

# مروی بر داده‌های گمشده

الهه کاظمی<sup>۱</sup>, \*مسعود کریملو<sup>۲</sup>, مهدی رهگذر<sup>۲</sup>

## Missing Data

Kazemi E. (M.Sc.)<sup>1</sup>, \*Karimlo M.(Ph.D.)<sup>2</sup>, Rahgozar M.(Ph.D.)<sup>2</sup>

### Abstract

In this paper, we are presenting the basic concepts of missing data in a very simple but practical approach.

Missing data are ubiquitous throughout the social, behavioral, and medical sciences. In Statistics, missing data occur when no data value is stored for the variable in the current observation. Missing data reduce the representativeness of the sample and can therefore distort inferences about the population.

Missing data are a common occurrence and can have a significant effect on the conclusions that can be drawn from the data. All the methods of parameters estimation are based on the completion of data set assumption and only in this case the result will be a non-biased one, and with the increase of missing proportion, the rate of biased results increase too.

For decades, researchers have relied on a variety of old techniques that attempt to “fix” the data by discarding incomplete cases or by filling in the missing values. Unfortunately, most of these techniques require a relatively strict assumption about the cause of missing data and are prone to substantial bias.

**Keywords:** Missing Data, Missing Completely at Random, Missing at Random, Non Ignorable, Missing by Natural Design

Accepted: 25/7/2011

Received: 2/7/2011

### چکیده

در این مقاله سعی شده است که مفاهیم گمشدگی داده به صورت ساده و کاربردی توضیح داده شود.

گمشدگی داده در تمامی پژوهش‌های علوم اجتماعی، رفتاری، پزشکی وجود دارد. در آمار، گم شدن داده به وضعیتی گفته می‌شود که بخشی از مجموعه داده‌ها گزارش نشده باشند. گمشدگی داده باعث کاهش طبقات جامعه نمونه با جامعه کل شده و می‌تواند منجر به نتیجه‌گیری اشتباه در مورد جمعیت اصلی شود.

گمشدگی داده یک اتفاق معمول بوده و بسته به میزان آن، می‌تواند اثر قابل توجهی در نتیجه‌گیری به دست آمده از داده‌ها داشته باشد. تمامی روش‌های برآورد پارامترها برایه فرض کامل بودن مجموعه داده‌ها استوار است و تحت برقراری این شرایط منجر به برآوردهای ناریب می‌شوند؛ و البته با افزایش نسبت گمشدگی، مقدار اریبی نیز افزایش خواهد یافت.

برای دهه‌ها، محققین از روش‌های قدریمی استفاده می‌کردند. این روش‌ها متکی به تصحیح مجموعه داده‌ها با صرف نظر کردن از موردهای دارای مقادیر گمشده و یا جایگزینی مقادیری تخمینی با مقادیر گمشده بودند. متأسفانه اکثر این روش‌ها وابسته به برقراری بودن فرض دلایل گمشدگی داده و نوع سازوکار گمشدگی است؛ و در صورت عدم برقراری این فرض منجر به اریبی نتایج می‌شود.

**کلیدوازه‌ها:** داده گمشده، سازوکار گمشدگی کاملاً تصادفی، سازوکار گمشدگی تصادفی، سازوکار گمشدگی غیر قابل اعتماد، سازوکار گمشدگی به علت ذات طرف

۱. کارشناس ارشد آمار حیاتی، دانشگاه علوم بهزیستی و توانبخشی؛ ۲. دکترای آمار حیاتی، دانشیار دانشگاه علوم بهزیستی و توانبخشی

\*آدرس نویسنده مسئول: تهران، اوین، بلوار دانشجو، خیابان کودکیار، دانشگاه علوم بهزیستی و توانبخشی، گروه آموزشی آمار حیاتی؛ تلفن: ۰۲۱۸۰۱۴۶؛ رایانمه:

[mkarimlo@yahoo.com](mailto:mkarimlo@yahoo.com)

1. M.Sc. of Biostatistics, University of Social Welfare and Rehabilitation Sciences, Tehran, Iran; 2. Biostatistician, Associate Professor of University of Social Welfare and Rehabilitation Sciences, Tehran, Iran

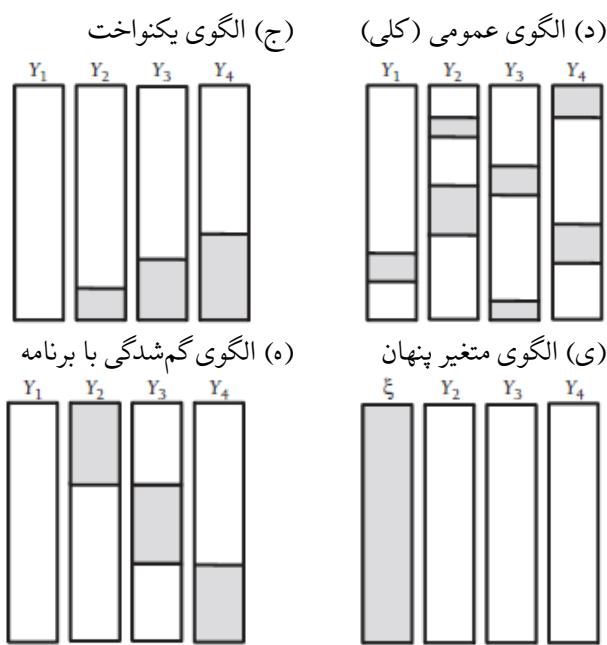
\*Correspondent Address: Statistics and Computer Department, University of Social Welfare and Rehabilitation Sciences, Koodakyar Alley, Daneshjoo Blv., Evin, Tehran, Iran; Tel: +98 21 22180 146; E-mail: [mkarimlo@yahoo.com](mailto:mkarimlo@yahoo.com)

علی رغم این که در اکثر مثال‌های کتاب‌های درسی داده‌ها به طور کامل موجود می‌باشند، جمع آوری داده‌ها به طور کامل در تحقیقات عملی امکان پذیر نمی‌باشد. داده‌گم شده یک مشکل عمومی در تحقیقات علوم پژوهشی، اپیدمیولوژیکی، توانبخشی، اجتماعی و رفتاری می‌باشد و عملاً تجزیه و تحلیل آماری را به سوی نتایج اریب سوق داده و نهایتاً دستیابی به یک نتیجه‌گیری مفید از داده‌های جمع آوری شده را با مشکل مواجه می‌سازد. با وجود تمامی این مشکلات گم شدنگی بهتر از جواب اشتیاه می‌باشد.

در ادبیات آماری اصطلاحات مختلف و غالباً مترادفی برای این مفهوم وجود دارد. این اصطلاحات عبارتند از مقادیر گم شده<sup>۱</sup>، داده های گم شده<sup>۲</sup>، داده های ناقص<sup>۳</sup> و بی پاسخ<sup>۴</sup>. گم شدگی هم در متغیر پاسخ و هم در متغیر های مستقل رخ می دهد. دو نوع گم شدگی (بی پاسخ) داریم، بی پاسخی آزمودنی<sup>۵</sup> که تمامی اطلاعات برای یک نمونه گم شده باشد (آزمودنی گم شده است). بی پاسخی در یک سوال<sup>۶</sup> که برخی از اطلاعات یک نمونه موجود نباشد (گم شده باشد).

به علاوه گم شدن در متغیرها به صورت های مختلفی می تواند رخ دهد. به عنوان مثال برخی از افراد شرکت کننده در مطالعه از ادامه همکاری انصراف می دهند، یا از پاسخ دادن به برخی از سئوالات اجتناب می کنند. محققین، تکنسین ها، جمع آوری کننده داده ها ممکن است اشتباهاتی را انجام دهند. در برخی مطالعات گم شدگی ممکن است به علت نوع طرح پژوهشی رخ داده باشد، به طور مثال در مطالعه ای برای جمع آوری داده های مورد نظر یک نمونه گیری دو مرحله ای انجام می شود، در مرحله اول مقادیر متغیرهایی که اندازه گیری آن ها آسان و ارزان است برای تمامی افراد شرکت کننده در مطالعه جمع آوری می شود و سپس در مرحله دوم مقادیر متغیرهایی که اندازه گیری آن ها پر هزینه و پیچیده می باشد برای زیر مجموعه ای از افراد شرکت کننده در مطالعه جمع آوری می شود، پس بنابراین جزئیات برای کل افراد شرکت کننده در مطالعه موجود نمی باشد. در یک مطالعه گذشته نگه به علت نقص، مدارک و سوابق، ممکن

- |                      |                      |
|----------------------|----------------------|
| 1. Missing Values    | 2. Missing Data      |
| 3. Incomplete Data   | 4. Non Response      |
| 5. Unit Non Response | 6. Item Non Response |

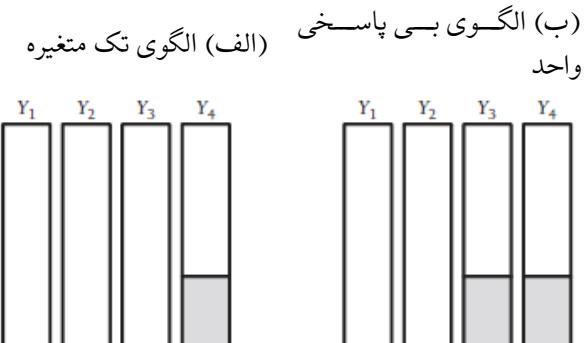


شکل ۱ - در شکل شش طرح الگوهای گم شدگی داده نشان داده شده است. نقاط سایه زده شده نشان دهنده مکان مقادیر گم شده در مجموعه دادهها با چهار متغیر هستند.

## الگوی گم شدگی

الگوی گم شدگی دادهها تنها مکان گم شدگی در دادهها را به ما نشان می‌دهد. شکل ۱ شش طرح الگوی گم شدگی دادهها را نشان می‌دهد، نواحی سایه زده شده نشان دهنده مکان مقادیر گم شده در مجموعه دادهها می‌باشند. در قسمت (الف) شکل ۱، الگوی تک متغیره<sup>۱</sup> نشان داده شده است که مقادیر گم شده در یک متغیر رخ داده است. در قسمت (ب) شکل ۱ الگوی گم شدگی بی پاسخی واحد<sup>۲</sup> نشان داده شده است که این نوع الگوی گم شدگی اغلب در تحقیقات پیمایشی<sup>۳</sup> رخ می‌دهد. الگوی گم شدگی یکنواخت<sup>۴</sup> در قسمت (ج) شکل ۱ نشان داده شده است که معمولاً در مطالعات طولی<sup>۵</sup> رخ می‌دهد، که فرد شرکت‌کننده از مطالعه خارج می‌شود و دیگر به مطالعه بر نمی‌گردد (در برخی متنون به آن ساییدگی<sup>۶</sup> می‌گویند). الگوی گم شدگی داده عمومی (کلی) در قسمت (د) شکل ۱ نشان داده شده است که مقادیر گم شده در سرتاسر مجموعه دادهها به روش تصادفی پخش شده‌اند. الگوی گم شدگی با برنامه<sup>۷</sup> در بخش (ه) شکل ۱ نشان داده شده است، که برای جمع آوری تعداد زیاد پرسشنامه‌ها با سوالات زیاد مورد استفاده قرار می‌گیرد که به طور همزمان هزینه پاسخ‌دهنده‌ها را نیز کاهش می‌دهد. در آخر، الگوی متغیر پنهان<sup>۸</sup> در قسمت (ی) شکل ۱ نشان داده شده است که فقط در تحلیل متغیرهای پنهان مانند مدل‌های معادلات ساختاری<sup>۹</sup> دیده می‌شود. از دیدگاه عملی تمایز بین الگوهای گم شدگی دادهها امروزه دیگر مهم نیست زیرا برآوردهای مراکزیم درست‌نمایی و جانبه‌ی چندگانه برای تمامی الگوهای گم شدگی داده مناسب هستند (۳).

### (الف) الگوی تک متغیره



- 1. Univariate pattern
- 2. Unit Non Response Pattern
- 3. Survey Research
- 4. Monotone Pattern
- 5. Longitudinal Study
- 6. Attrition
- 7. Planned Missing Data Pattern
- 8. Latent Variable Pattern
- 9. Structural Equation models

۲. مجموعه داده‌های بسط داده شده را به وسیله تکثیر کردن هر مقدار گم شده با جایگذاری  $X_{\text{mis}(i)} = 0$  و  $X_{\text{mis}(i)} = 1$  درست می‌کنیم. مجموعه داده بسط داده شده جدید شامل  $n'$  واحد می‌باشد. برای داده‌های جدید سایر متغیرها،  $X_{\text{obs}(i)}$  و  $Y_i$ ، را به همان صورت که مشاهده شده‌اند تکرار می‌کنیم. در این مجموعه داده مقدار  $n'$  از فرمول زیر به دست می‌آید:

$$n' = \sum_{i=1}^n \Delta_i + 2 \sum_{i=1}^n (1 - \Delta_i)$$

۳. مقادیر اولیه‌ای را برای  $\alpha$ ها در نظر می‌گیریم، با استفاده از این مقادیر اولیه برای هر واحد وزن‌های،  $w_i$ ، را برای  $i=1, 2, \dots, n$  باید محاسبه کنیم. برای داده‌های مشاهده شده،  $w_i=1$  می‌باشد. برای مقادیر تکثیر شده  $w_i$  به صورت زیر محاسبه می‌شوند:

۴. مدل رگرسیون لوگستیک وزنی را برای حالتی که در آن  $\Delta$  متغیر وابسته و  $X_{mis}$  و  $Y$  متغیر مستقل باشند (نم پارامترهای این مدل را  $\alpha$  می‌گذاریم). سپس با استفاده از مجموعه بسط داده شده با  $n$  واحد و وزن‌های  $W_i$  برآوردهای به روز شده  $\alpha$  ها را به دست می‌آوریم.

۵. با استفاده از برآوردهای جدید  $\alpha$ ، مجداداً وزن‌های واحدها را که در مرحله ۳ بیان شد محاسبه کرده و به مرحله ۴ رفته و برآوردهای جدید را با استفاده از وزن‌های جدید محاسبه می‌کنیم. این مراحل را به قدری تکرار می‌کنیم تا به هم گرایی برسیم.

پس از انجام عملیات بالا نتایج به دست آمده را بررسی کرده و در صورتی که برآورد پارامتر  $\alpha_x$  (پارامتر ضریب متغیر  $X_{mis}$ ) تقریباً مقداری نزدیک صفر با واریانسی بسیار کوچک باشد می‌توان گفت که مجموعه داده دارای سازو کار گم شدگ، تصادفی، می‌باشد.

۳. گم شدن غیر قابل اغماض<sup>۳</sup> (NI): در این حالت گم شدگی در متغیر کمکی،  $Y_{mis}$ ، بستگی به خود  $Y_{mis}$  دارد، حتی بعد از اینکه روی سایر متغیرها مشروط شده باشد. برآوردهای هیچ یک از پارامترها از روی داده‌های با مشاهدات کامل، سازگار نخواهد بود و هر گونه استنباطی مستلزم در نظر گرفتن مفروضاتی درباره ارتباط بین متغیرهای  $Y_{obs}$  و  $Y_{mis}$  نیز چرایی گم شدگی داده‌ها می‌باشد. ذکر این نکته حائز اهمیت است که هیچ تجزیه و تحلیلی از داده‌های دارای گم شدگی بدون اغماض، بدون انعام آزمون حساسیت کاملاً نیست (۱۶، ۱۵).

مقایسه‌های آزمون تی: در این روش مواردی را که مقداری گم شده و مشاهده شده دارند را برای یک متغیر خاص جدا می‌کنیم و از آزمون تی برای مقایسه میانگین‌های این دو گروه بر روی سایر متغیرها استفاده می‌کنیم. سازوکار گم شدگی کاملاً تصادفی بیان می‌کند که میانگین موارد مشاهده شده و گم شده باید برابر باشند. قبول فرض صفر این آزمون منجر به پذیرش سازوکار کاملاً تصادفی داده‌ها می‌شود، و رد فرض صفر، معنی دار شدن آماره تی یعنی تفاوت زیاد میانگین‌ها، بیان می‌کند که مجموعه داده‌ها ممکن است دارای سازوکار گم شدگی تصادفی یا غیر قابل اغماض باشند (۷).

آزمون گم شدگی کاملاً تصادفی لیتل: لیتل (۹) یک آزمون تی که برای چند متغیره بسط داده شده است را پیشنهاد کرده که به طور همزمان تفاوت میانگین ها را برای تمامی متغیرهای مجموعه داده ها ارزیابی می کند. مانند آزمون تی یک متغیره، آزمون لیتل نیز تفاوت میانگین ها را در بین زیر گروه ها مقایسه می کند. فرض صفر در این آزمون وجود سازوکار گم شدگی کاملاً تصادفی داده ها می باشد. این آزمون در نرم افزارهای آماری مانند SPSS موجود می باشد (۱۳).

۲. گم شدن تصادفی<sup>۱</sup> (MAR): در این حالت گم شدگی در متغیر،  $X_{mis}$  بستگی به متغیری که برای همه افراد شرکت کننده در مطالعه به طور کامل مشاهده شده است،  $X_{obs}$  دارد ولی به خود متغیر،  $X_{mis}$  بستگی ندارد. این سازه کار آزمون بذک نمایشد (۳، ۱۴).

برای تشخیص سازوکار گم شدگی تصادفی فلایس و همکاران<sup>۳</sup> در کتاب خود (۲) روشی را ارائه کردند. این روش عمومی نبوده و زمانی کاربرد دارد که مجموعه داده‌ها به گونه‌ای باشد که بتوان از رگرسیون لوچستیک استفاده کرد و همچنین متغیری که دارای مقادیر گم شده،  $X_{mis}$  می‌باشد متغیری رسته‌ای و دو حالتی باشد. متغیرهای  $X_{mis}$  و  $X_{obs}$  متغیر مستقل می‌باشند و متغیر  $Y$  را به عنوان متغیر وابسته در نظر می‌گیریم.

شیوه کار به صورت الگوریتم زیر می باشد:

۱. متغیر نشانگر گم شدگی دو حالتی  $\Delta$  را به صورت زیر تعریف ممکن است:

$$\left. \begin{array}{l} \text{اگر } X_{\text{mis}(i)} \text{ مشاهده شده باشد} \\ \text{اگر } X_{\text{mis}(i)} \text{ گم شده باشد} \end{array} \right\} = \Delta_i$$

تکمیل مقادیر گم شده است. در مرحله بعد می‌بایست با محاسبه احتمالات گم شدگی در سطوح مختلف متغیرها، نسبت به تشخیص نوع سازوکار گم شدگی اطمینان حاصل نمود، و برای اطمینان بیشتر از آزمون‌های موجود تشخیص گم شدگی نیز استفاده کرد. پس از تشخیص صحیح نوع سازوکار گم شدگی می‌توان روش مناسبی را انتخاب نمود و به بررسی و تحلیل داده‌های مان بپردازیم.

### تقدیر و تشکر

با تشکر از جناب آقای مایونقی چو پیک (Myunghee Cho) (Paik) که برنامه الگوریتم تشخیص سازوکار گم شدگی تصادفی را در اختیار نویسنده‌گان قرار دادند.

۴. گم شدگی به علت ذات طرح<sup>۱</sup> (MBND): گم شدگی به علت ذات طرح نوع دیگری از سازوکار گم شدگی داده است که مقادیر به علت این که آن‌ها را به طور طبیعی و معمول نمی‌توان اندازه‌گیری کرد گم شده‌اند. این یک نوع سازوکار گم شدگی جدیدی است که شامل مشکلاتی در اندازه‌گیری است (۱۷).

پس از تشخیص صحیح نوع سازوکار گم شدگی می‌توان روش مناسبی را انتخاب نمود و به بررسی و تحلیل داده‌های مان بپردازیم.

### نتیجه‌گیری

بنابراین در صورت مواجه شدن بداده‌های گم شده اولین قدم بازنگری و مشاهده مجدد واحدهای مورد مطالعه و

۱

1. Satten GA, Carroll RJ. Conditional and Unconditional Categorical Regression Models with Missing Covariates. *Biometrics*. 2000;56:384-388.
2. Fleiss JL, Levin B, Paik MC. Statistical Methods for Rates and Proportions. 3rd ed. New York: John Wiley & Sons; 2002.
3. Enders CK. Applied Missing Data Analysis. New York and London: Guilford Press; 2010.
4. Hosmer DW, Lemeshow S. Applied Logistic Regression. 2nd ed. New York: John Wiley & Sons; 2000.
5. Chen HY, Little RA. Test of missing completely at random for generalised estimating equations with missing data. *Biometrika*. 1999; 86:1–13.
6. Diggle PJ. Testing for random dropouts in repeated measurement data. *Biometrics*. 1989; 45:1255–1258.
7. Dixon WJ. BMDP statistical software. Los Angeles: University of California Press; 1988.
8. Kim KH, Bentler PM. Tests of homogeneity of means and covariance matrices for multivariate incomplete data. *Psychometrika*. 2002; 67:609–624.
9. Little RJA. A test of missing completely at random for multivariate data with missing values. *J Am Stat Assoc*. 1988; 83:1198–1202.
10. Muthén B, Kaplan D, Hollis M. On structural equation modeling with data that are not missing completely at random. *Psychometrika*. 1987; 52:431–462.
11. Park T, Lee S-Y. A test of missing completely at random for longitudinal data with missing observations. *Statistics in Medicine*. 1997; 16:1859–1871.
12. Thoemmes F, Enders C K. A structural equation model for testing whether data are missing completely at random. Paper presented at the annual meeting of the American Educational Research Association, Chicago, IL 2007 April.
13. SPSS Missing Value Analysis™ 17. United States of America: SPSS Inc 2007. <http://www.spss.com>
14. Longford NT. Missing data and small area estimation. Springer; 2005.
15. Karimlou M, Jandaghi GR, Mohammad K, Wolfe R, Azam K. A Comparison of Parameter Estimates in Standard Logistic Regressin Using WinBUGS MCMC and MLE Methods in R for Different Sample Size. *Far East J Theo Stat*. 2006.
16. Ibrahim JG, Chen MH, Lipsitz SR. Bayesian methods for generalized linear models with covariates missing at random. *Canadian Journal of Statistics*. 2008.
17. Marwala T. Computational Intelligence for Missing Data Imputation, Estimation, and Management: Knowledge Optimization Techniques. South Africa: University of Witwatersrand IGI Global; 2009.