Population Journal

Spring ۲۰۲۳, ۳۰(۱۲۳), ۱-۱۶

Home Page: https://www.population-journal.ir/

Missing Data Imputation Using Machine Learning: A Case Study on Imputing Maternal Age in Birth Records Registered in ۲۰۲۳

Sedigheh Omidvar Shalmani[۱]✉, Alireza Sajedi[۲]

۱. Corresponding Author, PhD is Statistics, National Population Monitoring Center, Civil Registration Organization, Tehran, Iran. E-mail: s.o۲۶۷@yahoo.com

۲. PhD is Statistics, National Population Monitoring Center, Civil Registration Organization, Tehran, Iran. E-mail: ali_sa۵٤@yahoo.com

ARTICLE INFO

Article type:
Research Article

Keywords:
Machin Learning, Missing Data Imputation, Missing Data Mechanism, Mother Age, Random Forest.

ABSTRACT

The accuracy of analyses and results can be substantially influenced by the absence of data in demographic studies. The objective of this investigation is to assess the efficacy of a variety of imputation techniques in ۲۰۲۳ to account for the absence of the maternal age variable in birth records. The efficacy of classical and machine learning-based imputation methods is evaluated in this study, taking into account varying missing data mechanisms and proportions. The results suggest that traditional methods are outperformed by machine learning-based methods, particularly the missForest algorithm, in terms of reducing imputation error. Nevertheless, traditional approaches, such as multiple imputation using chained equations, can also produce satisfactory results under specific circumstances. The significance of selecting an appropriate imputation method based on the dataset characteristics and missing data pattern is underscored by the results of this study.

Cite this article: Omidvar Shalmani, S., & Sajedi, A. R. (۲۰۲۳). Missing Data Imputation Using Machine Learning: A Case Study on Imputing Maternal Age in Birth Records Registered in ۲۰۲۳. *Population Journal*, *30*(۱۲۳), ۱-۱۶.

Extended Abstract

Introduction

A persistent challenge in the production of official statistics is the problem of missing data. Missingness occurs when values for certain variables are not recorded for a subset of, or all respondents.

Within vital registration systems, a notable example is the omission of the mother's date of birth on live birth records. Maternal age is a fundamental variable for demographic analysis and is indispensable for estimating key fertility indicators, most notably the Total Fertility Rate (TFR). The absence of precise maternal age information can introduce bias, distort fertility estimates, and lead to erroneous conclusions, ultimately undermining evidence-based decision-making in demographic and health policy.

Under varying assumptions regarding the proportion and mechanism of missingness, the objective of this study is to assess the implications of various imputation methods for maternal age.

Methods and Data

The dataset utilized in this study encompassed all registered births during the Persian calendar year ۱٤۰۲ (۲۰۲۳–۲۰۲٤ Gregorian year), obtained from the Population Information Database maintained by National Organization for Civil Registration of Iran. The analysis incorporated six variables: infant gender, birth order, province of birth occurrence, paternal age at birth, urban–rural classification of the birth location, and the primary variable of interest—maternal age at birth.

Six imputation methodologies were implemented to address absent values in maternal age data. These encompassed machine learning approaches, such as K-Nearest Neighbors (KNN), MiceForest, and MissForest, as well as statistical techniques, such as straightforward imputation, Expectation–Maximization (EM), and Multiple Imputation by Chained Equations (MICE). The investigation assessed the impact of different missingness mechanisms and proportions on the performance of imputation. Three distinct missing data mechanisms—Missing Completely at Random (MCAR), Missing at Random (MAR), and Missing Not at Random (MNAR)—were systematically simulated across varying missingness proportions in relation to maternal age.

Findings

The results of this study demonstrate that, across varying mechanisms and proportions of missingness, machine learning–based imputation methods consistently outperform traditional approaches. Among the conventional techniques, the MICE method exhibited markedly superior performance compared to simpler strategies such as mode imputation or the EM algorithm. Within the category of machine learning approaches, the performance of the KNN method was found to be closely aligned with that of MissForest; nevertheless, MissForest consistently proved to be the most effective method for imputing missing values of maternal age. Moreover, while the performance of MICE (a traditional method) was relatively comparable to that of MiceForest (a machine learning–based method), the latter demonstrated a clear and consistent advantage. Finally, the findings suggest that the effectiveness of machine learning–based imputation techniques is sensitive to both the underlying mechanism and the proportion of missingness.

Conclusion and Discussion

In this study, the performance of various imputation methods for handling missing values in maternal age within the Persian calendar year ۱٤۰۲ (۲۰۲۳–۲۰۲٤ Gregorian year) birth registration data was evaluated under different mechanisms and proportions of missingness. The findings revealed that machine learning–based approaches, particularly the MissForest algorithm, consistently outperformed traditional methods in reducing imputation error, as measured by RMSE. Among the traditional methods, Multiple Imputation by Chained Equations (MICE) also demonstrated favorable performance in many cases, with results approaching those of machine learning techniques. The evidence suggests that MICE may serve as a suitable alternative when the implementation of advanced methods is not feasible.

Analysis of method performance in relation to missingness mechanisms and proportions further indicated that machine learning–based approaches performed particularly well under MNAR with lower levels of missingness (۰٫۰۱–۰٫۱۵). However, as the proportion of missingness increased, these methods exhibited superior performance under completely random missingness.

From a practical perspective, this study underscores the importance of selecting an imputation method based on the type of missingness mechanism, the rate of missingness, and the characteristics of the dataset. The use of advanced approaches such as MissForest can enhance the accuracy of analyses and ensure more reliable results.

فصلنامهٔ جمعیت

بهار ۱۴۰۲، ۳۰(۱۲۳)، ۱۶-۱

سایت نشریه: https://www.population-journal.ir/

کاربرد یادگیری ماشین در جانهی داده‌های گمشده در مطالعات جمعیتی: مطالعهٔ موردی جانهی سن مادر در ولادت‌های ثبت‌شدهٔ سال ۱۴۰۲

صدیقه امیدوار شلمانی[1]✉، علیرضا ساجدی[2]

۱. نویسندهٔ مسئول، دکتری آمار، دفتر آمار و اطلاعات جمعیتی و مهاجرت، مرکز رصد جمعیت کشور، سازمان ثبت احوال کشور، تهران، ایران. رایانامه: s.o۲۶۷@yahoo.com

۲. دکتری آمار، دفتر آمار و اطلاعات جمعیتی و مهاجرت، مرکز رصد جمعیت کشور، سازمان ثبت احوال کشور، تهران، ایران. رایانامه: ali_sa۰۴@yahoo.com

اطلاعات مقاله

نوع مقاله:
علمی-پژوهشی

کلیدواژه‌ها:
جانهی داده‌های گمشده، جنگل تصادفی، سن مادر، مکانیسم گمشدگی داده‌ها، یادگیری ماشین.

چکیده

وجود داده‌های گمشده در مطالعات جمعیتی می‌تولند دقت تحلیل‌ها و نتایج را به‌طور قابل‌توجهی کاهش دهد. این پژوهش با هدف ارزیابی کارایی روش‌های مختلف جانهی داده‌های گمشده برای متغیر سن مادر در داده‌های ولادت سال ۱۴۰۲ انجام شده است. در این مطالعه، با درنظرگرفتن سازوکارها و نسبت‌های گمشدگی مختلف کارایی روش‌های کلاسیک و روش‌های مبتنی بر یادگیری ماشین بررسی شده است. نتایج مطالعه نشان می‌دهد روش‌های مبتنی بر یادگیری ماشین، به‌ویژه الگوریتم missForest، در کاهش خطای جانهی نسبت به روش‌های سنتی عملکرد بهتری دارند. بااین‌حال، روش‌های سنتی مانند جانهی چندگانه با معادلات زنجیره‌ای نیز در شرایط خاص نتایج مطلوبی ارائه داده‌اند. کارایی هر روش به نوع داده‌ها، نسبت گمشدگی و همچنین سازوکار گمشدگی داده‌ها بستگی دارد. یافته‌های این پژوهش بر اهمیت انتخاب روش جانهی مناسب براساس الگوی گمشدگی و ویژگی‌های داده‌ها تأکید دارد.

استناد: امیدوار شلمانی، صدیقه و ساجدی، علیرضا (۱۴۰۲). کاربرد یادگیری ماشین در جانهی داده‌های گمشده در مطالعات جمعیتی: مطالعهٔ موردی جانهی سن مادر در ولادت‌های ثبت‌شدهٔ سال ۱۴۰۲. *فصلنامهٔ جمعیت*، ۳۰(۱۲۳)، ۱۶-۱.

مقدمه

یکی از چالش‌های رایج در فرایند گردآوری آمارهای رسمی، وجود داده‌های گمشده[۱] است. اصطلاح گمشدگی به حالتی اشاره دارد که در آن برخی یا تمامی متغیرها برای تعدادی از واحدهای پاسخ‌دهنده ثبت نمی‌شوند. عوامل متعددی می‌توانند منجر به گمشدگی داده‌ها شوند، از جمله اشتباهات در مراحل گردآوری، اندازه‌گیری و ورود اطلاعات، ورود دستی داده‌ها، عدم تمایل پاسخ‌دهندگان به همکاری یا اجتناب از پاسخ به برخی سؤالات، ترک مطالعه پیش از اتمام آن، مشکلات سخت‌افزاری یا نرم‌افزاری، نقص در سیستم‌های جمع‌آوری داده‌ها و اختلال در زمان انتقال اطلاعات (متی و همکاران، ۲۰۱۱؛ امانوئل و همکاران، ۲۰۲۱؛ آستین و همکاران، ۲۰۲۱؛ جگادسیواری و همکاران، ۲۰۲۲؛ ریزوی و همکاران، ۲۰۲۳؛ لی و همکاران، ۲۰۲۴).

شکاف‌های موجود در داده‌ها به‌دلیل گمشدگی می‌تواند پیامدهای متعددی داشته باشد، از جمله کاهش بازنمایی نمونه، افزایش خطا یا ابهام در تفسیر داده‌ها، ایجاد اریبی در تحلیل‌های آماری، کاهش توان آماری، دقت پایین در محاسبه شاخص‌های مربوطه، تأثیر منفی بر عملکرد مدل‌های پیش‌بینی، کاهش دقت پیش‌بینی‌ها، مدل‌سازی ناکارآمد که درنهایت منجر به تولید نتایج نامعتبر می‌شوند (هاول، ۲۰۰۷؛ امانوئل و همکاران، ۲۰۲۱؛ فؤاد و همکاران،۲۰۲۱؛ ریزوی و همکاران،۲۰۲۳؛ لی و همکاران،۲۰۲۴). برای مدیریت داده‌های گمشده دو روش وجود دارد؛ روش اول حذف سطرها یا ستون‌های حاوی مقادیر گمشده است. این روش ساده به‌طور گسترده‌ای برای مدیریت مقادیر گمشده در طول پیش‌پردازش داده‌ها استفاده شده است (وانگ و همکاران، ۲۰۲۲b). اگرچه این روش در شرایطی که مجموعه داده‌ها بسیار بزرگ بوده و نرخ گمشدگی پایین است، قابل‌استفاده است (لین و همکاران، ۲۰۱۷)، اما در داده‌های با نرخ گمشدگی بالا کارایی چندانی ندارد. در چنین مواردی، ممکن است اطلاعات ارزشمندی که در داده‌های گمشده نهفته است، از دست برود (فؤاد و همکاران، ۲۰۲۱؛ جگادسیواری و همکاران، ۲۰۲۲). همچنین در مجموعه داده‌های کوچک، حذف موارد گمشده می‌تواند نتایج تحلیل را تحت تأثیر قرار دهد (ریزوی و همکاران، ۲۰۲۳). روش دوم برای مدیریت داده‌های گمشده، جایگزینی آن‌ها با یک مقدار مناسب است که به آن جانهی داده‌های گمشده[۲] گفته می‌شود (فؤاد و همکاران، ۲۰۲۱؛ لی و همکاران، ۲۰۲۴). برای جانهی داده‌های گمشده، رویکردهای متعددی مورد بررسی قرار گرفته است که از روش‌های آماری کلاسیک تا الگوریتم‌های یادگیری ماشین را شامل می‌شوند. روش‌های آماری مانند میانگین، مد، میانه، درون‌یابی خطی، رگرسیون و روش‌های یادگیری ماشین مانند K–نزدیک‌ترین همسایگی، جنگل تصادفی، شبکه عصبی و درخت تصمیم از جملهٔ این رویکردها هستند. بااین‌حال، هیچ نتیجهٔ قطعی درخصوص بهترین مدل جانهی وجود ندارد؛ زیرا کارایی هر روش به نوع داده‌ها، نسبت و سازوکار گمشدگی داده‌ها بستگی دارد (لین و همکاران، ۲۰۱۷؛ آستین و همکاران، ۲۰۲۱؛ ریزوی و همکاران، ۲۰۲۳).

یکی از موارد گمشدگی در ولادت‌های ثبتی، عدم درج تاریخ تولد مادر در ثبت رویداد ولادت است که مرتبط با برخی فرایندهای قانونی از جمله تنظیم سند براساس رأی ابطال و صدور، موارد مشمول بند ۶ ماده ۹۷۶ قانون مدنی و مواردی از ماده ۴۵ قانون ثبت‌احوال است. در این موارد برای جلوگیری از طولانی‌شدن فرایند ثبت، رویداد ولادت با عدم درج برخی اقلام اطلاعاتی به ثبت می‌رسد. در این راستا، در این مقاله، شش روش جانهی مبتنی بر روش‌های آماری کلاسیک (روش‌های جانهی ساده[۳]، امیدگیری- بیشینه‌سازی[۴] (EM) و جانهی چندگانه با معادلات زنجیره‌ای[۵] (MICE) و یادگیری ماشین (K–نزدیک‌ترین همسایگی[۶]، MiceForest و MissForest) برای داده‌های مربوط به موارد نامشخص سن مادر از مجموعه داده‌های ولادت سال ۱۴۰۲ انتخاب شده است. همچنین برای ارزیابی روش‌های جانهی، از نرم‌افزار پایتون[۷] استفاده شده است.

سن مادر به‌عنوان یکی از متغیرهای کلیدی در تحلیل داده‌های ولادت، نقش مهمی در محاسبهٔ شاخص‌های باروری به‌ویژه

---

۱. Missing data
۲. Missing data imputation
۳. Simple
٤. Expectation-Maximization
٥. Multiple Imputation by Chained Equations
٦. K-Nearest Neighbors
۷. Python

میزان باروری کل دارد. نبود اطلاعات دقیق درمورد سن مادر ممکن است منجر به محاسبات نادرست یا ناقص و ارائه نتایج گمراه‌کننده درمورد این شاخص‌ها شود که می‌تواند تصمیم‌گیری‌های نادرستی را در زمینهٔ سیاست‌های جمعیتی و بهداشتی به همراه داشته باشد. این مقاله تلاش کرده است تا با درنظرگرفتن مقادیر مختلف برای نسبت و سازوکارهای گمشدگی، تأثیر روش‌های جانهی بر متغیر سن مادر را مورد ارزیابی قرار دهد.

پیشینه تحقیق

مطالعات متعددی به بررسی و توسعه روش‌های جانهی داده‌های گمشده پرداخته‌اند. روبین (۱۹۷۶) برای اولین بار سازوکارهای گمشدگی داده‌ها را به سه دستهٔ گمشدگی کاملاً تصادفی[۱] (MCAR) گمشدگی تصادفی[۲] (MAR) و گمشدگی غیرتصادفی[۳] (MNAR) تقسیم‌بندی کرد و این چارچوب به‌عنوان پایه‌ای برای تحقیقات بعدی در این حوزه مورد استفاده قرار گرفت. او تأکید کرد که شناخت سازوکار گمشدگی برای انتخاب روش مناسب جانهی ضروری است؛ زیرا هر سازوکار گمشدگی تأثیر متفاوتی بر نتایج تحلیل‌ها دارد.

در سال‌های بعد، روش‌های آماری سنتی مانند جانهی ساده، جانهی EM و جانهی چندگانه[۴] توسعه یافتند. روش جانهی ساده شامل جایگزینی مقادیر گمشده با میانگین، میانه یا مد است که در مطالعات اولیه مورد استفاده قرار گرفته‌اند (لیتل و روبین، ۲۰۰۲). هرچند این روش‌ها ساده و سریع هستند، اما اغلب منجر به تخمین‌های نادرست و کاهش تغییرپذیری داده‌ها می‌شوند. الگوریتم EM به‌عنوان یک روش تکرارشونده برای برآورد پارامترها در حضور داده‌های گمشده توسط دمپستر و همکاران (۱۹۷۷) پیشنهاد و به‌دلیل توانایی در مدل‌سازی روابط پیچیده بین متغیرها، در بسیاری از تحقیقات به‌کار گرفته شد. به‌عنوان مثال، اسکفر (۱۹۹۷) از الگوریتم EM برای جانهی داده‌های چندمتغیره با توزیع نرمال استفاده کرد و نشان داد که این روش در مقایسه با روش‌های ساده‌تر مانند جانهی میانگین برآوردهای دقیق‌تری ارائه می‌دهد. همچنین، گراهام و همکاران (۲۰۰۷) نشان دادند الگوریتم EM در جانهی داده‌های گمشده با الگوی گمشدگی تصادفی نتایج قابل‌اطمینان‌تری تولید می‌کند. این مطالعات نشان می‌دهند که الگوریتم EM به‌دلیل رویکرد تکراری و مبتنی بر احتمال، یکی از روش‌های مؤثر برای جانهی داده‌های گمشده در تحقیقات مختلف بوده است.

جانهی چندگانه توسط روبین (۱۹۸۷) معرفی شد. این روش با تولید چندین مجموعه داده جانهی‌شده و ترکیب نتایج حاصل از تحلیل‌های انجام‌شده بر روی هر مجموعه داده، امکان محاسبه دقیق‌تر خطای استاندارد و فواصل اطمینان را فراهم می‌سازد. رویکرد اصلی این روش، درنظرگرفتن عدم قطعیت ذاتی ناشی از فرایند جانهی است که آن را از روش‌های تک‌مقداری متمایز می‌کند. مطالعات متعددی مانند آزور و همکاران (۲۰۱۱) و وایت و همکاران (۲۰۱۱) کارایی این روش را مورد بررسی قرار داده و نشان دادند که روش جانهی چندگانه تحت سازوکارهای مختلف گمشدگی داده‌ها بهینه عمل می‌کنند.

با گسترش الگوریتم‌های پیشرفته‌تر مانند MICE که توسط ون بورن و گروتویس–اودشوین (۲۰۱۱) توسعه یافت، امکان مدلسازی جداگانه برای هر متغیر با توجه به نوع آن فراهم شد که این امر تحولی در کاربردهای عملی این روش ایجاد کرده است. روش‌های جانهی چندگانه کاربردهای متعددی در حوزه‌های جمعیتی، تحقیقات اپیدمیولوژیک، پزشکی و پژوهش‌های اقتصادی–اجتماعی داشته که نشان‌دهنده آن است که جانهی چندگانه، به‌ویژه در ترکیب با روش‌های پیشرفته‌تر، می‌تواند تا حد زیادی از سوگیری‌های ناشی از داده‌های گمشده جلوگیری کند (آستین و همکاران، ۲۰۲۱؛ بیسلی و همکاران، ۲۰۲۱؛ وانگ و همکاران، ۲۰۲۲b؛ لی و همکاران، ۲۰۲۴).

با پیشرفت فناوری و گسترش روش‌های یادگیری ماشین، رویکردهای نوینی برای جانهی داده‌های گمشده توسعه یافتند. در این میان، ترویاتسکایا و همکاران (۲۰۰۱) روش K را به‌عنوان نزدیک‌ترین همسایگی را به‌عنوان یک راهکار ساده اما مؤثر برای

۱. Missing Completely at Random
۲. Missing at Random
۳. Missing Not at Random
٤. Multiple imputation

جانهی معرفی کردند. این روش با بهره‌گیری از مفهوم شـــباهت بین نمونه‌های داده، مقادیر گمشـــده را پیش‌بینی می‌کند. مزیت اصلی این روش، انعطاف‌پذیری بالا و عدم نیاز به فرضیات پارامتری دربارهٔ توزیع داده‌ها است که باعث شده در حوزه‌های متنوعی از جمله علوم زیستی تا پژوهش‌های اجتماعی به‌طور گسترده مورد استفاده قرار گیرد (جرز و همکاران، ۲۰۱۰؛ دی سیلوا و پررا، ۲۰۱۶؛ پوجیانتو و همکاران، ۲۰۱۹؛ ریزوی و همکاران، ۲۰۲۳؛ ســـانیا و همکاران، ۲۰۲۵). بااین‌حال، مطالعات متعددی به محدودیت‌های این روش نظیر حساسیت به انتخاب تعداد همسایگی (K) و هزینهٔ محاسباتی بالا در مجموعه داده‌های بزرگ اشاره کرده‌اند (باتیستاو مونارد، ۲۰۰۳؛ رحمان و اسلام، ۲۰۱۳، و لیو و همکاران، ۲۰۱۵، عابدین و اسماعیل، ۲۰۲۱). در پاسخ به این چالش‌ها، پژوهشـــگران روش‌های بهبودیافته‌ای را ارائه کرده‌اند که کارایی الگوریتم‌های مبتنی بر روش KNN را افزایش داده‌اند (امانوئل و همکاران، ۲۰۲۱).

در دهه‌های اخیر، الگوریتم‌های مبتنی بر جنگل تصـادفی[۱] به‌دلیل توانایی در مدیریت داده‌های پیچیده و غیرخطی مورد توجه پژوهشگران قرار گرفته‌اند (استخوون و بولمان، ۲۰۱۲؛ والجی و همکاران، ۲۰۱۳؛ داو و همکاران، ۲۰۱۴؛ تانگ و ایشواران، ۲۰۱۷؛ الصـابر و همکاران، ۲۰۲۱؛ پترازینی و همکاران، ۲۰۲۱؛ وانگ و همکاران، ۲۰۲۲a و لی و همکاران، ۲۰۲۴). از جملهٔ این روش‌ها الگوریتم missForest اسـت که توسـط اسـتخوون و بوهلمن (۲۰۱۲) توسـعه یافت. این الگوریتم با به‌کارگیری رویکرد تکراری جنگل تصادفی، مقادیر گمشده را با دقت بالایی پیش‌بینی می‌کند. مطالعات متعددی نشان داده‌اند که missForest در مقایسه با روش‌های سنتی جانهی، عملکرد بهتری در داده‌های چندبعدی دارد (والجی و همکاران، ۲۰۱۳؛ تانگ و ایشواران، ۲۰۱۷؛ الصابر و همکاران، ۲۰۲۱؛ پترازینی و همکاران، ۲۰۲۱؛ وانگ و همکاران، ۲۰۲۲a). بااین‌حال در کاربرد این روش، برخی محدودیت‌ها نظیر وجود اریبی در برآوردها به‌دلیل داده‌های با گمشـدگی غیرتصـادفی یا همبسـتگی بالا بین متغیرها گزارش شـده اسـت (شـاه و همکاران، ۲۰۱۴؛ هانگ و لین، ۲۰۲۰؛ آراکری و همکاران، ۲۰۲۳). همچنین روش MICEForest به‌عنوان ترکیبی از روش جانهی چندگانه (MICE) و جنگل تصادفی توسعه یافته که با ادغام قابلیت‌های این دو روش، انعطاف‌پذیری و دقت بیشتری را در مقایسه با روش‌های پیشین ارائه می‌دهد (داو و همکاران، ۲۰۱۴).

در حوزهٔ مطالعات جمعیتی، داده‌های گمشـــده به‌ویژه در متغیرهای کلیدی مانند سـن مادر، چالش‌های جدی برای محاسـبهٔ شاخص‌هایی نظیر نرخ باروری کل ایجاد می‌کند. امانوئل و همکاران (۲۰۲۱) نشان دادند که استفاده از روش‌های پیشرفته جانهی، به‌ویژه زمانی که نسبت گمشدگی بالا باشد، می‌تواند دقت تحلیل‌های جمعیتی را بهبود بخشند. همچنین لی و همکاران (۲۰۲۴) در مطالعه‌ای بر روی داده‌های ثبتی به کارایی بالای روش‌های یادگیری ماشین در مقایسه با روش‌های سنتی اشاره و بر اهمیت انتخاب روش مناسب با توجه به الگوی گمشدگی تأکید کرده‌اند.

روش‌شناسی

سـازوکار گمشـدگی داده‌ها: برای تعریف سـازوکارهای گمشـدگی داده‌ها، فرض کنید X ماتریس کل مجموعه داده‌ها باشـد که شـامل p سـتون و n سـطر اسـت ($X = [X_{ij}; i = ۱, \dots, n,\ j = ۱, \dots p]$). ماتریس نشـانگر $R = [R_{ij}; i = ۱, \dots, n,\ j = ۱, \dots p]$ به‌صورت زیر تعریف می‌شود:

$$R_{ij} = \begin{cases} ۱ & X_{ij} \text{ گمشده است} \\ ۰ & \text{در غیر این صورت} \end{cases}$$

در این صـورت، R ماتریس الگوی گمشـدگی X نامیده می‌شـود. براسـاس این تعریف، ماتریس X را می‌توان به دو بخش داده‌های مشاهده شده و گمشده به‌صورت $X = (X_{obs}, X_{mis})$ تجزیه کرد. به‌منظور تعریف سازوکارهای گمشـدگی مختلف، فرض کنید X و R متغیرهای تصـادفی با توابع توزیع احتمال P_X و P_R باشـند و پارامتر توزیع گمشـدگی P_R را با ϕ نشـان می‌دهیم.

۱. Random forest

گمشدگی کاملاً تصادفی (MCAR): در این حالت احتمال گمشدگی به هیچ‌یک از مقادیر مشاهده‌شده و گمشده بستگی ندارد. به عبارت دیگر:

$$P_R(R|\, X;\phi) = P_R(R) \qquad \forall\phi$$

به‌عنوان مثال، فرض کنید در یک نظرسنجی برخی از پاسخ‌دهندگان به‌طور تصادفی به یک یا چند سؤال پاسخ ندهند. در این حالت، عدم پاسخ‌دهی به هیچ ویژگی خاصی از پاسخ‌دهندگان یا سؤالات بستگی ندارد و کاملاً تصادفی است.

گمشدگی تصادفی (MAR): در این حالت احتمال گمشدگی تنها به مقادیر مشاهده‌شده (یعنی X_{obs}) بستگی دارد. در این صورت:

$$P_R(R|X;\phi) = P_R(R|X_{obs};\phi) \qquad \forall\phi, X_{mis}$$

در این وضعیت، احتمال گمشدگی یک مقدار خاص به مقادیر سایر متغیرها بستگی دارد؛ بنابراین، یک عامل مشترک را می‌توان در تمام مشاهداتی که مقادیر گمشده دارند شناسایی کرد. به عنوان‌مثال فرض کنید در یک مطالعهٔ پزشکی، برخی از بیماران به‌دلیل سن بالا یا وضعیت سلامتی ضعیف‌تر نتوانند در برخی از آزمایش‌ها شرکت کنند. در این حالت، گمشدگی داده‌ها به ویژگی‌های مشاهده‌شده (سن یا وضعیت سلامتی) بستگی دارد اما به مقادیر گمشده وابسته نیست.

گمشدگی غیرتصادفی (MNAR): گمشدگی غیرتصادفی زمانی رخ می‌دهد که احتمال گمشدگی به مقادیر گمشده و مشاهده‌شده بستگی داشته باشد. به عبارت دیگر:

$$P_R(R|X;\phi) = P_R(R|X_{obs}, X_{mis};\phi) \qquad \forall\phi, X_{obs}, X_{mis}$$

در این روش معمولاً مدیریت مقادیر گمشده غیرممکن است؛ زیرا به داده‌های مشاهده نشده بستگی دارد. به عنوان مثال، در یک نظرسنجی درمورد درآمد، افرادی که درآمد بالاتری دارند ممکن است تمایلی به افشای درآمد خود نداشته باشند، و این احتمال گمشدگی در مردان بیشتر از زنان است. در این حالت گمشدگی داده‌ها هم به متغیر جنسیت و هم به مقادیر گمشده (درآمد بالا) بستگی دارد.

برای ارزیابی عملکرد نوع سازوکار گمشدگی داده‌ها و انواع روش‌های جانهی داده‌های گمشده، لازم است مقادیر گمشده شبیه‌سازی شوند. اگر داده‌ها از قبل شامل مقادیر گمشده باشند، به‌دلیل عدم دسترسی به مقادیر واقعی، ابتدا باید مقادیر گمشده نادیده گرفته شوند. سپس با استفاده از سازوکارهای گمشدگی، مقادیر معلوم در داده‌ها حذف و درنهایت از روش‌های مختلف برای جانهی داده‌ها استفاده شود. در این مقاله برای تولید داده‌های گمشده تحت سه سازوکار گمشدگی مختلف از کدهای ارائه‌شده توسط موزلک و همکاران (۲۰۲۰) استفاده شده است.

روش‌های جانهی داده‌های گمشده

۱. جانهی ساده (Simple)

در این روش، مقادیر گمشده با یک مقدار ثابت یا آماره‌های محاسبه‌شده از بخش غیرگمشده هر ستونی که داده‌های گمشده در آن قرار دارند، جایگزین می‌شوند. این آماره‌ها می‌توانند شامل میانگین یا میانه برای متغیرهای کمی و مد برای متغیرهای کیفی باشند.

روش جانهی ساده به‌دلیل سادگی در اجرا، در بسیاری از مطالعات به‌عنوان یک روش مرجع متداول شناخته می‌شود. بااین‌حال، این روش به‌دلیل نادیده‌گرفتن همبستگی‌های بین ویژگی‌ها در مجموعه داده‌هایی با روابط پیچیده، ممکن است نتایج نادرست یا اریب ایجاد کند. همچنین در دنیای داده‌های با حجم بالا، این روش ممکن است عملکرد ضعیفی داشته و درنتیجه برای پیاده‌سازی روی چنین مجموعه‌های داده‌ای ناکافی باشد (خان و هوک، ۲۰۲۰؛ فؤاد و همکاران، ۲۰۲۱؛ لی و همکاران، ۲۰۲۴).

۲. جانهی امیدگیری–بیشینه‌سازی (EM)

الگوریتم امیدگیری–بیشینه‌سازی (EM) یک ابزار قدرتمند و روش تکراری برای جانهی داده‌های گمشده است. این الگوریتم از رویکرد «جایگزینی، برآورد و تکرار تا همگرایی» استفاده می‌کند. هر تکرار شامل دو مرحلهٔ امیدگیری و بیشینه‌سازی است. در مرحلهٔ امیدگیری، امید ریاضی مقادیر گمشده براساس داده‌های مشاهده‌شده محاسبه می‌شود. در مرحلهٔ بیشینه‌سازی، از داده‌های مشاهده‌شده و مقادیر برآوردشده مقادیر گمشده که در مرحله امیدگیری به‌دست آمده‌اند، برای بیشینه‌سازی توزیع احتمال داده‌های کامل (شامل مقادیر گمشده و مشاهده‌شده) استفاده می‌شود (امانوئل و همکاران، ۲۰۲۱).

مطالعات متعدد نشان داده‌اند که بسته به نوع داده‌های مورد مطالعه، روش EM عملکرد بهتری نسبت به روش‌های جانهی ساده نظیر حذف لیستی[۱] و رگرسیونی دارد (روبین و همکاران، ۲۰۰۷). بااین‌حال، این روش به‌ویژه در مجموعه داده‌های با ابعاد بالا نیازمند محاسبات ماتریسی پیچیده و پرهزینه است (دلالو و همکاران، ۲۰۱۲). علاوه‌براین، به‌دلیل اینکه این روش از کل اطلاعات داده‌ها برای جانهی مقادیر گمشده استفاده می‌کند فقط برای مجموعه داده‌هایی که همبستگی قوی بین ویژگی‌ها دارند، مناسب است (دب و لئو، ۲۰۱۶).

۳. جانهی چندگانه با معادلات زنجیره‌ای (MICE)

یکی از تکنیک‌های آماری مدیریت داده‌های گمشده، روش جانهی چندگانه است که در آن به‌جای جانهی ساده، از مدل‌های آماری مختلف برای جانهی یک مقدار گمشده استفاده می‌شود. نتایج به‌دست‌آمده از هریک از مجموعه داده‌های جانهی‌شده به‌طور مجزا تحلیل و سپس با استفاده از روش‌های ترکیبی مناسب با یکدیگر ترکیب می‌شوند (روبین، ۱۹۸۷). این رویکرد عدم قطعیت مرتبط با داده‌های گمشده را درنظر گرفته و طیفی از مقادیر قابل‌قبول برای مشاهدات گمشده ارائه می‌دهد.

اگرچه روش‌های جانهی چندگانه در عمل پیچیده به‌نظر می‌رسند، اما برخلاف روش‌های جانهی ساده، تحت تأثیر اریبی قرار نمی‌گیرند و خطای ناشی از جانهی کاهش می‌یابد (آزور و همکاران، ۲۰۱۱؛ خان و هوک، ۲۰۲۰). یکی از تکنیک‌های جانهی چندگانه که به‌طور گسترده مورد استفاده قرار گرفته است روش MICE است که برای جانهی مقادیر گمشده از چندین مدل رگرسیونی استفاده می‌کند. این روش به‌صورت تکراری و زنجیره‌ای عمل کرده و هر متغیر گمشده را به‌عنوان تابعی از سایر متغیرها مدلسازی می‌کند.

۴. جانهی K- نزدیک‌ترین همسایگی (KNN)

روش KNN یکی از روش‌های یادگیری ماشین نظارت‌شده[۲] برای جانهی مقادیر گمشده است. در این روش، ابتدا k نزدیک‌ترین همسایگی که بیشترین شباهت را به دادهٔ گمشده دارند شناسایی می‌شوند. سپس مقادیر گمشده با استفاده از مقادیر غیرگمشده (مشاهده‌شده) نقاط همسایگی برآورد می‌شوند. برای اندازه‌گیری شباهت از معیارهای فاصله مانند فاصلهٔ مینکوفسکی[۳]، فاصلهٔ منهتن[۴]، فاصلهٔ همینگ[۵] و فاصلهٔ اقلیدسی[۶] استفاده می‌شود که فاصلهٔ اقلیدسی رایج‌ترین آن است (داو و همکاران، ۲۰۱۴). از مزایای این روش می‌توان به‌سادگی در اجرا، انعطاف‌پذیری در برابر نوع داده (اعم از گسسته یا پیوسته)، امکان جانهی هم‌زمان مقادیر گمشده در چندین ویژگی یا ستون و عدم نیاز به فرضیات قوی درمورد توزیع داده‌ها اشاره کرد (امانوئل و همکاران، ۲۰۲۱؛ اسماعیل و همکاران، ۲۰۲۲؛ گلدانی، ۲۰۲۴).

اگرچه این روش به‌دلیل کارایی بالا در جانهی داده‌های گمشده، به‌طور گسترده در مطالعات مورد توجه قرار گرفته و نسخه‌های بهبودیافته آن توسط محققان متعددی معرفی شده است (زو و چنگ، ۲۰۱۵؛ پوجیانتو و همکاران، ۲۰۱۹)، اما هنوز هیچ روش استاندارد و اثبات‌شده‌ای برای انتخاب بهترین پارامترهای آن نظیر تعداد همسایه‌ها و معیار فاصله وجود ندارد. این امر

۱. List_wise
۲. Supervised machine learning
۳. Minkowski distance
٤. Manhattan distance
٥. Hamming distance
٦. Euclidean distance

می‌تواند منجر به نتایج متفاوت و ناپایدار در مطالعات مختلف شود. علاوه‌براین، در برخی مطالعات اثر سازوکارهای گمشدگی نادیده گرفته شده است که این موضوع می‌تواند منجر به نتایج غیرواقعی و اریب شود. استفاده از این روش در مجموعه داده‌های بزرگ نیز به‌دلیل نیاز به جستجو در کل مجموعه داده برای یافتن رکوردهای مشابه ممکن است هزینه‌بر باشد (رحمان و اسلام، ۲۰۱۳؛ فؤاد و همکاران، ۲۰۲۱).

۵. روش جانهی مبتنی بر جنگل‌های تصادفی

الگوریتم‌های جانهی داده‌های گمشده مبتنی بر جنگل تصادفی[۱] (RF) یکی از روش‌های مؤثر برای جانهی داده‌های گمشده هستند. این الگوریتم برمبنای مفهوم یادگیری جمعی[۲] و به‌ویژه تکنیک ادغام نمونه‌های بوت‌استرپ[۳] بنا شده است (بریمن، ۲۰۰۱). در این روش، مجموعه‌ای از درخت‌های تصمیم[۴] به‌صورت مستقل و موازی آموزش داده می‌شوند. برای آموزش هر درخت، یک نمونه بوت‌استرپ از داده‌ها استخراج و در هر گام از تقسیم گره، تنها یک زیرمجموعهٔ تصادفی از ویژگی‌ها برای انتخاب بهترین تقسیم‌بندی مورد استفاده قرار می‌گیرد. این سازوکار باعث ایجاد تنوع بالا در بین درخت‌های تصمیم شده و از بیش‌برازش[۵] مدل پایه (درخت تصمیم منفرد) جلوگیری می‌کند. نتیجه نهایی از طریق تجمیع[۶] خروجی تمامی درخت‌ها به‌دست می‌آید، به این صورت برای متغیرهای طبقه‌ای از رأی‌گیری اکثریت[۷] و برای متغیرهای عددی از میانگین‌گیری استفاده می‌شود.

الگوریتم جنگل تصادفی با برخورداری از ویژگی‌هایی مانند توانایی مدیریت انواع مختلف داده‌های گمشده، مدلسازی روابط غیرخطی و برهمکنش بین متغیرها، قابلیت مقیاس‌پذیری برای داده‌های بزرگ، به‌عنوان روشی انعطاف‌پذیر و با دقت بالا، به‌صورت گسترده در جانهی داده‌های گمشده مورد استفاده قرار می‌گیرد (تانگ و ایشواران، ۲۰۱۷). در حال حاضر، الگوریتم‌های جانهی RF مختلفی وجود دارند. در این مقاله به دو الگوریتم missForest و MICEForest می‌پردازیم.

۵-۱. روش جانهی missForest

الگوریتم missForest یک تکنیک جانهی مبتنی بر یادگیری ماشینی است که در آن از الگوریتم جنگل تصادفی برای جانهی داده‌های گمشده استفاده می‌شود. این الگوریتم توسط استخوون و بولمان در سال ۲۰۱۲ معرفی شد. روش جانهی missForest با یک حدس ابتدایی برای مقادیر گمشده آغاز می‌شود و تا رسیدن به معیار همگرایی، از فرایند برازش مدل جنگل تصادفی بر روی بخش مشاهده‌شده از مجموعه داده‌ها برای پیش‌بینی و به‌روزرسانی مقادیر داده‌های گمشده استفاده می‌کند. این الگوریتم علاوه بر آنکه برای داده‌های پیوسته و گسسته مناسب است و نیازی به تنظیم پارامترها یا فرضیات خاص ندارد، نتایج بسیار خوبی در داده‌های پیچیده با ابعاد بالا ارائه داده است. همچنین، در مقایسه با روش‌های دیگر مانند روش KNN و MICE، عملکرد بهتری نشان داده و می‌تواند کیفیت جانهی را بدون نیاز به داده‌های آزمون یا اعتبارسنجی پیچیده ارزیابی کند (والجی و همکاران، ۲۰۱۳). بااین‌حال برخی مطالعات اشاره کرده‌اند که برآوردهای حاصل از روش missForest برای متغیرهای به‌طور تصادفی گمشده اریب بوده و فواصل اطمینان حاصل از آن پوشش ضعیفی دارند (شاه و همکاران، ۲۰۱۴).

۵-۲. جانهی MICEForest

روش جانهی MICEForest یک روش پیشرفته برای جانهی داده‌های گمشده است که با استفاده از جنگل‌های تصادفی به‌عنوان مدل جانهی، اصول MICE را گسترش داده و انعطاف‌پذیری MICE را با توان پیش‌بینی جنگل‌های تصادفی ترکیب می‌کند. این روش به‌دلیل دقت بالا و انعطاف‌پذیری در مدیریت داده‌های گمشده بسیار مورد توجه قرار گرفته است (داو و همکاران، ۲۰۱۴).

---

۱. Random Forest
۲. Ensemble Learning
۳. Bootsrap aggregation
٤. Decision trees
٥. Overfitting
٦. Aggregation
۷. Majority Voting

اگرچه هر دو الگوریتم مذکور از جنگل تصادفی برای جانهی داده‌های گمشده استفاده می‌کنند، یک تفاوت اصلی در اجرا وجود دارد. در الگوریتم missForest تمرکز بر جانهی واحد است، به این معنی که برای جانهی داده‌های گمشده از جنگل تصادفی استفاده شده و این فرآیند تا زمانی که مقادیر جانهی‌شده بهبود یابند تکرار می‌شود. اما در روش MICEForest جانهی‌های متعددی برای مقادیر گمشده درنظر گرفته می‌شود که می‌تواند رویکرد جامع‌تری برای مدیریت داده‌های گمشده فراهم نماید.

منبع داده‌ها

داده‌های مورد بررسی در این مطالعه ولادت‌های رخداده در سال ۱۴۰۲ است که در پایگاه اطلاعات جمعیت کشور ثبت شده‌اند. برای اهداف این مطالعه، هشت متغیر جنسیت فرزند، مرتبه ولادت، استان محل رخداد ولادت، چندقلوزایی، سن پدر در زمان ولادت فرزند، شهری یا روستایی بودن ولادت، فاصله ازدواج تا تولد فرزند و متغیر اصلی یعنی سن مادر در زمان ولادت فرزند درنظر گرفته شده‌اند. آماره‌های توصیفی برای متغیرهای پیوسته و گسسته و درصد رکوردهای دارای مقادیر گمشده برای هر متغیر در جدول ۱ ارائه شده است.

یافته‌های تحقیق

آماره‌های توصیفی و درصد رکوردهای دارای مقادیر گمشده برای هر متغیر در جدول ۱ ارائه شده است. با توجه به جدول ۱، درصد گمشدگی داده‌ها از صفر درصد در متغیرهای جنسیت فرزند، نوع ولادت (شهری یا روستایی) و چندقلوزایی تا ۲.۱ درصد در متغیر فاصله ازدواج تا تولد فرزند متغیر است. به‌منظور بررسی دقت روش‌های جانهی پیشنهادی و حذف اثر مقادیر گمشده بر نتایج به‌دست‌آمده، رکوردهایی که مقادیر هر یک از متغیرها در آن‌ها نامشخص است قبل از مطالعه از مجموعه داده‌ها حذف شده‌اند. با حذف این موارد، تعداد ۱۰۲۱۷۲۷ رکورد با اطلاعات کامل وارد مطالعه شده‌اند.

برای بررسی اثر سازوکار گمشدگی داده‌ها و نسبت گمشدگی بر روی روش‌های جانهی معرفی‌شده، سه سازوکار گمشدگی شامل MAR، MCAR و MNAR و نسبت‌های گمشدگی ۰.۲ ,۰.۱۵، ۰.۱، ۰.۰۵، ۰.۰۱ $= p$ بر روی متغیر سن مادر درنظر گرفته شده است. مقادیر واقعی سن مادر قبل از اعمال سازوکار گمشدگی و بعد از حذف و برازش آن با استفاده از روش‌های جانهی مورد بررسی و مقایسه قرار گرفته‌اند. از شاخص ریشه توان دوم خطا[۱] (RMSE) برای ارزیابی روش‌های جانهی مختلف استفاده شده است که به‌صورت زیر تعریف می‌شود:

$$RMSE_{Method} = \sqrt{\frac{1}{m}\sum_{i=1}^{m}(x_i - \hat{x_i})^2}$$

که در آن m تعداد داده‌های گمشده در مجموعه داده، x_i مقدار واقعی و $\hat{x_i}$ مقدار داده جانهی‌شده توسط هر یک از روش‌های جانهی و اندیس «Method» اشاره به یکی از روش‌های جانهی داده‌های گمشده دارد. در جانهی ساده، مقادیر نامشخص سن مادر با مقداری که بیشترین فراوانی را دارد (مد[۲]) جایگزین شده است. همچنین به‌منظور انتخاب مقدار K بهینه در روش KNN از روش جستجوی شبکه‌ای[۳] براساس معیار RMSE بر روی مقادیر K=۲،۳,...,۹ استفاده شده است. کارایی روش‌های مختلف جانهی داده‌های نامشخص سن مادر به ازای مقادیر مختلف نسبت گمشدگی داده‌ها و سازوکارهای گمشدگی در جدول ۲ و نمودار ۱ ارائه شده است. براساس نتایج مشاهده می‌شود براساس معیار RMSE:

- به ازای سازوکارها و مقادیر مختلف نسبت گمشدگی، روش‌های جانهی مبتنی بر الگوریتم‌های یادگیری ماشین به‌طور قابل‌توجهی عملکرد بهتری نسبت به روش‌های سنتی جانهی داده‌های گمشده دارند. برای مثال برای سازوکار گمشدگی MCAR و نسبت گمشدگی۰.۱۵ $= p$، ۰.۹۵۱ $= RMSE_{MICE}$ درحالی‌که ۰.۷۸۱ $= RMSE_{missForest}$.

۱. Root mean squared error
۲. Mode
۳. Grid search

- در بین روش‌های سنتی جانهی داده‌های گمشده، بالاترین مقادیر RMSE به روش EM و کمترین مقادیر RMSE به روش MICE اختصاص دارد. به عبارت دیگر، روش جانهی MICE به‌طور قابل‌توجهی عملکرد بهتری نسبت به روش‌های ساده‌تر مانند جانهی مقادیر گمشده با بیشترین فراوانی و جانهی EM دارد. برای مثال تحت سازوکار گمشدگی MAR و $p = ۰.۰۵$، $RMSE_{MICE} = ۰.۹۸۲$ درحالی‌که $RMSE_{EM} = ۱.۵۷۷$ و $RMSE_{Simple} = ۱.۰۴۷$
- در بین روش‌های مبتنی بر الگوریتم‌های یادگیری ماشین، مقدار RMSE روش جانهی KNN بسیار نزدیک به روش جانهی missForest است. بااین‌حال الگوریتم missForest بهترین روش برای جانهی داده‌های نامشخص سن مادراست. برای مثال تحت سازوکار گمشدگی MAR و $p = ۰.۰۱$، $RMSE_{missForest} = ۰.۶۵۵$ درحالی‌که $RMSE_{KNN} = ۰.۶۹۱$.
- مقادیر RMSE مربوط به روش جانهی MICE (یکی از روش‌های سنتی جانهی داده‌های گمشده) به روش جانهی MICEForest (از روش‌های مبتنی بر الگوریتم‌های یادگیری ماشین) نزدیک است، اما کارایی روش MICEForest به‌طور قابل‌توجهی بهتر از روش MICE است. به‌عنوان مثال تحت سازوکار گمشدگی MNAR و نسبت گمشدگی $p = ۰.۲$، $RMSE_{MICE} = ۰.۹۶۷$ درحالی‌که $RMSE_{MICEForest} = ۰.۹۱۶$.
- در روش‌های جانهی داده‌های گمشده مبتنی بر الگوریتم‌های یادگیری ماشین، تحت سازوکار گمشدگی MCAR، با افزایش نسبت گمشدگی از ۰.۱۵ به ۰.۲ مقادیر RMSE به‌طور قابل‌ملاحظه‌ای کاهش می‌یابد. برای مثال به ازای $p = ۰.۱۵$، $RMSE_{KNN} = ۰.۸۰۹$ درحالی‌که به ازای $p = ۰.۲$، $RMSE_{KNN} = ۰.۶۵۰$. این روند در سازوکارهای گمشدگی MAR و MNAR چندان مشهود نیست.
- ارزیابی روش‌های جانهی مبتنی بر الگوریتم‌های یادگیری ماشین نشان می‌دهد که به ازای نسبت‌های گمشدگی بین ۰.۰۱ تا ۰.۱۵، مقادیر RMSE تحت سازوکار گمشدگی غیرتصادفی کمتر از سایر سازوکار گمشدگی داده‌ها است. اما به ازای نسبت گمشدگی p=۰.۲، کارایی روش‌های جانهی تحت سازوکار گمشدگی کاملاً تصادفی (MCAR) بهتر از سایر سازوکارهای گمشدگی داده‌ها است.
- در بین روش‌های سنتی جانهی داده‌های گمشده، روش جانهی MICE عملکردی مشابه روش‌های مبتنی بر الگوریتم‌های یادگیری ماشین دارد به قسمی که به ازای نسبت‌های گمشدگی ۰.۰۱ تا ۰.۱۵، مقدار RMSE تحت سازوکار گمشدگی MNAR و به ازای $p = ۰.۲$ تحت سازوکار گمشدگی MCAR کمترین مقدار را دارد. در مقابل مقدار RMSEدر الگوریتم EM و جانهی ساده تحت سازوکار گمشدگی کاملاً تصادفی به حداقل می‌رسد.

جدول ۱. آماره‌های توصیفی و درصد رکوردهای گمشده برای متغیرهای مرتبط با ولادت، ۱۴۰۲

ردیف	متغیر	میانگین و انحراف استاندارد، یا درصد	تعداد		درصد رکوردهای گمشده
			رکوردهای مشاهده‌شده	رکوردهای گمشده	
۱	استان محل ولادت فرزند	آذربایجان شرقی: ۴/۳؛ آذربایجان غربی: ۴/۸؛ اردبیل: ۱/۴؛ اصفهان: ۵/۰؛ البرز: ۲/۱؛ ایلام: ۰/۷؛ بوشهر: ۱/۳؛ تهران: ۱۲/۳؛ چهارمحال و بختیاری: ۱/۳؛ خراسان جنوبی: ۱/۵؛ خراسان رضوی: ۹/۵؛ خراسان شمالی: ۱/۳؛ خوزستان: ۸/۴؛ زنجان: ۱/۳؛ سمنان: ۰/۶؛ سیستان و بلوچستان: ۸/۴؛ فارس: ۵/۲؛ قزوین: ۱/۳؛ قم: ۱/۷؛ کردستان: ۲/۰؛ کرمان: ۴/۶؛ کرمانشاه: ۲/۲؛ کهگیلویه و بویراحمد: ۱/۰؛ گلستان: ۲/۹؛ گیلان: ۱/۸؛ لرستان: ۳/۳؛ مازندران: ۲/۵؛ مرکزی: ۱/۲؛ هرمزگان: ۳/۱؛ همدان: ۲/۱؛ یزد: ۱/۶	۱,۰۴۳,۳۴۱	۵۹۰	۰/۰۰۱
۲	جنسیت فرزند	دختر: ۵۱/۸؛ پسر: ۴۸/۲	۱,۰۴۳,۳۹۱	۰	۰
۳	نوع ولادت	شهری: ۷۵/۵؛ روستایی: ۲۴/۵	۱,۰۴۳,۳۹۱	۰	۰
۴	سن مادر	میانگین: ۳۰/۳؛ انحراف استاندارد: ۶/۵	۱,۰۳۵,۳۶۳	۸۵۶۸	۰/۰۰۸
۵	سن پدر	میانگین: ۳۵؛ انحراف استاندارد: ۶/۴	۱,۰۴۳,۲۱۰	۷۲۱	۰/۰۰۱
۶	فاصله ازدواج تا تولد فرزند (سال)	میانگین: ۸.۰؛ انحراف استاندارد: ۵/۴	۱,۰۲۱,۷۲۷	۲۲۲۰۴	۰/۰۲۱
۷	چندقلوزایی	یک‌قلو: ۹۶/۲؛ دوقلو: ۳/۶؛ سه‌قلو و بیشتر: ۰/۲	۱,۰۴۳,۹۳۱	۰	۰
۸	مرتبه ولادت فرزند	اول: ۳۶/۴؛ دوم: ۳۸/۵؛ سوم: ۱۷/۸؛ چهارم: ۵/۲؛ پنج و بیشتر: ۲/۱	۱,۰۳۵,۴۷۷	۸۴۵۴	۰/۰۰۸

نتیجه‌گیری

در این مطالعه کارایی روش‌های مختلف جانهی داده‌های گمشده برای متغیر سن مادر در داده‌های ولادت سال ۱۴۰۲ تحت سازوکارها و نسبت‌های مختلف گمشدگی مورد بررسی قرار گرفت. یافته‌های تحقیق نشان داد که روش‌های جانهی مبتنی بر الگوریتم‌های یادگیری ماشین به‌ویژه الگوریتم missForest در کاهش خطای جانهی براساس معیار RMSE عملکرد بهتری نسبت به روش‌های سنتی دارند. این نتایج با یافته‌های پژوهش استخوون و بولمان (۲۰۱۲) و تانگ و ایشواران (۲۰۱۷) که بر دقت بالاتر روش missForest در داده‌های با ساختار پیچیده تأکید داشته‌اند، همسو است.

در بین روش‌های سنتی جانهی داده‌های گمشده، روش جانهی MICE نیز در بسیاری از موارد عملکرد مطلوبی داشته و نتایج آن به روش‌های یادگیری ماشین نزدیک بوده است. این یافته با نتایج پژوهش ون بورن و گروتویس–آودشورن (۲۰۱۱) که بیان کرده‌اند روش MICE می‌تواند به دقت روش‌های یادگیری ماشین نزدیک شود مطابقت دارد. این یافته نشان می‌دهد که روش MICE می‌تواند در مواقعی که پیاده‌سازی روش‌های پیشرفته امکان‌پذیر نیست به‌عنوان جایگزین مناس‌بی برای جانهی مقادیر گمشده مورد استفاده قرار گیرد.

تحلیل وابستگی عملکرد روش‌های جانهی برحسب سازوکارها و نسبت‌های گمشدگی نشان داد روش‌های یادگیری ماشین در شرایط گمشدگی غیرتصادفی و نسبت‌های پایین گمشدگی (۰.۰۱ تا ۰.۱۵) عملکرد بهتری داشتند، درحالی‌که با افزایش نسبت گمشدگی ($p = ۰.۲$)، این روش‌ها تحت شرایط گمشدگی کاملاً تصادفی عملکرد مطلوب‌تری ارائه دادند. این الگوها با یافته‌های وانگ و همکاران (۲۰۲۲b) که به تأثیر سازوکارها و نسبت‌های گمشدگی بر عملکرد روش‌های جانهی داده‌های گمشده اشاره کرده‌اند همخوانی دارد.

از دیدگاه کاربردی این مطالعه نشان داد که انتخاب روش بهینه جانهی باید براساس نوع سازوکار گمشدگی داده‌ها، نرخ گمشدگی و ساختار داده‌ها صورت گیرد. همچنین استفاده از روش‌های پیشرفته مانند missForest می‌تواند به افزایش دقت تحلیل‌ها و ارائه نتایج معتبرتر منجر شود. با توجه به برتری روش missForest در این مطالعه و مطالعات مشابه پیشنهاد می‌شود

از این روش برای جانهی داده‌های نامشخص سن مادر استفاده شود. همچنین برای مواردی که پیاده‌سازی روش‌های پیچیده یادگیری ماشین امکان‌پذیر نیست، روش جانهی MICE به‌عنوان جایگزین مناسب پیشنهاد می‌شود.

جدول ۲. مقدار RMSEروش‌های جانهی داده‌های نامشخص سن مادر تحت سازوکار گمشدگی MCAR، MAR و MNAR و نسبت‌های گمشدگی مختلف

روش جانهی /سازوکار گمشدگی		نسبت گمشدگی				
		۰/۰۱	۰/۰۵	۰/۱	۰/۱۵	۰/۲
Simple (Mode)	MCAR	۱/۰۴۴	۱/۰۴۶	۱/۰۴۵	۱/۰۴۳	۱/۰۴۴
	MAR	۱/۰۱۹	۱/۰۴۷	۱/۰۱۱	۱/۰۶۱	۱/۱۲۴
	MNAR	۱/۱۰۵	۱/۰۸۹	۱/۰۸۵	۱/۰۸۹	۱/۰۹۰
EM	MCAR	۱/۱۹۵	۱/۱۸۹	۱/۱۸۹	۱/۱۹۱	۱/۱۹۰
	MAR	۱/۳۶۳	۱/۵۷۷	۱/۶۰۵	۱/۵۴۹	۱/۵۸۵
	MNAR	۱/۴۲۳	۱/۶۰۷	۱/۵۶۳	۱/۵۱۰	۱/۵۸۶
MICE	MCAR	۰/۹۵۰	۰/۹۵۰	۰/۹۵۱	۰/۹۵۱	۰/۹۵۲
	MAR	۰/۹۴۰	۰/۹۸۲	۰/۹۷۶	۰/۹۸۷	۰/۹۶۷
	MNAR	۰/۹۲۲	۰/۸۹۴	۰/۹۴۲	۰/۹۱۲	۰/۹۶۷
KNN	MCAR	۰/۸۰۴	۰/۸۱۶	۰/۸۰۶	۰/۸۰۹	۰/۶۵۰
	MAR	۰/۶۹۱	۰/۷۷۵	۰/۷۵۳	۰/۷۸۹	۰/۷۲۱
	MNAR	۰/۶۶۵	۰/۶۷۷	۰/۷۰۴	۰/۶۶۵	۰/۷۱۹
MICEForst	MCAR	۰/۹۲۰	۰/۹۲۷	۰/۹۳۱	۰/۹۲۸	۰/۸۶۷
	MAR	۰/۹۱۹	۰/۹۲۴	۰/۹۲۴	۰/۹۱۱	۰/۹۰۳
	MNAR	۰/۸۶۶	۰/۸۶۲	۰/۹۰۲	۰/۸۵۵	۰/۹۱۶
missForest	MCAR	۰/۷۷۵	۰/۷۸۱	۰/۷۸۱	۰/۷۸۱	۰/۶۰۹
	MAR	۰/۶۵۵	۰/۷۱۵	۰/۷۰۷	۰/۷۰۶	۰/۶۷۰
	MNAR	۰/۶۰۷	۰/۶۰۷	۰/۶۵۷	۰۶۰۷	۰/۶۷۱

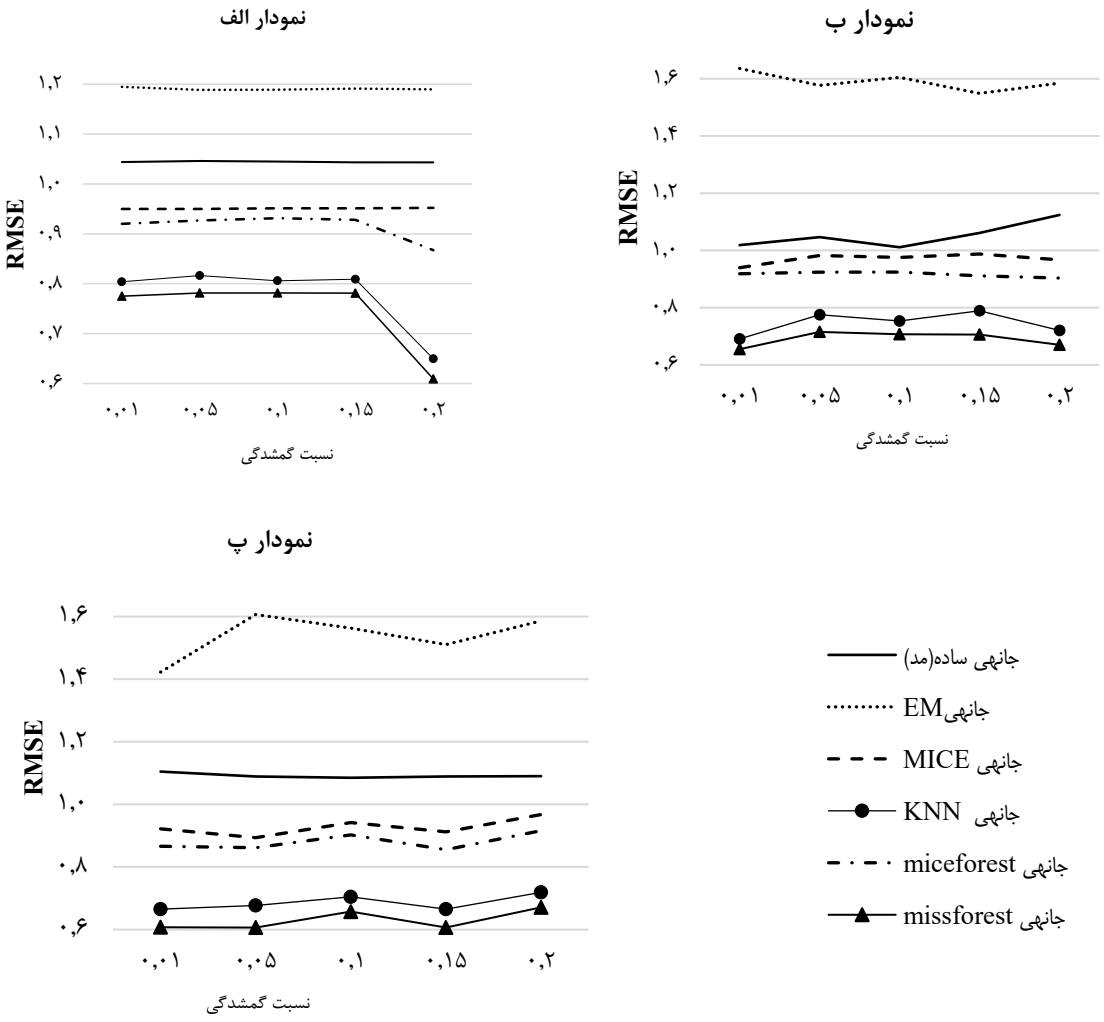

نمودار ۱. مقادیر RMSE روش‌های جانهی داده‌های گمشده سن مادر به ازای سازگار گمشدگی MCAR (نمودار الف)، MAR (نمودار ب) و MNAR (نمودار پ) به ازای نسبت‌های گمشدگی مختلف

References

- Abidin, N. Z., & Ismail, A. R. (۲۰۲۱). An improved K-Nearest neighbour with grasshopper optimization algorithm for imputation of missing data. *International Journal of Advances in Intelligent Informatics*, ۷(۳), ۳۰٤.
- Alsaber, A., Al-Herz, A., Pan, J., Al-Sultan, A. T., Mishra, D., & KRRD Group. (۲۰۲۱). Handling missing data in a rheumatoid arthritis registry using random forest approach. *International Journal of Rheumatic Diseases*, ۲٤(۱۰), ۱۲۸۲–۱۲۹۳.
- Aracri, F., Bianco, M. G., Quattrone, A., & Sarica, A. (۲۰۲۳). Imputation of missing clinical, cognitive and neuroimaging data of Dementia using missForest, a Random Forest based algorithm. *In 2023 IEEE 36th International Symposium on Computer-based Medical Systems. Pp. 684-688. IEEE*.
- Austin, P. C., White, I. R., Lee, D. S., & van Buuren, S. (۲۰۲۱). Missing data in clinical research: A tutorial on multiple imputation. *The Canadian Journal of Cardiology*, ۳۷(۹), ۱۳۲۲–۱۳۳۱.
- Azur, M. J., Stuart, E. A., Frangakis, C., & Leaf, P. J. (۲۰۱۱). Multiple imputation by chained equations: what is it and how does it work?: Multiple imputation by chained equations. *International Journal of Methods in Psychiatric Research*, ۲۰(۱), ٤۰–٤۹.
- Batista, G. E. A. P. A., & Monard, M. C. (۲۰۰۳). An analysis of four missing data treatment methods for supervised learning. *Applied Artificial Intelligence*, ۱۷(٥–٦), ٥۱۹–٥۳۳.
- Beesley, L. J., Bondarenko, I., Elliot, M. R., Kurian, A. W., Katz, S. J., & Taylor, J. M. (۲۰۲۱). Multiple imputation with missing data indicators. *Statistical methods in medical research*, ۳۰(۱۲), ۲۶۸۵–۲۷۰۰.
- Breiman, L. (۲۰۰۱). Random Forests. *Machine Learning*, ٤٥(۱), ٥–۳۲.
- De Silva, H., & Perera, A. S. (۲۰۱٦). Missing data imputation using Evolutionary k-Nearest neighbor algorithm for gene expression data. In ۲۰۱٦ Sixteenth International Conference on Advances in ICT for Emerging Regions (ICTer) (pp. ۱٤۱-۱٤٦). IEEE.
- Deb, R., & Liew, A. W.-C. (۲۰۱٦). Missing value imputation for the analysis of incomplete traffic accident data. *Information Sciences*, ۳۳۹, ۲۷٤–۲۸۹.
- Delalleau, O., Courville, A., & Bengio, Y. (۲۰۱۲). Efficient EM training of Gaussian mixtures with missing data. *arXiv preprint arXiv:1209.0521*.
- Dempster, A. P., Laird, N. M., & Rubin, D. B. (۱۹۷۷). Maximum likelihood from incomplete data via the EM algorithm. *Journal of the royal statistical society: series B (methodological),* ۳۹(۱), ۱-۲۲.
- Doove, L. L., Van Buuren, S., & Dusseldorp, E. (۲۰۱٤). Recursive partitioning for missing data imputation in the presence of interaction effects. *Computational Statistics & Data Analysis*, ۷۲, ۹۲–۱۰٤.
- Emmanuel, T., Maupong, T., Mpoeleng, D., Semong, T., Mphago, B., & Tabona, O. (۲۰۲۱). A survey on missing data in machine learning. *Journal of Big Data*, ۸(۱), ۱٤۰.
- Fouad, K. M., Ismail, M. M., Azar, A. T., & Arafa, M. M. (۲۰۲۱). Advanced methods for missing values imputation based on similarity learning. *PeerJ. Computer Science*, ۷(e٦۱۹), e٦۱۹.
- Goldani, M. (۲۰۲٤). Comparative analysis of missing values imputation methods: A case study in financial series (S&P٥۰۰ and bitcoin value data sets). *Iranian Journal of Finance*, ۸(۱), ٤۷–۷۰.

- Graham, J. W., Olchowski, A. E., & Gilreath, T. D. (۲۰۰۷). How many imputations are really needed? Some practical clarifications of multiple imputation theory. *Prevention Science: The Official Journal of the Society for Prevention Research*, ۸(۳), ۲۰۶–۲۱۳.
- Hong, S., & Lynn, H. S. (۲۰۲۰). Accuracy of random-forest-based imputation of missing data in the presence of non-normality, non-linearity, and interaction. *BMC Medical Research Methodology*, ۲۰(۱), ۱۹۹.
- Howell, D. C. (۲۰۰۷). The treatment of missing data. *The SAGE Handbook of Social Science Methodology*, ۲۱۲–۲۲۶.
- Ismail, A. R., Abidin, N. Z., & Maen, M. K. (۲۰۲۲). Systematic review on missing data imputation techniques with machine learning algorithms for healthcare. *Journal of Robotics and Control* , ۳(۲), ۱۴۳-۱۵۲.
- Jegadeeswari, K., Ragunath, R., & Rathipriya, R. (۲۰۲۲). Missing data imputation using ensemble learning technique: a review. *Soft Computing for Security Applications: Proceedings of ICSCS 2022*, ۲۲۳-۲۳۶.
- Jerez, J. M., Molina, I., García-Laencina, P. J., Alba, E., Ribelles, N., Martín, M., & Franco, L. (۲۰۱۰). Missing data imputation using statistical and machine learning methods in a real breast cancer problem. *Artificial intelligence in medicine*, ۵۰(۲), ۱۰۵-۱۱۵.
- Khan, S. I., & Hoque, A. S. M. L. (۲۰۲۰). SICE: an improved missing data imputation technique. *Journal of big Data*, ۷(۱), ۳۷.
- Li, J., Guo, S., Ma, R., He, J., Zhang, X., Rui, D., ... & Guo, H. (۲۰۲۴). Comparison of the effects of imputation methods for missing data in predictive modelling of cohort study datasets. *BMC Medical Research Methodology*, ۲۴(۱), ۴۱.
- Lin, W. C., Ke, S. W., & Tsai, C. F. (۲۰۱۷). When should we ignore examples with missing values?. *International Journal of Data Warehousing and Mining* , ۱۳(۴), ۵۳-۶۳.
- Little R.J. A. & Rubin, D. B. (۲۰۰۲) *Statistical analysis with missing data*, John Wiley & Sons.
- Liu, Z. G., Liu, Y., Dezert, J., & Pan, Q. (۲۰۱۵). Classification of incomplete data based on belief functions and K-nearest neighbors. *Knowledge-Based Systems*, ۸۹, ۱۱۳-۱۲۵.
- Mattei, A., Mealli, F., & Rubin, D. B. (۲۰۱۱). Missing data and imputation methods. *Modern Analysis of Customer Surveys: with Applications using R*, ۱۲۹-۱۵۴.
- Muzellec, B., Josse, J., Boyer, C., & Cuturi, M. (۲۰۲۰). Missing data imputation using optimal transport. *In International Conference on Machine Learning* (pp. ۷۱۳۰-۷۱۴۰). PMLR.
- Petrazzini, B. O., Naya, H., Lopez-Bello, F., Vazquez, G., & Spangenberg, L. (۲۰۲۱). Evaluation of different approaches for missing data imputation on features associated to genomic data. *BioData mining*, ۱۴, ۱-۱۳.
- Pujianto, U., Wibawa, A. P., & Akbar, M. I. (۲۰۱۹). K-nearest neighbor (k-NN) based missing data imputation. *In 2019 5th International Conference on Science in Information* ۸۳–۸۸. IEEE.
- Rahman, M. G., & Islam, M. Z. (۲۰۱۳). Data quality improvement by imputation of missing values. *In International Conference on Computer Science and Information Technology* (pp. ۸۲-۸۸). Springer-Verlag London Ltd..
- Rizvi, S. T. H., Latif, M. Y., Amin, M. S., Telmoudi, A. J., & Shah, N. A. (۲۰۲۳). Analysis of Machine Learning Based Imputation of Missing Data. *Cybernetics and Systems*, ۱-۱۵.
- Rubin, D. B. (۱۹۷۶). Inference and missing data. *Biometrika*, ۶۳(۳), ۵۸۱-۵۹۲.

- Rubin, D. B. (۱۹۸۷). *Multiple imputation for nonresponse in surveys* (Vol. ۸۱). John Wiley & Sons.
- Rubin, L. H., Witkiewitz, K., Andre, J. S., & Reilly, S. (۲۰۰۷). Methods for handling missing data in the behavioral neurosciences: Don't throw the baby rat out with the bath water. *Journal of Undergraduate Neuroscience Education*, ۵(۲), A۷۱.
- Sania, A., Pini, N., Nelson, M. E., Myers, M. M., Shuffrey, L. C., Lucchini, M., ... & Fifer, W. P. (۲۰۲۵). K-nearest neighbor algorithm for imputing missing longitudinal prenatal alcohol data. *Advances in Drug and Alcohol Research*, ٤, ۱۳٤٤۹.
- Schafer, J. L. (۱۹۹۷). *Analysis of incomplete multivariate data*. CRC press.
- Shah, A. D., Bartlett, J. W., Carpenter, J., Nicholas, O., & Hemingway, H. (۲۰۱٤). Comparison of random forest and parametric imputation models for imputing missing data using MICE: a CALIBER study. *American journal of epidemiology*, ۱۷۹(٦), ۷٦٤-۷۷٤.
- Stekhoven, D. J., & Bühlmann, P. (۲۰۱۲). MissForest—non-parametric missing value imputation for mixed-type data. *Bioinformatics*, ۲۸(۱), ۱۱۲-۱۱۸.
- Tang, F., & Ishwaran, H. (۲۰۱۷). Random forest missing data algorithms. *Statistical Analysis and Data Mining: The ASA Data Science Journal*, ۱۰(٦), ۳٦۳-۳۷۷.
- Troyanskaya, O., Cantor, M., Sherlock, G., Brown, P., Hastie, T., Tibshirani, R., ... & Altman, R. B. (۲۰۰۱). Missing value estimation methods for DNA microarrays. *Bioinformatics*, ۱۷(٦), ۵۲۰-۵۲۵.
- Van Buuren, S., & Groothuis-Oudshoorn, K. (۲۰۱۱). mice: Multivariate imputation by chained equations in R. *Journal of statistical software*, ٤۵, ۱-٦۷.
- Waljee, Akbar K., Ashin Mukherjee, Amit G. Singal, Yiwei Zhang, Jeffrey Warren, Ulysses Balis, Jorge Marrero, Ji Zhu, and Peter DR Higgins. (۲۰۱۳). Comparison of imputation methods for missing laboratory data in medicine. *BMJ open*, ۳(۸), e۰۰۲۸٤۷.
- Wang, K., Luo, M., Deng, M., & Chen, H. (۲۰۲۲a). Nested Random Forest: A Personalized Imputation Method for Missing Data. *In 2022 8th International Conference on Big Data and Information Analytics (BigDIA)* (pp. ۱۱۹-۱۲٦). IEEE.
- Wang, H., Tang, J., Wu, M., Wang, X., & Zhang, T. (۲۰۲۲b). Application of machine learning missing data imputation techniques in clinical decision making: taking the discharge assessment of patients with spontaneous supratentorial intracerebral hemorrhage as an example. *BMC Medical Informatics and Decision Making*, ۲۲, ۱-۱٤.
- White, I. R., Royston, P., & Wood, A. M. (۲۰۱۱). Multiple imputation using chained equations: issues and guidance for practice. *Statistics in medicine*, ۳۰(٤), ۳۷۷-۳۹۹.
- Zhu, M., & Cheng, X. (۲۰۱۵). Iterative KNN imputation based on GRA for missing values in TPLMS. *In 2015 4th international conference on computer science and network technology (ICCSNT)* (Vol. ۱, pp. ۹٤-۹۹). IEEE