ferguson et al. 2008	کاربرد جای گذاری چندگانه در مدل سازی
Fraser and Yan 2007	کاربرد جای گذاری چندگانه در تعیین مکانیسم گم شدن داده ها
Greenland 2009	کاربرد جای گذاری چندگانه در تحلیل باس
Hayes and Groner 2008	ترمیم داده های مراکز ثبت حوادث
He et al. 2008	ترمیم داده های مراکز ثبت سرطان
Heidarian Miri 2010	ترمیم داده ها در بررسی شیوع دیابت
Kang et al. 2003	ترمیم داده ها در بررسی وضعیت ابتلا به پرفشاری خون
Kmetic et al. 2003	ترمیم داده ها در بررسی وضعیت ابتلا به اوستئوپروز
Mao and Li 2005	ترمیم داده ها در بررسی وضع سلامت مادران و کودکان
Mishra and Dobson 2004	ترمیم داده ها در بررسی نمایه توده بدنی زنان
Moore et al. 2009,2005	ترمیم اجزای نمره گلاسکو برای ارزیابی کما
Morita et al. 2005	ترمیم داده های ناقص کیفیت زندگی در بیماران سرطانی
Mulla et al. 2009	ترمیم مقادیر گم شده آلبومین سرم
Santibanez et al. 2005	ترمیم داده ها در بررسی پوشش واکسیناسیون
Sbarra and Emery 2005	ترمیم داده ها در بررسی افسردگی در افراد طلاق گرفته
Soullier et al. 2008	ترمیم داده ها در تعیین میزان موفقیت باروری مصنوعی
Taylor et al. 1990	ترمیم داده ها در بررسی فاصله زمانی میان تشخیص HIV و شروع بیماری
Taylor et al. 2002	ترمیم داده ها در بررسی وضعیت شکایات اورولوژیک
Zeng 2009	ترمیم داده های ناقص مربوط به درآمد

\*مقالات بر اساس نام نویسنده اول و به ترتیب حروف الفبا در جدول آورده شده اند.

## References

- Albert, P.S., 2007. Imputation approaches for estimating diagnostic accuracy for multiple tests from partially verified designs. *Biometrics*, **63**(3), pp. 947-57.
- Altenburg, H.P., Agudo, A., Berrino, F., Boshuizen, H.C., Bueno-de-Mesquita, H.B., Janzon, L., Le Marchand, L., Linseisen, J., Lukanova, A., Rasmussen, T., Vineis, P., Riboli, E. and Miller, A., 2002. Using multiple imputation methods to estimate relative risks in small EPIC lung cancer subsets. *IARC Sci Publ*, 156, pp.53-4.
- Arnold, A.M. and Kronmal, R.A., 2003. Multiple imputation of baseline data in the cardiovascular health study. *Am J Epidemiol*, **157**(1), pp.74-84.
- Baccini, M., 2008. Multiple imputation for missing data: a brief introduction. *Epidemiol Prev*, **32**(3), pp.162-3.
- Baneshi, M.R. and Talei, A.R., 2010. Impact of Missing Data on Estimation of Survival Rates: An Example in breast Cancer. *Iran J Cancer Prev*, **3**(3), pp.127-131.
- Barnard, J. and Meng, X.L., 1999. Applications of multiple imputation in medical studies: from AIDS to NHANES. *Stat Methods Med Res*, **8**(1), pp.17-36.
- Barnes, S.A., Lindborg, S.R. and Seaman, J.W., 2006. Multiple imputation techniques in small sample clinical trials. *Stat Med*, **25**(2), pp.233-45.
- Betensky, R.A., 1998. Multiple imputation for early stopping of a complex clinical trial. *Biometrics*, **54**(1), pp.229-42.
- Brancato, G., Pezzotti, P., Rapiti, E., Perucci, C.A., Abeni, D., Babbalacchio, A. and Rezza, G., 1997. Multiple imputation method for estimating incidence of HIV infection. The Multicenter Prospective HIV Study. *Int J Epidemiol*, **26**(5), pp.1107-14.
- Burton, A., Billingham, L.J. and Bryan, S., 2007. Cost-effectiveness in clinical trials: using multiple imputation to deal with incomplete cost data. *Clin Trials*, **4**(2), pp.154-61.
- Carpenter, J.R., Kenward, M.G. and White, I.R., 2007. Sensitivity analysis after multiple imputation under missing at random: a weighting approach. *Stat Methods Med Res*, **16**(3), pp.259-75.
- Choi, Y.J., Nam, C.M. and Kwak, M.J., 2004. Multiple imputation technique applied to appropriateness ratings in cataract surgery. *Yonsei Med J*, **45**(5): pp. 829-37.
- Cordell, H.J., 2006. Estimation and testing of genotype and haplotype effects in case-control studies: comparison of weighted regression and multiple imputation procedures. *Genet Epidemiol*, **30**(3), pp.259-75.
- Croiseau, P., Bardel, C. and Genin, E., 2007. Efficiency of multiple imputation to test for association in the presence of missing data. *BMC Proc*, **1 Suppl 1**: S24.
- Croiseau, P., Genin, E. and Cordell, H.J., 2007. Dealing with missing data in family-based association studies: a multiple imputation approach. *Hum Hered*, **63**(3-4), pp.229-38.
- Delaney, J.A., McClelland, R.L., Brown, E., Bluemke, D.A., Vogel-Claussen, J., Lai, S. and Heckbert S.R., 2009. Multiple imputation for missing with cardiac magnetic resonance imaging data: results from the Multi-Ethnic Study of Atherosclerosis (MESA). *Can J Cardiol*, **25**(7), pp.232-5.
- Emerson, J.W., Dolled-Filhart, M., Harris, L., Rimm, D.L. and Tuck, D.P., 2009. Quantitative assessment of tissue biomarkers and construction of a model to predict outcome in breast cancer using multiple imputation. *Cancer Inform*, **7**, pp.29-40.
- Faris, P.D., Ghali, W.A., Brant, R., Norris, C.M., Galbraith, P.D. and Knudtson, M.L., 2002. Multiple imputation versus data enhancement for dealing with missing data in observational health care outcome analyses. *J Clin Epidemiol*, **55**(2), pp.184-91.
- Ferguson, M. K., Siddique, J. and Garrison, T., 2008. Modeling major lung resection outcomes using classification trees and

- multiple imputation techniques. *Eur J Cardiothorac Surg*, **34**(5), pp.1085-9.
- Fraser, G. and Yan, R., 2007. Guided multiple imputation of missing data: using a subsample to strengthen the missing-at-random assumption. *Epidemiology*, **18**(2), pp.246-52.
- Freedman, V.A. and Wolf, D.A., 1995. A case study on the use of multiple imputation. *Demography*, **32**(3), pp.459-70.
- Gelman, A., Van Mechelen, I., Verbeke, G., Heitjan, D.F. and Meuldres, M., 2005. Multiple imputation for model checking: completed-data plots with missing and latent data. *Biometrics*, **61**(1), pp.74-85.
- Ghosh, S. and Pahwa, PP., 2008. Assessing Bias Associated With Missing Data from Joint Canada/U.S. Survey of Health: An Application. *Biometrics Section*, pp.3394-401.
- Graham, J.W., Olchowski, A.E. and Gilreath, T.D., 2007. How many imputations are really needed? Some practical clarifications of multiple imputation theory. *Prev Sci*, **8**(3), pp.206-13.
- Greenland, S., 2009. Bayesian perspectives for epidemiologic research: III. Bias analysis via missing-data methods. *Int J Epidemiol*, **38**(6), pp.1662-73.
- Harel, O., Hofer, S.M., Hoffman, L., Pedersen, N.L. and Johansson, B., 2007. Population inference with mortality and attrition in longitudinal studies on aging: a two-stage multiple imputation method. *Exp Aging Res*, **33**(2), pp.187-203.
- Harel, O. and Zhou, X.H., 2007a. Multiple imputation for the comparison of two screening tests in two-phase Alzheimer studies. *Stat Med*, **26**(11), pp.2370-88.
- Harel, O. and Zhou X.H., 2007b. Multiple imputation: review of theory, implementation and software. *Stat Med*, **26**(16), pp.3057-77.
- Hayes, J.R. and Groner, J.I., 2008. Using multiple imputation and propensity scores to test the effect of car seats and seat belt usage on injury severity from trauma registry data. *J Pediatr Surg*, **43**(5), pp. 924-7.
- He, Y., 2010. Missing data analysis using multiple imputation: getting to the heart of the matter. *Circ Cardiovasc Qual Outcomes*, **3**(1), pp.98-105.
- He, Y., Yucel, R. and Zaslavsky, A.M., 2008. Misreporting, Missing Data, and Multiple Imputation: Improving Accuracy of Cancer Registry Databases. *Chance (N Y)*, **21**(3), pp.55-58.
- He, Y., Zaslavsky, A., Landrum, M., D. Harrington, D. and Catalano, P., 2009. Multiple imputation in a large-scale complex survey: a practical guide. *Stat Methods Med Res*.
- Heidarian Miri, H., 2010 . *Study of prevalence and risk factors of diabet type II in Iran*. M.Sc. Tehran University of Medical Sciences. [In Persian]
- Horton, N.J. and Kleinman, K.P., 2007. Much Ado About Nothing: A Comparison of Missing Data Methods and Software to Fit Incomplete Data Regression Models. *The American Statistician*, **61**(1), pp.79-90.
- Horton, N.J., White, I.R. and Carpenter, J., 2010. The performance of multiple imputation for missing covariates relative to complete case analysis. *Stat Med*, **29**(12), pp.1357.
- Joseph, L., Belisle, P., Tamim, H. and Sampalis, J.S., 2004. Selection bias found in interpreting analyses with missing data for the prehospital index for trauma. *J Clin Epidemiol*, **57**(2), pp.147-53.
- Kang, T., Kraft, P., Gauderman, W.J. and Thomas, D., 2003. Multiple imputation methods for longitudinal blood pressure measurements from the Framingham Heart Study. *BMC Genet*, **4 Suppl 1**: S43.
- Kenward, M.G. and Carpenter, J., 2007. Multiple imputation: current perspectives. *Stat Methods Med Res*, **16**(3), pp.199-218.
- Klebanoff, M.A. and Cole, S.R., 2008. Use of multiple imputation in the epidemiologic literature. *Am J Epidemiol*, **168**(4), pp.355-7.
- Kmetic, A., Joseph, L., Berger, C. and Tenenhouse A., 2002. Multiple imputation to account for missing data in a survey:

- estimating the prevalence of osteoporosis. *Epidemiology*, **13**(4), pp.437-44.
- Little, R.A. and Rubin, D.B., 2002. *Statistical Analysis with Missing Data*, John Wiley and Sons, New York.
- Mao, Q.X. and Li, X.S., 2005. Markov Chain Monte Carlo Method of multiple imputation for longitudinal data with missing values in the survey of maternal and children health. *Sichuan Da Xue Xue Bao Yi Xue Ban*, **36**(3), pp.422-5.
- Mishra, G.D. and Dobson, A.J., 2004. Multiple imputation for body mass index: lessons from the Australian Longitudinal Study on Women's Health. *Stat Med*, **23**(19), pp. 3077-87.
- Moore, L., Hanley, J.A., Lavoie, A. and Turgeon, A., 2009a. Evaluating the validity of multiple imputation for missing physiological data in the national trauma data bank. *J Emerg Trauma Shock*, **2**(2), pp.73-9.
- Moore, L., Hanley, J.A., Turgeon, A.F., Lavoie, A. and Emond, M., 2009b. A multiple imputation model for imputing missing physiologic data in the national trauma data bank. *J Am Coll Surg*, **209**(5), pp. 572-9.
- Moore, L., Lavoie, A., LeSage, N., Liberman, M., Sampalis, J.S., Bergeron, E. and Abdous, B., 2005. Multiple imputation of the Glasgow Coma Score. *J Trauma*, **59**(3), pp.698-704.
- Morita, S., Kobayashi, K., Eguchi, K., Matsumoto, T., Shibuya, M., Yamaji, Y. and Ohashi, Y., 2005. Analysis of incomplete quality of life data in advanced stage cancer: a practical application of multiple imputation. *Qual Life Res*, **14**(6), pp.1533-44.
- Mulla, Z.D., Seo, B., Kalamegham, R. and Nuwayhid, B.S., 2009. Multiple imputation for missing laboratory data: an example from infectious disease epidemiology. *Ann Epidemiol*, **19**(12), pp.908-14.
- Newgard, C.D. and Haukoos, J.S., 2007. Advanced statistics: missing data in clinical research--part 2: multiple imputation. *Acad Emerg Med*, **14**(7), pp.669-78.
- Padilla, M.A., Divers, J., Vaughan, L.K., Allison, D.B. and Tiwari, H.K., 2009. Multiple imputation to correct for measurement error in admixture estimates in genetic structured association testing. *Hum Hered*, **68**(1), pp.65-72.
- Patrician, P.A., 2002. Multiple imputation for missing data. *Res Nurs Health*. **25**(1), pp.76-84.
- Perez, A., Dennis, R.J., Gil, J.F., Rondon, M.A. and Lopez, A., 2002. Use of the mean, hot deck and multiple imputation techniques to predict outcome in intensive care unit patients in Colombia. *Stat Med*, **21**(24), pp.3885-96.
- Powers, J.R., Mishra, G. and Young, A.F., 2005. Differences in mail and telephone responses to self-rated health: use of multiple imputation in correcting for response bias. *Aust N Z J Public Health*, **29**(2), pp.149-54.
- Rubin, D.B. and Schenker, N., 1991. Multiple imputation in health-care databases: an overview and some applications. *Stat Med*, **10**(4), pp.585-98.
- Santibanez, T.A., Barker, L.E. and Shaw, K.M., 2005. Measurement of vaccination coverage at age 24 and 19-35 months: a case study of multiple imputation in public health. *Popul Health Metr*, **3**, P. 6.
- Sbarra, D.A. and Emery, R.E., 2005. Coparenting conflict, nonacceptance, and depression among divorced adults: results from a 12-year follow-up study of child custody mediation using multiple imputation. *Am J Orthopsychiatry*, **75**(1), pp.63-75.
- Schafer, J.L., 1999. Multiple imputation: a primer. *Stat Methods Med Res*, **8**(1), pp.3-15.
- Schiattino, I., Villegas, R., Cruzat, A., Cuenca, J., Salazar, L., Aravena, O., Pesce, B., Catalan, D., Llanos, C., Cuchacovich, M. and Aguilera, J.C., 2005. Multiple imputation procedures allow the rescue of missing data: an application to determine serum tumor necrosis factor (TNF) concentration values during the treatment of rheumatoid arthritis patients with anti-TNF therapy. *Biol Res*, **38**(1), pp.7-12.

- Schroeder, J.C. and Weinberg, C.R., 2001. Use of missing-data methods to correct bias and improve precision in case-control studies in which cases are subtyped but subtype information is incomplete. *Am J Epidemiol*, **154**(10), pp.954-62.
- Sinharay, S., Stern, H.S. and Russell, D., 2001. The use of multiple imputation for the analysis of missing data. *Psychol Methods*, **6**(4), pp.317-29.
- Soullier, N., Bouyer, J., Pouly, J.L., Guibert, J. and de La Rochebrochard, E., 2008. Estimating the success of an in vitro fertilization programme using multiple imputation. *Hum Reprod*, **23**(1), pp.187-92.
- Sterne, J.A., White, I.R., Carlin, J.B., Spratt, M., Royston, P., Kenward, M.J., Wood, A.M. and Carpenter J.R., 2009. Multiple imputation for missing data in epidemiological and clinical research: potential and pitfalls. *BMJ*, **338**: b2393.
- Stuart, E.A., Azur, M., Frangakis, C. and Leaf, P., 2009. Multiple imputation with large data sets: a case study of the Children's Mental Health Initiative. *Am J Epidemiol*, **169**(9), pp.1133-9.
- Taylor, J.M., Cooper, K.L., Wei, J.T., Sarma, A.V., Raghunathan, T.E. and Heeringa, S.G., 2002. Use of multiple imputation to correct for nonresponse bias in a survey of urologic symptoms among African-American men. *Am J Epidemiol*, **156**(8), pp.774-82.
- Taylor, J.M., Munoz, A., Bass, S.M., Saah, A.J., Chmiel, J.S. and Kingsley, L.A., 1990. Estimating the distribution of times from HIV seroconversion to AIDS using multiple imputation. Multicentre AIDS Cohort Study. *Stat Med*, **9**(5), pp.505-14.
- Taylor, L. and Zhou, X.H., 2009. Multiple imputation methods for treatment noncompliance and nonresponse in randomized clinical trials. *Biometrics*, **65**(1), pp.88-95.
- Yu, B. and Tiwari, R.C., 2006. Multiple imputation methods for modelling relative survival data. *Stat Med*, **25**(17), pp.2946-55.
- Yu, L.M., Burton, A. and Rivero-Arias, O., 2007. Evaluation of software for multiple imputation of semi-continuous data. *Stat Methods Med Res*, **16**(3), pp.243-58.
- Zeng, Z., 2009. Multiple imputation for missing income data in population-based health surveillance. *J Public Health Manag Pract*, **15**(6), pp.12-21.
- Zhou, X.H., Eckert, G.J. and Tierney, W.M., 2001. Multiple imputation in public health research. *Stat Med*, **20**(9-10), pp.1541-9.
- Zhou, Y.B., Jiang, Q.W. and Zhao, G.M., 2004. A method to manage of miss data--multiple imputation. *Zhonghua Yu Fang Yi Xue Za Zhi*, **38**(6), pp.424-6.