Human Information Interaction. Vol. 9, No. 4 (Winter 2023):13-25.
http://hii.khu.ac.ir
Original Article

A method to solve the problem of missing data, outlier data, and noisy data to improve the performance of human and information interaction.

***Mojtaba Mazoochi**: Assistant Professor, ICT Research Institute, Tehran, Iran. (Corresponding author) mazoochi@itrc.ac.ir

Leila Rabiei: Researcher, ICT Research Institute, Tehran, Iran.

Mohammad Moradi: Ph.D. in Information Technology, ICT Research Institute, Tehran, Iran.

Received: 2022/12/14 Received in revised form: 2023/02/09 Accepted: 2023/02/12 Published online: 2023/03/03

Abstract

Introduction: Errors in data collection and failure to pay attention to data that is noisy in the collection process for any reason cause problems in data-based analysis and, as a result, wrong decision-making. Therefore, solving the problem of missing or noisy data before processing and analysis is of vital importance in analytical systems. The purpose of this paper is to provide a method to identify noisy data, outliers, and missing data and provide a suitable solution for these data.
Methods: This study is applied research. Data mining techniques including binning smoothing and regression models have been used to identify and replace outlier and noisy data.
Results: The results of the tests performed in the real environment related to the data of social networks show the proper performance of the proposed method. It has also been shown that the proposed method has higher accuracy compared to the methods of binning smoothing, average and linear regression. So that for the data related to the tweet section, the mean squared error obtained for the proposed method was equal to 0.04, the binning smoothing method was equal to 0.38, the linear regression method was equal to 0.05 and the average method was equal to 0.06.
Conclusion: The method presented in this article can initially identify outlier data through one-third and two-thirds normal, and then replace the outlier data with a linear regression model, which results in improving the performance of using and processing information and improving human-information interaction.
Keywords: Noisy Data, Outliers, Missing Data, Smoothing, Binning Method, Regression Model

Conflicts of Interest: Not reported.
Funding: It did not have a financial sponsor.

How to cite this article

APA: Mazoochi, M, Rabiei, L, Moradi, M. (2023). A method to solve the problem of missing data, outlier data, and noisy data to improve the performance of human and information interaction. *Human Information Interaction*, 9(4); 13-25. (Persian)

Vancouver: Mazoochi, M, Rabiei, L, Moradi, M. (2023). A method to solve the problem of missing data, outlier data, and noisy data to improve the performance of human and information interaction. *Human Information Interaction*, 9(4); 13-25. (Persian)

The journal of *Human Information Interaction* is supported by Kharazmi University, Tehran, Iran.
This work is published under CC BY-NC-SA 3.0 license.

[Downloaded from c4i2016.khu.ac.ir on 2024-10-12]
[DOR: 20.1001.1.24237418.1401.9.4.1.3]

جلد نهم، شماره چهارم (زمستان ۱۴۰۱): ۲۵-۱۳
http://hii.khu.ac.ir
مقاله اصیل پژوهشی

ارائه روشی برای حل مشکل داده‌های گم شده، پرت و نویزی به‌منظور بهبود عملکرد تعامل انسان و اطلاعات

*مجتبی مازوچی: استادیار، پژوهشگاه ارتباطات و فناوری اطلاعات، تهران، ایران. (نویسنده مسئول) mazoochi@itrc.ac.ir
لیلا ربیعی: پژوهشگر، پژوهشگاه ارتباطات و فناوری اطلاعات، تهران، ایران.
محمد مرادی: دکتری مهندسی فناوری اطلاعات، پژوهشگاه ارتباطات و فناوری اطلاعات، تهران، ایران.

نوع مقاله: مقاله پژوهشی
تاریخ دریافت: ۱۴۰۰/۰۹/۲۳
تاریخ بازنگری: ۱۴۰۰/۱۱/۲۰
تاریخ پذیرش: ۱۴۰۰/۱۱/۲۳
تاریخ انتشار: ۱۴۰۰/۱۲/۱۲

چکیده

زمینه و هدف: خطا در جمع‌آوری داده‌ها و عدم توجه به داده‌هایی که در پروسه جمع‌آوری به هر دلیل دچار نویز شده‌اند باعث ایجاد اشکال در تحلیل‌های مبتنی بر داده و به‌تبع آن، تصمیم‌سازی‌های اشتباه می‌گردد؛ لذا رفع مشکل داده‌های گم شده و یا نویزی، قبل از انجام مراحل پردازش و تحلیل دارای اهمیت حیاتی در سامانه‌های تحلیلی است. هدف این مقاله، ارائه روشی به‌منظور شناسایی داده‌های نویزی، پرت و داده‌های گم شده و ارائه راهکاری مناسب برای هموارسازی این داده‌ها است.

روش پژوهش: این پژوهش بر مبنای هدف، از نوع کاربردی است. به‌منظور تحلیل داده‌ها از تکنیک‌های داده‌کاوی شامل هموارسازی پیاله‌ای و مدل رگرسیون به‌منظور شناسایی و جاگذاری داده‌های پرت و نویزی استفاده شده است.

نتایج: نتایج آزمایش‌های انجام شده در محیط واقعی مربوط به داده‌های شبکه‌های اجتماعی، نشان‌دهنده عملکرد مناسب روش پیشنهادی است. همچنین نشان‌داده‌شده است که روش پیشنهادی دارای دقت بالاتری در مقایسه با روش‌های هموارسازی پیاله‌ای، میانگین و رگرسیون خطی است. به‌طوری‌که برای داده‌های مربوط به بخش توئیت، میانگین مربعات خطای به‌دست‌آمده برای روش پیشنهادی برابر ۰٫۰۰۴، روش هموارسازی پیاله‌ای برابر ۰٫۰۳۸، روش رگرسیون خطی برابر ۰٫۰۰۵ و روش جایگزینی با میانگین برابر ۰٫۰۰۶ بوده است.

نتیجه‌گیری: روش ارائه شده در این مقاله، می‌تواند در ابتدا از طریق یک‌سوم و دوسوم نرمال، داده‌های پرت را شناسایی کند و سپس با مدل رگرسیون خطی به جایگزینی داده‌های پرت بپردازد که در نتیجه سبب بهبود عملکرد استفاده و پردازش اطلاعات و بهبود تعامل انسان و اطلاعات خواهد شد.

کلمات کلیدی: داده‌های نویزی، داده‌های پرت، داده‌های گم شده، هموارسازی، روش پیاله‌ای، مدل رگرسیون

تعارض منافع: گزارش نشده است.
منبع حمایت‌کننده: حامی مالی نداشته است.

شیوه استناد به این مقاله

APA: Mazoochi, M, Rabiei, L, Moradi, M. (2023). A method to solve the problem of missing data, outlier data and noisy data in order to improve the performance of human and information interaction. *Human Information Interaction*, 9(4); 13-25. (Persian)

Vancouver: Mazoochi, M, Rabiei, L, Moradi, M. (2023). A method to solve the problem of missing data, outlier data and noisy data in order to improve the performance of human and information interaction. *Human Information Interaction*, 9(4); 13-25. (Persian)

انتشار مجله تعامل انسان و اطلاعات با حمایت مالی دانشگاه خوارزمی انجام می‌شود.
انتشار این مقاله به‌صورت دسترسی آزاد مطابق با CC BY-NC-SA 3.0 صورت گرفته است.

[Downloaded from c4i2016.khu.ac.ir on 2024-10-12]
[DOR: 20.1001.1.24237418.1401.9.4.1.3]

مقدمه

باتوجه‌به پیشرفت فناوری در دنیای امروز و گسترش روزافزون داده‌ها، تجزیه‌وتحلیل داده‌ها از اهمیت ویژه‌ای برخوردار است. این تحلیل‌ها با تمرکز بر سنجش ذائقه کاربران و نیز پیش‌بینی‌های مبتنی بر داده، کاربردهای فراوانی در حوزه‌های مختلف از جمله اقتصاد، سیاست، جامعه‌شناسی و کسب‌وکار دارند. داده‌کاوی و تجزیه‌وتحلیل داده‌ها روشی برای استخراج الگو و تبدیل داده به دانش است (اگاروال و یو[1]، ۲۰۰۵). اگر نمونه‌ها نماینده خوبی از بدنه بزرگ‌داده نباشند، این فرایند شکست خواهد خورد (ارنینگ و همکاران[2]، ۱۹۹۶).

پرت‌کاوی به مشکل پیداکردن الگوها در مجموعه‌داده‌های بزرگ که مطابق با رفتار مورد انتظار نیستند، اشاره دارد (کنتارزیک[3]، ۲۰۱۱). درواقع پایگاه‌داده ممکن است شامل اشیای داده‌ای باشد که با رفتار عمومی یا مدل داده منطبق نیستند. چنین اشیای داده‌ای که به طور برجسته متفاوت یا در تضاد با مجموعه‌داده باقی‌مانده هستند، نقاط دورافتاده یا پرت نامیده می‌شوند (هان و کمبر[4]، ۲۰۰۶). داده‌های پرت و داده‌هایی که دارای نویز هستند، در بسیاری از مجموعه‌داده‌ها دیده می‌شوند. به‌عنوان‌مثال ممکن است مدیر یک فروشگاه اینترنتی قصد تحلیل سن کاربران خود را به‌منظور دریافت این دانش که افراد در بازه سنی مختلف، بیشتر به کدام محصولات تمایل نشان می‌دهند را داشته باشد. این احتمال وجود دارد که مشتریان سهواً سن خود را به‌جای ۲۵ سال، ۲۵۰ سال درج کنند و یا این که شخصی به‌جای این که سن خود را درج کند، سهواً سال تولد خود را وارد نماید. به این دست از داده‌ها که معمولاً با باقی داده‌ها ناسازگار هستند، داده‌های پرت گفته می‌شود و مجموعه‌داده را دارای نویز می‌دانند. نویزها که به داده‌های غیرطبیعی نیز شهرت دارند، سبب خراب‌شدن آمارها می‌شوند.

همچنین، این احتمال وجود دارد که در مراحل جمع‌آوری داده‌ها برخی داده‌ها ازدست‌رفته و به‌اصطلاح گم شوند. عدم توجه به داده‌هایی که در پروسه جمع‌آوری به هر دلیل گم و یا دچار نویز شده‌اند باعث ایجاد اشکال در تحلیل‌های مبتنی بر داده و به‌تبع آن، تصمیم‌سازی‌های اشتباه می‌گردد؛ لذا رفع مشکل داده‌های گم شده و یا نویزی، قبل از انجام مراحل پردازش و تحلیل دارای اهمیت حیاتی در سامانه‌های تحلیلی است (کیانی و منتظری، ۱۳۹۴).

هدف از انجام این پژوهش، ارائه روشی مناسب برای حل مشکل داده‌های گم شده و داده‌های نویزی به‌منظور بهبود عملکرد تحلیل داده‌ها و درنتیجه بهبود تعامل انسان و اطلاعات است. در ادامه، ابتدا به‌مرور کارهای مرتبط با پژوهش و بیان ضعف‌ها و محدودیت‌های روش‌های موجود پرداخته شده است. سپس، روش پیشنهادی ارائه شده است. در بخش بعد، روش پیشنهادی پیاده‌سازی شده و مورد ارزیابی نسبت با سایر روش‌ها قرار گرفته است. در نهایت نیز نتیجه‌گیری بیان شده است.

پیشینهٔ تحقیق

تادا و همکاران[5] (۲۰۲۲) به روش محاسبه مقدار گم شده برای داده‌های ماتریس چند کلاسه بر اساس مجموعه آیتم‌های بسته پرداخته‌اند. در این پژوهش، دو روش مبتنی بر مجموعه آیتم‌های بسته، ***CImpute*** و ***ICImpute*** ، برای دستیابی به مقدار گم شده با استفاده از فضای ویژگی محلی برای داده‌های ماتریس چند کلاسه پیشنهاد شده است ***CImpute***. مقادیر گمشده را با استفاده از مجموعه آیتم‌های بسته استخراج شده از هر کلاس تخمین می‌زند. ***ICImpute*** یک روش بهبودیافته ***CImpute*** است که در آن یک فرایند کاهش ویژگی معرفی شده است. نتایج تجربی نشان می‌دهد که کاهش ویژگی به طور قابل‌توجهی زمان محاسباتی را کاهش می‌دهد و دقت انتساب را بهبود می‌بخشد. علاوه بر این، نشان‌داده‌شده است که در مقایسه با روش‌های موجود، ***ICImpute*** دقت انتساب بالاتری را ارائه می‌کند؛ اما به زمان محاسباتی بیشتری نیاز دارد.

ژنگ و همکاران[6] (۲۰۲۱) به پژوهش دررابطه‌با مقادیر گم شده در سری‌های زمانی چندمتغیره پرداختند. نویسندگان بیان می‌کنند که یک فاز اضافی برای بهینه‌سازی نویز تصادفی ورودی ژنراتور موردنیاز است. علاوه بر این، مقادیر منتسب به دلیل دشواری آموزش و فرایند تولید ناپایدار، می‌توانند بسیار متفاوت از مقادیر واقعی باشند؛ بنابراین، آن‌ها یک مدل انتها به انتها برای نسبت‌دادن مقادیر ازدست‌رفته در یک‌سری زمانی چندمتغیره پیشنهاد می‌کنند. آزمایش‌ها بر روی سه مجموعه‌داده‌های سری زمانی چندمتغیره در دنیای واقعی نشان می‌دهند که مدل پیشنهادی از روش‌های پیشرفته در وظایف انتساب و کاربردهای پایین‌دستی، از جمله طبقه‌بندی و رگرسیون، بهتر عمل می‌کند.

[1] Aggarwal & Yu
[2] Arning et al
[3] Kantardzic
[4] Han & Kamber
[5] Tada et al
[6] Zhang et al

[Downloaded from c4i2016.khu.ac.ir on 2024-10-12]
[DOR: 20.1001.1.24237418.1401.9.4.1.3]

در پژوهش لی و همکاران[1] (۲۰۲۱)، تجزیه حالت تجربی با یک شبکه یادگیری عمیق حافظه کوتاه‌مدت برای بازیابی داده‌های سیگنال اندازه‌گیری شده ترکیب شده است. روش ترکیبی پیشنهادی وظیفه انتساب داده‌های گم شده را به‌عنوان یک کار پیش‌بینی سری زمانی تبدیل می‌کند که سپس با یک استراتژی «تقسیم و غلبه» حل می‌شود. مفهوم اصلی این استراتژی، پیش‌بینی دنباله‌های داده‌های سیگنال اندازه‌گیری شده خام است که به‌جای پیش‌بینی مستقیم، با تجزیه حالت تجربی تجزیه می‌شوند، زیرا تجزیه می‌تواند به مدل‌سازی تغییرات دوره‌ای نامنظم داده‌های سیگنال اندازه‌گیری شده کمک کند. علاوه بر این، شبکه حافظه کوتاه‌مدت و بلندمدت در مدل ترکیبی می‌تواند همبستگی‌های دوربرد بیشتری از دنباله‌های فرعی را نسبت به شبکه عصبی مصنوعی سنتی به‌خاطر بسپارد. سه مدل پیش‌بینی پرکاربرد، یعنی میانگین متحرک یکپارچه اتورگرسیو، رگرسیون بردار پشتیبان و مدل‌های شبکه عصبی مصنوعی نیز به‌عنوان مدل‌های معیار پیاده‌سازی می‌شوند. داده‌های شتاب خام جمع‌آوری‌شده از یک پل کابلی برای ارزیابی عملکرد روش پیشنهادی برای ازدست‌رفتن داده سیگنال اندازه‌گیری شده استفاده می‌شود. نتایج بازیابی داده‌های سیگنال اندازه‌گیری شده نشان می‌دهد که روش ترکیبی پیشنهادی، عملکرد عالی را نشان می‌دهد.

لیو و همکاران[2] (۲۰۲۰) در پژوهش خود بیان می‌کنند که داده‌های ازدست‌رفته یکی از بزرگ‌ترین مشکلات برای پیش‌پردازش داده‌ها در معماری اینترنت اشیا است. به دلیل جمع‌آوری داده‌های حسگر با فرکانس بالا، داده‌های ازدست‌رفته در اینترنت اشیا چالش‌های جدیدی را به همراه دارد. برای پرداختن به این موضوع، نویسندگان بر روی انتساب داده‌های گم شده برای شکاف‌های بزرگ در داده‌های سری زمانی تک‌متغیره تمرکز می‌کنند و یک چارچوب تکراری با استفاده از تکرار شکاف چندگانه به نام ***Itr-MS-STLecImp*** برای ارائه مناسب‌ترین مقادیر پیشنهاد شده است. شکاف ابتدا به چند قطعه تقسیم می‌شود تا فرایند انتساب مقدار گم شده را مقداردهی اولیه کند و سپس، به طور مکرر بازسازی شکاف و الحاق شکاف برای به‌دست‌آوردن نتایج انتساب نهایی اجرا می‌شود. روش پیشنهادی با استفاده از داده‌های حسگر جمع‌آوری‌شده از کارخانه‌های تولید واقعی در استرالیا بررسی شده است و نتایج مقایسه نشان می‌دهد که روش پیشنهادی از نظر خطای ریشه میانگین مربع از روش‌های پیشرفته بهتر عمل می‌کند. در شرایط مختلف طول شکاف، رویکرد پیشنهادی به طور مداوم میزان خطا را بیشتر از الگوریتم پایه کاهش می‌دهد و کاهش خطا زمانی که طول شکاف‌ها افزایش می‌یابد بیشتر است که نشان می‌دهد عملکرد به طور قابل‌توجهی بهبودیافته است.

بیزمن و همکاران[3] (۲۰۱۹) به پژوهشی با عنوان «مقادیر ازدست‌رفته برای جداول» پرداخته‌اند. آن‌ها بیان می‌کنند که روش‌های انتساب مقدار گم شده کنونی بر روی داده‌های عددی یا دسته‌بندی تمرکز می‌کنند و مقیاس‌بندی آن‌ها در مجموعه‌های داده با میلیون‌ها ردیف دشوار است. آن‌ها روشی را ارائه می‌کنند که می‌تواند برای جداول با انواع داده‌های ناهمگن، از جمله متن بدون ساختار اعمال شود. روش پیشنهادی، استخراج‌کننده ویژگی‌های یادگیری عمیق را با تنظیم خودکار فراپارامتر ترکیب می‌کند. این به کاربران بدون پیش‌زمینه یادگیری ماشین، مانند مهندسان داده، امکان می‌دهد تا مقادیر گم شده را با کمترین تلاش در جدول‌هایی با انواع داده‌های ناهمگون نسبت دهند. آن‌ها روش پیشنهادی را با روش‌های موجود مقایسه می‌کنند و نتایج نشان از رضایت‌بخش بودن روش ارائه شده دارد.

روش‌های بسیاری برای هموارسازی و جایگزینی داده‌های پرت و یا ناسازگار با سایر داده‌ها وجود دارد. یکی از روش‌های مرسوم، استفاده از هموارسازی پیاله‌ای است که در بسیاری مواقع نسبت به جایگزینی با میانگین، عملکرد بهتری دارد (سادیک و گرونوالد[4]، ۲۰۱۰). مشکل این روش این است که علاوه بر ازبین‌بردن خط روند، ممکن است روی داده‌های واقعی نیز تأثیر بگذارد. روش ماشین بردار پشتیبان نیز یکی دیگر از راه‌های برازش داده‌های پرت است (هنگهای و همکاران[5]، ۲۰۰۵). اما این روش هنگام حذف هر داده، تمام ویژگی‌های آن را نیز حذف می‌کند درحالی‌که ممکن است برخی از ویژگی‌ها مشمول داده پرت نباشند. یکی دیگر از راه‌های جایگزینی مقادیر پرت وقتی که چند دسته داده با ارتباط معنادار میان آن‌ها وجود داشته باشد، استفاده از برازش رگرسیون خطی است (ژو و همکاران[6]، ۲۰۰۳). مشکل این روش این است که همه داده‌ها را روی یک خط راست برازش می‌کند و لذا برای حالتی که داده‌ها نوسان زیادی دارند، تخمین مناسبی به‌حساب نمی‌آید. یک روش مرسوم، حذف داده‌های پرت است؛ اما این روش به‌ویژه زمانی که تعداد داده‌های پرت زیاد باشند موجب خدشه در روند آماری تحلیل‌ها می‌شود. یک روش دیگر، جایگزین‌کردن داده‌های پرت با میانگین سایر

[1] Li et al
[2] Liu et al
[3] Biessmann et al
[4] Sadik & Gruenwald
[5] Honghai et al
[6] Zhou et al

[Downloaded from c4i2016.khu.ac.ir on 2024-10-12]
[DOR: 20.1001.1.24237418.1401.9.4.1.3]

داده‌هاست (ترویانسکایا و همکاران[1]، ۲۰۰۱). این روش با این که در بسیاری از مواقع، کارآمد است؛ اما موجب اختلال در توزیع و کم برآوردشدن واریانس می‌شود؛ لذا چنانچه بیان شد، هرکدام از روش‌های موجود برای هموارسازی و جایگزینی داده‌های نویزی دارای اشکالات و محدودیت‌هایی است. در این پژوهش سعی شده است، روشی پیشنهاد شود که بر محدودیت‌های روش‌های موجود فائق آید و همچنین خطای کم‌تری داشته باشد.

روش پژوهش

شکل ۱، ساختار کلی روش پیشنهادی را نشان می‌دهد. همان‌طوری که در این شکل مشاهده می‌شود، روش پیشنهادی شامل دو بخش اصلی است:

۱. شناسایی داده‌های ازدست‌رفته و داده‌های پرت
۲. هموارسازی داده‌ها

در ادامه، هرکدام از این مراحل توضیح داده شده است.

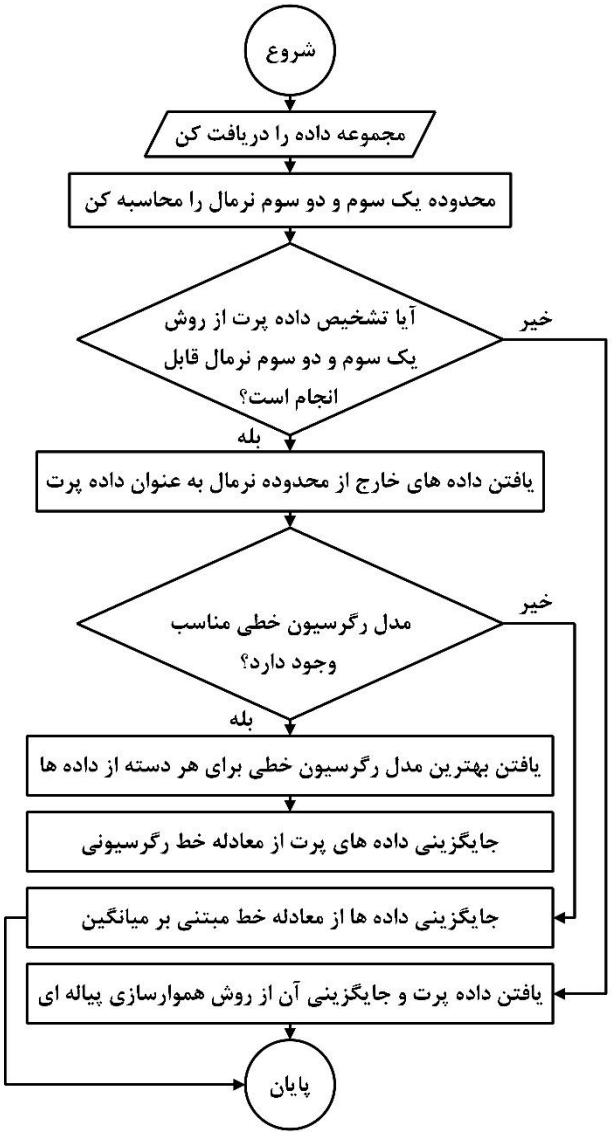

شکل ۱. فلوچارت روش پیشنهادی

[1] Troyanskaya et al

[Downloaded from c4i2016.khu.ac.ir on 2024-10-12]
[DOR: 20.1001.1.24237418.1401.9.4.1.3]

شناسایی داده‌های ازدست‌رفته و داده‌های پرت

معمولاً به دلیل ایجاد مشکلات فنی در فرایند جمع‌آوری داده‌ها از قبیل ایجاد مشکل در خزشگرها، شبکه و یا ذخیره‌سازی داده‌ها، ممکن است بخشی از داده‌ها از دست برود. در این حالت، تعداد داده به‌دست‌آمده بسیار کمتر از تعداد داده مورد انتظار خواهد بود. شناسایی داده‌های ازدست‌رفته می‌تواند با بررسی‌کردن داده‌های جمع‌آوری شده و شناسایی فیلدهای خالی انجام شود.

شناسایی داده‌های پرت

ممکن است به دلایل فنی، بخشی از داده‌ها اشتباه بوده و با سایر داده‌ها ناسازگار باشد. شناسایی این نوع از داده‌ها به‌راحتی انجام نمی‌شود. بدین منظور داده‌های خارج از محدوده نرمال شناسایی می‌شوند. حتی اگر توزیع داده‌ها به‌صورت نرمال نباشد؛ اما محدوده نرمال می‌تواند محدوده مناسبی برای شناسایی داده‌های پرت باشد. حد بالای محدوده نرمال را مقدار میانگین به‌علاوه سه برابر انحراف معیار داده‌ها و حد پایین را مقدار میانگین منهای سه برابر انحراف معیار داده‌ها در نظر می‌گیرند و داده‌های خارج از این محدوده به‌عنوان داده پرت در نظر گرفته می‌شوند. اما در حالتی که انحراف معیار عدد بزرگی باشد ممکن است حد پایین صفر یا منفی شود که در این صورت برای حد پایین از دو سوم نرمال یعنی مقدار میانگین منهای دوبرابر انحراف معیار داده‌ها و یا از یک‌سوم نرمال یعنی مقدار میانگین منهای انحراف معیار داده‌ها استفاده می‌کنیم. به عبارتی، سه مقدار برای حدود بالایی و سه مقدار برای حدود پایینی داده‌ها داریم که با کنترل داده‌ها می‌توان دریافت که بیشتر داده‌ها بین کدام دو کران قرار دارند و نهایتاً داده‌های ناسازگار را شناسایی کرد. روش کار به این صورت است که ابتدا میانگین همه داده‌ها در بازه شش ماه قبل و شش ماه بعد از هر داده محاسبه شده و منهای انحراف معیار آن‌ها خواهد شد. اگر این مقدار مثبت شود تمام داده‌های کمتر از آن، به‌عنوان داده پرت در نظر گرفته می‌شود. اما در حالتی که این مقدار باز هم صفر یا منفی باشد برای شناسایی داده پرت، داده‌ها را به چندین پیاله تقسیم می‌کنیم و پیاله پایینی را داده پرت در نظر می‌گیریم. در شکل ۲، کران‌های بالا و پایین برای شناسایی داده پرت با خطوط قرمز مشخص شده‌اند.

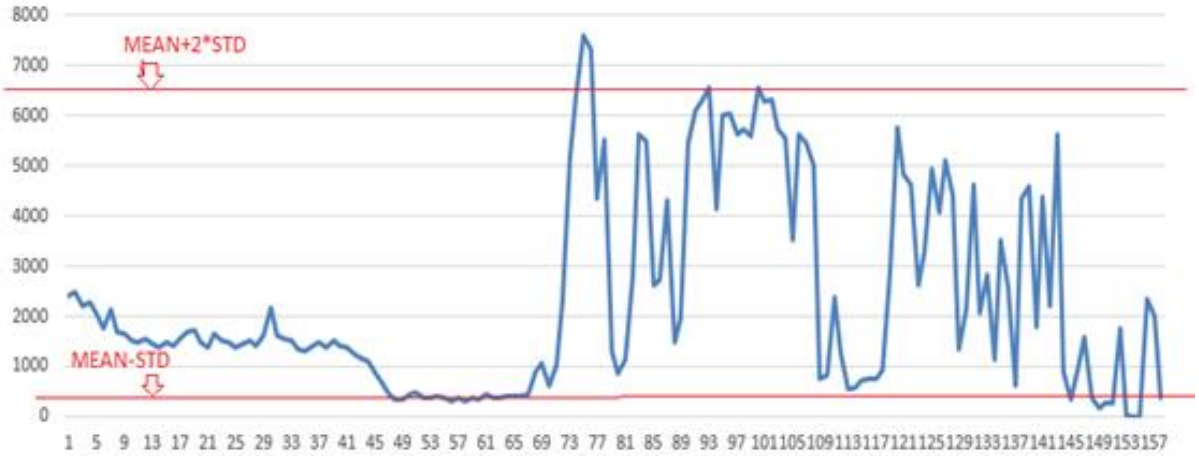

شکل ۲. کران‌های بالا و پایین برای شناسایی داده پرت

هموارسازی داده‌ها

در روش پیشنهادی، ابتدا به‌صورت پیش‌فرض از برازش داده‌ها با رگرسیون خطی استفاده می‌شود. اما در شرایط مختلف که این روش کارایی کمتری دارد به‌تناسب از روش جانهی با خط مبتنی بر میانگین و هموارسازی پیاله‌ای استفاده خواهد شد. در استفاده از رگرسیون، ابتدا میان چند دسته از داده‌ها که دوبه‌دو رابطه معناداری با هم دارند مدل رگرسیونی خطی در نظر می‌شود و

سپس برای برازش داده پرت، معادله خطی انتخاب می‌شود که بیشترین معیار مربعات R را داشته باشد. برای مثال، در بستر اینستاگرام، بین تعداد پست‌ها، تعداد لایک‌ها و تعداد کامنت‌ها رابطه معناداری وجود دارد. اگر همه معیارهای مربعات R در

[Downloaded from c4i2016.khu.ac.ir on 2024-10-12]
[DOR: 20.1001.1.24237418.1401.9.4.1.3]

انتخاب‌های دوبه‌دو از میان دسته‌های مختلف، از مقدار ۰/۵ معینی کم‌تر باشند، بیانگر این است که بین هیچ‌کدام از دسته‌های مختلف داده‌ها، برازش خطی کارایی وجود ندارد. همچنین در حالتی که هر دو داده متقابل در دودسته منتخب برای مدل رگرسیونی داده پرت باشند نمی‌توان از این مدل برای برازش استفاده کرد. ضمناً ممکن است داده برازش شده از خط رگرسیون کم‌تر از داده اولیه باشد که مطلوب نیست. برای سه حالت اخیر از معادله خط مبتنی بر میانگین که حالت بهبودیافته جانهی داده پرت با میانگین است استفاده می‌کنیم. این روش در بخش تست و ارزیابی به‌تفصیل بیان شده است. در شکل ۳، داده‌های سمت چپ جدول که به‌صورت رنگی نشان داده شده‌اند، داده‌های نویزی شناسایی شده و داده‌های همرنگ آن‌ها در سمت راست جدول از معادله خط L که همان خط مبتنی بر میانگین است به دست آمده‌اند.

140	4379	1379541	54411	1400-01-21	4379	1379541	54411
141	2207	996533	38336	1400-01-22	2207	996533	38336
142	5621	1220302	54154	1400-01-23	5621	1220302	54154
143	897	392344	20140	1400-01-24	897	1328328.622	57190
144	326	693281	22059	1400-01-25	1388.592	1654243.393	59396.85
145	988	551593	19023	1400-01-26	988	1500795.289	55905.45
146	1578	644379	32743	1400-01-27	5384.976	1601282.527	71683.45
147	363	306259	17965	1400-01-28	1506.696	1235098.567	54688.75
148	153	201563	6886	1400-01-29	836.376	1121712.799	41947.9
149	277	323532	14584	1400-01-30	1232.184	1253805.226	50800.6
150	277	338241	14708	1400-01-31	1232.184	1269735.073	50943.2
151	1748	532980	21717	1400-02-01	1748	1480637.41	59003.55
152	20	29599	1242	1400-02-02	411.84	935475.787	35457.3
153	8	6728	144	1400-02-03	373.536	910706.494	34194.6
MEAN	2356.162	2567984.701	96460.01299				
STD	1982.402	1657275.958	62265.16154				
MEAN- STD	373.7608	910708.7434	34194.85145				
MEAN+3*STD	6320.965						

شکل ۳. داده‌های جایگزین شده با معادله خط **L**

به‌علاوه همان‌طور که در بخش شناسایی داده پرت گفته شد گاهی ممکن است یافتن داده‌های پرت از محدوده‌های نرمال میسر نباشد که در این حالت، از تقسیم‌بندی داده‌ها به چندین پیاله استفاده می‌شود. برای جانهی داده‌ها در این مواقع، چون پراکندگی داده‌ها زیاد است، کل داده شش‌ماهه را به ده پیاله تقسیم می‌کنیم. سپس تمام داده‌های پایین‌ترین دهک را به‌عنوان داده پرت لحاظ کرده و همه داده‌های پایین‌ترین دهک را با ماکزیمم همان پیاله جایگزین می‌کنیم.

پیاده‌سازی و ارزیابی روش پیشنهادی

به‌منظور پیاده‌سازی و ارزیابی روش پیشنهادی، از بستر ذکاوت که با همکاری نویسندگان این مقاله و جمعی از پژوهشگران دیگر در راستای ذائقه‌سنجی و تحلیل کاربران شبکه‌های اجتماعی توییتر، تلگرام و اینستاگرام، توسعه داده شده است، استفاده گردید. این بستر دارای اجزای مختلف از قبیل جمع‌آوری داده‌های شبکه‌های اجتماعی، یکپارچه‌سازی داده‌ها، پیش‌پردازش، پردازش و تحلیل داده‌ها و مصورسازی است. یکی از مشکلات مهم و رایج در تحلیل شبکه‌های اجتماعی که باعث ایجاد اشتباهات و انحرافات فراوان در تحلیل نتایج و در نتیجه تصمیم‌سازی‌های غلط می‌گردد فقدان بخشی از داده‌ها و وجود داده‌های نویزی به دلیل سیاست‌های متولیان بسترهای این شبکه‌ها و همچنین ایجاد مشکلات فنی در فرایند جمع‌آوری داده‌ها است. بستر ذکاوت هم از این قاعده مستثنی نیست. فقدان بخشی از داده‌ها در هنگام جمع‌آوری در برخی از بازه‌های زمانی، باعث می‌گردد که اطلاعات آماری مستخرج از آن‌ها، نویزی شده و عملاً تحلیل‌های آماری، دارای اشتباهات و انحرافات زیاد شوند. در این بخش، تأثیر روش پیشنهادی برای رفع این مشکل بررسی شده است.

ابتدا داده‌های نویزی شناسایی و مقدار صفر برای آن‌ها لحاظ شد تا توسط الگوریتم هموارسازی مقدار مناسب آن جایگزین گردد. در مرحله اول هموارسازی در بازه‌های زمانی یک‌ماهه روی بسترهای اینستاگرام، تلگرام و توییتر پیاده‌سازی شد. در اینستاگرام، برای هر ماه، تعداد کل پست‌ها، میانگین تعداد لایک

[Downloaded from c4i2016.khu.ac.ir on 2024-10-12]
[DOR: 20.1001.1.24237418.1401.9.4.1.3]

و کامنت، تعداد پست‌های شامل یک هشتگ خاص، موضوع خاص و میانگین لایک و کامنت آن هشتگ، هرکدام به‌عنوان یک متغیر در نظر گرفته شده و در ستون‌های مجزا قرار گرفتند. برای بستر توییتر نیز تعداد کل پست‌ها، تعداد ری‌توییت‌ها، متوسط لایک و کامنت، تعداد توئیت شامل یک هشتگ خاص، موضوع خاص، تعداد ری‌توییت و تعداد لایک و کامنت آن در نظر گرفته شد. سپس رگرسیون خطی میان تمام ستون‌ها به دست آمد و معادله رگرسیون خطی که بیشترین معیار مربعات R را داشت برای جایگزینی صفرهای ایجاد شده استفاده شد. در حالتی که هیچ یک از معیارهای R مقداری بیشتر از ۵۰ درصد نداشت و نیز در حالتی که دو داده متقابل در دو ستونی که رگرسیون روی آن‌ها نوشته شده هر دو صفر شوند، مقادیر صفر را با مقدار میانگین داده‌های غیرصفر جایگزین کردیم. همچنین در حالتی که داده نویزی از روش هموارسازی پیاله‌ای شناسایی شده بود مقادیر صفر با نزدیک‌ترین مقدار یعنی کوچک‌ترین داده غیرصفر جایگزین شد. اما در بررسی بیشتر مشخص شد همه داده‌ها در طول یک ماه نویزی نبوده‌اند و فقط در برخی از روزها جمع‌آوری داده دچار مشکل شده است؛ بنابراین در این مرحله، مجموعه‌داده‌ها به‌صورت روزانه در نظر گرفته شد. داده‌های نویزی مانند مرحله اول شناسایی و در صورت امکان، با رگرسیون خطی جایگزین شدند. در برخی از موارد، داده‌هایی که با میانگین جایگزین شدند در چند روز متوالی اتفاق افتاده بودند. این امر باعث می‌شد تا نموداری که روند انتشار پست‌ها یا سایر متغیرها را نشان می‌دهد در این بازه‌ها به‌صورت خط مستقیم درآید. یک نمونه از روند انتشار قبل و بعد از هموارسازی به ترتیب در شکل ۴ و شکل ۵ نشان‌داده‌شده است.

شکل ۴. روند انتشار تعداد لایک‌های اینستاگرام قبل از هموارسازی

[Downloaded from c4i2016.khu.ac.ir on 2024-10-12]
[DOR: 20.1001.1.24237418.1401.9.4.1.3]

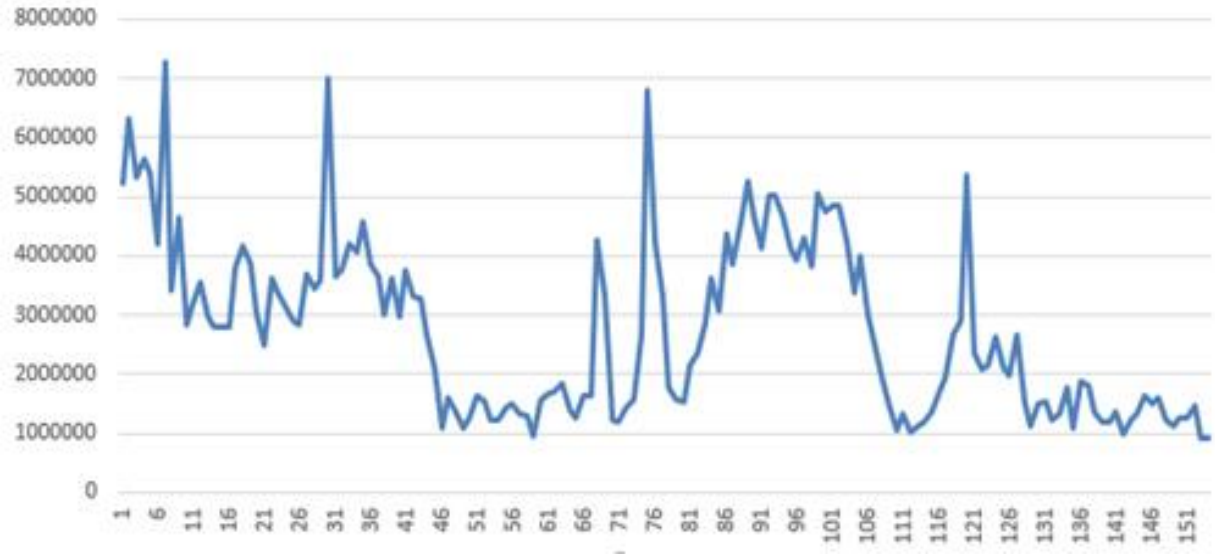

شکل ۵. روند انتشار تعداد لایک‌های اینستاگرام بعد از هموارسازی

برای جلوگیری از این مشکل و برای حفظ روند صعود یا نزول هر متغیر، برای جایگزینی صفرها از معادله خط مبتنی بر میانگین استفاده شد. به این صورت که ابتدا تمام داده‌های نویزی شناسایی شدند. سپس کم‌ترین و بیشترین آن‌ها، یعنی $x1$ و xn، تعیین شدند. مقدار $y1$، کران پایینی شناسایی داده پرت یعنی تفاضل میانگین و انحراف معیار قرار داده شد. مقدار yn، میانگین هندسی کل داده‌ها در نظر گرفته شد. معادله خط واصل بین $(x1,y1)$ و (xn,yn) از رابطه (۱) محاسبه شد که در این معادله، x داده نویزی اولیه و y داده جایگزین است.

$$y=\frac{y_n-y_1}{x_n-x_1}(x-x_1)+y_1 \qquad (۱)$$

به‌منظور بررسی عملکرد روش پیشنهادی، یک مجموعه‌داده واقعی دوماهه بدون نویز در نظر گرفته شد. سپس ۱۰ درصد از داده‌ها، به‌صورت تصادفی با ضریب ۰/۵ دست‌کاری شده و روش یافتن داده نویزی روی این مجموعه‌داده جدید آزمایش شد. باتوجه‌به محدودیت فضا، بخشی از این داده در شکل ۶ نمایش‌داده‌شده است.

[Downloaded from c4i2016.khu.ac.ir on 2024-10-12]

[DOR: 20.1001.1.24237418.1401.9.4.1.3]

10	1399-07-10	636944	10	1399-07-10	636944
11	1399-07-11	307764	11	1399-07-11	307764
12	1399-07-12	659217	12	1399-07-12	659217
13	1399-07-13	651665	13	1399-07-13	651665
14	1399-07-14	696065	14	1399-07-14	696065
15	1399-07-15	666840	15	1399-07-15	666840
16	1399-07-16	738398	16	1399-07-16	738398
17	1399-07-17	658697	17	1399-07-17	658697
18	1399-07-18	312766	18	1399-07-18	312766
19	1399-07-19	619436	19	1399-07-19	619436
20	1399-07-20	671312	20	1399-07-20	671312
21	1399-07-21	663739	21	1399-07-21	663739
22	1399-07-22	662170	22	1399-07-22	662170
23	1399-07-23	651952	23	1399-07-23	651952
24	1399-07-24	319195	24	1399-07-24	319195
25	1399-07-25	596779	25	1399-07-25	596779
26	1399-07-26	711513	26	1399-07-26	711513
27	1399-07-27	758291	27	1399-07-27	758291
28	1399-07-28	747862	28	1399-07-28	747862
29	1399-07-29	892420	29	1399-07-29	892420
30	1399-07-30	964481	30	1399-07-30	964481
31	AVERAGE	640262.4333	31	AVERAGE	640262.4333
32	STD.S	137358.6961	32	STD.S	137358.6961
33	AVERAGE-STD.S	502903.7372	33	AVERAGE-2×STD.S	365545.0411

شکل ۶ بخشی از داده‌های نویزی تشخیص داده شده در مجموعه داده مورد مطالعه با روش ارائه شده

در شکل ۶، داده‌های زردرنگ، داده‌هایی هستند که به‌صورت تصادفی نویزی شده‌اند و داده آبی‌رنگ، کران پایین برای داده غیر نویزی را نشان می‌دهد. در بخش سمت راست شکل ۶، برای کران پایین از میانگین منهای انحراف معیار و در بخش سمت چپ، از میانگین منهای دوبرابر انحراف معیار استفاده شده است که در هر دو مورد، شناسایی داده‌های نویزی به‌درستی انجام‌گرفته است. لازم به ذکر است که ضریب یک و دو که بر روی انحراف معیار اعمال شده، بستگی به پراکندگی داده‌ها دارد و باید بررسی شود که اکثریت داده‌ها در کدام یک از بازه‌های نرمال که در بخش روش پیشنهادی معرفی شد قرار دارند. ضمناً طبق تجارب به‌دست‌آمده، ضریب پنجاه‌درصد که در این پژوهش برای ایجاد داده نویزی استفاده شده به‌مراتب بیشتر از آن چیزی است که در عمل روی داده‌های واقعی اتفاق می‌افتد و این بیانگر این مطلب است که در نویزهایی که کاهش محسوس‌تری روی داده ایجاد می‌کنند، این روش برای یافتن داده نویزی همچنان کارا خواهد بود. در ادامه، یک نویز ۷۰ روی ده درصد از داده‌های همین مجموعه‌داده، اعمال شد. نتایج نشان داد که همچنان روش پیشنهادی کارا است. لازم به ذکر است که اگر تعداد داده‌های نویزی زیاد شده و بیشتر از ده درصد از کل داده‌ها باشد، از کارایی این روش کاسته می‌شود.

پس از آزمودن روش یافتن داده‌های نویزی، به بررسی عملکرد روش پیشنهادی برای جایگزینی داده‌های نویزی می‌پردازیم. همان‌طور که در روش پیشنهادی بیان شد در صورت وجود رگرسیون خطی مناسب با معیار مربعات R بالاتر از ۰/۵، داده‌ها با رگرسیون خطی جایگزین می‌شوند. در غیر این صورت، جایگزینی باتوجه‌به خط مبتنی بر میانگین و یا هموارسازی پیاله‌ای انجام می‌شود. برای بررسی عملکرد روش پیشنهادی، ابتدا یک مجموعه‌داده واقعی بدون نویز که مربوط به داده‌های توییتر مهر و آبان ۱۳۹۹ است، در نظر گرفته شد. ۱۰ درصد از داده‌ها به‌صورت تصادفی نویز داده شدند. سپس جایگزینی داده‌های نویزی با استفاده از روش‌های هموارسازی پیاله‌ای، میانگین داده‌ها، رگرسیون خطی و همچنین روش پیشنهادی در این مقاله انجام شد. به‌عنوان نمونه، در شکل ۷ داده‌های نویزی با استفاده از روش پیشنهادی جایگزین شده‌اند. داده‌های جایگزین شده با رنگ آبی در این شکل مشخص شده‌اند.

[Downloaded from c4i2016.khu.ac.ir on 2024-10-12]
[DOR: 20.1001.1.24237418.1401.9.4.1.3]

shdate	count(*)	sum(like	sum(com	sum(copi	shdate	count(*)	sum(likes	sum(comments	sum(copies)
1399-07-01	627835	7641542	677278	682071	1399-08-01	868055	7391655	1368460.72	691789
1399-07-02	598443	6206703	638478	574105	1399-08-02	780309	6370673	644346	474896
1399-07-03	570534	6195023	445897	455125	1399-08-03	915292	6333758	784818	455705
1399-07-04	626976	7024088	689473	744683	1399-08-04	936144	6342516	791850	598823
1399-07-05	618325	6177121	650874	370499	1399-08-05	959373	6367915	880607	402816
1399-07-06	641865	9562344	566189	1340446	1399-08-06	949754	6378741	854941	434746
1399-07-07	526219	7276575	710957	815281	1399-08-07	947583	5983693	820995	344251
1399-07-08	648248	6868799	696674	680869	1399-08-08	889461	6382950	824411	593416
1399-07-09	625236	6255763	659553	445237	1399-08-09	949311	6024357	1335492.22	540918
1399-07-10	636944	7347858	716346	715309	1399-08-10	971298	6238731	845321	516733
1399-07-11	615528	8792936	878943	1044204	1399-08-11	753427	6810216	889109	592451
1399-07-12	659217	9317304	866396	879730	1399-08-12	988663	6410562	833442	596025
1399-07-13	651665	6880148	782858	482993	1399-08-13	980563	6564640	829135	403334
1399-07-14	696065	7337649	739806	635748	1399-08-14	1103120	8212112	936133	475949
1399-07-15	528994	7953498	829496	773184	1399-08-15	943760	7371177	839755	771296.86
1399-07-16	738398	1.34E+07	753428	3283430	1399-08-16	1018486	7623558	884186	543726
1399-07-17	658697	1.53E+07	1329164	2910053	1399-08-17	993523	7157405	894313	409951
1399-07-18	625532	7457920	675548	545539	1399-08-18	959347	5479251	753358	362575
1399-07-19	619436	1.54E+07	1216929	2855663	1399-08-19	738398	5197907	816933	390504
1399-07-20	671312	3.76E+06	1067032	120814	1399-08-20	1009438	5960716	828097	450282
1399-07-21	663739	2.41E+07	1711460	5637413	1399-08-21	942125	5952368	795123	392040
1399-07-22	662170	1.05E+07	854167	1474092	1399-08-22	923169	6848392	1697474.26	677195.56
1399-07-23	651952	8504318	838455	813544	1399-08-23	959226	6347570	786535	355037
1399-07-24	638390	3.14E+06	1031598	1684202	1399-08-24	939518	8210904	868070	619166
1399-07-25	596779	7332689	663417	873225	1399-08-25	738398	7289412	867362	478111
1399-07-26	711513	1.29E+07	1118875	1955421	1399-08-26	944048	6913326	849862	484271
1399-07-27	738398	9448569	843738	1005405	1399-08-27	936620	8517277	922928	833761
1399-07-28	747862	1.98E+07	1301373	3331408	1399-08-28	970427	8452914	957453	806700
1399-07-29	892420	2.63E+07	1756449	4185377	1399-08-29	920701	7923406	883409	736119
1399-07-30	964481	2.49E+07	1692083	5312499	1399-08-30	954370	8458948	936657	794518

شکل ۷. جایگزینی داده‌های نویزی با استفاده از روش پیشنهادی

به‌منظور مقایسه عملکرد روش‌های هموارسازی پیاله‌ای، میانگین داده‌ها، رگرسیون خطی و همچنین روش پیشنهادی، از میانگین مربعات خطا استفاده شد. برای این منظور، میانگین مربعات خطای داده‌های اصلی قبلی از نویزی شدن و داده‌های جایگزین شده با استفاده از هر روش، محاسبه شد. جدول ۱ و شکل ۸، میانگین مربعات خطای به‌دست‌آمده در این چهار روش را نشان می‌دهند. همان‌طوری که مشاهده می‌شود، روش پیشنهادی در این مقاله، همواره عملکرد بهتری نسبت به سایر روش‌ها داشته است.

جدول ۱. مقایسه عملکرد روش‌های هموارسازی پیاله‌ای، میانگین داده‌ها، رگرسیون خطی و روش پیشنهادی، در تشخیص و جایگزینی داده‌های نویزی بر اساس معیار میانگین مربعات خطا

روش	مجموع تعداد ری‌توییت	مجموع تعداد کامنت	مجموع تعداد لایک	مجموع تعداد توییت
روش پیشنهادی	۰٫۳۰	۰٫۰۹	۰٫۱۶	۰٫۰۴
هموارسازی پیاله‌ای	۰٫۴۹	۰٫۳۲	۰٫۴۶	۰٫۳۸
رگرسیون خطی	۰٫۳۰	۰٫۱۸	۰٫۱۶	۰٫۰۵
جایگزینی با میانگین	۰٫۸۶	۰٫۳۷	۰٫۲۳	۰٫۰۶

[Downloaded from c4i2016.khu.ac.ir on 2024-10-12]
[DOR: 20.1001.1.24237418.1401.9.4.1.3]

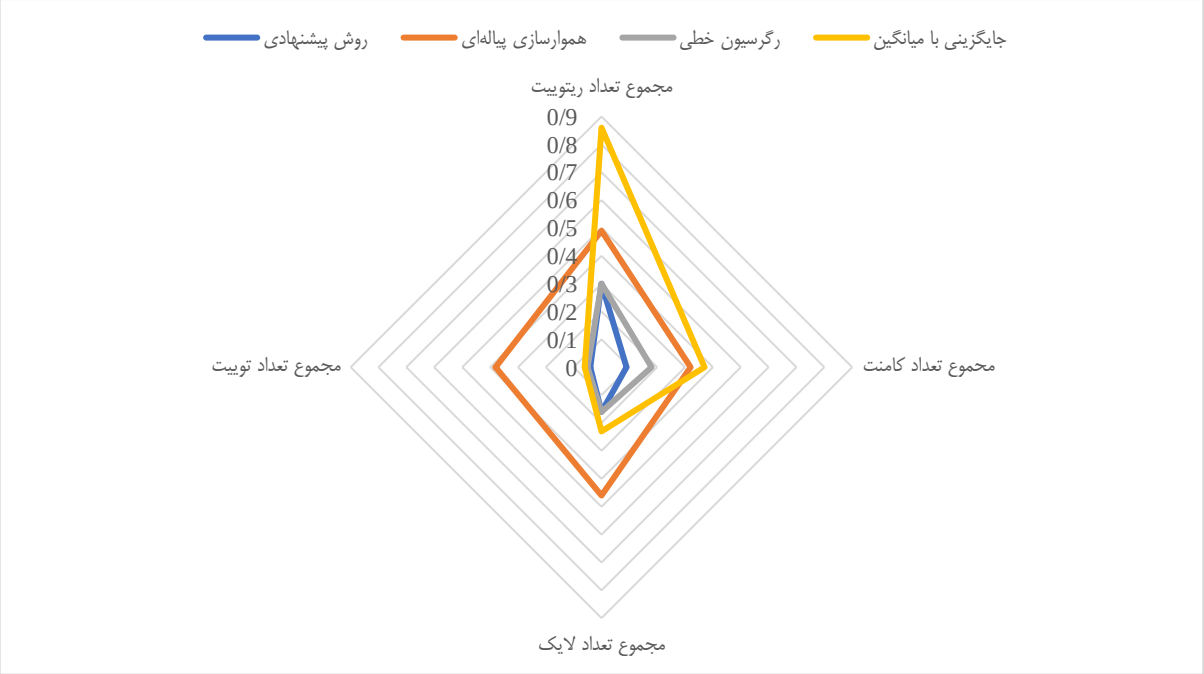

شکل ۸. نمودار مقایسه عملکرد روش‌های هموارسازی پیاله‌ای، میانگین داده‌ها، رگرسیون خطی و روش پیشنهادی، در تشخیص و جایگزینی داده‌های نویزی بر اساس معیار میانگین مربعات خطا

نتیجه‌گیری

یکی از مشکلات مهم و رایج در تحلیل داده‌ها که باعث ایجاد اشتباهات و انحرافات زیاد در نتایج تحلیل و در نتیجه، تصمیم‌سازی‌های غلط می‌گردد فقدان بخشی از داده‌ها و وجود داده‌های نویزی به دلیل ایجاد مشکلات فنی در فرایند جمع‌آوری داده‌ها است. روش‌های مختلفی برای حذف یا جایگزینی چنین داده‌هایی وجود دارد لیکن هرکدام از آن‌ها دارای مشکلات و محدودیت‌های خاص خود است. یک روش مرسوم، جایگزین‌کردن داده‌های ازدست‌رفته با میانگین سایر داده‌ها است. این روش با این که در بسیاری از مواقع، کارآمد است؛ اما موجب اختلال در توزیع و کم برآوردشدن واریانس می‌شود. یکی دیگر از راه‌های جایگزینی مقادیر ازدست‌رفته، وقتی که چند دسته داده با ارتباط معنادار میان آن‌ها وجود داشته باشد، استفاده از برازش رگرسیون خطی است. اشکال این روش این است که همه داده‌ها را روی یک خط راست برازش می‌کند و لذا برای حالتی که داده‌ها

نوسان زیادی دارند، تخمین مناسبی به‌حساب نمی‌آید. روش *SVM* نیز یکی دیگر از راه‌های جایگزینی داده‌های ازدست‌رفته است. یکی دیگر از روش‌های مرسوم، استفاده از هموارسازی پیاله‌ای است که در بسیاری مواقع نسبت به جایگزینی با میانگین، عملکرد بهتری دارد. اشکال این روش این است که علاوه بر ازبین‌بردن خط روند، ممکن است روی داده‌های واقعی نیز تأثیر بگذارد .

در این پژوهش، روشی جامع برای شناسایی و جایگزینی داده‌های پرت با بهره‌گیری از قابلیت‌های روش‌های موجود در موقعیت‌های مختلف ارائه شد. روش پیشنهادی، در برگیرنده شناسایی داده‌های ازدست‌رفته و داده‌های پرت و همچنین هموارسازی داده‌ها است. در بخش شناسایی داده‌های پرت، ابتدا میانگین همه داده‌ها محاسبه شده و از انحراف معیار آن‌ها کم می‌شود. اگر این مقدار مثبت بود تمام داده‌های کمتر از آن، به‌عنوان داده پرت در نظر گرفته می‌شود. اما در حالتی که این مقدار باز هم صفر یا منفی باشد برای شناسایی داده پرت، داده‌ها به چندین پیاله تقسیم می‌شوند و پیاله پایینی، داده پرت در نظر گرفته می‌شود. در بخش هموارسازی، از برازش داده‌ها با رگرسیون خطی استفاده می‌شود. اما در شرایط مختلف که این روش کارایی کمتری دارد به‌تناسب از روش جانهی با خط مبتنی بر میانگین و هموارسازی پیاله‌ای استفاده می‌شود .

به‌منظور ارزیابی روش پیشنهادی، از بستر ذکاوت که با همکاری نویسندگان این مقاله و جمعی از پژوهشگران دیگر به‌منظور ذائقه‌سنجی و تحلیل کاربران شبکه‌های اجتماعی توییتر، تلگرام و اینستاگرام، توسعه داده شده است و داده‌های واقعی جمع‌آوری شده از شبکه‌ها توسط این بستر، استفاده گردید. نتایج به‌دست‌آمده نشان‌دهنده عملکرد مناسب روش پیشنهادی است. همچنین مقایسه میانگین مربعات خطای هموارسازی داده‌های نویزی با

[Downloaded from c4i2016.khu.ac.ir on 2024-10-12]
[DOR: 20.1001.1.24237418.1401.9.4.1.3]

استفاده از روش‌های هموارسازی پیاله‌ای، میانگین داده‌ها، رگرسیون خطی و راهکار پیشنهادی نشان داد که روش پیشنهادی همواره دارای دقت بالاتری نسبت به سایر روش‌ها است.

به‌عنوان پژوهش‌های آتی می‌توان به استفاده از تکنیک‌های داده‌کاوی شامل خوشه‌بندی و رگرسیون، و همچنین الگوریتم‌های هیوریستیک شامل الگوریتم ژنتیک اشاره کرد. بدین صورت که از خوشه‌بندی به‌منظور شناسایی رکوردهای مشابه، و محاسبه داده ازدست‌رفته بر اساس رکوردهای مشابه موجود در خوشه استفاده شود. استفاده از مدل رگرسیون در خوشه که سبب می‌شود در محاسبه داده‌های ازدست‌رفته، فیلدهای مربوط در صفات (ستون‌ها) دیگر نیز در نظر گرفته شود. همچنین، استفاده از جهش و ترکیب کروموزوم‌ها در الگوریتم ژنتیک که منجر به استفاده تلفیقی از میانگین، میانه، مد و مدل رگرسیون می‌شود، سبب دستیابی به نتایج قابل‌قبول‌تری خواهد شد.

References

Aggarwal, C. C., & Yu, P. S. (2005). An effective and efficient algorithm for high-dimensional outlier detection. The VLDB journal, 14, 211-221.

Arning, A., Agrawal, R., & Raghavan, P. (1996, August). A Linear Method for Deviation Detection in Large Databases. In KDD (Vol. 1141, No. 50, pp. 972-981).

Biessmann, F., Rukat, T., Schmidt, P., Naidu, P., Schelter, S., Taptunov, A., ... & Salinas, D. (2019). DataWig: Missing Value Imputation for Tables. J. Mach. Learn. Res., 20(175), 1-6.

Han, J, & Kamber, M. (2006). Data mining: concepts and techniques, 2nd. University of Illinois at Urbana Champaign: Morgan Kaufmann.

Honghai, F., Guoshun, C., Cheng, Y., Bingru, Y., & Yumei, C. (2005, September). A SVM regression based approach to filling in missing values. In International Conference on Knowledge-Based and Intelligent Information and Engineering Systems (pp. 581-587). Springer, Berlin, Heidelberg.

Kantardzic, M. (2011). Data mining: concepts, models, methods, and algorithms. John Wiley & Sons.

Kiani, R., & Montazeri, M. (2015). A review of outlier detection methods. International Conference on Research in Science and Technology, Kualalampur, Malaysia. (Persian)

Li, L., Zhou, H., Liu, H., Zhang, C., & Liu, J. (2021). A hybrid method coupling empirical mode decomposition and a long short-term memory network to predict missing measured signal data of SHM systems. Structural Health Monitoring, 20(4), 1778-1793.

Liu, Y., Dillon, T., Yu, W., Rahayu, W., & Mostafa, F. (2020). Missing value imputation for industrial IoT sensor data with large gaps. IEEE Internet of Things Journal, 7(8), 6855-6867.

Sadik, M., & Gruenwald, L. (2010, August). DBOD-DS: Distance based outlier detection for data streams. In International Conference on Database and Expert Systems Applications (pp. 122-136). Springer, Berlin, Heidelberg.

Tada, M., Suzuki, N., & Okada, Y. (2022). Missing Value Imputation Method for Multiclass Matrix Data Based on Closed Itemset. Entropy, 24(2), 286.

Troyanskaya, O., Cantor, M., Sherlock, G., Brown, P., Hastie, T., Tibshirani, R., ... & Altman, R. B. (2001). Missing value estimation methods for DNA microarrays. Bioinformatics, 17(6), 520-525.

Zhang, Y., Zhou, B., Cai, X., Guo, W., Ding, X., & Yuan, X. (2021). Missing value imputation in multivariate time series with end-to-end generative adversarial networks. Information Sciences, 551, 67-82.

Zhou, X., Wang, X., & Dougherty, E. R. (2003). Missing-value estimation using linear and non-linear regression with Bayesian gene selection. Bioinformatics, 19(17), 2302-2307.

[Downloaded from c4i2016.khu.ac.ir on 2024-10-12]

[DOR: 20.1001.1.24237418.1401.9.4.1.3]