

مقایسه روش‌های مناسب جانمایی مقادیر سانسور شده در داده‌های ژئوشیمیایی

سید علی حسینی¹، سمانه افتخاری مهابادی²، امید اصغری^{3*}

1- دانشجوی دکتری، آزمایشگاه شبیه‌سازی و پردازش داده، دانشکده مهندسی معدن، دانشگاه تهران

2- استادیار آمار، دانشکده ریاضی، آمار و علوم کامپیوتر، دانشگاه تهران

2- استادیار، آزمایشگاه شبیه‌سازی و پردازش داده، دانشکده مهندسی معدن، دانشگاه تهران

(دریافت: اسفند 1393 پذیرش: مهر 1394)

چکیده

در این تحقیق به بررسی روش‌های جانمایی مقادیر سانسور شده در مجموعه داده‌های چند متغیره ژئوشیمیایی پرداخته شده است. وجود مقادیر گم‌شده باعث محدودیت در استفاده از اغلب روش‌های آماری همچون تحلیل مولفه‌های اصلی می‌شود. حذف نمونه‌های شامل داده‌های گم‌شده باعث اریب شدن نتایج و از دست دادن اطلاعات می‌شود به همین دلیل در نظر گرفتن رویکردی مناسب در مواجهه با داده‌های گم‌شده یک نیاز اساسی در تحلیل مجموعه داده‌های ناکامل است. در این مقاله، با توجه به ماهیت ترکیبی داده‌های ژئوشیمیایی، چند روش مناسب برای جانمایی مقادیر گم‌شده که در چند سال اخیر ارائه شده‌اند و به سادگی در محیط نرم‌افزار آماری R قابل اجرا هستند، معرفی شده‌اند. در نهایت با استفاده از یک مجموعه داده کامل مربوط به منطقه ظفرقند، این روش‌ها با یکدیگر مقایسه شده‌اند. نتایج نشان می‌دهند که استفاده از روش‌های چند متغیره برای جانمایی و به طور خاص روش $ilr-EM$ نسبت به دیگر روش‌ها ارجحیت دارند.

واژگان کلیدی

داده‌های ژئوشیمیایی، مقادیر سانسور شده، روش‌های جانمایی، ماهیت ترکیبی، روش $ilr-EM$

ارجاع به این مقاله:

حسینی، ع.، افتخاری مهابادی، س.، اصغری، الف.، (1394)، مقایسه روش‌های مناسب جانمایی مقادیر سانسور شده در داده‌های ژئوشیمیایی، روش‌های تحلیلی و عددی در مهندسی معدن، 5(9)، 63-72.

[http://dx.medra.org/10.17383/S2251-6565\(15\)940916-X](http://dx.medra.org/10.17383/S2251-6565(15)940916-X)

* عهده دار مکاتبات: o.asghari@ut.ac.ir

1- مقدمه

داده‌های ژئوشیمیایی به صورت گسترده در مطالعات اکتشافی و بررسی‌های محیط زیستی مورد استفاده قرار می‌گیرد. در عمل پس از جمع‌آوری این‌گونه داده‌ها، از تحلیل‌های آماری تک متغیره، چند متغیره و روش‌های آمار فضایی به منظور توصیف و تحلیل داده‌های ژئوشیمیایی استفاده می‌شود. اغلب در مجموعه داده‌های ژئوشیمیایی وجود داده‌های گم‌شده¹ موضوعی اجتناب ناپذیر است یکی از دلایل رخداد گم‌شدگی در این‌گونه داده‌ها مقادیر کوچک‌تر از حد تشخیص دستگاه اندازه‌گیری² (داده‌های سانسور شده) است.

وجود مقادیر گم‌شده در یک مجموعه داده باعث محدودیت‌هایی در محاسبات و استفاده از روش‌های آماری همچون تحلیل مولفه‌های اصلی می‌شود چرا که استفاده این روش‌ها نیازمند وجود یک مجموعه داده کامل است. یک راه حل مرسوم برای این مشکل، حذف نمونه‌های دارای گم‌شدگی از مجموعه داده‌ها است که به آن تحلیل داده‌های کامل³ (CCA) گفته می‌شود. استفاده از این روش باعث انحراف در نتایج و از دست دادن اطلاعات می‌شود. می‌توان به جای حذف نمونه‌های دارای گم‌شدگی، سلول‌های دارای گم‌شدگی در مجموعه داده‌ها را با یک مقدار مناسب جانهی⁴ نمود [1].

از طرفی، داده‌های ژئوشیمیایی به صورت سهمی از یک مقدار ثابت به عنوان مثال درصد و یا ppm گزارش می‌شوند. این مقادیر، منحصر به فرد، مثبت و مجموع آنها ثابت است (در صورتی که تمام عناصر موجود در نمونه اندازه‌گیری شوند). بنابراین داده‌های ژئوشیمیایی ماهیت ترکیبی⁵ دارند [2]. این ویژگی داده‌های ژئوشیمیایی موجب محدودیت در استفاده از روش‌های آماری چون آنالیز فاکتوری و آنالیز مولفه اصلی می‌شود. برای تحلیل داده‌های ترکیبی روش‌های مختلفی ارائه شده است که بر پایه هندسه آجیسون⁶ هستند [3]. بنابراین انتظار می‌رود یک روش جانهی مناسب، ماهیت ترکیبی داده‌های ژئوشیمیایی را نیز در نظر بگیرد.

تقریباً در تمام مقالات و کتاب‌ها به این نکته اشاره شده است که، روش‌های جانهی داده‌های گم‌شده نباید ساختار کلی داده‌ها را دچار تغییرات شدید کند. چندین روش برای

جانهی مقادیر گم‌شده در مجموعه داده‌ها ترکیبی ارائه شده است که می‌توان از آنها برای کامل کردن مجموعه داده‌های ژئوشیمیایی و تجزیه و تحلیل آنها بهره گرفت. در این مقاله ابتدا چندین روش مناسب برای استفاده در تجزیه و تحلیل داده‌های ژئوشیمیایی مرور می‌شود، از آن جمله می‌توان به روش معرفی شده توسط هرون و همکاران [4] که اخیراً در تجزیه و تحلیل داده‌های ژئوشیمیایی نیز به کار گرفته شده است، روش جایگزینی ضربی ساده⁷ [5، 6] و جایگزینی لاگ نرمال ضربی⁸ [7] و الگوریتم EM^9 و DA^{10} در فضای تبدیل یافته لگاریتمی [8، 9] اشاره نمود. سپس در ادامه با استفاده از یک مجموعه داده کامل ژئوشیمیایی مربوط به منطقه ظفرقند، مجموعه داده‌های جدید که شامل مقادیر سانسور شده با نرخ‌های متفاوت هستند، ایجاد شده و توسط هر کدام از روش‌ها عملیات جانهی صورت گرفته و در نهایت دقت هر کدام از روش‌ها با بررسی میزان تغییر در آماره‌های مهم توزیع آنها و مقایسه مقدار واقعی و جانهی شده، مورد ارزیابی قرار خواهد گرفت.

2- گم‌شدگی در مجموعه داده‌های ژئوشیمیایی

مشکلی که اغلب متخصصان تجزیه و تحلیل داده‌های حاصل از نمونه‌گیری تجربی و اندازه‌گیری عناصر با آن روبرو هستند، این است که غلظت برخی از عناصر در نمونه به صورت "کمتر از"¹¹ و یا به ندرت "بیشتر از"¹² یک مقدار مشخص گزارش شده است. در مطالعات ژئوشیمیایی معمولاً مجموعه داده‌های در دسترس شامل سلول‌هایی است که به صورت کمتر از حد تشخیص دستگاه اندازه‌گیری¹³ (DL) گزارش شده است. چگونگی رسیدگی و برخورد با مقادیر گم‌شده برای تجزیه و تحلیل داده‌ها از نگرانی اصلی متخصصان به شمار می‌رود [10]. مقادیر کمتر از حد تشخیص دستگاه و یا سانسور در واقع مقادیر گم‌شده هستند، چرا که اطلاعات کاملی در مورد آنها وجود ندارد. با توجه به این‌که سانسور شدن و یا عدم ثبت مقدار واقعی عنصر، وابسته به غلظت خود عنصر در نمونه است به این‌گونه گم‌شدگی مکانیزم گم‌شدگی غیر تصادفی $NMAR^{14}$ اتلاق می‌گردد [1]. گم‌شدگی در این مکانیزم غیر قابل چشم پوشی است و تجزیه و تحلیل داده‌ها به روش CCA باعث اربب شدن نتایج می‌شود به ویژه اگر درصد گم‌شدگی بیشتر از 5٪ باشد.

3- روش‌های جهانی مقادیر سانسور شده

3-1- جایگزینی ضربی ساده¹⁵ (SMR)

یکی از روش‌های تک متغیره‌ای که اغلب برای جهانی مقادیر کمتر از حد تشخیص دستگاه در مطالعات زیست محیطی استفاده می‌شود روش جایگزینی ضربی ساده است [11] که شامل جایگزین کردن 50٪ و یا 70٪ حد تشخیص دستگاه اندازه‌گیری به جای مقادیر گم شده است. بالا را و همکاران [7] با بهره گرفتن از این ایده بر روی داده‌های ترکیبی، نشان داده‌اند که یک ضریب تعدیل در جایگزینی مقدار سانسور شده برای حفظ مبانی مربوط به داده‌های ترکیبی مانند قید مجموع ثابت نیاز است. فرض کنید مجموعه‌ی داده‌ها (ماتریس $X_{n \times D}$) شامل n نمونه ($i = 1, \dots, n$) و D عنصر اندازه‌گیری شده ($j = 1, \dots, D$) باشد. مقدار جهانی برای x_{ij} که اندازه‌گیری مربوط به عنصر j ام در نمونه i ام را نشان می‌دهد و به طور کامل مشاهده نشده است از رابطه (1) به دست می‌آید:

$$x_{ij} = \begin{cases} \delta_{ij} & \text{if } x_{ij} < DL_{ij} \\ \left(1 - \frac{\sum_{k|x_{ik} < DL_{ij}} \delta_{ik}}{c_i}\right) x_{ij} & \text{if } x_{ij} \geq DL_{ij} \end{cases} \quad (1)$$

که $c_i = \sum_{j=1}^D x_{ij}$ برابر مجموع عناصر برای نمونه i ام (به عنوان مثال 1,000,000 اگر مقادیر به صورت ppm گزارش شده باشد) و δ_{ij} درصدی از DL_{ij} ($\delta_{ij} = \alpha DL_{ij}$) است. توجه داشته باشید δ و DL به این خاطر اندیس ij گرفته اند و این امکان را فراهم می‌کنند که غلظت عناصر در نمونه‌ها از روش‌های مختلفی با DL متفاوت، اندازه‌گیری شده باشند. فرناندز و همکاران [12] نشان داده‌اند که اگر δ_{ij} برابر با 65٪ حد تشخیص دستگاه در نظر گرفته شود، ساختار کوواریانس داده‌ها تغییر نخواهد یافت البته اگر میزان گم‌شدگی کمتر از 10٪ باشد.

3-2- جایگزینی لاگ نرمال ضربی¹⁶ (MLNR)

این روش از ویژگی‌های آماری توزیع داده‌ها با فرض یک مدل احتمالی خاص استفاده می‌کند. معمولاً از توزیع لاگ نرمال برای مدل کردن توزیع داده‌های با چولگی به راست مانند غلظت شیمیایی استفاده می‌شود [11]. در این روش به جای در نظر گرفتن درصدی از حد تشخیص

دستگاه برای تعیین δ_{ij} در رابطه (1) از تخمینی از میانگین هندسی مقادیر کمتر از حد تشخیص دستگاه با فرض توزیع لاگ نرمال برای متغیر z ام ترکیب استفاده می‌شود. رابطه مقدار جایگزین بر اساس این روش به صورت زیر است.

$$\hat{x}_{ij} = \begin{cases} \delta_{ij} - \exp(\hat{\mu}_j - \hat{\sigma}_j \hat{\lambda}_{ij}) & \text{if } x_{ij} < DL_{ij} \\ \left(1 - \frac{\sum_{k|x_{ik} < DL_{ij}} \delta_{ik}}{c_i}\right) x_{ij} & \text{if } x_{ij} \geq DL_{ij} \end{cases} \quad (2)$$

که در آن:

$$\hat{\lambda}_{ij} = \frac{\phi\left(\frac{(\ln DL_{ij} - \hat{\mu}_j) / \hat{\sigma}_j}{\Phi\left(\frac{(\ln DL_{ij} - \hat{\mu}_j) / \hat{\sigma}_j}{\hat{\sigma}_j}\right)}\right)}{\Phi\left(\frac{(\ln DL_{ij} - \hat{\mu}_j) / \hat{\sigma}_j}{\hat{\sigma}_j}\right)}$$

در رابطه فوق $\phi(\cdot)$ و $\Phi(\cdot)$ به ترتیب تابع چگالی و تابع تجمعی توزیع نرمال استاندارد، $\hat{\mu}_j$ و $\hat{\sigma}_j$ پارامترهای تخمین خورده از الگوریتم مبتنی بر احتمال¹⁷ برای داده‌های سانسور شده در z امین عنصر هستند.

3-3- k - نزدیک‌ترین همسایگی¹⁸ (KNN)

روش جهانی KNN بعنوان یکی از روش‌های موفق برای داده‌های چند متغیره استاندارد شناخته شده است [13]. در این روش از یک اندازه فاصله برای پیدا کردن k مشاهده مشابه برای ترکیب‌های دارای گم‌شدگی استفاده می‌شود و مقادیر گم‌شده را توسط اطلاعات متغیرهای مشاهده شده در نزدیک‌ترین همسایگی آن مقدار جهانی می‌کند. با توجه به ماهیت ترکیبی داده‌ها در این روش از اندازه فاصله آجیسون استفاده می‌شود. فرض کنید $M_i \subset \{1, \dots, D\}$ مجموعه‌ای از اندیس‌ها برای نشان دادن سلول‌های دارای گم‌شدگی در سطر i ام ماتریس مشاهدات X ، $X_i = (x_{i1}, \dots, x_{iD})$ باشد. بنابراین $O_i = \{1, \dots, D\} \setminus M_i$ اندیس مقادیر مشاهده شده را در X_i نشان می‌دهد. برای جهانی سلول گم‌شده X_{ij} ، برای هر $j \in M_i$ ، تمام اجزاء باقی‌مانده ترکیب که در عنصر z ام و اندیس‌های O_i مشاهده شده‌اند در نظر گرفته می‌شود و k همسایه $x_{i1}, \dots, x_{ik}$ برای نمونه X_i با استفاده از فاصله آجیسون محاسبه می‌شود. ابتدا این مقادیر همسایه انتخاب شده توسط فاکتور زیر تعدیل می‌شوند.

در k امین تکرار، $\hat{\sigma}_j^2$ برآورد واریانس شرطی متغیر y_j در k امین تکرار، ψ بردار مربوط به مقدار حد تشخیص دستگاه بعد از تبدیل alr ، ϕ و Φ به ترتیب تابع چگالی و تابع توزیع تجمعی نرمال استاندارد هستند. بعد از همگرایی الگوریتم مقادیر به دست آمده در آخرین تکرار با استفاده از رابطه (7) تبدیل معکوس می‌شوند:

$$\hat{X}_i = \begin{cases} \hat{x}_{ij} = \frac{\exp(\hat{y}_{ij})}{\sum_{j \neq D} \exp(\hat{y}_{ij}) + 1} \\ \hat{x}_{iD} = \frac{1}{\sum_{j \neq D} \exp(\hat{y}_{ij}) + 1} \end{cases} \quad (7)$$

بعد از اجرای تبدیل معکوس alr مجموعه داده کامل شده در دست خواهد بود.

5-3- الگوریتم DA نسبت لگاریتمی جمعی ($alr-DA$)²⁴

این روش شامل الگوریتم داده افزایی (DA) بر اساس مدل ALN بریده شده²⁵ نرمال است. این الگوریتم یک حلقه تکراری بر پایه شبیه‌سازی است که مقادیری را از توزیع پسین²⁶ مقادیر سانسور شده و پارامترهای مدل ALN تولید می‌کند. مدلسازی ALN بر اساس معادلات رگرسیون در فضای تبدیل یافته alr خواهد بود. بنابراین در k امین تکرار مقدار سانسور شده در فضای alr به صورت تصادفی از توزیع زیر جانمایی می‌شود:

$$\hat{y}_{ij}^{(k)} \sim TruncNormal(y_i^t \hat{\beta}_j^{(k)}, \hat{\sigma}_j^{2(k)}, y_{ij} < \psi_{ij} | \hat{\mu}^{(k)}, \hat{\Sigma}^{(k)}) \quad (8)$$

این طرح شباهت زیادی به الگوریتم بر پایه EM دارد (بخش 3-4). تفاوت اصلی آنها این است که در روش $alr-DA$ تخمین پارامترها توسط شبیه‌سازی صورت می‌گیرد. بعد از همگرایی الگوریتم با استفاده از رابطه (7) مقادیر تبدیل معکوس و به واحد اصلی برگردانده می‌شوند.

6-3- الگوریتم EM نسبت لگاریتمی ایزومتريک (ilr)²⁷

در آخر روش ارائه شده توسط فرناندز و همکاران [9] معرفی می‌شود. در این روش هدف کاهش تأثیر مقادیر دور افتاده بر روی مقادیر جانمایی شده است. این روش بر پایه یک مدل نرمال چند متغیره بر روی داده‌های تبدیل یافته ilr هستند. تبدیل ilr برای یک ترکیب D -جزئی می‌شود. $X_i = [x_{i1}, \dots, x_{iD}]$ ، $i = 1, \dots, n$ به صورت زیر تعریف می‌شود:

$$f_{il} = \frac{\text{median}_{o \in O_l} x_{io}}{\text{median}_{o \in O_l} x_{io}} \quad \text{for } l = 1, \dots, k \quad (3)$$

با استفاده از این فاکتور تعدیل به عنوان وزن برای مشاهدات، k همسایه قابل مقایسه می‌شوند. در نهایت مقدار جانمایی برای سلول X_{ij} برابر است با:

$$x_{ij}^* = \text{median}\{f_{i1} x_{1j}, \dots, f_{ik} x_{kj}\} \quad (4)$$

با توجه به این که در ضریب تعدیل از میانه استفاده شده است این روش در صورت وجود مقادیر دور افتاده¹⁹ مقاوم²⁰ است.

4-3- الگوریتم EM نسبت لگاریتمی جمعی ($alr-EM$)²¹

در این روش ابتدا از تبدیل نسبت لگاریتمی جمعی²² به عنوان بخشی از الگوریتم استفاده می‌شود. این تبدیل برای ترکیب D - جزئی نام $X_i = [x_{i1}, \dots, x_{iD}]$ با در نظر گرفتن یک جزء k ام به عنوان مخرج به صورت زیر تعریف می‌شود:

$$y_{ij} = \ln\left(\frac{x_{ij}}{x_{ik}}\right), \quad j \in \{1, \dots, D\} \quad (5)$$

از این تبدیل برای مدل کردن آماری بر اساس مدل جمعی لوژیستیک نرمال²³ (ALN)، که یک مدل چند متغیره با بردار میانگین و ماتریس کوواریانس داده‌های تبدیل یافته توسط رابطه (5) است، استفاده می‌شود. در روش $alr-EM$ طی یک فرآیند تکراری (الگوریتم EM) مقادیر گم‌شده و پارامترهای مدل ALN متعاقباً به روز می‌شوند تا الگوریتم به همگرایی برسد. برای شروع الگوریتم پارامترهای مدل باید مقدار دهی اولیه شوند که می‌توان آنها را از مقادیر مشاهده شده محاسبه کرد. در k امین تکرار یک مقدار گم‌شده y_{ij} توسط مقدار مورد انتظار تخمین شرطی $\hat{y}_{ij}$ با توجه به تخمین‌های $\hat{\mu}^{(k)}$ و $\hat{\Sigma}^{(k)}$ جانمایی می‌شود:

$$\hat{y}_{ij} = y_i^t \hat{\beta}_j^{(k)} = \hat{\sigma}_j^{(k)} \frac{\phi\left(\frac{\psi_{ij} - y_i^t \hat{\beta}_j^{(k)}}{\hat{\sigma}_j^{(k)}}\right)}{\Phi\left(\frac{\psi_{ij} - y_i^t \hat{\beta}_j^{(k)}}{\hat{\sigma}_j^{(k)}}\right)} \quad (6)$$

که در آن y_i^t بردار ترانهاده مقادیر مشاهده شده (بعد از تبدیل alr)، $\hat{\beta}_j^{(k)}$ بردار ضرایب رگرسیونی برآورد شده

نوار ولکانوپلوتونیک ارومیه- دختر واقع است. مطالعات ژئوشیمیایی کل سنگ نشان می دهد که سنگ های اصلی تشکیل دهنده منطقه اکثرا از نوع بازالت-آندزیت هستند. مشاهدات صحرایی و میکروسکوپی نشان می دهند که در این منطقه تناوبی از ماگماتیسم بی مدال اسیدی و بازی وجود دارد [14].

5-1- داده های اصلی

مجموعه داده اصلی شامل نتایج آنالیز 250 نمونه جمع آوری شده از قسمت های مختلف ناحیه بوده است که به روش *MASS-ICP* صورت گرفته است. این مجموعه داده کامل بوده و دارای مقادیر سانسور شده نیست. نمونه ها برای 43 عنصر آنالیز شده است و در جدول 1 عناصر و حد تشخیص دستگاه اندازه گیری برای هر کدام آورده شده است.

5-2- ایجاد داده های سانسور به طور مصنوعی در داده های اصلی

به منظور ارزیابی روش های اشاره شده برای جانمایی داده های سانسور شده، بر اساس مکانیزم زیر در مجموعه داده های اصلی داده های سانسور شده ایجاد شده است:

$$CM = \begin{cases} \text{Censored} & \text{if } x_{ij} \leq n \times DL_{x_j} \\ \text{Observed} & \text{otherwise} \end{cases} \quad (11)$$

در حالت اول با استفاده از رابطه (12) چهار مجموعه داده تولید شده است که فقط عنصر بریلیموم دارای داده های سانسور است. به ازای مقادیر $n = \{2.5, 4.25, 5, 5.5\}$ در رابطه (12) در داده های عنصر بریلیموم 15٪، 25٪، 40٪ داده سانسور به طور مصنوعی ایجاد شده است.

در حالت دوم 13 عنصر از 43 عنصر بطور تصادفی انتخاب شده است و با استفاده از رابطه (12) درصدهای متفاوتی از سانسور در آنها ایجاد شده است و یک مجموعه داده ای جدید ساخته شده است. 13 عنصری که از 43 عنصر دارای داده سانسور هستند و همچنین درصد سانسور در هر کدام در جدول 2 آورده شده است. در این حالت میانگین درصد سانسور در کل مجموعه داده برابر 15٪ است.

$$ilr(x_{ij}) = z_{ij} = \sqrt{\frac{D-j}{D-j+1}} \ln \frac{\sqrt{\prod_{l=j+1}^D x_{il}}}{x_{ij}}, \quad \text{for } j=1, \dots, D-1 \quad (9)$$

و تبدیل معکوس *ilr* به صورت زیر است:

$$\begin{cases} x_{i1} = \exp\left(-\sqrt{\frac{D-1}{D}} z_{i1}\right) \\ x_{ij} = \exp\left(\sum_{l=1}^{j-1} \frac{1}{\sqrt{(D-l+1)(D-l)}} z_{il} - \sqrt{\frac{D-j}{D-j+1}} z_{ij}\right) \\ x_{iD} = \exp\left(\sum_{l=1}^{D-1} \frac{1}{\sqrt{(D-l+1)(D-l)}} z_{il}\right) \end{cases} \quad (10)$$

این روش بر اساس یک مدل رگرسیون مقاوم سانسور شده بنا گشته است. مراحل اجرای این الگوریتم را می توان به صورت زیر خلاصه کرد.

1. انتخاب یک عنصر (x_j) که دارای مقادیر گم شده است و اجرای تبدیل *ilr* آن بر اساس رابطه (9).
2. استفاده از رابطه (6) بر اساس رگرسیون مقاوم سانسور شده Z_1 بر روی $Z_2, \dots, Z_{D-1}$ به منظور تخمین سلول های گم شده و تکرار طرح *EM* تا زمان رسیدن به همگرایی.
3. اجرای تبدیل معکوس با استفاده از رابطه (10).
4. تکرار مراحل 1-3 برای تمام متغیرهای دارای گم شدگی.

4- نحوه اجرای روش های جانمایی

تمام روش های ذکر شده توسط نرم افزار *R* که یک نرم افزار محبوب در محاسبات آماری است به سادگی قابل اجرا است. توابع مورد نیاز برای اجرای روش ها در دو بسته *robcomsitions* و *zcompositions*²⁸ در این نرم افزار در دسترس و قابل استفاده است. توابع مربوط به اجرای روش ها به ترتیب آورده شده در بالا عبارت اند از: *impKNNa(.)*، *multLN(.)*، *multRepl(.)*، *impRZilr(.)*، *lrDA(.)*، *lrEM(.)*

5- مطالعه موردی (ناحیه ظفرقند)

در این تحقیق به منظور اجرای روش های مختلف جانمایی برای داده ژئوشیمیایی از داده های ناحیه ظفرقند که در جنوب شرقی اردستان در 110 کیلومتری شمال شرق اصفهان است، استفاده شده است. از نظر موقعیت زمین شناسی بخشی از زون ایران مرکزی محسوب شده و در

جدول 1: لیست عناصر آنالیز شده و حد تشخیص دستگاه (در واحد ppm) متناظر هر عنصر

عنصر	حد تشخیص	عنصر	حد تشخیص	عنصر	حد تشخیص	عنصر	حد تشخیص
Au	0/001	Bi	0/2	Nb	1	Th	0/5
Al	100	Cd	0/1	Ni	1	Ti	10
Ca	100	Ce	1	P	10	Tl	0/2
Fe	100	Co	1	Pb	1	U	0/5
K	100	Cr	1	Rb	1	V	2
Mg	100	Cs	0/5	S	50	W	0/5
Na	100	Cu	1	Sb	0/5	Y	0/5
Ag	0/1	La	1	Sc	0/5	Yb	0/2
As	0/5	Li	1	Sn	0/5	Zn	1
Ba	2	Mn	5	Sr	2	Zr	5
Be	0/2	Mo	0/5	Te	0/1		

جدول 2: عناصر دارای گم‌شدگی در حالت دوم و درصد سانسور هر کدام

عنصر	درصد سانسور
Ag	44/6
Au	14/34
Bi	16/73
Co	34/66
Cu	30/67
Li	15/14
Mo	27/5
Na	1/6
Nb	0/4
Te	6/7
U	39/44
W	61/75
Zn	16/73

که در آن X_{true} ماتریس داده‌های اصلی، X_{imp} ماتریس داده‌های جانپی شده هستند.

در ابتدا مجموعه داده‌های ساخته شده در دو حالت که نحوه تولید آنها در بالا توضیح داده شد مورد استفاده قرار گرفت و با استفاده از روش‌های گفته شده داده‌های سانسور شده در آنها جانپی شدند. سپس میزان $NRMSE$ برای هر روش در مجموعه داده‌های مختلف محاسبه شد که در جدول 3 آورده شده است.

روش KNN در مقایسه با سایر روش‌ها نتایج خوبی ارائه نکرده است که احتمالاً مربوط به مکانیزم گم‌شدگی است و این روش برای جانپی زمانی که مکانیزم گم‌شدگی $NMAR$ است مناسب نیست. روش‌های تک متغیره جایگزینی ضربی ساده و نرمال تقریباً نتایج مشابهی ارائه کرده‌اند.

در بین روش‌های چند متغیره روش $ilr-EM$ دقت بیشتری دارد. به منظور مقایسه تغییرات ایجاد شده در آماره‌های توزیع، در شکل 1 میزان خطای برآورد میانگین هندسی و انحراف استاندارد در روش‌های مختلف جانپی برای عنصر بریلیوم محاسبه شده و نمایش داده شده است. زمانی که درصد داده‌های سانسور شده پایین است روش‌های جانشینی ضربی لاگ نرمال، $alr-EM$ و $ilr-EM$ نتایج مشابهی ارائه کرده‌اند اما زمانی که درصد داده‌های سانسور بالا باشد روش $ilr-EM$ بهترین دقت را دارد. با افزایش میزان داده‌های سانسور شده از دقت روش‌ها نیز کاسته می‌شود اما میزان کاهش دقت در روش‌های مختلف

6- مقایسه روش‌های مختلف جانپی

برای ارزیابی روش‌های مختلف اشاره شده برای جانپی داده‌های سانسور شده معیاری برای مقایسه مقدار واقعی و مقدار جانپی شده به عنوان ریشه دوم نرمال شده میانگین مربع خطا²⁹ ($NRMSE$) در نظر گرفته شده است که به صورت زیر تعریف می‌شود:



$$NRMSE = \left(\frac{\text{mean}((X_{true} - X_{imp})^2)}{\text{var}(X_{true})} \right)^{1/2} \quad (12)$$

3. $Q-Q$ plot برای بریلیموم داده‌های اصلی و بعد از جانهی مقادیر سانسور شده (در حالتی که 25٪ داده سانسور شده است) به منظور مشاهده بهتر این تغییرات نشان داده شده است. قابل توجه است که از نظر زمان انجام محاسبات رایانه‌ای روش‌های تک متغیره زمان کمتری نیاز دارند.

متفاوت است (شکل 1). در شکل‌های 2 هیستوگرام عنصر بریلیموم با داده‌های اصلی و بعد از جانهی مقادیر سانسور شده توسط روش‌های مختلف به منظور مقایسه آورده شده است. همانطور که مشاهده می‌شود روش‌های تک متغیره با جانهی یک مقدار ثابت، باعث تغییر زیادی در هیستوگرام به ویژه زمانی که نرخ سانسور بالا است، می‌شود. در شکل

جدول 3: NRSME برای روش‌های مختلف جانهی در دو حالت در نظر سانسور

NRSME					روش جانپى
حالت دوم	حالت اول				
	40%	25%	15%	7/5%	
50/516	2/738	3/510	5/034	6/053	<i>kNN (Aitch.)</i>
1/040	2/180	2/482	1/780	1/303	<i>lrDA</i>
0/530	0/950	1/072	1/047	1/054	<i>alr-EM</i>
0/504.	0/873	1/035	0/993	1/083	<i>ilr EM</i>
0/616	1/320	1/410	1/714	2/525	<i>SMR</i>
0/550	1/210	1/231	1/218	1/082	<i>MLNR</i>




شکل 1: خطای تخمین میانگین هندسی (چپ) و انحراف استاندارد (راست) برای روش‌های مختلف جانهی در حالت اول


ژئوشیمیایی استفاده کرد. روش‌های تک متغیره مانند جایگزینی ضریب لاگ نرمال زمانی که نسبت داده‌های سانسور پایین باشد (کمتر از 10٪) مناسب است و از نظر محاسبات کامپیوتری با توجه به حجم زیاد داده‌ها زمان کمتری نیاز دارد. بطور کلی روش‌های چند متغیره مدل پایه نتایج بهتری ارائه می‌کنند. استفاده از روش‌های چند متغیره با توجه به این که از روابط بین متغیرها را در نظر می‌گیرند، برای حفظ ساختار کوواریانس بین داده‌ها مناسب‌تر است. در بین روش‌های چند متغیره روش $ilr-EM$ نتایج بهتری ارائه می‌دهد.

7- نتیجه‌گیری

اغلب مجموعه داده‌های ژئوشیمیایی شامل داده‌های سانسور یا گم‌شده هستند که در برخی مواقع درصد گم‌شدگی باعث محدودیت استفاده از روش‌های آماری و ارب شدن نتایج تجزیه و تحلیل آنها می‌شود. از طرفی داده‌های ژئوشیمیایی ماهیت ترکیبی دارند که در روش‌های جانهی باید مورد توجه باشد. روش‌های مختلفی برای جانهی داده‌های گم‌شده برای داده‌هایی که ماهیت ترکیبی دارند ارائه شده است که می‌توان از آنها در داده‌های



شکل 2: هیستوگرام بریلیوم با داده‌های اصلی و بعد از جانهی مقادیر سانسور شده با روش‌های مختلف. الف) 75 درصد داده سانسور شده، ب) 15٪، ج) 25٪، د) 40٪ داده سانسور شده.



شکل 3: *Q-Q plot* بریلیموم داده‌های اصلی و بعد از جانهی مقادیر سانسور شده با روش‌های مختلف در حالتی که 25٪ داده سانسور شده است.

7- مراجع

R. B. (2001). Missing value estimation methods for DNA microarrays. *Bioinformatics*, 17(6), 520-525.
 [14] Sadeghian, M., & Ghaffary, M. (2011). The Petrogenesis of Zafarghand Granitoid Pluton (Se of Ardestan). *Petrology*, (6), 47-70. (In Persian)

- [1] Rubin, D. B., & Little, R. J. (2002). *Statistical analysis with missing data*. Hoboken, NJ: J Wiley & Sons.
 [2] Buccianti, A., & Grunsky, E. (2014). Compositional data analysis in geochemistry: Are we sure to see what really occurs during natural processes?. *Journal of Geochemical Exploration*, 141, 1-5.
 [3] Aitchison, J. (1986). *The Statistical Analysis of Compositional Data*. New York: Chapman and Hall. 416p.
 [4] Hron, K., Templ, M., & Filzmoser, P. (2010). Imputation of missing values for compositional data using classical and robust methods. *Computational Statistics & Data Analysis*, 54(12), 3095-3107.
 [5] de Caritat, P., & Grunsky, E. C. (2013). Defining element associations and inferring geological processes from total element concentrations in Australian catchment outlet sediments: multivariate analysis of continental-scale geochemical data. *Applied Geochemistry*, 33, 104-126.
 [6] Carranza, E. J. M. (2011). Analysis and mapping of geochemical anomalies using logratio-transformed stream sediment data with censored values. *Journal of Geochemical Exploration*, 110(2), 167-185.
 [7] Palarea-Albaladejo, J., & Martín-Fernández, J. A. (2013). Values below detection limit in compositional chemical data. *Analytica chimica acta*, 764, 32-43.
 [8] Palarea-Albaladejo, J., & Martín-Fernández, J. A. (2008). A modified EM algorithm for replacing rounded zeros in compositional data sets. *Computers & Geosciences*, 34(8), 902-917.
 [9] Martín-Fernández, J. A., Hron, K., Templ, M., Filzmoser, P., & Palarea-Albaladejo, J. (2012). Model-based replacement of rounded zeros in compositional data: classical and robust approaches. *Computational Statistics & Data Analysis*, 56(9), 2688-2704.
 [10] Palarea-Albaladejo, J., Martín-Fernández, J. A., & Buccianti, A. (2014). Compositional methods for estimating elemental concentrations below the limit of detection in practice using R. *Journal of Geochemical Exploration*, 141, 71-77.
 [11] Helsel, D. R. (2011). *Statistics for censored environmental data using Minitab and R* (Vol. 77). John Wiley & Sons.
 [12] Martín-Fernández, J. A., Barceló-Vidal, C., & Pawlowsky-Glahn, V. (2003). Dealing with zeros and missing values in compositional data sets using nonparametric imputation. *Mathematical Geology*, 35(3), 253-278.
 [13] Troyanskaya, O., Cantor, M., Sherlock, G., Brown, P., Hastie, T., Tibshirani, R., ... & Altman,

-
- 1- Missing data
 2- Below Detection limit
 3- Complete Case Analysis
 4- Impute
 5- Compositional
 6- Aitchison
 7- Simple multiplicative Replacement
 8- Lognormal multiplicative replacement
 9- Expectation Maximization
 10- Data augmentation
 11- Less than
 12- Greater than
 13- Detection limit
 14- Not missing at random
 15- Simple multiplicative replacement
 16- Multiplicative lognormal replacement
 17- likelihood-based
 18- k-nearest neighbor
 19- Outlier
 20- Robust
 21- additive logratio Expectation Maximization
 22- additive logratio
 23- additive logistic normal
 24- additive logratio Data augmentation
 25- Truncated
 26- Posterior distribution
 27- isometric logratio Expectation Maximization
 28- package
 29- Normalized Root Mean Squared Error

The Comparison of Appropriate Methods in Imputation of The Censored Values in the Geochemical Datasets

S. A. Hosseini¹, S. Eftekhari Mahabadi², O. Asghari^{3*}

1- PhD student, Simulation and Data Processing Laboratory, Dept. of Mining, University of Tehran, Iran

2- Assistant Professor, Dept. of Mathematics, Statistics and Computer Science, University of Tehran., Iran

3- Assistant Professor, Simulation and Data Processing Laboratory, Dept. of Mining, University of Tehran, Iran

* Corresponding Author: o.asghari@ut.ac.ir

(Received: March 2015, Accepted: October 2015)

Abstract

This study deals with the imputation methods of censored values in the multivariable geochemical data. Presence of the missing values causes limitation in the use of most of statistical methods, e.g. principle component analysis. Excluding the samples which include missing values bias the results and leads to the loss of information. Due to this, consideration of an appropriate approach to deal with missing values is necessary in the analysis of incomplete datasets. In this paper considering the nature of geochemical data, various approaches for imputing the missing values, which have been suggested in the recent years and are easy to be used in the R statistic software, are introduced. Finally, using the complete dataset of the Zafarghand region, these methods are compared with each other. Results show that the application of the multivariable methods in the imputation and particularly the ilr-EM method is preferable to the other methods.

Keywords

Geochemical Data, Censored Values, Imputation Methods, Compositional Nature, ilr-Em

Cite This Paper:

Hosseini, S. A., Eftekhari Mahabadi, S., Asghari, O. (2015). "The Comparison of Appropriate Methods in Imputation of the Censored Values in the Geochemical Datasets." Journal of Analytical and Numerical Methods in Mining Engineering 5(9): 63-72. [http://dx.medra.org/10.17383/S2251-6565\(15\)940916-X](http://dx.medra.org/10.17383/S2251-6565(15)940916-X)