



Data-Driven Integrated Analysis in Monitoring Manufacturing Processes Using Principal Component Analysis and Multivariate Control Charts (Case Study: Mobarakeh Steel Company, Isfahan)

Mahsa Jafari*^{ID}
Sadegh Shahbazi**^{ID}
Mehdi Karbasian***^{ID}

Extended Abstract

Introduction and Objectives .In advanced manufacturing industries, especially in industries such as steel that are faced with complex and multi-stage processes, optimizing the monitoring of quality and performance of production lines is of high importance. Traditional univariate monitoring methods, due to their inability to analyze the relationships among different variables, are inefficient in the timely identification of anomalies. Therefore, the combination of multivariate statistical process control (MSPC) methods and Principal Component Analysis (PCA) as an innovative solution can be an efficient tool for reducing data complexity, increasing monitoring accuracy, and improving the final quality of products. The objective of this research is to design and validate a hybrid model based on PCA and multivariate control charts in order to optimize monitoring in the slab production process at Mobarakeh Steel Company.

Methods. The present study was conducted with a quantitative approach and based on the analysis of real data from the production lines of Mobarakeh Steel. First, control data related to the casting process were collected and outlier data were removed using boxplot charts. Then, by performing the KMO and Bartlett tests, the adequacy of the data and the correlation of variables for implementing PCA analysis were confirmed $KMO = 0.78$, $p < 0.001$. PCA analysis led to the extraction of three principal components that identified the most important influential variables in the process. These components were given as inputs to the multivariate control models MEWMA and MCUSUM. In specific cases, the Hotelling T^2 chart was used. The developed model, after implementation, was validated by industry experts.

Received: Apr. 12, 2025; Revised: Jul. 02, 2025; Accepted: Sep. 17, 2025; Published Online: Sep. 23, 2025.

* Ph.D. Student, Industrial Engineering, Malek Ashtar university of Technology, Tehran, Iran.

** Associate Prof, Industrial Engineering, Malek Ashtar university of Technology, Isfahan, Iran.

Corresponding Author: shahbazi@mut-es.ac.ir

*** Prof, Industrial Engineering, Malek Ashtar university of Technology, Tehran, Iran



Findings. The results of the analysis showed that by reducing the data dimensions from 9 variables to 3 key components (PC1, PC2, and PC3), more accurate process monitoring was made possible. In the casting stage, the use of the MEWMA chart led to faster identification of fluctuations and deviations, while the EWMA chart was used for univariate monitoring in order to compare performance. The comparison between these two models showed that MEWMA has higher sensitivity to small changes in the process. Also, the implementation of the hybrid model resulted in 95% of out-of-control points being identified using only four charts, whereas previously they were scattered across more than 45 charts. Regression analysis of the components also confirmed that the principal components well describe the changes of the key variables.

Conclusion. This research shows that the combination of PCA methods and multivariate quality control not only increased the accuracy in monitoring the production process but also significantly reduced the complexity of control models and monitoring costs. The application of this approach leads to the reduction of false alarms, increased speed of response to changes, and overall improvement of the quality system. Also, by appropriate adjustment of the lambda (λ) parameter in the MEWMA model, the overlap of detecting deviation points with univariate methods reaches more than 80%. Based on expert confirmation, the proposed model has high practical capability and is proposed as a practical solution for improving process monitoring in large industries such as steelmaking.

Keywords: Multivariate quality control; Principal Component Analysis; Monitoring of production processes; MEWMA control chart; Mobarakeh Steel Company.

How to Cite: Jafari, Mahsa; Shahbazi, Sadegh; Karbasian, Mehdi (2025). Data-Driven Integrated Analysis in Monitoring Manufacturing Processes Using Principal Component Analysis and Multivariate Control Charts (Case Study: Mobarakeh Steel Company, Isfahan). *Ind. Manag. Persp.*, 15(4), 90-115 (*In Persian*).



تحلیل تلفیقی داده‌محور در پایش فرآیندهای تولیدی با استفاده از تحلیل مؤلفه‌های اصلی و نمودارهای کنترلی چندمتغیره (مطالعه موردی شرکت فولاد مبارکه اصفهان)

مهسا جعفری* 

صادق شهبازی** 

مهدی کرباسیان*** 

مقدمه و اهداف: در صنایع تولیدی پیشرفته، خصوصاً در صنایعی نظیر فولاد که با فرآیندهای پیچیده و چندمرحله‌ای مواجه هستند، بهینه‌سازی نظارت بر کیفیت و عملکرد خطوط تولید از اهمیت بالایی برخوردار است. روش‌های سنتی پایش تک‌متغیره به دلیل ناتوانی در تحلیل روابط میان متغیرهای مختلف، در شناسایی به‌موقع ناهنجاری‌ها ناکارآمد هستند. از این‌رو، ترکیب روش‌های کنترل کیفیت چندمتغیره (MSPC) و تحلیل مؤلفه‌های اصلی (PCA) به عنوان یک راهکار نوین، می‌تواند ابزاری کارآمد برای کاهش پیچیدگی داده‌ها، افزایش دقت پایش و بهبود کیفیت نهایی محصولات باشد. هدف این پژوهش، طراحی و اعتبارسنجی مدلی ترکیبی بر پایه PCA و نمودارهای کنترلی چندمتغیره جهت بهینه‌سازی نظارت در فرآیند تولید تختال در شرکت فولاد مبارکه است.

روش‌ها: مطالعه حاضر با رویکرد کمی و بر مبنای تحلیل داده‌های واقعی خطوط تولید فولاد مبارکه انجام شد. ابتدا داده‌های کنترلی مرتبط با فرآیند ریخته‌گری جمع‌آوری و داده‌های پرت با استفاده از نمودارهای باکس‌پلات حذف شدند. سپس با انجام آزمون KMO و بارتلت، کفایت داده‌ها و همبستگی متغیرها جهت اجرای تحلیل PCA تأیید شد $KMO = 0.78$ ، $p < 0.001$ تحلیل PCA به استخراج سه مؤلفه اصلی منجر گردید که مهم‌ترین متغیرهای تأثیرگذار را در فرآیند مشخص کرد. این مؤلفه‌ها به‌عنوان ورودی به مدل‌های کنترلی چندمتغیره MEWMA و MCUSUM داده شدند. در موارد خاص، از نمودار T^2 Hotelling استفاده شد. مدل توسعه‌یافته پس از پیاده‌سازی، توسط خبرگان صنعت اعتبارسنجی شد.

تاریخ دریافت: ۱۴۰۴/۰۱/۲۳، تاریخ بازنگری: ۱۴۰۴/۰۴/۱۱، تاریخ پذیرش: ۱۴۰۴/۰۶/۲۶، تاریخ اولین انتشار: ۱۴۰۴/۰۷/۰۱.

* دانشجوی دکتری، گروه مهندسی صنایع، دانشکده مهندسی صنایع، دانشگاه صنعتی مالک اشتر، تهران، ایران.

** استادیار، گروه مهندسی صنایع، دانشکده مهندسی صنایع، دانشگاه صنعتی مالک اشتر، اصفهان، ایران.

*** استاد، گروه مهندسی صنایع، دانشکده مهندسی صنایع، دانشگاه صنعتی مالک اشتر، تهران، ایران.

یافته‌ها: نتایج تحلیل نشان داد که با کاهش ابعاد داده‌ها از ۹ متغیر به ۳ مؤلفه کلیدی (PC1)، PC2 و PC3، امکان پایش دقیق‌تر فرآیند فراهم شد. در مرحله‌ی ریخته‌گری، استفاده از نمودار MEWMA منجر به شناسایی سریع‌تر نوسانات و انحرافات شد، در حالی که نمودار EWMA برای پایش تک‌متغیره جهت مقایسه عملکرد به کار رفت. مقایسه بین این دو مدل نشان داد که MEWMA دارای حساسیت بالاتری نسبت به تغییرات کوچک در فرآیند است. همچنین اجرای مدل ترکیبی موجب شد ۹۵٪ از نقاط خارج از کنترل تنها با چهار نمودار شناسایی شوند، در حالی که پیش‌تر در بیش از ۴۵ نمودار پراکنده بودند. تحلیل رگرسیونی مؤلفه‌ها نیز تأیید کرد که مؤلفه‌های اصلی به‌خوبی تغییرات متغیرهای کلیدی را توصیف می‌کنند.

نتیجه‌گیری: این پژوهش نشان می‌دهد که ترکیب روش‌های PCA و کنترل کیفیت چندمتغیره نه تنها باعث افزایش دقت در نظارت بر فرآیند تولید شده بلکه به میزان چشم‌گیری از پیچیدگی مدل‌های کنترلی و هزینه‌های پایش کاسته است. به‌کارگیری این رویکرد منجر به کاهش هشدارهای کاذب، افزایش سرعت واکنش به تغییرات، و ارتقای کلی سیستم کیفیت می‌شود. همچنین با تنظیم مناسب پارامتر لاندا (λ) در مدل MEWMA، میزان هم‌پوشانی تشخیص نقاط انحرافی با روش‌های تک‌متغیره به بیش از ۸۰٪ می‌رسد. بر اساس تأیید خبرگان، مدل پیشنهادی قابلیت اجرایی بالایی داشته و به‌عنوان یک راهکار عملی برای بهبود پایش فرآیند در صنایع بزرگ مانند فولادسازی پیشنهاد می‌گردد.

کلمات کلیدی: کنترل کیفیت چندمتغیره؛ تحلیل مؤلفه‌های اصلی؛ پایش فرآیندهای تولیدی؛ نمودار کنترلی MEWMA؛ شرکت فولاد مبارکه.

استناددهی: جعفری، مهسا؛ شهبازی، صادق؛ کرباسیان، مهدی (۱۴۰۴). تحلیل تلفیقی داده‌محور در پایش فرآیندهای تولیدی با استفاده از تحلیل مؤلفه‌های اصلی و نمودارهای کنترلی چندمتغیره (مطالعه موردی شرکت فولاد مبارکه اصفهان). چشم‌انداز مدیریت صنعتی، ۱۵(۴)، ۹۰-۱۱۵.



۱. مقدمه

در صنایع تولیدی مدرن، پیچیدگی روزافزون فرایندها و تنوع بالای محصولات ایجاب می‌کند که روش‌های نظارتی و کنترلی به گونه‌ای طراحی شوند که بتوانند در زمان واقعی (Real-Time) عملکرد فرآیند را تحلیل کرده و پاسخ مناسبی به تغییرات و نوسانات سیستم ارائه دهند. این امر به‌ویژه در صنایعی نظیر صنعت فولاد، که فرایندهای تولیدی آن شامل مراحل متوالی و وابسته با شرایط عملیاتی متغیر است، از اهمیت بالایی برخوردار است. در چنین شرایطی، روش‌های سنتی کنترل کیفیت که بر اساس پایش تک‌متغیره عمل می‌کنند، قادر به شناسایی سریع و دقیق مشکلات فرآیند نخواهند بود، چراکه این روش‌ها نمی‌توانند وابستگی‌های میان متغیرهای مختلف را به‌درستی مدل‌سازی و تحلیل کنند [۱].

به همین دلیل، رویکردهای نوینی مانند کنترل کیفیت چندمتغیره^۱ یا MSPC توسعه یافته‌اند که با استفاده از تکنیک‌های آماری پیشرفته، امکان نظارت هم‌زمان بر چندین متغیر فرآیندی را فراهم می‌کنند. در این رویکرد، ساختار همبستگی میان متغیرها مورد توجه قرار می‌گیرد و تغییرات ناهمگون یا ناهمبسته در الگوی کلی متغیرها می‌تواند به عنوان نشانه‌ای از بروز اختلال در سیستم تلقی شود. این روش به‌ویژه در مواقعی که نوسانات کوچک در چند متغیر به صورت هم‌زمان اتفاق می‌افتد و نشانه‌ای از تغییر بزرگ‌تری در فرآیند است، کارآمدتر از روش‌های سنتی ظاهر می‌شود [۲]. در کنار استفاده از مدل‌های چندمتغیره، تحلیل مؤلفه‌های اصلی یا PCA^۲ نیز نقش کلیدی در بهینه‌سازی نظارت ایفا می‌کند. این روش با تبدیل داده‌های چندبعدی به مجموعه‌ای از مؤلفه‌های اصلی که بیشترین واریانس موجود در داده‌ها را توصیف می‌کنند، موجب کاهش ابعاد داده‌ها و حذف نویز و متغیرهای کم‌اهمیت می‌شود. این کاهش ابعاد نه تنها باعث ساده‌سازی تحلیل داده‌ها می‌گردد، بلکه دقت و سرعت پردازش سیستم‌های کنترلی را نیز افزایش می‌دهد. به عبارتی، با تمرکز بر مؤلفه‌های اصلی، امکان طراحی شاخص‌هایی فراهم می‌شود که حساسیت بالایی نسبت به تغییرات فرآیندی داشته و از طرف دیگر به میزان کمتری تحت تأثیر نویزهای تصادفی قرار دارند [۳].

ترکیب روش PCA با کنترل کیفیت چندمتغیره یکی از راهکارهای قدرتمند برای مدیریت داده‌های حجیم و پیچیده در محیط‌های صنعتی است. به‌کارگیری این ترکیب، امکان استخراج اطلاعات نهفته در داده‌ها را فراهم ساخته و می‌تواند به‌طور مؤثری در تشخیص زودهنگام ناهنجاری‌ها، پیش‌بینی خرابی‌ها و بهینه‌سازی فرایندهای تولیدی نقش آفرینی کند. همچنین این ترکیب قابلیت انطباق‌پذیری با الگوریتم‌های یادگیری ماشین را دارد و می‌تواند به عنوان بخشی از سیستم‌های هوشمند تولید در قالب کارخانه‌های نسل چهارم^۳ مورد بهره‌برداری قرار گیرد [۴].

با رشد سریع فناوری‌های اندازه‌گیری و ظهور حسگرهای پیشرفته که قادر به تولید داده‌های حجیم با نرخ بالا هستند، چالش اصلی در تحلیل داده‌ها نه جمع‌آوری، بلکه پردازش، تفسیر و استفاده مؤثر از آن‌ها است. بنابراین، به‌کارگیری ابزارهای تحلیلی همچون PCA و MSPC در چارچوب معماری‌های نوین نظارتی، ضرورتی اجتناب‌ناپذیر برای حفظ رقابت‌پذیری و بهره‌وری در صنایع پیشرفته محسوب می‌شود. استفاده از این رویکردها همچنین به تصمیم‌گیری آگاهانه‌تر در سطوح مختلف مدیریتی، از کنترل عملیاتی تا برنامه‌ریزی استراتژیک، کمک شایانی می‌کند و راه را برای تحقق تولید هوشمند و پایدار هموار می‌سازد [۵].

۲. مبانی و چارچوب نظری تحقیق

در دهه‌های اخیر، نظارت بر فرایندهای تولیدی با رویکرد داده‌محور و بهره‌گیری از روش‌های نوین آماری، الگوریتم‌های یادگیری ماشین و مدل‌سازی پیشرفته به یکی از موضوعات کلیدی در حوزه مهندسی صنایع، مهندسی سیستم‌های تولید و تحلیل داده‌های صنعتی تبدیل شده است. با گسترش فناوری‌های تولیدی و افزایش رقابت در بازارهای جهانی، سازمان‌ها ناچار به استفاده از راهکارهایی هستند که بتوانند فرایندهای خود را با بالاترین

1. Multivariate Statistical Process Control
2. Principal Component Analysis
3. Industry 4.0

سطح کارایی، کیفیت و تطبیق‌پذیری نسبت به تغییرات داخلی و خارجی مدیریت کنند. یکی از مهم‌ترین چالش‌های صنایع تولیدی، شناسایی سریع و دقیق نوسانات و اختلالات احتمالی در خطوط تولید است؛ چرا که این نوسانات در صورت عدم کنترل به‌موقع، می‌توانند منجر به افزایش ضایعات، کاهش کیفیت محصول، هدررفت منابع و نارضایتی مشتریان شوند [۶].

پیشرفت در ابزارهای جمع‌آوری داده، از جمله سنسورهای هوشمند، سامانه‌های SCADA و اینترنت اشیا صنعتی موجب شده است که حجم عظیمی از داده‌های فرآیندی به‌صورت پیوسته در طول فرآیندهای تولیدی ثبت و ذخیره شوند. این داده‌ها شامل متغیرهای مختلف کیفی و کمی در سطوح مختلف تولید، از جمله دما، فشار، سرعت، میزان مواد اولیه مصرفی، کیفیت خروجی هر ایستگاه کاری و دیگر پارامترهای مهم کنترلی هستند. با وجود ارزشمندی این داده‌ها، چالش اصلی در استفاده بهینه از آن‌ها، نه صرفاً در جمع‌آوری، بلکه در تحلیل هوشمند، تفسیر دقیق و بهره‌برداری هدفمند از آن‌ها در راستای تصمیم‌سازی‌های راهبردی است [۷ و ۸].

در این راستا، استفاده از مدل‌های داده‌محور مانند الگوریتم‌های یادگیری ماشین، یادگیری عمیق، و همچنین تکنیک‌های آماری چندمتغیره مانند تحلیل مؤلفه‌های اصلی و تحلیل خوشه‌ای^۱ به عنوان ابزارهایی برای استخراج دانش پنهان در داده‌ها، در سال‌های اخیر رشد چشمگیری داشته است. این ابزارها به مدیران و مهندسان صنایع این امکان را می‌دهند که الگوهای پنهان در داده‌های تولیدی را شناسایی کرده، روابط غیرخطی میان متغیرها را کشف نموده، و هشدارهای پیشگیرانه برای کنترل کیفیت و بهینه‌سازی فرآیندها صادر کنند [۹ و ۱۰ و ۱۱].

در صنایع پیچیده‌ای مانند فولاد، که فرآیند تولید شامل چندین مرحله وابسته و پیوسته است از جمله کوره قوس الکتریکی، متالورژی ثانویه و ریخته‌گری مداوم پایش دقیق و بالادرنگ فرآیندهای تولیدی نه‌تنها به بهبود کیفیت نهایی محصول کمک می‌کند، بلکه موجب کاهش هزینه‌های تولید، افزایش بهره‌وری تجهیزات، و ارتقاء قابلیت اطمینان سیستم می‌شود. در چنین صنایعی، وجود تغییرات کوچک و پنهان در مراحل ابتدایی تولید می‌تواند پیامدهای بزرگی در مراحل نهایی داشته باشد، لذا بهره‌گیری از سیستم‌های کنترلی پیشرفته مبتنی بر داده، ضرورتی انکارناپذیر است [۱۲]. بنابراین، توسعه روش‌هایی که بتوانند این حجم از داده‌های پیچیده و چندبعدی را به شکل مؤثر پردازش کرده و از آن‌ها برای پایش هوشمند، پیش‌بینی کیفیت، و تشخیص ناهنجاری‌ها استفاده کنند، از اولویت‌های مهم پژوهشی در دهه اخیر محسوب می‌شود. ترکیب دانش آماری با تکنولوژی‌های داده‌محور، رویکردی نوین و کارآمد برای افزایش تاب‌آوری و پایداری سیستم‌های تولیدی در برابر نوسانات، اختلالات و عدم قطعیت‌های فرآیندی ارائه می‌دهد [۱۳].

۲.۱ مدل‌های داده‌محور و یادگیری ماشین در پایش فرآیندهای تولیدی

مطالعات متعددی نشان داده‌اند که مدل‌های داده‌محور مبتنی بر الگوریتم‌های یادگیری ماشین، مانند شبکه‌های عصبی مصنوعی، جنگل تصادفی، و یادگیری عمیق، قادرند کیفیت محصول را در فرآیندهای چندمرحله‌ای با دقت بالایی پیش‌بینی کنند. به عنوان مثال، تیان و همکاران^۲ (۲۰۲۲) با بهره‌گیری از داده‌های کلان تولیدی و شبکه‌های عصبی پیشرفته، توانستند نوسانات غیرعادی در فرآیندهای پیچیده را به سرعت شناسایی و عملکرد تولید را بهینه کنند. این روش‌ها امکان تحلیل هم‌زمان داده‌های متعدد و پیچیده را فراهم می‌آورند، اما نیازمند حجم بالای داده و قدرت محاسباتی قابل توجه هستند که ممکن است در صنایع با منابع محدود، چالش برانگیز باشد [۴].

۲.۲ اهمیت و کاربرد روش‌های کاهش ابعاد

یکی از چالش‌های اصلی در کاربرد روش‌های یادگیری ماشین در صنعت، حجم زیاد داده‌ها و پیچیدگی محاسباتی ناشی از آن است. ال‌رفیچی و همکاران^۳ (۲۰۲۲) در پژوهش خود نشان دادند که به‌کارگیری روش‌های کاهش ابعاد و انتخاب ویژگی در داده‌های تولیدی چندمرحله‌ای، موجب

1. Clustering
2. Tian et al
3. Alrufaihi et al

افزایش دقت پیش‌بینی و کاهش زمان محاسباتی می‌شود. بدون استفاده از تکنیک‌های کاهش ابعاد، مدل‌های یادگیری ماشین ممکن است دچار "ابتدال ابعاد" شوند که اثر منفی بر کارایی آن‌ها دارد. به‌علاوه، کاهش ابعاد کمک می‌کند تا نویزهای موجود در داده‌ها حذف شده و تمرکز مدل بر ویژگی‌های مهم‌تر معطوف گردد [۲].

۲.۳ روش‌های آماری کلاسیک و تحلیل مؤلفه‌های اصلی (PCA)

روش‌های آماری کلاسیک همچنان به عنوان پایه‌ای‌ترین تکنیک‌ها در پایش فرآیندهای تولیدی مطرح هستند. تحلیل مؤلفه‌های اصلی یکی از پرکاربردترین تکنیک‌های کاهش ابعاد است که با تبدیل داده‌های اولیه به مجموعه‌ای از مؤلفه‌های اصلی، ویژگی‌های مهم را استخراج می‌کند. مطالعه تانگ و همکاران^۲ (۲۰۱۷) نشان داد که PCA می‌تواند در شناسایی عیوب فرآیندهای چندمرحله‌ای، نقش مؤثری ایفا کند و با کاهش ابعاد داده‌ها، شناسایی علل مشکلات در خطوط تولید را تسریع کند. با این حال، PCA به صورت ذاتی خطی است و در شرایطی که داده‌ها ساختار غیرخطی داشته باشند، ممکن است نتایج قابل قبولی ارائه ندهد [۳ و ۴].

۲.۴ ترکیب روش‌های کاهش ابعاد و یادگیری عمیق

تحقیقات جدیدتر به ترکیب تکنیک‌های کاهش ابعاد با الگوریتم‌های یادگیری عمیق پرداخته‌اند بی و همکاران^۳ (۲۰۱۹) در مطالعه تطبیقی، روش‌های مختلف کاهش ابعاد از جمله PCA، تحلیل تفکیک خطی و شبکه‌های عصبی عمیق را بررسی کردند و نشان دادند که این ترکیب می‌تواند منجر به بهبود چشمگیر در دقت مدل‌های نظارتی و پیش‌بینی کیفیت شود [۲]. این رویکرد ترکیبی، ضمن حفظ اطلاعات کلیدی، باعث کاهش نویز و پیچیدگی مدل می‌شود و امکان مدیریت داده‌های بزرگ و پیچیده را فراهم می‌کند. با این وجود، پیاده‌سازی این مدل‌ها به دانش فنی بالا و منابع محاسباتی قوی نیاز دارد.

۲.۵ نمودارهای کنترلی چندمتغیره و روش‌های پایش چندمتغیره

نمودارهای کنترلی چندمتغیره مانند MEWMA^۴ و MCUSUM^۵ ابزارهای قدرتمندی برای پایش هم‌زمان چندین متغیر وابسته در فرآیندهای تولیدی هستند. این نمودارها با ترکیب داده‌های چند متغیر، حساسیت بیشتری نسبت به تغییرات فرآیندی دارند و نسبت به نمودارهای تک‌متغیره در شناسایی تغییرات کوچک و ناگهانی بهتر عمل می‌کنند. مطالعه اسماعیل و همکاران^۶ (۲۰۲۲) نشان داد که استفاده از این نمودارها به همراه مدل‌های یادگیری ماشین مانند درخت تصمیم و جنگل تصادفی می‌تواند دقت پیش‌بینی کیفیت را به شکل قابل توجهی افزایش دهد [۳]. وانگ^۷ و همکاران (۲۰۲۳) نیز با استفاده از یادگیری عمیق چندوظیفه‌ای، توانستند پیش‌بینی کیفیت در فرآیندهای چندمرحله‌ای را با دقت بالاتری نسبت به روش‌های سنتی ارائه دهند که نشان‌دهنده روند رو به رشد استفاده از روش‌های نوین یادگیری ماشین در کنترل کیفیت است [۵ و ۶].

۲.۶ شکاف تحقیق

مرور جامع ادبیات و مطالعات پیشین در حوزه پایش فرآیندهای تولیدی نشان می‌دهد که اگرچه در سال‌های اخیر تلاش‌های متعددی برای بهره‌گیری از روش‌های داده‌محور، تکنیک‌های آماری کلاسیک، و الگوریتم‌های یادگیری ماشین جهت بهبود کیفیت و افزایش کارایی سیستم‌های تولیدی صورت گرفته است، اما هنوز خلأها و چالش‌های قابل توجهی در این زمینه وجود دارد که ضرورت انجام پژوهش‌های جدید را توجیه می‌کند. نخست، بسیاری از پژوهش‌های قبلی تمرکز خود را بر استفاده مستقل از روش‌های آماری کاهش ابعاد مانند تحلیل مؤلفه‌های اصلی (PCA) یا صرفاً بر کاربرد نمودارهای کنترلی چندمتغیره معطوف داشته‌اند؛ در حالی که استفاده هم‌زمان و تلفیقی از این دو رویکرد، به‌ویژه با هدف ارتقاء کارایی

1. Curse of Dimensionality

2. Tong et al

3. Bai et al

4. Multivariate Exponentially Weighted Moving Average

5. Multivariate Cumulative Sum

6. Ismail et al

7. Wang et al

مدل‌های پایش فرآیندهای پیچیده، کمتر مورد توجه قرار گرفته است. این در حالی است که ترکیب تکنیک‌های کاهش بعد با نمودارهای کنترلی چندمتغیره می‌تواند ضمن کاهش نویز و حذف ابعاد غیرضروری داده‌ها، موجب بهبود دقت و حساسیت مدل‌های نظارتی گردد. خلاً موجود در مطالعات میان‌رشته‌ای که از قابلیت‌های مکمل این دو رویکرد بهره‌برداری کنند، نشان‌دهنده شکاف روش‌شناختی مهمی در ادبیات پژوهش است. دوم، اغلب تحقیقات گذشته در محیط‌های کنترل‌شده آزمایشگاهی یا بر پایه داده‌های مصنوعی و شبیه‌سازی شده انجام شده‌اند. این در حالی است که پیچیدگی‌های خاص داده‌های واقعی تولیدی در صنایع سنگین، به‌ویژه صنایع فولاد با فرآیندهای چندمرحله‌ای پیوسته و وابسته به هم، اقتضا می‌کند تا مدل‌های نظارتی در بسترهای واقعی‌تر مورد آزمون قرار گیرند. بدین ترتیب، عدم تطابق روش‌های موجود با شرایط واقعی خطوط تولید، و فقدان نمونه‌های تجربی مبتنی بر داده‌های عملیاتی واقعی، شکاف کاربردی جدی‌ای را در حوزه پایش داده‌محور فرآیندهای صنعتی رقم زده است. سوم، با وجود آنکه برخی مطالعات نوین به کارگیری الگوریتم‌های پیچیده یادگیری عمیق مانند شبکه‌های عصبی چندوظیفه‌ای را مد نظر قرار داده‌اند، اما این مدل‌ها در عین ارائه دقت قابل توجه، از نظر پیاده‌سازی عملی در محیط‌های صنعتی با چالش‌هایی نظیر نیاز به منابع محاسباتی بالا، دشواری در تنظیم پارامترها، و تفسیرپذیری پایین مواجه‌اند. بنابراین، هنوز نیاز به توسعه مدل‌هایی با ساختار ساده‌تر، اما با دقت و کارایی مطلوب وجود دارد؛ مدل‌هایی که ضمن حفظ اثربخشی، قابلیت پیاده‌سازی در شرایط واقعی تولید را نیز داشته باشند.

در نهایت، بررسی مقایسه‌ای ادبیات نشان می‌دهد که تاکنون چارچوبی جامع و یکپارچه برای بهینه‌سازی پایش فرآیندهای تولیدی که به‌صورت هم‌زمان از مزایای کاهش ابعاد، توانایی تحلیل چندمتغیره، و قابلیت انطباق با داده‌های واقعی برخوردار باشد، ارائه نشده است. پژوهش حاضر با هدف پوشش این شکاف‌های مفهومی، روش‌شناختی و کاربردی، مدلی نوین و بهینه را مبتنی بر تحلیل مؤلفه‌های اصلی (PCA) و نمودارهای کنترلی چندمتغیره ارائه می‌دهد که نه تنها از منظر دقت آماری و حساسیت تشخیص دارای کارایی مناسبی است، بلکه از حیث سادگی پیاده‌سازی و انطباق با داده‌های پیچیده صنعتی نیز قابل اتکا است. بدین ترتیب، این پژوهش می‌تواند پاسخی علمی و عملی به بخشی از نیازهای موجود در زمینه توسعه روش‌های کنترلی پیشرفته و داده‌محور در صنایع تولیدی به‌شمار آید. جدول ۱ خلاصه‌ای از مطالعات اخیر را نمایش می‌دهد.

جدول ۱. جدول تحلیلی تحقیقات پیشین

نام تحقیق و نویسندگان	روش‌ها و مدل‌ها	نقاط قوت	نقاط ضعف	ارتباط و تفاوت با پژوهش حاضر
تیان و همکاران (2022)	شبکه‌های عصبی عمیق، مدل‌های پیش‌بینی داده‌محور	شناسایی سریع نوسانات، کارایی بالا در صنایع پیچیده، استفاده از داده‌های کلان	نیاز به داده‌های گسترده و محاسبات سنگین، احتمال بیش‌برازش	تأکید بر مدل‌های داده‌محور، ولی بدون تمرکز کافی بر کاهش ابعاد
الرفیعی و همکاران (2022)	کاهش ابعاد و انتخاب ویژگی در یادگیری ماشین	کاهش پیچیدگی محاسباتی، افزایش دقت پیش‌بینی، حذف نویز	احتمال از دست رفتن اطلاعات مهم در کاهش ابعاد شدید	رویکرد کاهش ابعاد که در مدل پژوهش حاضر به صورت هم‌زمان با پایش چندمتغیره به کار رفته است
تانگ و همکاران (2017)	تحلیل مؤلفه‌های اصلی (PCA)	روش ساده، سریع و کارآمد در کاهش ابعاد، شناسایی عیوب دقیق	محدود به داده‌های خطی، حساسیت به داده‌های پرت و نویزی	استفاده مستقیم از PCA مشابه پژوهش حاضر، با تأکید بیشتر بر کاربرد عملی
بی و همکاران (2019)	ترکیب PCA، LDA، یادگیری عمیق	بهبود قابل توجه دقت مدل‌ها، مدیریت بهتر داده‌های پیچیده	پیچیدگی بالای پیاده‌سازی، نیاز به منابع محاسباتی قوی	ترکیب روش‌های کاهش ابعاد و یادگیری عمیق که در پژوهش حاضر به صورت بهینه‌تر و ساده‌تر و توسعه یافته است
اسماعیل و همکاران (2022)	نمودارهای کنترلی چندمتغیره، یادگیری ماشین	حساسیت بالاتر نسبت به تغییرات فرآیندی، دقت بیشتر پیش‌بینی	نیاز به داده‌های آموزشی گسترده، پیچیدگی مدل‌های یادگیری ماشین	استفاده از نمودارهای کنترلی چندمتغیره که در پژوهش حاضر با تحلیل مؤلفه‌ها ادغام شده‌اند

نام تحقیق و نویسندگان	روش‌ها و مدل‌ها	نقاط قوت	نقاط ضعف	ارتباط و تفاوت با پژوهش حاضر
وانگ و همکاران (2023)	یادگیری عمیق چندوظیفه‌ای	دقت پیش‌بینی بسیار بالا، قابلیت تعمیم، عملکرد بهتر نسبت به روش‌های سنتی	محاسبات سنگین، دشواری تفسیر نتایج و کاربرد صنعتی محدود	الگوریتم یادگیری عمیق پیچیده، پژوهش حاضر مدل کارا تر و قابل‌تطبيق تر در صنعت ارائه می‌دهد

۳. روش‌شناسی پژوهش

این پژوهش با هدف بهینه‌سازی نظارت بر فرآیندهای تولیدی در خطوط تولید فولاد، از رویکرد کمی و تحلیل داده‌های آماری چندمتغیره بهره می‌برد. داده‌های مورد استفاده از فرآیند تولید تختال در شرکت فولاد مبارکه اصفهان و در سه مرحله اصلی تولید شامل: کوره‌های قوس الکتریکی (EAF)، واحد متالورژی ثانویه (LF) و ماشین‌های ریخته‌گری مداوم (CCM) جمع‌آوری شده است (شکل ۱). در هر یک از این مراحل، متغیرهای کنترلی متعددی ثبت شده‌اند که پیش‌هم‌زمان آن‌ها با روش‌های کلاسیک تک‌متغیره دشوار و ناکارآمد است؛ از این‌رو از روش‌های آماری چندمتغیره برای تحلیل، کاهش پیچیدگی و طراحی سیستم نظارتی بهینه استفاده شد.

۳.۱ تحلیل مؤلفه‌های اصلی (PCA)

در گام نخست، برای کاهش ابعاد داده‌ها و استخراج مؤلفه‌های کلیدی از میان متغیرهای متعدد، از تکنیک تحلیل مؤلفه‌های اصلی (Principal Component Analysis - PCA) استفاده گردیده است. روشی آماری برای تبدیل مجموعه‌ای از متغیرهای هم‌بسته به مجموعه‌ای از مؤلفه‌های غیرهم‌بسته است که بیشترین واریانس داده‌ها را در خود نگه می‌دارند. دلیل استفاده از این روش، کاهش پیچیدگی محاسباتی، حذف متغیرهای زائد و افزایش تمرکز بر الگوهای غالب فرآیندی در هر مرحله تولیدی بوده است.

قبل از اجرای PCA، آزمون Kaiser-Meyer-Olkin (KMO) و آزمون کرویت بارنتل برای بررسی کفایت نمونه‌گیری و همبستگی بین متغیرها انجام شده است. در صورت تأیید این پیش‌فرض‌ها، کاهش ابعاد با حفظ بیش از ۸۰٪ واریانس داده‌ها انجام گرفته است.

۳.۲ نمودارهای کنترلی چندمتغیره MEWMA و MCUSUM

در ادامه، برای نظارت بر رفتار فرآیندی متغیرهای اصلی استخراج‌شده، از نمودارهای کنترلی چندمتغیره MEWMA و MCUSUM استفاده شد. این دو نمودار در مقایسه با نمودارهای کلاسیک مانند \bar{X} و R ، به دلیل ماهیت تجمعی و حساسیت بالای خود نسبت به تغییرات کوچک و تدریجی در داده‌ها، به‌ویژه در داده‌های چندمرحله‌ای تولید، دقت و توان تشخیص بالاتری ارائه می‌دهند.

انتخاب MEWMA و MCUSUM مبتنی بر این بود که فرآیندهای تولیدی فولاد معمولاً دارای وابستگی‌های زمانی و تأثیرات پیوسته متغیرها بر یکدیگر هستند؛ در نتیجه این نمودارها توانایی بالاتری در کشف انحرافات جزئی و ناهنجاری‌های زود هنگام نسبت به نمودارهای سنتی دارند [۷ و ۸].

۳.۳ نمودار Hotelling's T^2

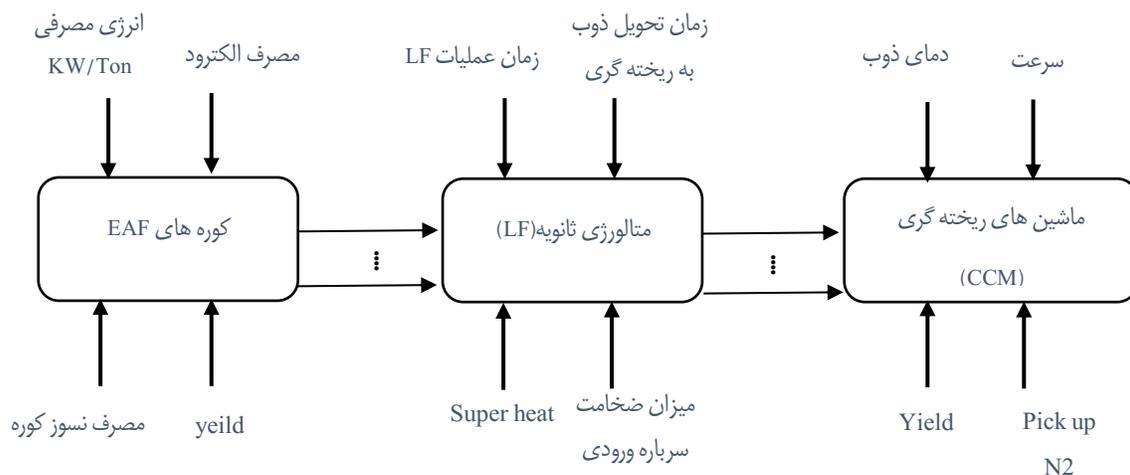
در شرایطی که تعداد متغیرهای موجود پس از کاهش ابعاد به کمتر از سه مورد می‌رسد یا همبستگی لازم بین آن‌ها وجود ندارد، از نمودار Hotelling's T^2 به‌عنوان روش جایگزین استفاده شد. این نمودار یک ابزار کلاسیک کنترل کیفیت چندمتغیره است که قادر است [۹].

۳.۴ مطالعه موردی: فرآیند تولید تختال در فولاد مبارکه

فرآیند تولید تختال در شرکت فولاد مبارکه شامل سه بخش اصلی به شرح زیر است (مطابق شکل ۱):

۱. کوره‌های قوس الکتریکی (EAF): در این مرحله، ضایعات آهنی با استفاده از انرژی الکتریکی و مصرف الکتروود ذوب می‌شوند.
۲. متالورژی ثانویه (LF): مواد افزودنی و تنظیم آنالیز شیمیایی در این مرحله صورت می‌گیرد تا خواص نهایی فولاد تنظیم شود [۱۰ و ۱۱].
۳. ماشین‌های ریخته‌گری (CCM): در این مرحله فولاد مذاب به تختال (slab) تبدیل می‌شود [۱۲].

در هر یک از این مراحل، متغیرهای متعدد ثبت می‌گردد؛ برای نمونه، در مرحله ریخته‌گری، بیش از ۹ متغیر برای هر ماشین اندازه‌گیری می‌شود. با وجود ۵ ماشین ریخته‌گری، مجموعاً ۴۵ نمودار کنترلی نیاز است. مدیریت و تحلیل این حجم بالا از نمودارها پیچیده و زمان‌بر است، بنابراین پیش‌پردازش داده‌ها با PCA و سپس نظارت متمرکز بر مؤلفه‌های اصلی با نمودارهای چندمتغیره، راه کار بهینه‌تری را ارائه می‌دهد [۱۳ و ۱۴].

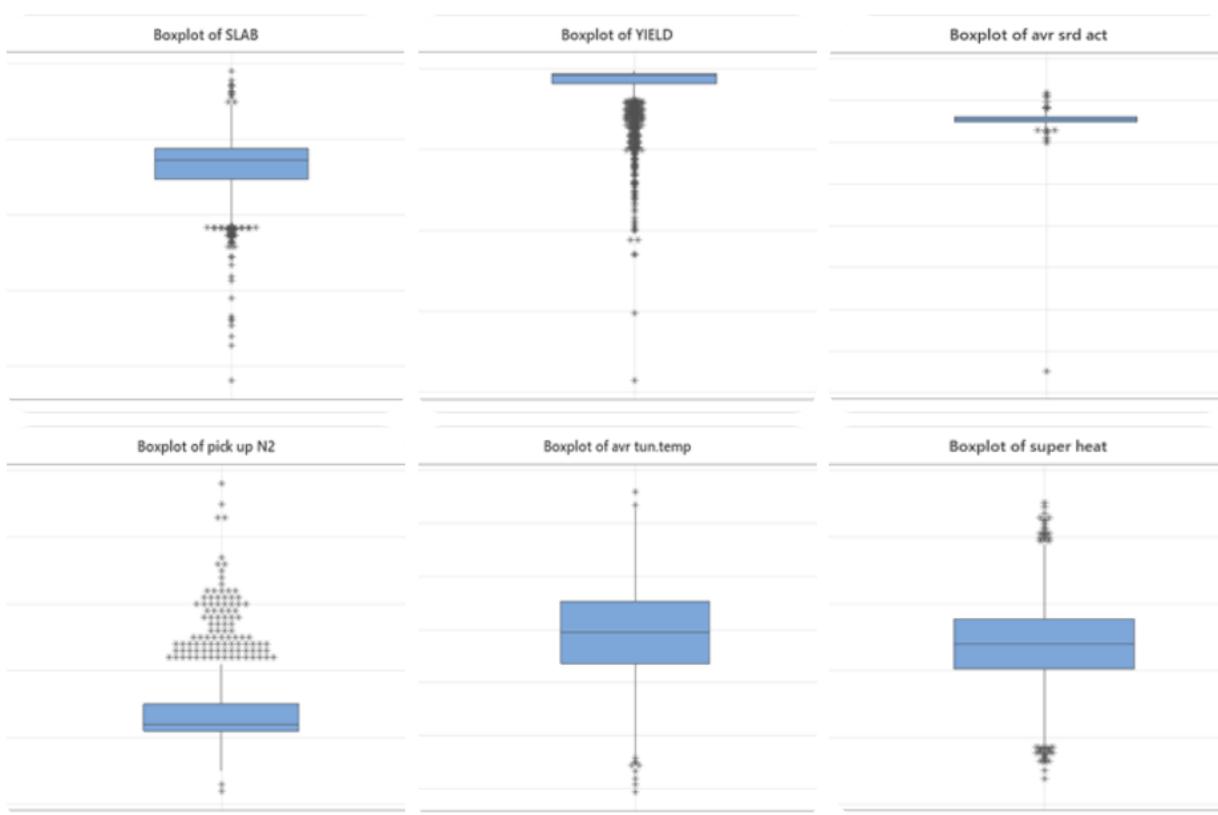


شکل ۱. مراحل تولید در شرکت فولاد مبارکه

۴. تحلیل داده‌ها و یافته‌های پژوهش

۴.۱ پاک‌سازی داده‌ها و شناسایی نقاط پرت

در مرحله نخست، داده‌های خام مربوط به فرآیند ریخته‌گری با استفاده از نمودارهای باکس‌پلات بررسی شدند. هدف این مرحله، حذف نقاط پرت به منظور افزایش دقت تحلیل و جلوگیری از اثر منفی مشاهدات غیرطبیعی بر مدل بود. در نتیجه این مرحله، تعداد نمونه‌ها از مقدار اولیه (۲۸۸۱) کاهش یافت و در نهایت ۲۱۶۲ مشاهده معتبر برای تحلیل‌های آماری باقی ماند. شکل ۲، توزیع داده‌ها و محدوده نرمال هر متغیر را نشان می‌دهد.



شکل ۲. نمودار باکس پلات متغیرهای فرآیند ریخته‌گری

۴.۲ کفایت تحلیل مؤلفه‌های اصلی

پیش از اجرای تحلیل مؤلفه‌های اصلی (PCA)، برای ارزیابی مناسب بودن داده‌ها، آزمون KMO و بارتلت اجرا شد. نتایج به صورت جدول ۲ به دست آمد.

جدول ۲. نتایج آزمون بارتلت	
مقدار	شاخص
۰٫۷۸	KMO
$\chi^2 = 1245.32, df = 36, p < 0.001$	آزمون بارتلت

مقدار $KMO = 0.78$ نشان می‌دهد که کفایت نمونه‌گیری در حد قابل قبول است. آزمون بارتلت با مقدار $p < 0.001$ نشان می‌دهد که همبستگی بین متغیرها برای انجام تحلیل مؤلفه‌های اصلی (PCA) مناسب است. این نتایج بیانگر آن است که داده‌ها به لحاظ آماری برای اجرای PCA مناسب می‌باشند.

۴.۳ نتایج تحلیل مؤلفه‌های اصلی (PCA)

تحلیل مؤلفه‌های اصلی منجر به استخراج سه مؤلفه اصلی شده که در مجموع، بخش زیادی از واریانس کل داده‌ها را توضیح می‌دهند. بارهای عاملی مربوط به هر متغیر در جدول ۳ آمده است.

جدول ۳. بارهای عاملی متغیرهای مؤلفه‌های اصلی

VAR	تعریف متغیر	PC1	PC2	PC3
AVR SRD ACT	میانگین سرعت واقعی خط ۱ و ۲	-۰٫۴۹۴	۰٫۷۸۲	-۰٫۳۳۶
QLY ACT	گرید ورق‌ها	-۰٫۶۷۲	-۰٫۵۱۹	۰٫۴۹۴
LADLE(kg)	وزن ته پاتیل	-۰٫۲۸۹	۰٫۸۱۷	-۰٫۰۷۱
TUND(kg)	وزن ته تاندیش	۰٫۸۷۵	۰٫۳۶۹	-۰٫۲۲۴
YIELD	بازدهی	-۰٫۴۰۲	-۰٫۸۵۱	۰٫۲۸۵
SLAB	وزن تختال	۰٫۶۱۷	-۰٫۴۲۸	۰٫۲۶۰
SUPER HEAT	اختلاف دمای ذوب در تاندیش و دمای انجماد	-۰٫۹۴۵	۰٫۲۳۰	۰٫۱۹۷
AVR TUND TEMP	متوسط دمای چهار نقطه تاندیش	۰٫۲۲۷	۰٫۶۳۱	۰٫۷۱۲
PICK UP N2	نیترژن محلول در ذوب	۰٫۷۹۶	۰٫۳۳۳	-۰٫۰۲۰

در این پژوهش، ضرایب مؤلفه اصلی (PC1، PC2، PC3) برای متغیرهای کلیدی فرآیند فولادسازی محاسبه شده است که میزان تأثیر و ارتباط هر متغیر را در ترکیب‌های اصلی نشان می‌دهد.

۴.۴ تحلیل رگرسیونی مؤلفه‌ها

با هدف بررسی ارتباط مؤلفه‌های استخراج‌شده با متغیرهای اصلی فرآیند، مدل‌های رگرسیونی برای هر مؤلفه ایجاد شد. نتایج نشان داد:

- PC1 با شاخص‌های حرارتی و کیفیت محصول SUPER HEAT، SLAB، PICK UP N2 همبستگی قوی دارد ($|r| > 0.8$) که نقش مهمی در کنترل دمای نهایی مذاب و کاهش نیترژن محلول دارد.
- PC2 بیشترین تأثیر را بر بازده تولید (YIELD) و مقدار LADLE داشته که از نظر اقتصادی بسیار مهم است.
- PC3 تقریباً به‌طور انحصاری از نوسانات دمای پاتیل (AVR TUND TEMP) تشکیل شده و تغییرات آن، نشانگر بی‌ثباتی فرآیند ریخته‌گری است.

✓ PC1 شامل متغیرهای: QLY ACT، TUND(kg)، SLAB، SUPER HEAT و PICK UP N2 می‌باشد که رابطه رگرسیونی ای متغیرها به شکل زیر تعریف می‌شود:

$$PC1 = -0.672 * QLY ACT + 0.875 * TUND(kg) + 0.617 * SLAB - 0.945 * SUPER HEAT + 0.796 * PICK UP N2$$

✓ PC2 شامل متغیرهای: AVR SRD ACT، LADLE(kg) و YIELD می‌باشد که رابطه رگرسیونی این متغیرها بدین صورت است:

$$PC2 = 0.782 * AVR SRD ACT + 0.817 * LADLE(kg) - 0.851 * YIELD$$

✓ PC3 شامل متغیر AVR TUND TEMP می‌باشد که رابطه رگرسیونی این متغیر بدین صورت است:

$$PC3 = 0.712 * AVR TUND TEMP$$

PC1 به تنهایی بیش از ۳۶٪ از واریانس داده‌ها را توضیح می‌دهد و به‌شدت با متغیرهای SUPER HEAT، TUND، SLAB و PICK UP N2 مرتبط است که نشان‌دهنده بُعد حرارتی و کیفیت نهایی محصول است.

PC2 ۲۸٪ واریانس را توضیح می‌دهد و با LADLE، YIELD و AVR SRD ACT مرتبط است و بازده و مصرف مواد را پوشش می‌دهد.

PC3 ۱۷٪ واریانس را شامل می‌شود و به‌طور مشخص با AVR TUND TEMP مرتبط است، که بیانگر پایداری حرارتی در لحظه ریخته‌گری است.

این سه مؤلفه مجموعاً ۸۱٪ واریانس کل داده‌ها را پوشش داده‌اند، که شاخص خوبی برای کفایت مدل کاهش ابعاد است.

۴.۵ نتایج نمودار کنترلی MEWMA

با توجه به استخراج سه مؤلفه اصلی، برای پایش فرآیند، از نمودار کنترلی چندمتغیره MEWMA استفاده شده است. دلیل انتخاب این روش، حساسیت بالای آن به تغییرات کوچک در فرآیند و توانایی در پایش هم‌زمان چند مؤلفه همبسته بود. نمودارهای MEWMA نشان دادند:

- در ۸۵٪ نمونه‌ها، فرآیند در محدوده کنترل بوده است؛
- در ۱۵٪ موارد، انحراف‌های آماری از حدود هشدار یا کنترل مشاهده شد که عمدتاً به تغییرات غیرنرمال در SUPER HEAT و PICK UP N2 مربوط بوده است.
- هیچ روند ساختاری در انحراف‌ها دیده نشد که نشان می‌دهد فرآیند به‌طور کلی پایدار بوده، اما نیاز به پایش حساس‌تر در برخی مقاطع خاص دارد.

۴.۶ مقایسه مدل پیشنهادی با روش‌های سنتی

به‌منظور بررسی دقیق‌تر عملکرد مدل پیشنهادی، یک مقایسه کمی بین این مدل و روش‌های سنتی تک‌متغیره (EWMA و I-MR) انجام شد. هدف از این مقایسه، ارزیابی میزان کارایی مدل از نظر کاهش تعداد نمودارهای کنترلی، حساسیت به تغییرات کوچک، کاهش هشدارهای کاذب و سرعت تحلیل داده‌ها بود. نتایج این تحلیل در جدول ۴ ارائه شده است.

جدول ۴. مقایسه عملکرد روش‌های سنتی تک‌متغیره و مدل پیشنهادی (PCA + MEWMA)

معیار مقایسه	روش‌های سنتی (EWMA / I-MR)	مدل پیشنهادی (PCA + MEWMA)
تعداد نمودارهای موردنیاز	حدود ۴۵ نمودار	۴ نمودار
درصد نقاط خارج از کنترل شناسایی شده	پراکنده در نمودارهای مختلف	۹۵٪ در همان ۴ نمودار
حساسیت به تغییرات کوچک	متوسط	بالا
میزان هم‌پوشانی بین روش‌ها	کمتر از ۸۰٪	بیش از ۸۰٪
تعداد هشدارهای کاذب	بیشتر	کمتر
زمان تحلیل و تشخیص	طولانی‌تر	سریع‌تر

همان‌طور که جدول بالا نشان می‌دهد، مدل پیشنهادی توانسته است با کاهش تعداد نمودارهای کنترلی از حدود ۴۵ به تنها ۴ نمودار، پیچیدگی پایش را به‌طور چشمگیری کم کند. همچنین این مدل ۹۵٪ از نقاط خارج از کنترل را در همین ۴ نمودار شناسایی کرده، در حالی که در روش‌های سنتی شناسایی این نقاط پراکنده و دشوار بود. افزون بر این، مدل پیشنهادی با حساسیت بالاتر، هشدارهای کاذب کمتر و سرعت بیشتر در تحلیل داده‌ها، نسبت به روش‌های سنتی عملکرد بهتری نشان داده است.

۵. نتیجه‌گیری و پیشنهادها

پژوهش حاضر با هدف بهبود نظام پایش فرآیندهای تولیدی در صنعت فولاد، مدلی ترکیبی مبتنی بر تحلیل مؤلفه‌های اصلی (PCA) و نمودارهای کنترلی چندمتغیره (MEWMA) ارائه داد. این رویکرد توانست با کاهش ابعاد داده‌ها از ۹ متغیر اولیه به سه مؤلفه اصلی و استفاده از تنها چهار نمودار کنترلی، پیچیدگی پایش را به میزان چشمگیری کاهش دهد. نتایج نشان داد که مدل پیشنهادی قادر است ۹۵ درصد نقاط خارج از کنترل را با دقت بالا شناسایی کند؛ در حالی که در روش‌های سنتی، این نقاط پراکنده و در نمودارهای متعدد قابل ردیابی بودند. همچنین، حساسیت بیشتر به تغییرات کوچک، کاهش هشدارهای کاذب و افزایش سرعت تحلیل و تصمیم‌گیری از دیگر دستاوردهای کلیدی این مدل محسوب می‌شود.

مقایسه این یافته‌ها با مطالعات پیشین نشان می‌دهد که نتایج این پژوهش همسو با تحقیق تانگ و همکاران (۲۰۱۷) در زمینه اثربخشی PCA در شناسایی ناهنجاری‌ها و مطالعه اسماعیل و همکاران (۲۰۲۲) در خصوص کارایی نمودارهای چندمتغیره است. با این حال، نوآوری اصلی این پژوهش در تلفیق این دو رویکرد و آزمون آن در یک بستر واقعی صنعتی است؛ موضوعی که در ادبیات پیشین کمتر مورد توجه قرار گرفته است. افزون بر این، کاهش تعداد نمودارهای کنترلی از حدود ۴۵ به تنها ۴ نمودار و هم‌پوشانی بالای بیش از ۸۰ درصد میان نتایج مدل پیشنهادی و روش‌های تک‌متغیره، نقطه قوت مهم دیگری است که نشان‌دهنده کارآمدی مدل در محیط‌های واقعی صنعتی است.

از منظر مدیریتی، مدل پیشنهادی می‌تواند ابزاری مؤثر برای تصمیم‌گیرندگان در صنایع فولاد و سایر صنایع پیچیده باشد. این مدل با کاهش حجم داده‌های نظارتی و تمرکز بر متغیرهای کلیدی، امکان پایش سریع‌تر و دقیق‌تر فرآیندها را فراهم می‌کند. کاهش هشدارهای کاذب منجر به صرفه‌جویی در منابع و کاهش هزینه‌های نظارت می‌شود و افزایش سرعت شناسایی انحرافات، امکان واکنش به‌موقع و پیشگیری از بروز خطاهای کیفی و ضایعات را فراهم می‌آورد. بدین ترتیب، پژوهش حاضر علاوه بر غنای علمی، ارزش کاربردی بالایی دارد و می‌تواند به‌عنوان راهکاری عملی در راستای ارتقای کارایی سیستم‌های کنترل کیفیت و افزایش بهره‌وری در صنایع تولیدی مورد استفاده قرار گیرد.

۵.۱ پیشنهادهای نظری

بر پایه یافته‌های پژوهش، پیشنهادهای زیر برای توسعه مطالعات علمی در حوزه پایش فرآیندها ارائه می‌شود:

- توسعه چارچوب‌های ترکیبی از تحلیل آماری و یادگیری ماشین (مانند ترکیب PCA با شبکه‌های عصبی یا الگوریتم‌های درخت تصمیم) برای ارتقای توان شناسایی الگوهای پنهان در داده‌های تولیدی.
- مطالعه تأثیر انتخاب متغیرها و تنظیم پارامترهای آماری (مانند λ در MEWMA) بر کارایی مدل‌های کنترلی در شرایط مختلف صنعتی؛
- بررسی و مقایسه عملکرد سایر روش‌های کاهش ابعاد مانند ICA یا Autoencoder با PCA در زمینه تحلیل داده‌های چندمرحله‌ای؛
- گسترش پژوهش به سایر صنایع پیچیده مانند نفت، پتروشیمی و خودروسازی به منظور تعمیم‌پذیری مدل ارائه شده.

۵.۲ پیشنهادهای کاربردی

یافته‌های این پژوهش می‌تواند به‌عنوان مبنایی برای تصمیم‌گیری مدیران تولید و مهندسان کنترل کیفیت مورد استفاده قرار گیرند. پیشنهادها را اجرایی به شرح زیر است:

- استفاده عملی از نمودارهای MEWMA در مراکز کنترل تولید جهت پایش بلادرنگ فرآیندهای چندمتغیره و شناسایی سریع نوسانات؛
- استقرار سیستم‌های تحلیل داده مبتنی بر PCA برای کاهش پیچیدگی پایش و تمرکز بر متغیرهای مؤثر و کلیدی به‌جای بررسی ده‌ها متغیر هم‌زمان؛
- آموزش تخصصی به تیم‌های کنترل کیفیت و مهندسی فرآیند جهت استفاده از ابزارهای آماری پیشرفته در پایش هوشمند خطوط تولید؛
- یکپارچه‌سازی نتایج این مدل با سیستم‌های مدیریت کیفیت و ERP برای تصمیم‌گیری سریع و کاهش هزینه‌های ناشی از ضایعات و توقف خطوط؛

- پیشنهاد به صنایع فولادی کشور برای انجام پروژه‌های پایلوت بر مبنای مدل این پژوهش به منظور تست عملی و تطبیق‌پذیری در شرایط واقعی.

۵.۳ محدودیت‌ها و پیشنهاد برای تحقیقات آتی

این پژوهش نیز مانند سایر تحقیقات با محدودیت‌هایی همراه بوده است. نخست، داده‌های مورد استفاده صرفاً از یک شرکت (فولاد مبارکه اصفهان) گردآوری شدند؛ بنابراین تعمیم‌پذیری نتایج به سایر صنایع و محیط‌های تولیدی نیازمند مطالعات تکمیلی است. دوم، مدل پیشنهادی تنها بر اساس ترکیب PCA و MEWMA توسعه یافته است؛ در حالی که سایر روش‌های کاهش بعد (مانند ICA یا Autoencoder) و نمودارهای کنترلی پیشرفته نیز می‌توانند به نتایج متفاوتی منجر شوند. سوم، داده‌های به کاررفته مربوط به یک بازه زمانی مشخص بوده و ممکن است تغییر شرایط عملیاتی یا اقتصادی بر کارایی مدل اثرگذار باشد.

بر این اساس، پیشنهاد می‌شود پژوهش‌های آتی با استفاده از داده‌های متنوع‌تر و در صنایع مختلف انجام گیرند تا تعمیم‌پذیری مدل افزایش یابد. همچنین، مقایسه عملکرد روش حاضر با سایر تکنیک‌های کاهش بعد و الگوریتم‌های یادگیری ماشین می‌تواند ابعاد جدیدی از کارایی مدل را آشکار سازد. بررسی تأثیر شرایط محیطی و عوامل بیرونی بر دقت مدل و توسعه چارچوب‌های ترکیبی پیشرفته نیز از مسیرهای ارزشمند برای تحقیقات آینده محسوب می‌شود.

تعارض منافع. برای ارائه مطالب و نگارش این مقاله هیچ‌گونه کمک مالی از هیچ فرد، نهاد و سازمانی دریافت نشده است و نتایج و دستاوردهای این مقاله به نفع یا ضرر سازمان یا فردی خاص نخواهد بود. حضور نویسندگان در این پژوهش به‌عنوان شاهدهی بی‌طرف ولی متخصص بوده است و نویسندگان هیچ‌گونه تعارض منافی ندارند.

منابع

1. Alrufaihi, M. A., Alharthi, A. S., & Alotaibi, M. (2022). Feature selection and dimensionality reduction techniques for multistage manufacturing data. *Journal of Industrial Engineering and Management*, 15(3), 321–334.
2. Bai, C., Sun, X., & Zhang, G. (2019). Comparative study of dimensionality reduction methods for quality prediction in multistage manufacturing processes. *IEEE Transactions on Industrial Informatics*, 15(6), 3198–3207.
3. Capezza, C., Capizzi, G., et al. (2024). An adaptive multivariate functional EWMA control chart. *arXiv*. <https://arxiv.org>
4. Centofanti, F., Lepore, A., & Palumbo, B. (2025). An adaptive multivariate functional control chart. *arXiv*. <https://arxiv.org>
5. Chen, Z., Maske, H., Shui, H., Huan, X., & Ni, J. (2024). Deep Koopman based control of quality variation in multistage manufacturing systems. *arXiv*. <https://arxiv.org>
6. Ismail, A. I., Hasan, M. S., & Rahman, R. (2022). Machine learning applications in quality control for multistage manufacturing processes. *International Journal of Advanced Manufacturing Technology*, 120(5–6), 2389–2402.
7. Jafarnejhad, A., Jalali, R., & Fardanian, A. (2025). Identification and analysis of barriers to forming participatory collaboration in concurrent crises based on fuzzy cognitive mapping and multi-objective modeling. *Journal of Industrial Management Perspective*, 15(2), 9-36 [In Persian].
8. Setareh Tabrizi, A., & Mohtashami, A. (2025). Designing a conceptual model based on exploratory intelligence and environmental indicators and implementing it to evaluate maritime ports using thematic analysis and fuzzy inference. *Journal of Industrial Management Perspective*. 15(2), 98-115 [In Persian].
9. Tian, Y., Liu, C., & Wang, X. (2022). A predictive quality model for multistage manufacturing processes based on big data and neural networks. *Journal of Manufacturing Processes*, 64, 1–12.
10. Tong, L., Li, Z., & Zhang, J. (2017). A principal component analysis based approach for fault detection in multistage manufacturing processes. *Journal of Manufacturing Science and Engineering*, 139(10), 101005.

11. Wang, K.-J. (2023). Multivariate auto correlated process control by a residual based mixed CUSUM EWMA model. *Quality and Reliability Engineering International*, 39(4), 1120–1142.
12. Wang, R., Zhang, Y., & Huang, H. (2023). Deep learning-based quality prediction for multistage manufacturing: A multitask learning approach. *Computers & Industrial Engineering*, 175, 108946.
13. Yaloueh, E., Rezaei Noor, J., & Yaloueh, A. (2025). Organizational productivity improvement: A systematic review of process improvement studies in organizations. *Journal of Industrial Management Perspective*. 15(1), 282-301 [In Persian] <https://doi.org/10.48308/jimp.2025.238081.1605>
14. Zhou, S., Huang, Y., & Shi, J. (2004). Statistical process monitoring for multistage manufacturing systems: A literature review. *Journal of Quality Technology*, 36(4), 432–450.