Industrial Management Studies
Vol(issue), PP.
jims.atu.ac.ir
DOI: 10.22054/jims.2026.94136.3051

A Systematic Review and Framework-Based Integration of Artificial Intelligence into Univariate and Multivariate Statistical Control Charts

Karim Atashgar — Department of Industrial Engineering, Faculty of Industrial Engineering and Management, Malek Ashtar University of Technology, Tehran, Iran

Mahsa Akbari — Department of Public Administration, Faculty of Management and Accounting, Allameh Tabataba'i University, Tehran, Iran

Reza Ahmadi* — Department of Industrial Engineering, Faculty of Industrial Engineering and Management, Malek Ashtar University of Technology, Tehran, Iran

Abstract

Integrating Artificial Intelligence (AI) with Statistical Process Control (SPC) charts is an innovative approach to improving the monitoring and analysis of complex processes in quality management. Despite the expansion of studies in this field, the dispersion of approaches and the diversity of AI methods have made it necessary to systematically review the existing knowledge and identify research gaps. This study employs a systematic literature review (SLR) approach, analyzing 40 selected articles based on AI entry modes, data characteristics, integration levels, and implementation challenges. The findings indicate that research primarily focuses on pattern recognition, data analysis, and intelligent monitoring. Furthermore, successful AI deployment depends not only on algorithm selection but also on data quality, computational infrastructure, model interpretability, and organizational readiness. Based on these results, a conceptual framework consisting of four layers—Data, AI/ML, Control Chart, and Implementation—is proposed to facilitate a systematic transition toward intelligent statistical process control.

Keywords: Statistical Process Control (SPC), Artificial Intelligence (AI), Machine Learning, Control Charts, Real-Time Monitoring, Systematic Literature Review.

* Corresponding Author: reza_ahmadi@mut.ac.ir
How to Cite: xxxxxxx

eISSN: 2476-5988 ISSN: 2251-8037 Accepted: Review Received: Original Research

Introduction

The integration of artificial intelligence (AI) and machine learning (ML) with statistical process control (SPC) has expanded the capabilities of process monitoring beyond conventional statistical approaches. Previous research has examined classical, memory-type, adaptive, robust, multivariate, nonparametric, and functional control charts. More recent studies have applied neural networks, support vector machines, convolutional neural networks, long short-term memory networks, ensemble learning, and hybrid architectures to control-chart pattern recognition, anomaly and change-point detection, process interpretation, prediction, and adaptive monitoring. Despite these advances, the literature remains fragmented. In particular, the relationships among process-data characteristics, intelligent algorithms, statistical control mechanisms, infrastructure, and organizational implementation have not been sufficiently integrated into a unified analytical framework. This study addresses this gap by systematically reviewing research on AI and ML integration with statistical control charts and by developing a conceptual framework to organize the main integration levels, applications, and implementation considerations.

Methodology

This study employed a systematic review approach to identify, screen, and analyze research on statistical control charts, statistical process monitoring, and the integration of AI and ML. Searches were conducted in Scopus and Web of Science, while Consensus was used as a complementary tool to identify potentially relevant studies. Articles identified through Consensus were included only when their bibliographic information could be verified through the major scientific databases. The search initially identified 134 articles. Following title, abstract, and full-text screening according to predefined inclusion and exclusion criteria, 40 studies were selected for final analysis. Data were systematically extracted on bibliographic characteristics, control-chart types, AI techniques, data characteristics, application domains, reported performance measures, and implementation challenges. The selected studies were analyzed using content analysis and an analytical-critical approach. To enhance review reliability, two reviewers independently assessed the studies. Agreement was observed in 34 of the 40 studies, corresponding to 85% agreement, with a Cohen’s kappa coefficient of 0.78. Methodological quality was assessed using a five-criterion checklist.

Findings

The findings show that AI integration with SPC spans several levels, from algorithmic applications for pattern recognition and classification to data analysis, intelligent monitoring, prediction, adaptive control, and decision support. The reviewed studies most frequently used convolutional neural networks, recurrent architectures such as long short-term memory networks, support vector machines, artificial neural networks, and hybrid models to recognize control-chart patterns and detect process deviations. The studies were classified into four integration levels: algorithmic integration (50%), data and analytical integration (20%), intelligent monitoring (15%), and adaptive control and decision-making (15%). Hybrid deep-learning architectures reported strong performance in several pattern-recognition studies. However, direct comparison of results was limited by differences in datasets, simulation settings, process characteristics, validation procedures, and evaluation criteria. The review also identified data-related challenges as a prominent concern, alongside model and algorithmic limitations and infrastructure and deployment issues. Based on the synthesis, a four-layer conceptual framework was developed, comprising the data layer, the AI and ML layer, the control-chart layer, and the implementation layer.

Discussion

The findings indicate that the development of intelligent SPC involves more than replacing traditional statistical techniques with machine-learning algorithms. AI can contribute at multiple stages of the SPC cycle, including feature extraction, pattern recognition, anomaly detection, prediction, interpretation, and adaptive monitoring. At the same time, the heterogeneity of the evidence base—particularly the emphasis on model development and simulation rather than long-term operational deployment—limits direct comparisons among approaches. Accordingly, the practical assessment of AI-based SPC should consider not only model performance but also data quality and availability, computational requirements, validation procedures, interpretability, deployment conditions, and organizational readiness. The identified research gaps point to the need for further investigation into the integration of intelligent models with real-time process data, adaptive monitoring, deployment infrastructure, organizational decision-making, and the economic aspects of implementation. The proposed framework helps bring these interdependent considerations together in a single analytical structure.

Conclusion

This study provides a systematic and critical synthesis of research on integrating AI with statistical control charts. It identifies the principal integration levels, applications, challenges, and research gaps, and proposes a four-layer conceptual framework comprising the data, AI and ML, control-chart, and implementation layers. The framework emphasizes the interdependence of process data, intelligent models, statistical control mechanisms, and practical deployment. It therefore offers a structured conceptual roadmap for guiding future research and supporting the development of intelligent, adaptive, and operationally viable process-monitoring systems.

آماده انتشار

مقاله پژوهشی

مطالعات مدیریت صنعتی
دوره ؟، شماره ؟، نام فصل، سال، ص ص
jims.atu.ac.ir
DOI: 10.22054/jims.2026.94136.3051

ادغام هوش مصنوعی در نمودارهای کنترل آماری: مروری تحلیلی و چارچوب‌محور

کریم آتشگر گروه مهندسی صنایع، دانشکده صنایع و مدیریت، دانشگاه صنعتی مالک اشتر، تهران، ایران

مهسا اکبری گروه مدیریت دولتی، دانشکده مدیریت و حسابداری، دانشگاه علامه طباطبائی، تهران، ایران

رضا احمدی * گروه مهندسی صنایع، دانشکده صنایع و مدیریت، دانشگاه صنعتی مالک اشتر، تهران، ایران

تاریخ دریافت: 00/00/00؛ تاریخ پذیرش: 00/00/00 ISSN:2251-8037 eISSN: 2476-5988

چکیده

ادغام هوش مصنوعی با نمودارهای کنترل آماری، رویکردی نوین برای ارتقای پایش و تحلیل فرآیندهای پیچیده در مدیریت کیفیت است. با وجود گسترش مطالعات این حوزه، پراکندگی رویکردها و تنوع روش‌های هوش مصنوعی، نیاز به مرور نظام‌مند وضعیت موجود و شناسایی شکاف‌های پژوهشی را ضروری ساخته است. پژوهش حاضر با رویکرد مرور نظام‌مند، مطالعات مرتبط را بررسی و ۴۰ مقاله منتخب را بر اساس نحوه ورود هوش مصنوعی، ویژگی داده، سطح ادغام و چالش‌های پیاده‌سازی تحلیل کرده است. یافته‌ها نشان داد که مطالعات عمدتاً بر تشخیص الگو، تحلیل داده و پایش هوشمند تمرکز داشته‌اند و موفقیت استقرار هوش مصنوعی تنها به انتخاب الگوریتم وابسته نیست، بلکه به کیفیت داده، زیرساخت محاسباتی، تفسیرپذیری مدل و آمادگی سازمانی نیز وابسته است. بر اساس نتایج، چارچوبی مفهومی در چهار لایه شامل لایه داده، لایه هوش مصنوعی و یادگیری ماشین، لایه نمودار کنترل و لایه پیاده‌سازی برای گذار نظام‌مند به کنترل فرآیند آماری هوشمند ارائه شد.

کلیدواژه‌ها: کنترل فرآیند آماری، هوش مصنوعی، یادگیری ماشین، نمودارهای کنترل، پایش بلادرنگ، مرور نظام‌مند

* نویسنده مسئول: reza_ahmadi@mut.ac.ir

مقدمه

کنترل فرایند آماری در دهه‌های اخیر یکی از ارکان اصلی مدیریت کیفیت و بهبود مستمر بوده است. منطق این حوزه بر این فرض استوار است که هر فرایند، حتی در شرایط عادی، با نوعی نوسان همراه است؛ اما همه نوسان‌ها منشأ یکسانی ندارند. بخشی از آن‌ها طبیعی و ناشی از علل عام‌اند و بخشی دیگر نتیجه علل ویژه یا تغییراتی هستند که می‌توانند به افت کیفیت، کاهش قابلیت اطمینان و افزایش هزینه‌های سازمان منجر شوند. نمودارهای کنترل از مهم‌ترین ابزارهای کنترل فرایند آماری‌اند، زیرا امکان تشخیص به‌موقع انحراف از وضعیت تحت کنترل را فراهم می‌کنند و از این طریق، مبنایی برای تصمیم‌گیری اصلاحی و پیشگیرانه در اختیار مدیران و تحلیل‌گران قرار می‌دهند. به همین دلیل، این ابزارها مدت‌هاست که در صنایع تولیدی و نیز در بسیاری از حوزه‌های خدماتی، سلامت، لجستیک و زنجیره تأمین کاربرد یافته‌اند.

با وجود این، شرایطی که امروز فرایندها در آن عمل می‌کنند با گذشته تفاوت جدی دارد. در بسیاری از محیط‌های واقعی، داده‌ها دیگر ساده، محدود و تک‌متغیره نیستند. سازمان‌ها با حجم زیادی از داده‌های چندمنبعی، متغیرهای به‌هم‌وابسته، رفتارهای پویا، تغییرات زمانی و الگوهای پیچیده مواجه‌اند. در چنین شرایطی، استفاده از ابزارهای کلاسیک بدون توسعه روش‌شناختی ممکن است به کاهش دقت تشخیص، افزایش هشدارهای کاذب یا ناتوانی در شناسایی برخی تغییرات معنادار منجر شود. به بیان دیگر، اگرچه بنیان‌های نظری کنترل فرایند آماری همچنان معتبرند، اما شکل کاربرد آن‌ها در محیط‌های جدید نیازمند بازنگری و توسعه است (Yang et al., 2023; Xie & Qiu, 2023).

در پاسخ به این تغییرات، ادبیات پژوهشی سال‌های اخیر به‌طور جدی به سمت توسعه نمودارهای کنترل پیشرفته حرکت کرده است. این توسعه‌ها شامل نمودارهای حافظه‌دار، انطباقی، مقاوم، ناپارامتری، چندمتغیره و تابعی است که هر یک با هدف پاسخ‌گویی به بخشی از چالش‌های جدید طراحی شده‌اند. نمودارهای حافظه‌دار برای افزایش حساسیت نسبت به تغییرات کوچک، نمودارهای انطباقی برای واکنش بهتر به شرایط متغیر، و نمودارهای چندمتغیره برای پایش هم‌زمان چند شاخص وابسته توسعه یافته‌اند (Zaman et al., 2022; Capezza et al., 2025). این روند نشان می‌دهد که کنترل فرایند آماری از یک مجموعه

ابزار نسبتاً ثابت، به حوزه‌ای پویا و در حال تحول تبدیل شده است که باید خود را با پیچیدگی روزافزون داده‌ها و نیازهای محیط‌های عملیاتی هماهنگ کند.

در همین مسیر، هوش مصنوعی و یادگیری ماشین نیز به‌تدریج به یکی از محورهای مهم تحول در این حوزه تبدیل شده‌اند. دلیل این توجه روشن است. بسیاری از مسائل نوین پایش فرایند با ساختارهای غیرخطی، هم‌بستگی‌های پیچیده، داده‌های حجیم و الگوهای پنهانی همراه‌اند که شناسایی آن‌ها صرفاً با تکیه بر مدل‌های آماری کلاسیک دشوار است. روش‌های هوشمند، به‌ویژه الگوریتم‌های یادگیری ماشین و یادگیری عمیق، این قابلیت را دارند که الگوهای نهفته در داده را شناسایی کنند، روابط پیچیده میان متغیرها را بیاموزند و در تشخیص تغییرات یا تفسیر رفتار فرایند نقش مکمل ایفا کنند. از همین رو، در سال‌های اخیر از این روش‌ها برای طبقه‌بندی الگوهای نمودارهای کنترل، شناسایی نقاط تغییر، تفسیر تغییرپذیری فرایند و حتی طراحی ساختارهای جدید پایش استفاده شده است (Tran et al., 2021; Chang & Ghafariasl, 2025).

نمونه‌های این تحول در ادبیات پژوهش به‌خوبی قابل مشاهده است. استفاده از شبکه‌های عصبی و یادگیری عمیق برای طبقه‌بندی الگوهای نمودارهای کنترل، به‌ویژه در مسائل چندمتغیره، نشان داده است که روش‌های هوشمند می‌توانند در شناسایی الگوهای پیچیده عملکرد قابل توجهی داشته باشند (Cheng et al., 2023). همچنین در برخی مطالعات، مدل‌های ترکیبی برای شناسایی برخط الگوهای فرایندی خودهمبسته به‌کار رفته‌اند که بیانگر تلاش برای هماهنگ‌سازی ظرفیت‌های یادگیری ماشین با ویژگی‌های خاص داده‌های فرایندی است (Chiu & Fu, 2024). از سوی دیگر، ورود سازوکارهایی مانند مکانیزم توجه به طراحی نمودارهای کنترل نسبت نیز نشان می‌دهد که هوش مصنوعی تنها در سطح طبقه‌بندی یا تفسیر باقی نمانده، بلکه در حال ورود به سطح طراحی ابزارهای جدید پایش است (Yeganeh et al., 2025). این مجموعه مطالعات نشان می‌دهد که ادغام هوش مصنوعی با کنترل فرایند آماری دیگر صرفاً یک ایده نوظهور نیست، بلکه به یک جهت‌گیری جدی پژوهشی تبدیل شده است.

با این حال، رشد سریع این حوزه به معنای انسجام کامل آن نیست. یکی از مشکلات مهم در ادبیات موجود، پراکندگی مفهومی و روشی است. بخشی از مطالعات بر توسعه نمودارهای کنترل جدید تمرکز دارند و بخشی دیگر بر به‌کارگیری الگوریتم‌های هوشمند در مسائل

خاص، اما میان این دو جریان، پیوند تحلیلی روشنی کمتر دیده می‌شود. در بسیاری از پژوهش‌ها مشخص نیست که نقش هوش مصنوعی در پایش فرایند دقیقاً در چه سطحی تعریف می‌شود: آیا صرفاً ابزاری برای طبقه‌بندی الگوهاست، یا می‌تواند در کشف تغییر، تفسیر، پیش‌بینی و حتی بازطراحی منطق پایش نیز نقشی مؤثر داشته باشد؟ در نتیجه، با وجود تعدد مطالعات، هنوز تصویری منسجم از سطوح ادغام هوش مصنوعی با کنترل فرایند آماری و حدود واقعی توانمندی‌ها و محدودیت‌های آن وجود ندارد (Boaventura et al., 2022; Tran et al., 2021).

افزون بر این، بخش قابل توجهی از مطالعات موجود در محیط‌های شبیه‌سازی‌شده یا بر داده‌های آزمایشگاهی انجام شده‌اند. هرچند این مطالعات از نظر روش‌شناختی ارزشمندند، اما ارزیابی ظرفیت واقعی رویکردهای هوشمند بدون توجه به شرایط کاربردی ناقص خواهد بود. در محیط‌های واقعی، موضوعاتی مانند کیفیت داده، دسترس‌پذیری داده‌های برچسب‌خورده، قابلیت تفسیر نتایج، هزینه محاسباتی، سهولت استقرار، پایداری عملکرد در شرایط متغیر و میزان پذیرش توسط کاربران و مدیران، نقش تعیین‌کننده‌ای در موفقیت یا شکست یک سامانه پایش دارند (Bekkum et al., 2021; Boaventura et al., 2022). به همین دلیل، هر ارزیابی جدی از ادغام هوش مصنوعی با کنترل فرایند آماری باید فراتر از معیارهای صرفاً فنی برود و ابعاد اجرایی و سازمانی را نیز در نظر بگیرد.

از این منظر، نیاز به مطالعه‌ای که بتواند این حوزه را به‌صورت منسجم و تحلیلی مرور کند، کاملاً محسوس است. مسئله اصلی فقط فهرست‌کردن روش‌های جدید نیست، بلکه فهم این نکته است که این حوزه دقیقاً چگونه در حال تحول است، چه نیازهایی این تحول را پیش برده‌اند، چه ظرفیت‌هایی ایجاد شده و چه خلأهایی همچنان پابرجاست. مرور تحلیلی ادبیات می‌تواند به روشن‌شدن روندهای غالب، شناسایی شکاف‌های پژوهشی و فهم بهتر جایگاه هر رویکرد در منظومه کلی کنترل فرایند آماری کمک کند.

بر همین اساس، مقاله حاضر با رویکردی مروری و تحلیلی به بررسی ادغام هوش مصنوعی در نمودارهای کنترل آماری می‌پردازد. هدف این پژوهش آن است که نخست، تحولات اصلی در نمودارهای کنترل آماری نوین را مرور کند؛ دوم، نقش و جایگاه هوش مصنوعی و یادگیری ماشین را در توسعه این حوزه بررسی نماید؛ و سوم، با تحلیل مطالعات موجود، روندهای غالب، چالش‌های کاربردی، شکاف‌های پژوهشی و مسیرهای آینده را تبیین کند.

انتظار می‌رود این مطالعه بتواند تصویری منسجم‌تر از وضعیت موجود ارائه دهد و برای پژوهشگرانی که در پی توسعه چارچوب‌های جدید و نیز برای تصمیم‌گیرانی که به دنبال استقرار سامانه‌های پایش هوشمند در محیط‌های واقعی‌اند، مبنایی مفید فراهم سازد.

مبانی نظری

کنترل فرآیند آماری مجموعه‌ای از روش‌های آماری برای پایش تغییرپذیری فرآیند و تمایز میان تغییرات ناشی از علل عام و علل ویژه است. نمودارهای کنترل کلاسیک مانند نمودار میانگین، دامنه، میانگین متحرک نمایی و مجموع تجمعی از مهم‌ترین ابزارهای این حوزه هستند (Montgomery, 2020; Woodall, 2000). با افزایش تعداد متغیرهای فرآیند و وجود هم‌بستگی میان آن‌ها، نمودارهای کنترل چندمتغیره برای پایش هم‌زمان چند ویژگی کیفی توسعه یافته‌اند (Lowry & Montgomery, 1995; Bersimis et al., 2007).

بااین‌حال، داده‌های صنعتی نوین معمولاً حجیم، چندمتغیره، خودهم‌بسته و غیرایستا هستند. در چنین شرایطی، اتکای صرف به فروض کلاسیک آماری می‌تواند موجب افزایش هشدارهای کاذب یا کاهش توان شناسایی انحرافات واقعی شود (Qin, 2003, 2012; Ge et al., 2013). همچنین، گسترش صنعت ۴.۰ و تولید هوشمند، نیاز به روش‌هایی را افزایش داده است که بتوانند داده‌های برخط و پیچیده را با سرعت و دقت بیشتری تحلیل کنند (Kusiak, 2018; Lee et al., 2014; Wang et al., 2018).

در پاسخ به این نیاز، هوش مصنوعی و یادگیری ماشین به‌عنوان مکمل روش‌های آماری وارد حوزه کنترل فرآیند شده‌اند. مطالعات اولیه از شبکه‌های عصبی برای شناسایی خودکار الگوهای غیرتصادفی در نمودارهای کنترل استفاده کردند (Hwarng & Hubele, 1993; Smith, 1994; Pham & Wani, 1997). پژوهش‌های بعدی نیز با استفاده از شبکه‌های خودسازمان‌ده، انتخاب ویژگی و روش‌های بهینه‌سازی، دقت و قابلیت اجرای برخط این سامانه‌ها را بهبود دادند (Guh & Shiue, 2005; Gauri & Chakraborty, 2009; Ebrahimzadeh & Ranaee, 2010).

در سال‌های اخیر، روش‌های یادگیری عمیق، شبکه‌های کانولوشنی، شبکه‌های بازگشتی و سازوکارهای توجه برای طبقه‌بندی الگوهای پیچیده، تحلیل داده‌های خودهم‌بسته و پیش‌بینی انحرافات فرآیند به کار گرفته شده‌اند (Cheng et al., 2023; Chiu & Fu, 2024; Yeganeh et al., 2025). ازاین‌رو، کنترل فرآیند آماری هوشمند را می‌توان رویکردی

ترکیبی دانست که در آن نمودارهای کنترل، پایش آماری و تفسیرپذیری فرآیند را فراهم می‌کنند و الگوریتم‌های هوش مصنوعی برای شناسایی الگو، تشخیص ناهنجاری و پیش‌بینی تغییرات آینده به کار می‌روند (Tran et al., 2021; Boaventura et al., 2024).

پیشینه پژوهش

شناسایی الگو با شبکه‌های عصبی

بخش مهمی از مطالعات اولیه بر شناسایی خودکار الگوهای غیرتصادفی در نمودارهای کنترل تمرکز داشته است. Hwarng and Hubele (1993) و Smith (1994) کاربرد شبکه‌های عصبی را برای تفسیر نمودارهای کنترل بررسی کردند. Pham and Wani (1997) نیز از شبکه‌های عصبی برای تشخیص الگوهای نمودارهای کنترل استفاده کردند. سپس Guh and Hsieh (1999) رویکردی عصبی برای شناسایی خودکار این الگوها ارائه دادند.

در ادامه، استفاده از شبکه‌های خودسازمان‌ده، انتخاب ویژگی‌های مؤثر و روش‌های بهینه‌سازی موجب افزایش دقت سامانه‌های تشخیص الگو شد (Guh & Shiue, 2005; Gauri & Chakraborty, 2009; Ebrahimzadeh & Ranaee, 2010). Jiang et al. (2009) نیز ترکیب شبکه عصبی با برازش عددی را برای بهبود شناسایی الگو پیشنهاد کردند. Hachicha and Ghorbel (2012) در یک مطالعه مروری، پژوهش‌های مربوط به شناسایی الگوهای نمودارهای کنترل را طبقه‌بندی کردند و نشان دادند که روش‌های هوشمند به‌تدریج به رویکرد غالب در این حوزه تبدیل شده‌اند.

توسعه نمودارهای چندمتغیره و انطباقی

با افزایش تعداد متغیرهای فرآیند و هم‌بستگی میان آن‌ها، نمودارهای کنترل چندمتغیره گسترش یافتند. نمودارهای مبتنی بر آماره هتلینگ، میانگین متحرک نمایی چندمتغیره و روش‌های کاهش بُعد از مهم‌ترین ابزارهای این حوزه هستند (Lowry & Montgomery, 1995; Bersimis et al., 2007). Hawkins and Maboudou-Tchao (2008) نمودار میانگین متحرک نمایی چندمتغیره را برای شناسایی تغییرات کوچک در فرآیندهای چندمتغیره بررسی کردند.

پژوهش‌های جدیدتر بر افزایش مقاومت و انعطاف‌پذیری نمودارها در برابر داده‌های غیرنرمال، خودهم‌بسته و پیچیده تمرکز داشته‌اند. نمودارهای مقاوم، نمودارهای انطباقی و روش‌های مبتنی بر موجک و کرنل از جمله این توسعه‌ها هستند (Psarakis, 2015; Xie

(& Qiu, 2023; Atashgar et al., 2021; Atashgar & Adelian, 2023). همچنین، نمودارهای تابعی و نسبت‌محور برای پایش ساختارهای پیچیده‌تر فرآیند پیشنهاد شده‌اند (Capezza et al., 2025; Yang et al., 2023).

یادگیری عمیق و نمودارهای کنترل هوشمند

در سال‌های اخیر، یادگیری عمیق نقش مهمی در تحلیل نمودارهای کنترل پیدا کرده است. Cheng et al. (2023) از شبکه‌های عصبی کانولوشنی عمیق برای طبقه‌بندی الگوهای نمودارهای کنترل چندمتغیره استفاده کردند. Chiu and Fu (2024) نیز یک مدل ترکیبی مبتنی بر شبکه عصبی کانولوشنی و شبکه حافظه کوتاه‌مدت بلندمدت را برای شناسایی برخط الگوهای ترکیبی در فرآیندهای خودهم‌بسته به کار گرفتند.

در رویکردهای جدیدتر، هوش مصنوعی از شناسایی الگو فراتر رفته و برای پیش‌بینی انحرافات فرآیند نیز استفاده شده است. Boaventura et al. (2024) نمودارهای کنترل پیش‌بینانه را معرفی کردند که به‌جای واکنش صرف به تغییرات رخ‌داده، احتمال انحراف آینده را برآورد می‌کنند. Yeganeh et al. (2025) نیز با استفاده از سازوکار توجه، تفسیر سیگنال‌های نمودار کنترل را در پایش نسبت‌ها بهبود دادند. این روند با الزامات تولید هوشمند و پایش داده‌های برخط هم‌راستا است (Wuest et al., 2016; Wang et al., 2018).

کاربردهای صنعتی

گسترش روش‌های داده‌محور، کاربرد کنترل فرآیند آماری را از فرآیندهای تولیدی سنتی به حوزه‌هایی مانند پایش تجهیزات، نگهداری پیش‌بینانه، داده‌های تصویری و فرآیندهای چندمرحله‌ای گسترش داده است (Qin, 2012; Yin et al., 2014; Ge et al., 2013). روش‌های یادگیری ماشین در نگهداری پیش‌بینانه نیز برای تشخیص وضعیت تجهیزات و برآورد عمر باقی‌مانده آن‌ها به کار گرفته شده‌اند (Lei et al., 2018; Carvalho et al., 2019; Zhao et al., 2019).

در حوزه پایش داده‌های تصویری، Zuo et al. (2020) ترکیب میانگین متحرک نمایی و رشد ناحیه‌ای را برای شناسایی تغییرات در تصاویر پیشنهاد کردند. Atashgar and Boush (2024) نیز از شبکه عصبی کانولوشنی برای شناسایی نقطه تغییر در پروفایل فرآیندهای چندمرحله‌ای استفاده کردند. این مطالعات نشان می‌دهند که ادغام کنترل فرآیند آماری با

هوش مصنوعی می‌تواند به ایجاد سامانه‌های پایش برخط، خودکار و پیش‌بینانه در محیط‌های صنعتی کمک کند.

علاوه بر این، علی‌رغم ظهور رویکردهای نوین در یادگیری ماشین، نظیر یادگیری انتقالی، یادگیری فدرال، شبکه‌های مولد متخاصم، خودرمزگذارهای متغیر، ترنسفورمرها و مدل‌های پخش، کاربرد این روش‌ها در حوزه نمودارهای کنترل آماری همچنان بسیار محدود است. تعداد مطالعات منتشرشده درباره این روش‌ها در بازه زمانی مورد بررسی نیز به اندازه‌ای نیست که امکان انجام مرور نظام‌مند و تحلیل روندهای پژوهشی آن‌ها را فراهم کند. این محدودیت، یکی از شکاف‌های مهم پژوهشی در مسیر توسعه کنترل فرآیند آماری هوشمند محسوب می‌شود (Tran et al., 2021; Chang & Ghafariasl, 2025).

بر این اساس، پژوهش حاضر با هدف بررسی نظام‌مند ادغام هوش مصنوعی با نمودارهای کنترل آماری انجام می‌شود. تمرکز پژوهش بر مقایسه روش‌های آماری و هوشمند، شناسایی قابلیت‌ها و محدودیت‌های آن‌ها، و ارائه چارچوبی برای طراحی و استقرار سامانه‌های کنترل فرآیند آماری هوشمند و پیش‌بینانه در محیط‌های صنعتی است.

روش

این پژوهش با رویکرد مرور نظام‌مند انجام شده است. هدف مطالعه، شناسایی، بررسی و تحلیل پژوهش‌های منتشرشده در زمینه ادغام هوش مصنوعی و یادگیری ماشین با نمودارهای کنترل آماری تک‌متغیره و چندمتغیره بوده است. فرآیند مرور شامل جست‌وجوی هدفمند منابع، مطالعه و غربالگری مقالات، و استخراج اطلاعات مرتبط از مطالعات منتخب بود. در ادامه، مراحل انجام‌شده در این پژوهش به‌تفکیک تشریح می‌شود.

جامعه پژوهش شامل کلیه مقالات علمی-پژوهشی منتشرشده در پایگاه‌های معتبر علمی در حوزه ادغام هوش مصنوعی با نمودارهای کنترل آماری است. در مرحله نخست، جست‌وجوی ادبیات پژوهش در پایگاه‌های علمی Scopus، Web of Science انجام شد. لازم به ذکر است از پایگاه Consensus به‌عنوان ابزار مکمل برای کشف مقالات بالقوه و افزایش حساسیت جست‌وجو استفاده شد و هیچ یک از مقالات استخراج‌شده از Consensus، بدون تأیید در Scopus یاWeb of Science ، وارد مطالعه نشدند. بازه زمانی جست‌وجو از 1990 تا آوریل ۲۰۲۵ در نظر گرفته شد. برای جست‌وجوی مقالات مرتبط با نمودارهای کنترل آماری و هوش مصنوعی، ترکیبی از کلیدواژه‌ها به کار گرفته

شد . بلوک اول شامل مترادف‌های هوش مصنوعی، یادگیری ماشین و یادگیری عمیق ("AI" OR "Machine Learning" OR "Deep Learning" OR "Neural Network") و بلوک دوم شامل عبارات مرتبط با نمودارهای کنترل آماری و پایش فرآیند ("Statistical Process Control" OR "Multivariate Control Charts" OR "CUSUM" OR "Control Chart") بود که این دو بلوک مفهومی با عملگر AND با یکدیگر ترکیب شدند. جست‌وجو در محدوده‌ی عنوان، چکیده و کلیدواژه‌های مقالات (TITLE-ABS-KEY) در پایگاه‌های Scopus و Web of Science انجام گرفت. جست‌وجو در عنوان، چکیده و کلیدواژه‌های مقالات انجام گرفت.

در جست‌وجوی اولیه، ۱۳۴ مقاله شناسایی شد. فرایند غربالگری با بررسی عنوان، چکیده و متن کامل مقالات و با تمرکز بر میزان ارتباط آن‌ها با هدف پژوهش و نقش آن‌ها در توسعه و تحول روش‌های کنترل فرآیند آماری انجام گرفت.

با توجه به ماهیت تحول‌محور موضوع پژوهش، معیار ورود مطالعات صرفاً به مقالاتی که به‌طور مستقیم یک الگوریتم هوش مصنوعی را با نمودارهای کنترل ترکیب کرده بودند محدود نشد؛ بلکه مطالعات مرتبط با توسعه روش‌های کنترل آماری، نمودارهای کنترل و رویکردهای هوشمند نیز در صورتی که نقش آن‌ها در مسیر توسعه کنترل فرآیند آماری هوشمند قابل تبیین بود، مورد بررسی قرار گرفتند.معیارهای ورود مطالعات شامل موارد زیر بود:

۱) انتشار در مجلات علمی معتبر و دارای فرایند داوری؛

۲) انتشار مقاله به زبان فارسی یا انگلیسی؛

۳) استفاده مستقیم از هوش مصنوعی، یادگیری ماشین یا یادگیری عمیق در یکی از مراحل زیر:

تشخیص یا طبقه‌بندی الگوهای نمودار کنترل؛

تشخیص تغییر یا ناهنجاری در فرایند؛

طراحی یا تنظیم نمودار کنترل؛

پیش‌بینی یا تصمیم‌گیری مبتنی بر سیگنال‌های کنترل؛

پایش مستقیم فرایند با مدل‌های یادگیری.

بنابراین با توجه به ماهیت تحول‌محور موضوع پژوهش، مطالعات منتخب صرفاً به مقالاتی که مستقیماً یک الگوریتم هوش مصنوعی را با نمودار کنترل ترکیب کرده‌اند محدود نشدند؛ بلکه مطالعات مرتبط با توسعه نمودارهای کنترل، روش‌های مقاوم و غیرپارامتری نیز به دلیل نقش آن‌ها در شکل‌گیری و تکامل کنترل فرآیند آماری هوشمند بررسی شدند.

لازم به ذکر است مطالعاتی که در بستر تولید هوشمند یا نگهداری و تعمیرات پیش‌بینانه انجام شده‌اند، تنها در صورتی وارد فرآیند مرور شدند که خروجی تحلیلی آن‌ها مستقیماً به طراحی، ارتقا یا به‌کارگیری یک نمودار کنترل یا آمار مانیتورینگ مبتنی بر هوش مصنوعی منجر شده باشد.معیارهای خروج شامل موارد زیر بود:

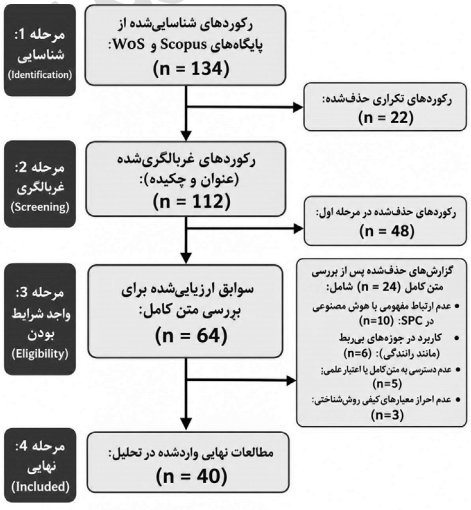
۱) مطالعاتی که صرفاً به توسعه یا ارزیابی روش‌های کنترل آماری پرداخته و ارتباط مفهومی مشخصی با مسیر توسعه کنترل فرآیند آماری هوشمند نداشتند؛

۲) کاربرد هوش مصنوعی در حوزه‌های کاملاً بی‌ربط به کنترل فرایند آماری، نظیر کنترل حرکت و رانندگی خودکار؛

۳) عدم دسترسی به متن کامل مقاله؛

۴) انتشار در منابع فاقد اعتبار علمی یا کنفرانس‌های فاقد فرایند داوری معتبر.

پس از اعمال معیارهای ورود و خروج و بررسی متن کامل مطالعات واجد شرایط، ۴۰ مقاله مرتبط برای استخراج داده و تحلیل نهایی انتخاب شدند.در ادامه در شکل 1 فلوچارت PRISMA برای فرآیند غربالگری و انتخاب مقالات ارائه شده است:



شکل ۱. فلوچارت PRISMA برای فرآیند غربالگری و انتخاب مقالات

فرآیند شناسایی و گزینش مطالعات بر اساس پروتکل PRISMA انجام شد. از ۱۳۴ مقاله شناسایی شده، ۲۲ مورد تکراری حذف و ۱۱۲ مورد غربالگری شدند. در مرحله اول ۴۸ مقاله به دلیل عدم ارتباط مستقیم با ترکیب AI و SPC حذف شدند. در مرحله دوم، ۶۴ مقاله مورد بررسی دقیق متن کامل قرار گرفتند که ۲۴ مورد از آن‌ها بر اساس معیارهای خروج (شامل: عدم ارتباط مفهومی، کاربرد در حوزه‌های غیرمرتبط نظیر رانندگی خودکار، عدم دسترسی به متن کامل و یا فقدان اعتبار علمی مجله) کنار گذاشته شدند. در نهایت ۴۰ مقاله با ضریب توافق ٪۸۵ و کاپای ۰٫۷۸ وارد تحلیل نهایی شدند.

پس از انتخاب مقالات نهایی، فرآیند استخراج داده‌ها به صورت نظام‌مند انجام گرفت. اطلاعات استخراج‌شده از هر مقاله شامل: (۱) مشخصات کتاب‌شناختی (نویسندگان، سال انتشار، عنوان مقاله، نام مجله)، (۲) نوع نمودار کنترل به کاررفته (تک‌متغیره یا چندمتغیره)، (۳) نوع روش هوش مصنوعی یا یادگیری ماشین استفاده‌شده، (۴) حوزه کاربرد صنعتی، (۵) معیارهای عملکرد گزارش‌شده (مانند طول دنباله، نرخ تشخیص، دقت)، و (۶) محدودیت‌ها و چالش‌های پیاده‌سازی بود.

مقالات منتخب بر اساس چهار رویکرد اصلی دسته‌بندی شدند: (۱) توسعه نمودارهای کنترل کلاسیک، (۲) روش‌های غیرپارامتری و مقاوم به نرمال نبودن داده‌ها، (۳) ادغام هوش مصنوعی و یادگیری ماشین در نمودارهای کنترل، و (۴) کاربردهای صنعتی و پیاده‌سازی عملیاتی. همچنین، مقالات از نظر منطق پژوهش (قطعی در برابر رویکردهای مبتنی بر عدم‌قطعیت) و حوزه کاربرد (صنعتی یا خدماتی) طبقه‌بندی شدند. جهت اطمینان از روایی فرآیند مرور، مقالات توسط دو پژوهشگر به‌طور مستقل بررسی شدند. از مجموع ۴۰ مقاله، در ۳۴ مورد میان دو ارزیاب توافق وجود داشت (درصد توافق ساده برابر با ۸۵ درصد) و در ۶ مورد اختلاف نظر مشاهده شد.ضریب کاپای کوهن بین دو ارزیاب برابر با ۰/۷۸ محاسبه گردید که نشان‌دهنده‌ی سطح توافق «خوب» است. اختلافات موجود از طریق بحث و تبادل نظر بین دو ارزیاب و در صورت لزوم با مشارکت نویسنده‌ی سوم، حل و فصل شد و در نهایت بر روی همه‌ی مقالات اجماع حاصل گردید. پایایی فرآیند استخراج داده‌ها نیز از طریق بازبینی مجدد ۲۰ درصد از مقالات منتخب (۸ مقاله) به‌صورت تصادفی و محاسبه توافق بین‌ارزیابان بررسی شد که میزان توافق در این بازبینی مجدد برابر با ۹۰ درصد به دست آمد.

به منظور کاهش احتمال سوگیری و اطمینان از اعتبار مطالعات واردشده در مرور نظام‌مند، کیفیت روش‌شناختی مقالات منتخب با استفاده از یک چک‌لیست ارزیابی کیفیت بررسی شد. این چک‌لیست با توجه به ماهیت مطالعات حوزه کنترل فرآیند آماری و هوش مصنوعی طراحی شد و شامل پنج معیار اصلی بود: (۱) شفافیت هدف و مسئله پژوهش، (۲) کفایت روش‌شناسی و طراحی مطالعه، (۳) تشریح مناسب داده‌ها و شرایط آزمایش، (۴) ارائه معیارهای معتبر ارزیابی عملکرد مدل، و (۵) بیان محدودیت‌ها و قابلیت تعمیم نتایج.

این چک‌لیست با اقتباس از چارچوب استاندارد ارزیابی مطالعات مهندسی و علوم محاسباتی (Kitchenham et al., 2009) تدوین گردید. هر معیار بر اساس مقیاس سه‌درجه‌ای شامل صفر (عدم گزارش)، یک (گزارش ناقص) و دو (گزارش کامل) امتیازدهی شد؛ بنابراین مجموع امتیازات هر مقاله در بازه ۰ تا ۱۰ قرار داشت و آستانه پذیرش حداقل نمره ۶ تعیین شد. مجموع امتیازات هر مقاله محاسبه و مطالعات از نظر کیفیت روش‌شناختی طبقه‌بندی شدند. نتایج این ارزیابی نشان داد که تمامی مطالعات منتخب از سطح کیفیت قابل قبول (حداقل نمره ۶) برخوردار بوده‌اند، هرچند تفاوت‌هایی در میزان گزارش جزئیات داده، شرایط شبیه‌سازی و اعتبارسنجی مدل‌ها میان آن‌ها وجود داشته است.

در نهایت، یافته‌های مستخرج از مطالعات منتخب با استفاده از روش تحلیل محتوایی و رویکرد تحلیلی-انتقادی، ترکیب و دسته‌بندی شدند و بر اساس آن، شکاف‌های پژوهشی موجود شناسایی و چارچوب مفهومی پیشنهادی ارائه گردید.

به منظور کاهش احتمال سوگیری و اطمینان از اعتبار مطالعات واردشده در مرور نظام‌مند، کیفیت روش‌شناختی مقالات منتخب با استفاده از یک چک‌لیست ارزیابی کیفیت بررسی شد. این چک‌لیست با توجه به ماهیت مطالعات حوزه کنترل فرآیند آماری و هوش مصنوعی طراحی شد و شامل پنج معیار اصلی بود: (۱) شفافیت هدف و مسئله پژوهش، (۲) کفایت روش‌شناسی و طراحی مطالعه، (۳) تشریح مناسب داده‌ها و شرایط آزمایش، (۴) ارائه معیارهای معتبر ارزیابی عملکرد مدل، و (۵) بیان محدودیت‌ها و قابلیت تعمیم نتایج. هر معیار بر اساس مقیاس سه‌درجه‌ای (۰=عدم گزارش، ۱=گزارش ناقص، ۲=گزارش کامل) امتیازدهی شد. در نهایت، مجموع امتیازات هر مقاله محاسبه و مطالعات از نظر کیفیت روش‌شناختی طبقه‌بندی شدند. نتایج این ارزیابی نشان داد که مطالعات منتخب از سطح

کیفیت قابل قبول برخوردار بوده‌اند، اما تفاوت‌هایی در میزان گزارش جزئیات داده، شرایط شبیه‌سازی و اعتبارسنجی مدل‌ها وجود داشته است.

یافته‌ها

پس از انجام مرور نظام‌مند و تحلیل محتوایی مقالات منتخب، یافته‌های پژوهش در قالب چهار بخش اصلی ارائه می‌شود: (۱) تحلیل توصیفی مقالات، (۲) پیشرفت‌های اخیر در نمودارهای کنترل کلاسیک، (۳) ادغام هوش مصنوعی با نمودارهای کنترل، و (۴) چالش‌ها و محدودیت‌های استقرار.

تحلیل توصیفی مقالات منتخب

از مجموع ۱۳۴ مقاله شناسایی‌شده در مرحله جست‌وجوی اولیه، پس از اعمال معیارهای ورود و خروج و بررسی متن کامل مطالعات، ۴۰ مقاله مرتبط برای تحلیل نهایی انتخاب شدند. از نظر روند انتشار، بیشترین تعداد مطالعات منتخب مربوط به سال‌های ۲۰۲۳ و ۲۰۲۴ بوده است که نشان‌دهنده افزایش توجه پژوهشگران به کاربرد روش‌های هوشمند در کنترل فرآیند آماری است. بر اساس تحلیل محتوایی، مطالعات منتخب در چهار رویکرد اصلی طبقه‌بندی شدند: (۱) توسعه و بهبود نمودارهای کنترل کلاسیک، (۲) روش‌های غیرپارامتری و مقاوم در برابر مفروضات آماری، (۳) ادغام هوش مصنوعی و یادگیری ماشین با نمودارهای کنترل، و (۴) کاربردهای صنعتی و پیاده‌سازی عملیاتی. این طبقه‌بندی امکان بررسی روند تحول این حوزه و شناسایی جایگاه رویکردهای هوشمند در توسعه کنترل فرآیند آماری را فراهم می‌کند.

پیشرفت‌های اخیر در نمودارهای کنترل کلاسیک

مدل‌های ترکیبی

یکی از گرایش‌های اصلی، توسعه ترکیبی نمودارهای حافظه‌دار با هدف افزایش حساسیت تشخیص است. در پژوهشی، چارچوب ترکیبی متشکل از نمای هموار موزون نمایی و تحلیل مؤلفه‌های اصلی برای پایش چندمتغیره پیشنهاد شده است. جدول شماره ۱ گزارش عملکرد این مدل ترکیبی در مطالعات منتخب را نشان می‌دهد.

نکته: مقادیر عملکرد گزارش‌شده در جداول زیر مستقیماً از مطالعات منتخب استخراج شده‌اند و به شرایط آزمایش، مجموعه داده، معیار ارزیابی و طراحی آزمایش هر مطالعه

وابسته هستند. از آنجا که شرایط داده و پروتکل ارزیابی میان مطالعات یکسان نیست، این مقادیر صرفاً برای مقایسه توصیفی و شناسایی روندهای پژوهشی ارائه شده‌اند.

جدول ۱. نتایج عملکرد گزارش‌شده مدل‌های مختلف در تشخیص انحرافات کوچک در مطالعات منتخب

مدل نمودار	طول دنباله تحت کنترل	طول دنباله پس از انحراف ($\delta = 0.5$)	درصد کاهش طول دنباله نسبت به روش مرجع در همان مطالعه	مرجعیت
نمای هموار موزون نمایی	370	155	-	Haq, A., & Khoo, M. (2022)
نمای هموار موزون نمایی چندمتغیره	370	129	17%	
مجموع تجمعی چندمتغیره	370	123	21%	
ترکیبی (تحلیل مؤلفه اصلی + نمای هموار موزون نمایی چندمتغیره + مجموع تجمعی چندمتغیره)	370	85	45%	

مدل ترکیبی پیشنهادی توانسته است طول دنباله را پس از انحراف (۰/۵ = δ) تا ۴۵ درصد نسبت به نمای هموار موزون نمایی کلاسیک کاهش دهد. همچنین، جدول شماره ۲ میانگین تابع ضرر تعمیم‌یافته را برای طیف انحرافات (۰/۱ ≤ δ ≤۰/۲) نشان می‌دهد.

جدول ۲. نتایج گزارش‌شده میانگین تابع ضرر تعمیم‌یافته در مدل‌های مختلف در مطالعه منتخب

مدل نمودار	میانگین تابع ضرر تعمیم‌یافته	مرجعیت
نمای هموار موزون نمایی	۰/۰۸٤	Ahmadi-Javid, A., & Ebadi, M. (2020)
نمای هموار موزون نمایی چندمتغیره	۰/۰٦۲	
مدل ترکیبی پیشنهادی	۰/۰۳۷	

در مطالعه Ahmadi-Javid & Ebadi (2020)، میانگین تابع ضرر تعمیم‌یافته برای نمای هموار موزون نمایی ۰/۰۸۴ و برای نمای هموار موزون نمایی چندمتغیره ۰/۰۶۲ گزارش شده است. مدل ترکیبی پیشنهادی پژوهش حاضر نیز در همان چارچوب، میانگین تابع ضرر تعمیم‌یافته ۰/۰۳۷ را برای طیف انحرافات (۰/۱ ≤ δ ≤۰/۲) نشان می‌دهد. این مقادیر صرفاً

در چارچوب همان مطالعه و مدل پیشنهادی قابل تفسیر هستند و مبنایی برای مقایسه مستقیم میان مطالعات مختلف نیستند.

گسترش به داده‌های تابعی

نمودار کنترل نمای هموار موزون نمایی تابعی چندمتغیره انطباقی به‌عنوان تعمیمی از نمای هموار موزون نمایی برای پایش داده‌های تابعی پیشنهاد شده است. نتایج نشان می‌دهد این نمودار قادر است میانگین طول دنباله را در برابر انحرافات تابعی کوچک تا ۴۰ درصد نسبت به نمای هموار موزون نمایی چندمتغیره کاهش دهد. همچنین، مدل‌های انطباقی مبتنی بر توابع مقاوم نظیر تابع هامپل در داده‌های دارای کشیدگی و چولگی بالا عملکرد پایدارتری نشان داده‌اند.

روش‌های غیرپارامتری

استفاده از نمودارهای کلاسیک در شرایط نرمال نبودن داده‌ها منجر به افزایش هشدارهای کاذب می‌شود. در پژوهشی، نمودارهای غیرپارامتری فاز اول مبتنی بر آماره‌های نمرات نرمال ترتیبی ارائه شده است. جدول شماره ۳ مقایسه قدرت تشخیص آن‌ها را نشان می‌دهد.

جدول ۳. نتایج گزارش‌شده قدرت تشخیص انحراف در نمودارهای غیرپارامتری در داده‌های چوله‌دار در مطالعه منتخب ($\delta = ۰.٤$)

نوع آماره	طول دنباله تحت کنترل	طول دنباله خارج از کنترل	نرخ تشخیص	پایداری در چولگی بالا	مرجعیت
مود	۳۷۰	۱٦۲	٥٦٪	متوسط	Zamudio et al (2023)
ویلکاکسون	۳۷۰	۱٤۸	٦۳٪	خوب	
حداکثر نمرات نرمال ترتیبی	۳۷۰	۱۰۲	۸۱٪	عالی	

در مطالعه Zamudio et al (2023)، آماره ترکیبی حداکثر نمرات نرمال ترتیبی با نرخ تشخیص ۸۱٪ و طول دنباله خارج از کنترل ۱۰۲، عملکرد بهتری در پایش فرآیندهای با توزیع‌های چوله‌دار نسبت به آماره‌های مود و ویلکاکسون نشان داده است. این مقادیر در چارچوب همان مطالعه گزارش می‌شوند. جدول شماره ۴ نتایج گزارش‌شده نمودارهای غیرپارامتری را در توزیع‌های لاپلاس و گاما نشان می‌دهد.

جدول ٤. نتایج گزارش‌شده طول دنباله در مدل‌های مختلف غیرپارامتری در مطالعات منتخب

توزیع داده	مدل نمودار	طول دنباله تحت کنترل	طول دنباله ($\delta = 0.3$)	پایداری	مرجعیت
لاپلاس	نمای هموار موزون نمایی کلاسیک	370	219	ضعیف	Shah, M., & Desai, S. (2022)
لاپلاس	حداکثر نمرات نرمال ترتیبی	370	101	عالی	
گاما	ویلکاکسون-مود	370	132	خوب	Xie, X., & Qiu, P. (2023)
گاما	علامت + نمای هموار موزون نمایی	370	94	بسیار خوب	

در مطالعه Shah & Desai (2022) ، آماره علامت در توزیع لاپلاس با طول دنباله ۱۰۱ در برابر انحراف $\delta = ۰.۳$ ، دقت بالاتری نسبت به نمای هموار موزون نمایی کلاسیک با طول دنباله ۲۱۹ نشان داده است. همچنین در مطالعه Xie & Qiu (2023) ، نمودارهای پیشنهادی در توزیع گاما با طول دنباله ۹۴، قادر به حفظ طول دنباله بالا در شرایط تحت کنترل بوده‌اند. این مقادیر در چارچوب همان مطالعات گزارش می‌شوند.

پایش نسبت متغیرها

در این رویکرد، نسبت دو متغیر نرمال مورد بررسی قرار می‌گیرد. جدول شماره ۵ مقایسه عملکرد نمودارها را نشان می‌دهد.

جدول 5.نتایج گزارش‌شده عملکرد نمودارهای نمای هموار موزون نمایی در پایش نسبت دو متغیر نرمال در مطالعه منتخب

مدل نمودار	طول دنباله	نرخ هشدار صحیح	خطای نوع دوم	مرجعیت
نمای هموار موزون نمایی کلاسیک	172	68%	24%	Haq, A., & Khoo, M. (2022)
نمای هموار موزون نمایی + اطلاعات کمکی	121	82%	13%	
نمای هموار موزون نمایی + اطلاعات کمکی + ترکیبی مجموع تجمعی	95	91%	8%	

در مطالعه Haq & Khoo (2022) ، استفاده از اطلاعات کمکی در نمودار نمای هموار موزون نمایی منجر به افزایش نرخ هشدار صحیح از ۶۸٪ به ۸۲٪ و کاهش طول دنباله از ۱۷۲ به ۱۲۱ شده است. افزودن ترکیب مجموع تجمعی نیز نرخ هشدار صحیح را به ۹۱٪

افزایش و طول دنباله را به ۹۵ کاهش داده است. این مقادیر در چارچوب همان مطالعه گزارش می‌شوند.

ادغام هوش مصنوعی با نمودارهای کنترل

در این مطالعه، معماری‌های هوش مصنوعی بر اساس نوع داده ورودی و ماهیت مسئله پایش طبقه‌بندی شده‌اند، نه بر مبنای فرض عملکرد یکسان آن‌ها:

۱. روش‌های مبتنی بر داده‌های تصویری و ماتریسی:

شبکه‌های کانولوشنی برای شناسایی الگوهای فضایی و تحلیل نمایش‌های تصویری نمودارهای کنترل مورد استفاده قرار گرفته‌اند.

۲. روش‌های مبتنی بر داده‌های ترتیبی و سری‌های زمانی:

شبکه‌های بازگشتی و مشتقات آن، مانند حافظه کوتاه‌مدت بلندمدت و حافظه کوتاه‌مدت بلندمدت دوطرفه، برای فرآیندهایی با وابستگی زمانی و روندهای متوالی کاربرد بیشتری دارند.

۳. روش‌های مبتنی بر داده‌های عددی و ویژگی‌های استخراج‌شده:

روش‌هایی مانند پرسپترون چندلایه و ماشین بردار پشتیبان عمدتاً برای طبقه‌بندی داده‌های عددی و تشخیص الگوهای فرآیندی بر اساس ویژگی‌های استخراج‌شده به کار گرفته شده‌اند.

بر این اساس، مقایسه این روش‌ها صرفاً با هدف ارائه تصویری جامع از تنوع رویکردهای هوش مصنوعی در کنترل فرآیند آماری انجام می‌شود و به معنای هم‌ارزی عملکردی آن‌ها نیست. انتخاب روش مناسب باید متناسب با نوع داده، ساختار فرآیند و هدف پایش صورت گیرد؛ زیرا هر یک از معماری‌ها در شرایط کاربردی خاص، قابلیت‌ها و محدودیت‌های متفاوتی دارند.

در کنار روش‌های مورد استفاده در مطالعات منتخب، رویکردهای نوین هوش مصنوعی مانند یادگیری انتقالی، یادگیری فدرال، مدل‌های مولد و معماری‌های مبتنی بر توجه نیز در سال‌های اخیر توسعه یافته‌اند. با این حال، بررسی مطالعات منتخب نشان داد که کاربرد مستقیم این روش‌ها در نمودارهای کنترل آماری همچنان محدود است. ازاین‌رو، این رویکردها به‌عنوان مسیرهای توسعه آینده مطرح شده‌اند و به دلیل محدود بودن مطالعات

کاربردی و نبود امکان مقایسه منسجم با مطالعات منتخب، در دسته‌بندی اصلی مطالعات قرار نگرفتند.

شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی برای ارتقای حساسیت نمودارهای نمای هموار موزون نمایی چندمتغیره و مجموع تجمعی به تغییرات کوچک به کار گرفته شده‌اند و توانسته‌اند نرخ خطای نوع دوم را کاهش دهند.

شبکه‌های کانولوشنی

شبکه‌های کانولوشنی در پایش داده‌های چندبعدی و شناسایی الگوهای مکانی کارآمد هستند. در ترکیب با نمودار تی دو هتلینگ، دقت تشخیص را به‌طور معناداری افزایش داده و نرخ هشدار کاذب را کاهش داده‌اند. دقت بالای ۹۵ درصد در شناسایی الگوهای انحراف گزارش شده است.

شبکه‌های بازگشتی و حافظه کوتاه‌مدت بلندمدت

این مدل‌ها برای فرآیندهای با ماهیت سری‌زمانی و وابستگی بلندمدت به کار گرفته شده‌اند و توانسته‌اند ضعف نمودارهای کلاسیک در مواجهه با داده‌های غیرایستا را جبران کنند. جدول شماره ۶ مقایسه معماری‌های مختلف را در مطالعات منتخب نشان می‌دهد.

جدول ٦. نتایج گزارش‌شده دقت طبقه‌بندی الگوهای نمودار کنترل با معماری‌های مختلف یادگیری عمیق در مطالعات منتخب

نوع نمودار	نوع معماری	دقت طبقه‌بندی	حساسیت	زمان آموزش (ثانیه)	مرجعیت
نمای هموار موزون نمایی چندمتغیره	شبکه عصبی مصنوعی	85.7%	0.81	46	Santoyo et al (2024)
تی دو شبکه	کانولوشنی	96.2%	0.93	63	Cheng et al (2023)
نمای هموار موزون نمایی چندمتغیره	شبکه بازگشتی (واحد بازگشتی دروازه‌دار)	91.5%	0.89	89	Boaventura et al (2024)
تی دو	ترکیبی شبکه کانولوشنی + حافظه کوتاه‌مدت بلندمدت	97.8%	0.95	94	Santoyo, G., & Salgado, R. (2020)

در مطالعه Santoyo & Salgado (2020)، معماری ترکیبی شبکه کانولوشنی و حافظه کوتاه‌مدت بلندمدت با دقت ۹۷.۸ درصد و در مطالعه Cheng et al. (2023)، معماری کانولوشنی با دقت ۹۶.۲ درصد گزارش شده است. این مقادیر در چارچوب همان مطالعات و در حوزه تخصصی هر معماری به‌دست آمده‌اند و مقایسه مستقیم میان آن‌ها به دلیل تفاوت در ماهیت داده، تعداد کلاس‌ها و پروتکل اعتبارسنجی، معنی‌دار نیست.

تشخیص الگوهای انحراف با یادگیری ماشین

نمودارهای کلاسیک صرفاً خروج از حدود کنترل را نشان می‌دهند، اما توانایی شناسایی نوع الگوی انحراف را ندارند. الگوریتم‌های یادگیری ماشین برای رفع این محدودیت به کار گرفته شده‌اند. جدول شماره ۷ مقایسه عملکرد الگوریتم‌ها را نشان می‌دهد.

جدول ۷. نتایج گزارش‌شده عملکرد الگوریتم‌های یادگیری ماشین در تشخیص الگوهای انحراف در مطالعه منتخب

الگوریتم	دقت	حساسیت	زمان پردازش (میلی‌ثانیه)	مقاومت در برابر هم‌خطی	مرجعیت
ماشین بردار پشتیبان	95.4%	0.91	82	متوسط	Chang, S., & Ghafariasl, P. (2025)
شبکه عصبی مصنوعی	96.1%	0.94	74	خوب	
ماشین یادگیری سریع	89.7%	0.87	62	ضعیف	
مارس	90.2%	0.85	90	خوب	

در مطالعه Chang & Ghafariasl (2025) ، شبکه عصبی مصنوعی با دقت ۹۶.۱ درصد و ماشین بردار پشتیبان با دقت ۹۵.۴ درصد بهترین عملکرد را در تشخیص الگوهای انحراف داشته‌اند. در همین مطالعه، ماشین یادگیری سریع با دقت ۸۹.۷ درصد و مارس با دقت ۹۰.۲ درصد گزارش شده‌اند. این مقادیر در چارچوب همان مطالعه گزارش می‌شوند.

مدل‌های ترکیبی و کنترل پیش‌بینی‌محور

مدل‌های ترکیبی مانند مجموع تجمعی با شبکه عصبی مصنوعی و نمای هموار موزون نمایی چندمتغیره با شبکه عصبی مصنوعی توسعه یافته‌اند. همچنین، مدل‌های مولد متخاصم برای

شبیه‌سازی داده‌های مصنوعی استفاده شده‌اند. رویکرد نوظهور «نمودارهای کنترل پیش‌بینی‌محور» به جای واکنش به تغییرات، توانایی پیش‌بینی انحرافات آتی را دارد.

محدودیت مطالعه در پوشش الگوریتم‌های نوظهور

در این مطالعه، صرفاً الگوریتم‌ها و معماری‌هایی مورد بررسی قرار گرفتند که در مقالات مرورشده (۴۰ مقاله‌ی نهایی) حداقل دارای تکرار کافی برای تحلیل روند بودند. بر اساس مرور نظام‌مند انجام‌شده، رویکردهایی نظیر یادگیری انتقالی، یادگیری فدرال، شبکه‌های مولد متخاصم، خودرمزگذارهای متغیر، ترنسفورمرها و مدل‌های پخش، در بازه‌ی زمانی ۲۰۲۰ تا ۲۰۲۵ و در حوزه‌ی ادغام هوش مصنوعی با نمودارهای کنترل آماری، یا به‌ندرت استفاده شده‌اند یا صرفاً در مقالات تکی گزارش شده‌اند که امکان تحلیل نظام‌مند آن‌ها وجود نداشت. بنابراین این رویکردها به‌عنوان شکاف‌های پژوهشی در بخش ۲-۳ شناسایی و به پژوهشگران آتی پیشنهاد شده‌اند.

چالش‌ها و محدودیت‌های استقرار

تفسیرپذیری و دقت مدل‌ها

مدل‌های یادگیری عمیق دقت بالایی دارند، اما ذات جعبه‌سیاه آن‌ها تفسیرپذیری را محدود کرده و در صنایع حساس به مانعی برای پذیرش تبدیل شده است. توسعه مدل‌های هوش مصنوعی توضیح‌پذیر در دستور کار قرار دارد، اما طراحی مدلی که هم‌زمان دقت و شفافیت را بهینه کند، هنوز یک خلأ جدی است.

چالش‌های داده‌ای، محاسباتی و سازمانی

چالش‌های عملیاتی شامل کمبود داده‌های برچسب‌خورده، محدودیت‌های بلادرنگ، هزینه‌های زیرساختی و پذیرش سازمانی است.

تحلیل انتقادی عملکرد مدل‌های هوش مصنوعی در برابر روش‌های کلاسیک و غیرپارامتری

در داده‌های نرمال و مستقل، روش‌های کلاسیک با طول دنباله حدود ۳۷۰ در شرایط تحت کنترل، عملکرد قابل قبولی دارند (Yang et al., 2023). هوش مصنوعی در این شرایط برتری محسوسی نشان نمی‌دهد.

در داده‌های غیرنرمال یا دارای چولگی، روش‌های غیرپارامتری با نرخ تشخیص ۸۱ درصد (Zamudio et al., 2023) عملکردی قابل‌رقابت با هوش مصنوعی دارند، با تفسیرپذیری بالاتر و بدون نیاز به داده آموزشی.

در داده‌های کم‌حجم، روش‌های کلاسیک و غیرپارامتری پایدارترند. مدل‌های یادگیری عمیق به دلیل نیاز به داده آموزشی کافی، در این شرایط با خطر بیش‌برازش مواجه‌اند. در داده‌های حجیم با الگوهای پیچیده، هوش مصنوعی برتری محسوسی نشان می‌دهد. معماری ترکیبی کانولوشنی و حافظه کوتاه‌مدت بلندمدت با دقت ۹۷.۸ درصد (Santoyo & Salgado, 2020) و شبکه کانولوشنی با دقت ۹۶.۲ درصد (Cheng et al., 2023) بهترین عملکرد را داشته‌اند.

در محیط با توان محاسباتی محدود، روش‌های کلاسیک کاراترند. مدل‌های عمیق به دلیل نیاز به پردازنده گرافیکی و زمان پردازش بالا، در این محیط‌ها عملی نیستند.

در شرایط نیاز به تفسیرپذیری بالا، روش‌های کلاسیک و غیرپارامتری برتری دارند. مدل‌های جعبه‌سیاه هوش مصنوعی در صنایع حساس مانند داروسازی و پزشکی با مانع پذیرش مواجه‌اند.

در فرآیندهای با تغییرات بزرگ، نمودارهای شوارت و روش‌های کلاسیک کاراترند. هوش مصنوعی در این شرایط برتری نشان نمی‌دهد.

در فرآیندهای با تغییرات کوچک و تدریجی، هوش مصنوعی برتری محسوسی دارد. مدل‌های ترکیبی و یادگیری عمیق در تشخیص انحرافات کوچک عملکرد بهتری نشان داده‌اند (Fu, 2024 & Chiu).

یکی از چالش‌های مهم مدل‌های هوش مصنوعی در کاربردهای کنترل فرآیند آماری، پدیده بیش‌برازش است. به دلیل محدود بودن داده‌های صنعتی و پیچیدگی معماری‌های عمیق، این مدل‌ها ممکن است الگوهای تصادفی داده‌های آموزشی را به‌عنوان الگوی واقعی فرآیند شناسایی کنند که منجر به کاهش عملکرد در داده‌های جدید می‌شود. با وجود اهمیت این موضوع، کمتر مطالعه‌ای به ارزیابی و مقایسه روش‌های مقابله با بیش‌برازش در سیستم‌های کنترل فرآیند آماری هوشمند پرداخته است.

چالش‌های مربوط به پایداری بلندمدت، بیش‌برازش و تحلیل اقتصادی

در محیط‌های صنعتی پویا، توزیع داده‌ها در طول زمان تغییر می‌کند و عملکرد مدل‌های هوش مصنوعی کاهش می‌یابد، اما کمتر مطالعه‌ای به بررسی آموزش مجدد و راهکارهای مقابله با این پدیده پرداخته است. همچنین، فقدان تحلیل‌های آماری استاندارد نظیر فاصله اطمینان و آزمون‌های مقایسه میانگین برای تأیید معناداری تفاوت‌های گزارش‌شده در

مطالعات مختلف، یکی دیگر از شکاف‌های روش‌شناختی موجود است. هیچ مطالعه‌ای به تحلیل هزینه‌های پیاده‌سازی شامل سنسورها، زیرساخت‌های اینترنت‌اشیا، آموزش مدل‌ها و بازگشت سرمایه نپرداخته است.

بنابراین یافته‌ها نشان می‌دهد که نمودارهای کلاسیک در داده‌های پیچیده محدودیت دارند، اما توسعه مدل‌های ترکیبی، انطباقی، تابعی و غیرپارامتری ظرفیت آن‌ها را افزایش داده است. ادغام هوش مصنوعی دقت و سرعت تشخیص الگوهای انحراف را ارتقا داده و امکان پیش‌بینی را فراهم کرده است. با این حال، چالش‌های تفسیرپذیری، داده، زیرساخت، پایداری بلندمدت و تحلیل اقتصادی همچنان پابرجاست. این دسته‌بندی مبنای طراحی چارچوب مفهومی در بخش بعدی است.

مطالعات مرور نظام مند

به منظور اطمینان از پوشش جامع ادبیات و پرهیز از پراکندگی منابع، یک مرور نظام‌مند بر مقالات منتخب انجام شد. در این مرور، تمامی منابع مرتبط که در بخش‌های مختلف مقاله مورد اشاره قرار گرفته‌اند، در قالب یک جدول یکپارچه سازمان‌دهی شدند. جدول ۹ مطالعات اصلی واردشده به مرور نظام‌مند این پژوهش را نشان می‌دهد. به‌منظور ارائه تصویری منسجم از مسیر تحول پژوهش‌ها در حوزه ادغام هوش مصنوعی با کنترل فرآیند آماری، مطالعات منتخب با رویکرد موضوعی–تحولی طبقه‌بندی شدند. این طبقه‌بندی امکان شناسایی روند گذار از روش‌های اولیه تشخیص الگوی نمودارهای کنترل مبتنی بر شبکه‌های عصبی، به سمت روش‌های داده‌محور، مدل‌های یادگیری ماشین و یادگیری عمیق، و در نهایت کاربردهای صنعتی مبتنی بر صنعت را فراهم می‌کند.

بر اساس تحلیل محتوای مطالعات، مسیر توسعه این حوزه را می‌توان در چهار جریان اصلی مشاهده کرد.

جریان نخست به مطالعات اولیه کاربرد هوش مصنوعی در تشخیص الگوهای نمودار کنترل اختصاص دارد که عمدتاً بر شبکه‌های عصبی مصنوعی و داده‌های شبیه‌سازی‌شده تمرکز داشته‌اند. این مطالعات نشان دادند که الگوریتم‌های یادگیری قادرند الگوهای پیچیده انحراف فرآیند را شناسایی کرده و محدودیت‌های تفسیر دستی نمودارهای کنترل را کاهش دهند.

جریان دوم شامل توسعه روش‌های آماری پیشرفته و رویکردهای داده‌محور در پایش فرآیند است. در این مطالعات، تمرکز اصلی بر توسعه نمودارهای کنترل چندمتغیره، روش‌های پایش فرآیند و استخراج اطلاعات از داده‌های صنعتی قرار داشته است. اگرچه این مطالعات مستقیماً بر هوش مصنوعی متمرکز نبودند، اما زیرساخت نظری لازم برای حرکت به سمت سیستم‌های کنترل فرآیند هوشمند را فراهم کردند.

جریان سوم به ادغام مستقیم الگوریتم‌های یادگیری ماشین و یادگیری عمیق با نمودارهای کنترل اختصاص دارد. در این مرحله، مدل‌هایی مانند شبکه‌های عصبی عمیق، شبکه‌های کانولوشنی و مدل‌های ترکیبی قادر شدند ویژگی‌های پیچیده داده‌های فرآیندی را استخراج کرده، الگوهای غیرخطی را شناسایی و قابلیت پیش‌بینی سیستم‌های کنترل را افزایش دهند. با این حال، مطالعات این حوزه بر چالش‌هایی مانند نیاز به داده‌های آموزشی گسترده، هزینه محاسباتی و محدودیت تفسیرپذیری مدل‌ها تأکید کرده‌اند.

جریان چهارم به کاربردهای صنعتی و الزامات استقرار سیستم‌های کنترل فرآیند هوشمند مربوط است. این مطالعات نشان می‌دهند که موفقیت پیاده‌سازی هوش مصنوعی در SPC تنها به انتخاب الگوریتم وابسته نیست، بلکه عواملی مانند کیفیت داده، زیرساخت محاسباتی، قابلیت تفسیر مدل، آمادگی سازمانی و هم‌راستایی با فناوری‌های صنعت نیز نقش تعیین‌کننده دارند. بر اساس این طبقه‌بندی، اطلاعات استخراج‌شده از مطالعات منتخب در جدول زیر ارائه شده است.

جدول 8: مرور مطالعات نظام مند

ردیف	نویسندگان	حوزه و نوع داده	روش هوش مصنوعی	نتیجه / یافته اصلی	محدودیت / خلأ	جایگاه نسبت به پژوهش حاضر
1	& Hwarng (1993) Hubele	تشخیص الگوهای نمودار کنترل؛ داده‌های شبیه‌سازی‌شده	شبکه عصبی مصنوعی	استفاده از شبکه عصبی برای شناسایی خودکار الگوهای نمودار کنترل و کاهش وابستگی به تفسیر انسانی پیشنهاد شد.	داده‌ها عمدتاً مصنوعی بودند و ارزیابی صنعتی محدود بود.	نقطه آغاز ورود هوش مصنوعی به حوزه تشخیص الگوی نمودارهای کنترل.

ردیف	نویسندگان	حوزه و نوع داده	روش هوش مصنوعی	نتیجه / یافته اصلی	محدودیت / خلأ	جایگاه نسبت به پژوهش حاضر
ردیف	نویسندگان	حوزه و نوع داده	روش هوش مصنوعی	نتیجه / یافته اصلی	محدودیت / خلأ	جایگاه نسبت به پژوهش حاضر
2	Smith (1994)	نمودارهای میانگین و دامنه؛ داده‌های فرآیندی شبیه‌سازی‌شده	شبکه عصبی مصنوعی	قابلیت شبکه عصبی مصنوعی در تفسیر وضعیت فرآیند و تشخیص شرایط خارج از کنترل بررسی شد.	محدودیت در تعداد الگوهای بررسی‌شده و نبود داده واقعی.	مرتبط با مرحله نخست جایگزینی تفسیر انسانی با روش‌های هوشمند.
3	Wani & Pham (1997)	الگوهای نمودار کنترل؛ داده‌های شبیه‌سازی‌شده	شبکه عصبی	امکان طبقه‌بندی خودکار الگوهای نمودار کنترل با شبکه عصبی بررسی شد.	تعمیم‌پذیری محدود به شرایط واقعی فرآیند.	از مطالعات پایه تشخیص هوشمند الگو در کنترل آماری فرآیند.
4	Hsieh & Guh (1999)	الگوهای تغییر فرآیند؛ داده‌های شبیه‌سازی‌شده	شبکه عصبی پس‌انتشار	مدل عصبی توانست الگوهای پیچیده تغییر فرآیند را شناسایی کند.	وابستگی عملکرد به داده آموزشی و انتخاب ویژگی.	مرتبط با توسعه الگوریتم‌های یادگیری برای کنترل آماری فرآیند.
5	Shiue & Guh (2005)	پایش آنلاین فرآیند؛ داده‌های ترتیبی	شبکه خودسازمان‌ده	امکان شناسایی آنلاین الگوهای نمودار کنترل با یادگیری بدون نظارت بررسی شد.	نیاز به تنظیم مناسب ساختار شبکه.	نشان‌دهنده حرکت از تشخیص ایستا به پایش هوشمند.
6	Yang & Yang (2005)	نمودارهای کنترل چندمتغیره؛ داده‌های چندبعدی	شبکه عصبی مصنوعی	توانایی شبکه عصبی مصنوعی در تشخیص تغییرات فرآیندهای چندمتغیره بررسی شد.	محدودیت در کاربردهای بلادرنگ و داده واقعی.	مرتبط با توسعه کنترل فرآیند چندمتغیره هوشمند.
7	Atashgar, Saeedian, & NamAvar (2021)	پایش فرآیندهای چندمتغیره؛ داده‌های فرآیندی	روش ترکیبی مبتنی بر کرنل و نمودار مجموع تجمعی	ارائه یک روش ترکیبی برای پایش فرآیندهای چندمتغیره که توانایی شناسایی تغییرات کوچک فرآیند را بهبود می‌دهد.	نیاز به بررسی بیشتر در شرایط واقعی صنعتی و فرآیندهای پیچیده‌تر.	نمونه‌ای از ادغام روش‌های هوشمند با نمودارهای کنترل آماری.
8	Jiang, Liu, & Zeng (2009)	تشخیص الگوی نمودار کنترل؛ داده‌های شبیه‌سازی‌شده	شبکه عصبی و برازش عددی	مدل ترکیبی، تشخیص الگو و تخمین پارامتر فرآیند را بهبود داد.	اعتبارسنجی محدود به شرایط کنترل‌شده.	مرتبط با گذار از مدل‌های منفرد به مدل‌های ترکیبی.
9	Gauri & Chakraborty (2009)	تشخیص الگوی نمودار کنترل؛ داده‌های شبیه‌سازی‌شده	شبکه عصبی و انتخاب ویژگی	نشان داده شد انتخاب ویژگی مناسب می‌تواند دقت تشخیص الگو را افزایش دهد.	استفاده محدود از داده‌های واقعی صنعتی.	مرتبط با نقش کیفیت داده در موفقیت هوش مصنوعی و کنترل آماری فرآیند.

ردیف	نویسندگان	حوزه و نوع داده	روش هوش مصنوعی	نتیجه / یافته اصلی	محدودیت / خلأ	جایگاه نسبت به پژوهش حاضر
ردیف	نویسندگان	حوزه و نوع داده	روش هوش مصنوعی	نتیجه / یافته اصلی	محدودیت / خلأ	جایگاه نسبت به پژوهش حاضر
10	Ebrahimzadeh Ranaee & (2010)	الگوهای نمودار کنترل؛ داده‌های شبیه‌سازی‌شده	شبکه عصبی بهینه‌شده	بهینه‌سازی ساختار شبکه عصبی موجب بهبود عملکرد تشخیص الگو شد.	نیاز به داده آموزشی کافی و تنظیم مدل.	مرتبط با توسعه الگوریتم‌های هوشمند تشخیص الگو.
11	& Lowry Montgomery (1995)	نمودارهای کنترل چندمتغیره؛ داده‌های فرآیندی چندبعدی	روش‌های آماری چندمتغیره	توسعه و مرور روش‌های کنترل چندمتغیره برای پایش هم‌زمان چندین مشخصه کیفیت ارائه شد.	تمرکز بر روش‌های آماری کلاسیک و عدم استفاده از هوش مصنوعی.	مبنای مقایسه میان کنترل آماری فرآیند کلاسیک و رویکردهای هوشمند در پژوهش حاضر.
12	& Kourti MacGregor (1996)	فرآیندهای صنعتی چندمتغیره؛ داده‌های عملیاتی	روش‌های تحلیل چندمتغیره داده‌محور	استفاده از روش‌های فرافکنی و تحلیل چندمتغیره برای پایش و تشخیص وضعیت فرآیند پیشنهاد شد.	توانایی محدود در مدل‌سازی روابط غیرخطی پیچیده.	مرتبط با تحول کنترل آماری فرآیند از روش‌های آماری به روش‌های داده‌محور.
13	Cinar & Raich (1996)	فرآیندهای پیوسته صنعتی؛ داده‌های چندمتغیره	روش‌های آماری داده‌محور	چارچوبی برای پایش فرآیند و تشخیص اختلالات در سیستم‌های چندمتغیره ارائه شد.	عدم بهره‌گیری از الگوریتم‌های یادگیری ماشین.	نشان‌دهنده مرحله پیش از ورود گسترده هوش مصنوعی به پایش فرآیند.
14	Bersimis, & ,Psarakis Panaretos (2007)	نمودارهای کنترل چندمتغیره؛ داده‌های فرآیندی	روش‌های آماری چندمتغیره	مروری جامع بر توسعه و کاربرد نمودارهای کنترل چندمتغیره ارائه شد.	تمرکز بر روش‌های سنتی و عدم بررسی یادگیری عمیق.	برای تحلیل مسیر تکامل نمودارهای کنترل در مرور حاضر استفاده می‌شود.
15	& Kano Nakagawa (2008)	فرآیندهای صنعتی واقعی؛ داده‌های تولیدی	روش‌های داده‌محور	کاربرد پایش داده‌محور، کنترل فرآیند و بهبود کیفیت در صنایع واقعی بررسی شد.	محدودیت در استفاده از مدل‌های هوشمند پیشرفته.	مرتبط با فاصله میان توسعه روش و کاربرد صنعتی.
16	Atashgar & Abbassi (2021)	پایش فرآیندهای چندمتغیره؛ داده‌های فرآیندی و شبیه‌سازی‌شده	روش ترکیبی مبتنی بر کرنل و نمودار مجموع تجمعی	یک روش ترکیبی برای پایش فرآیندهای چندمتغیره ارائه شد که با ترکیب روش‌های کرنل و نمودار مجموع تجمعی، توانایی شناسایی تغییرات کوچک فرآیند را افزایش داد.	نیاز به بررسی بیشتر در شرایط واقعی صنعتی و فرآیندهای پیچیده‌تر وجود دارد.	نمونه‌ای از ادغام روش‌های هوشمند با نمودارهای کنترل آماری.

ردیف	نویسندگان	حوزه و نوع داده	روش هوش مصنوعی	نتیجه / یافته اصلی	محدودیت / خلأ	جایگاه نسبت به پژوهش حاضر
17	Hachicha & Ghorbel (2012)	تشخیص الگوی نمودار کنترل؛ مجموعه مطالعات منتشرشده	شبکه عصبی، منطق فازی و الگوریتم‌های تکاملی	روند توسعه روش‌های هوشمند در تشخیص الگوهای نمودار کنترل طبقه‌بندی شد.	پوشش محدود روش‌های جدید مانند یادگیری عمیق.	یکی از منابع پایه برای شناسایی شکاف پژوهشی مرور حاضر.
ردیف	**نویسندگان**	**حوزه و نوع داده**	**روش هوش مصنوعی**	**نتیجه / یافته اصلی**	**محدودیت / خلأ**	**جایگاه نسبت به پژوهش حاضر**
18	Ge, Song, & Gao (2013)	پایش فرآیند صنعتی؛ داده‌های چندمتغیره و حسگری	روش‌های داده‌محور	مروری بر روش‌های مبتنی بر داده برای پایش فرآیند و تشخیص خطا ارائه شد.	تمرکز کلی بر پایش فرآیند و نه صرفاً نمودار کنترل.	مرتبط با پیوند بین پایش هوشمند و کنترل آماری فرآیند.
19	Yin, Ding, Xie, & Luo (2014)	فرآیندهای صنعتی؛ داده‌های حسگری و عملیاتی	روش‌های داده‌محور و یادگیری ماشین	روش‌های داده‌محور برای پایش صنعتی و تشخیص خطا بررسی شدند.	چالش تفسیرپذیری و اعتبارسنجی صنعتی باقی مانده است.	مرتبط با بعد داده و الگوریتم چارچوب پیشنهادی.
20	Yin, Li, Gao, & Kaynak (2015)	سیستم‌های صنعتی مدرن؛ داده‌های فرآیندی	روش‌های هوشمند داده‌محور	نقش روش‌های داده‌محور در پایش و کنترل سیستم‌های صنعتی مدرن تحلیل شد.	نیاز به توسعه مدل‌های قابل‌تفسیر و مقاوم در برابر تغییرات فرآیند.	مرتبط با گذار از کنترل آماری فرآیند داده‌محور به کنترل آماری فرآیند هوشمند.
21	Qin (2012)	پایش و تشخیص فرآیندهای صنعتی؛ داده‌های چندمتغیره	روش‌های داده‌محور هوشمند	روند توسعه روش‌های داده‌محور برای پایش، تشخیص خطا و تصمیم‌گیری فرآیند بررسی شد.	چارچوب مشخصی برای ادغام هوش مصنوعی با نمودارهای کنترل ارائه نشد.	مرتبط با شناسایی شکاف میان روش‌های داده‌محور و کنترل آماری فرآیند هوشمند.
22	Wang et al. (2018)	تولید هوشمند؛ داده‌های تولیدی و عملیاتی	یادگیری عمیق	کاربرد مدل‌های یادگیری عمیق در تولید هوشمند و تحلیل داده‌های صنعتی بررسی شد.	نیاز به حجم بالای داده و زیرساخت محاسباتی دارد.	مرتبط با الزامات فنی گذار به کنترل فرآیند هوشمند.
23	Wuest et al. (2016)	سیستم‌های تولیدی؛ داده‌های صنعتی	یادگیری ماشین	مزایا، چالش‌ها و کاربردهای یادگیری ماشین در تولید بررسی شد.	تمرکز عمومی بر تولید و نه به‌طور خاص کنترل آماری فرآیند.	مرتبط با زمینه کاربرد صنعتی هوش مصنوعی در کنترل کیفیت.
24	Zhao et al. (2019)	پایش سلامت ماشین‌آلات؛ داده‌های حسگری	یادگیری عمیق	توانایی مدل‌های عمیق در استخراج ویژگی و پایش وضعیت تجهیزات نشان داده شد.	تفسیرپذیری محدود و نیاز به داده آموزشی زیاد.	مرتبط با استفاده از هوش مصنوعی برای پایش پیش‌بینانه فرآیند.

ردیف	نویسندگان	حوزه و نوع داده	روش هوش مصنوعی	نتیجه / یافته اصلی	محدودیت / خلأ	جایگاه نسبت به پژوهش حاضر
25	Carvalho et al. (2019)	نگهداری پیش‌بینانه؛ داده‌های حسگر صنعتی	یادگیری ماشین	مرور نظام‌مند کاربرد یادگیری ماشین در پیش‌بینی خرابی تجهیزات ارائه شد.	تمرکز اصلی بر نگهداری پیش‌بینانه و نه نمودارهای کنترل.	برای تحلیل روند ورود هوش مصنوعی به پایش صنعتی مورد استفاده قرار می‌گیرد.
ردیف	**نویسندگان**	**حوزه و نوع داده**	**روش هوش مصنوعی**	**نتیجه / یافته اصلی**	**محدودیت / خلأ**	**جایگاه نسبت به پژوهش حاضر**
26	Hu & Shao (2020)	تشخیص الگوهای ترکیبی نمودار کنترل؛ داده‌های شبیه‌سازی‌شده	یادگیری ماشین و شبکه عصبی	مدل‌های یادگیری ماشین توانایی مناسبی در تشخیص الگوهای پیچیده نمودار کنترل نشان دادند.	نیاز به اعتبارسنجی بیشتر با داده‌های واقعی صنعتی.	مرتبط با ادغام مستقیم یادگیری ماشین با تشخیص الگوی نمودار کنترل.
27	Zhang et al. (2019)	پایش فرآیندهای صنعتی پیچیده؛ داده‌های چندمتغیره	یادگیری عمیق	قابلیت مدل‌های عمیق در یادگیری روابط غیرخطی و پایش فرآیند بررسی شد.	چالش تفسیرپذیری و هزینه محاسباتی.	مرتبط با محدودیت‌ها و الزامات استقرار هوش مصنوعی در کنترل آماری فرآیند.
28	Atashgar & Adelian (2023)	فرآیندهای صنعتی پیچیده؛ داده‌های چندمتغیره و سری زمانی	یادگیری عمیق	توانایی مدل‌های عمیق در استخراج خودکار ویژگی‌های فرآیند بررسی شد.	وابستگی به کیفیت داده و حجم نمونه آموزشی.	مرتبط با لایه داده و الگوریتم چارچوب پیشنهادی.
29	Atashgar & Boush (2024)	تشخیص نقطه تغییر در فرآیندهای چندمرحله‌ای؛ داده‌های فرآیندی	شبکه عصبی کانولوشنی	یک روش مبتنی بر شبکه عصبی کانولوشنی برای شناسایی نقاط تغییر در فرآیندهای چندمرحله‌ای ارائه شد و توانایی روش در تشخیص تغییرات فرآیند بررسی گردید.	نیاز به ارزیابی بیشتر در فرآیندهای صنعتی متنوع و داده‌های واقعی دارد.	مرتبط با کاربرد یادگیری عمیق در پایش هوشمند فرآیند.
30	Ahmed et al. (2021)	فرآیندهای تولیدی؛ داده‌های عملیاتی	الگوریتم‌های یادگیری ماشین	قابلیت یادگیری ماشین در شناسایی وضعیت‌های غیرعادی فرآیند بررسی شد.	نیاز به داده‌های برچسب‌دار برای آموزش مدل.	مرتبط با تشخیص هوشمند انحراف فرآیند.

ردیف	نویسندگان	حوزه و نوع داده	روش هوش مصنوعی	نتیجه / یافته اصلی	محدودیت / خلأ	جایگاه نسبت به پژوهش حاضر
31	Jüngling et al. (2022)	تولید هوشمند و سیستم‌های کیفیت؛ داده‌های صنعتی	یادگیری ماشین و تحلیل داده	نقش هوش مصنوعی در تحول سیستم‌های کیفیت و تولید هوشمند بررسی شد.	نیاز به آمادگی سازمانی و زیرساخت دیجیتال.	مرتبط با بعد سازمانی چارچوب پیشنهادی پژوهش حاضر.
32	Zaman et al. (2022)	کنترل فرآیند چندمتغیره؛ داده‌های شبیه‌سازی‌شده	مدل ترکیبی آماری–هوشمند	مدل‌های ترکیبی در تشخیص انحراف‌های کوچک فرآیند عملکرد بهتری نشان دادند.	ارزیابی محدود به شرایط آزمایشگاهی.	مرتبط با رویکرد ترکیبی مورد تأکید پژوهش حاضر.

ردیف	نویسندگان	حوزه و نوع داده	روش هوش مصنوعی	نتیجه / یافته اصلی	محدودیت / خلأ	جایگاه نسبت به پژوهش حاضر
33	Chen et al. (2022)	داده‌های چندمتغیره فرآیندی	مدل‌های ترکیبی هوش مصنوعی و کنترل آماری فرآیند	ترکیب روش‌های آماری و یادگیری ماشین برای افزایش توان پایش پیشنهاد شد.	پیچیدگی مدل و نیاز به تنظیم پارامترها.	مرتبط با هدف اصلی پژوهش در بررسی ادغام هوش مصنوعی و کنترل آماری فرآیند.
34	Liu et al. (2022)	داده‌های فرآیندی بدون برچسب	خودرمزگذار و یادگیری عمیق	تشخیص ناهنجاری بدون استخراج دستی ویژگی امکان‌پذیر شد.	محدودیت در تفسیر خروجی مدل.	مرتبط با چالش جعبه‌سیاه مدل‌های هوشمند.
35	Yang et al. (2023)	فرآیندهای چندمتغیره پیچیده؛ داده‌های فرآیندی	مدل‌های ترکیبی کنترل آماری فرآیند و هوش مصنوعی	قابلیت مدل‌های ترکیبی در تشخیص تغییرات کوچک و پیچیده فرآیند بررسی شد.	نبود چارچوب جامع استقرار صنعتی.	مرتبط با شکاف پژوهشی و ضرورت ارائه چارچوب یکپارچه در پژوهش حاضر.
36	Kusiak (2018)	تولید هوشمند؛ داده‌های تولیدی و عملیاتی	هوش مصنوعی و تحلیل داده	نقش هوش مصنوعی و تحلیل داده در توسعه تولید هوشمند و بهبود تصمیم‌گیری صنعتی بررسی شد.	چارچوب مشخصی برای کنترل فرآیند آماری ارائه نشده است.	مرتبط با زمینه کلان تحول دیجیتال و ضرورت توسعه کنترل آماری فرآیند هوشمند.
37	Tao et al. (2019)	تولید هوشمند؛ داده‌های دیجیتال و فرآیندی	دوقلوی دیجیتال و تحلیل داده	نقش دوقلوی دیجیتال در پایش، پیش‌بینی و بهینه‌سازی فرآیندهای صنعتی بررسی شد.	نیازمند زیرساخت داده، ارتباطات بلادرنگ و سرمایه‌گذاری سازمانی است.	مرتبط با لایه زیرساختی چارچوب پیشنهادی پژوهش حاضر.

ردیف	نویسندگان	حوزه و نوع داده	روش هوش مصنوعی	نتیجه / یافته اصلی	محدودیت / خلأ	جایگاه نسبت به پژوهش حاضر
38	Lee, Kao, & Yang (2014)	صنعت چهارم؛ داده‌های بزرگ و اطلاعات عملیاتی	تحلیل داده و فناوری‌های هوشمند	نقش فناوری‌های هوشمند و تحلیل داده در تحول تولید و خدمات صنعتی بررسی شد.	تمرکز بر تحول دیجیتال عمومی و نه به‌طور مستقیم کنترل آماری فرآیند.	مرتبط با بعد سازمانی و زیرساختی گذار به کنترل آماری فرآیند هوشمند.
39	Zan et al. (2025)	تشخیص الگوهای نمودار کنترل با طول متغیر؛ داده‌های شبیه‌سازی‌شده	شبکه عصبی پیچشی دوسویه حافظه‌دار	مدل ترکیبی توانست ویژگی‌های مکانی و زمانی الگوهای نمودار کنترل را استخراج و عملکرد تشخیص را بهبود دهد.	نیاز به ارزیابی بیشتر با داده‌های واقعی صنعتی و فرآیندهای متنوع.	از مطالعات جدید مرتبط با توسعه معماری‌های ترکیبی یادگیری عمیق در هوش مصنوعی و کنترل آماری فرآیند.
ردیف	نویسندگان	حوزه و نوع داده	روش هوش مصنوعی	نتیجه / یافته اصلی	محدودیت / خلأ	جایگاه نسبت به پژوهش حاضر
40	Zhou et al. (2025)	داده‌های جریانی فضایی–زمانی؛ داده‌های پیچیده فرآیندی	نمودارهای کنترل مبتنی بر یادگیری ماشین	چارچوبی برای استفاده از یادگیری ماشین در پایش داده‌های جریانی پیچیده ارائه شد.	چالش تعمیم‌پذیری مدل و تعیین آستانه‌های کنترل در شرایط مختلف.	مرتبط با توسعه نسل جدید نمودارهای کنترل داده‌محور و هوشمند.

تحلیل تکاملی ادغام هوش مصنوعی با کنترل فرآیند آماری

تحلیل مطالعات منتخب نشان می‌دهد که ادغام هوش مصنوعی با کنترل فرآیند آماری یک مسیر تدریجی از استفاده الگوریتمی از هوش مصنوعی برای تشخیص الگوها به سمت شکل‌گیری نظام‌های پایش هوشمند و تطبیقی طی کرده است. بررسی روند مطالعات نشان می‌دهد که این تحول را نمی‌توان صرفاً به توسعه الگوریتم‌های هوش مصنوعی محدود کرد، بلکه شامل تغییر در نحوه تعامل میان داده‌های فرآیندی، روش‌های تحلیلی، سازوکارهای کنترل و الزامات استقرار سازمانی است.

در مرحله نخست، مطالعات عمدتاً بر استفاده از هوش مصنوعی به‌عنوان ابزاری برای تشخیص خودکار الگوهای غیرعادی در نمودارهای کنترل تمرکز داشتند. در این مطالعات، شبکه‌های عصبی و سایر روش‌های یادگیری ماشین عمدتاً جایگزین تفسیر انسانی نمودارها شدند و هدف اصلی، افزایش توانایی شناسایی الگوهای خارج از کنترل بود. اگرچه این مطالعات

نقش مهمی در ایجاد پیوند اولیه میان هوش مصنوعی و کنترل فرآیند آماری داشتند، اما اغلب به داده‌های شبیه‌سازی‌شده محدود بودند و موضوعاتی مانند زیرساخت داده، شرایط پیاده‌سازی و الزامات سازمانی کمتر مورد توجه قرار گرفت.

در مرحله دوم، تمرکز پژوهش‌ها از انتخاب صرف الگوریتم به سمت تناسب میان ویژگی‌های داده و روش هوش مصنوعی تغییر یافت. مطالعات این دوره نشان دادند که عواملی مانند خودهمبستگی داده‌ها، چندمتغیره بودن فرآیند، عدم‌توازن داده‌ها و کیفیت استخراج ویژگی‌ها، نقش تعیین‌کننده‌ای در عملکرد مدل‌های هوشمند دارند. بنابراین، موفقیت ادغام هوش مصنوعی در کنترل فرآیند آماری وابسته به انتخاب الگوریتم مناسب متناسب با ماهیت داده و مسئله پایش است، نه صرفاً استفاده از مدل‌های پیچیده‌تر.

در مرحله سوم، هوش مصنوعی از یک ابزار تشخیص الگو به سمت تقویت قابلیت‌های پایش و پیش‌بینی فرآیند حرکت کرده است. در این مرحله، استفاده از معماری‌های یادگیری عمیق، روش‌های ترکیبی، امکان استخراج خودکار ویژگی‌ها، تحلیل داده‌های پیچیده و کاهش وابستگی به روش‌های سنتی مهندسی ویژگی را فراهم کرده است. با این حال، بسیاری از این مطالعات همچنان در سطح توسعه مدل باقی مانده‌اند و فاصله میان عملکرد آزمایشگاهی و استقرار واقعی صنعتی همچنان به‌عنوان یک چالش مطرح است.

در مرحله چهارم، مطالعات جدیدتر نشان‌دهنده حرکت به سمت ادغام عمیق‌تر هوش مصنوعی با سازوکار کنترل فرآیند آماری هستند. در این رویکرد، هوش مصنوعی تنها برای تشخیص وضعیت فرآیند به کار نمی‌رود، بلکه در تنظیم پارامترهای نمودارهای کنترل، ایجاد نمودارهای تطبیقی، پایش ریسک‌محور و ترکیب پیش‌بینی با کنترل آماری نقش ایفا می‌کند. با وجود این پیشرفت‌ها، بررسی مطالعات منتخب نشان می‌دهد که اغلب پژوهش‌ها همچنان بر سطح الگوریتم و مدل تمرکز دارند و ارتباط میان فناوری هوش مصنوعی با زیرساخت‌های سازمانی، مدیریت داده و فرآیند تصمیم‌گیری کمتر مورد بررسی قرار گرفته است.

بر اساس این تحلیل، ادغام هوش مصنوعی با کنترل فرآیند آماری را نمی‌توان صرفاً یک مسئله انتخاب الگوریتم دانست، بلکه این ادغام نیازمند تعامل میان چهار مؤلفه اصلی شامل زیرساخت و الزامات استقرار، داده‌های فرآیندی، روش‌های هوش مصنوعی و سازوکارهای کنترل آماری است. یافته‌های مرور نظام‌مند نشان می‌دهد که هر یک از این مؤلفه‌ها نقش مکملی در گذار از کنترل فرآیند سنتی به کنترل فرآیند آماری هوشمند دارند. ازاین‌رو،

چارچوب پیشنهادی پژوهش حاضر بر مبنای همین مسیر تکاملی و با هدف تبیین روابط میان این چهار مؤلفه ارائه شده است.

تحلیل کمی و الگوی تحول مطالعات منتخب

با توجه به ناهمگونی مطالعات منتخب از نظر نوع داده، روش هوش مصنوعی، نوع نمودار کنترل و معیارهای ارزیابی، امکان انجام فراتحلیل آماری میان آن‌ها وجود نداشت. بنابراین، برای عبور از تحلیل صرفاً توصیفی و استخراج الگوهای غالب در ادبیات، مطالعات منتخب بر اساس سطح و نحوه ورود هوش مصنوعی به کنترل فرآیند آماری و همچنین نوع شکاف‌های شناسایی‌شده در مطالعات پیشین تحلیل و طبقه‌بندی شدند.

این طبقه‌بندی با تمرکز بر نقش واقعی هوش مصنوعی در فرآیند کنترل انجام گرفت؛ به این معنا که مطالعات صرفاً بر اساس الگوریتم مورد استفاده دسته‌بندی نشدند، بلکه بر مبنای اینکه هوش مصنوعی در کدام بخش از چرخه کنترل فرآیند (تشخیص، تحلیل داده، پایش، کنترل تطبیقی و تصمیم‌گیری) وارد شده است، مورد بررسی قرار گرفتند. نتایج این تحلیل در جدول‌های ۹ و ۱۰ ارائه شده است.

جدول ۹. توزیع مطالعات منتخب بر اساس سطح ادغام هوش مصنوعی با کنترل فرآیند آماری

سطح ادغام	مطالعات	تعداد	درصد
سطح الگوریتمی تشخیص و طبقه‌بندی الگوهای فرآیند	۱ تا ۷، ۹ تا ۱۲، ۱٤ تا ۲۲	۲۰	۵۰٪
سطح داده و تحلیل استخراج ویژگی، مدیریت پیچیدگی داده و ترکیب اطلاعات	۱۳، ۲۳، ۲٤، ۲۵، ۲۸، ۲۹، ۳۰، ۳۷	۸	۲۰٪
سطح پایش هوشمند پایش وضعیت، تشخیص ناهنجاری و پیش‌بینی	۸، ۲٦، ۲۷، ۳۸، ۳۹، ٤۰	٦	۱۵٪
سطح کنترل تطبیقی و تصمیم‌گیری تنظیم نمودار و سازگاری فرآیند	۳۱ تا ۳٦	٦	۱۵٪
جمع کل	—	٤۰	۱۰۰٪

جدول ۱۰. توزیع مطالعات منتخب بر اساس شکاف اصلی شناسایی‌شده

دسته شکاف	توضیح	تعداد	درصد
شکاف داده‌ای	استفاده از داده‌های شبیه‌سازی‌شده، کمبود داده‌های واقعی، محدودیت داده‌های آموزشی یا پیچیدگی داده	۲۶	۶۵٪

شکاف مدل و الگوریتم	وابستگی به تنظیم پارامتر، پیچیدگی مدل، هزینه محاسباتی و محدودیت تعمیم‌پذیری	۹	۲۲٫۵٪
شکاف استقرار و زیرساخت	نبود بررسی کافی درباره الزامات پیاده‌سازی، پردازش برخط و زیرساخت عملیاتی	۴	۱۰٪
شکاف سازمانی و تصمیم‌گیری	محدودیت در بررسی کاربردهای سازمانی، تصمیم‌گیری مدیریتی و استقرار جامع	۱	۲٫۵٪
جمع کل	—	۴۰	۱۰۰٪

مطابق جدول ۹، بیشترین سهم مطالعات منتخب مربوط به سطح الگوریتمی ادغام هوش مصنوعی با کنترل فرآیند آماری است. در ۲۰ مطالعه (۵۰ درصد)، هوش مصنوعی عمدتاً برای تشخیص و طبقه‌بندی الگوهای غیرعادی فرآیند به کار گرفته شده است. این مطالعات که بخش عمده پژوهش‌های اولیه این حوزه را تشکیل می‌دهند، نشان می‌دهند که نخستین کاربردهای هوش مصنوعی در کنترل فرآیند آماری بیشتر با هدف کاهش وابستگی به تفسیر انسانی نمودارهای کنترل و افزایش توانایی تشخیص الگو توسعه یافته‌اند.

در مرحله بعد، ۸ مطالعه (۲۰ درصد) بر ویژگی‌های داده و روش‌های تحلیل تمرکز داشته‌اند. این مطالعات نشان می‌دهند که عملکرد مدل‌های هوش مصنوعی به‌طور مستقیم تحت تأثیر ماهیت داده‌های فرآیندی، از جمله چندمتغیره بودن، خودهمبستگی، عدم‌توازن داده‌ها و پیچیدگی ساختار اطلاعاتی قرار دارد. بنابراین، انتخاب روش هوش مصنوعی بدون توجه به ویژگی‌های داده نمی‌تواند تضمین‌کننده عملکرد مطلوب در پایش فرآیند باشد.

همچنین، ۶ مطالعه (۱۵ درصد) در سطح پایش هوشمند قرار گرفته‌اند که در آن‌ها هوش مصنوعی برای تشخیص ناهنجاری، پایش وضعیت فرآیند و تحلیل داده‌های واقعی یا پیچیده به کار رفته است. این روند نشان‌دهنده حرکت تدریجی حوزه از تشخیص صرف الگو به سمت ایجاد قابلیت‌های پیش‌بینانه در نظام کنترل فرآیند آماری است.

در نهایت، تنها ۶ مطالعه (۱۵ درصد) به سطح کنترل تطبیقی و تصمیم‌گیری نزدیک شده‌اند. این مطالعات نشان می‌دهند که در برخی پژوهش‌های جدید، هوش مصنوعی از یک ابزار تحلیل‌گر فراتر رفته و در تنظیم پارامترهای نمودار کنترل، سازگاری با تغییرات فرآیند و بهبود تصمیم‌گیری پایش نقش پیدا کرده است. با این حال، سهم محدود این مطالعات بیانگر آن است که بخش قابل توجهی از ادبیات موجود هنوز در سطح توسعه مدل باقی مانده و فاصله میان الگوریتم‌های هوشمند و استقرار یک نظام کنترل فرآیند آماری هوشمند وجود دارد.

تحلیل شکاف‌های مطالعات منتخب در جدول ۱۰ نیز این نتیجه را تأیید می‌کند. بیشترین محدودیت شناسایی‌شده مربوط به حوزه داده است؛ به‌طوری‌که ۲۶ مطالعه (۶۵ درصد) با چالش‌هایی مانند استفاده از داده‌های شبیه‌سازی‌شده، کمبود داده واقعی یا محدودیت داده آموزشی مواجه بوده‌اند. پس از آن، محدودیت‌های مرتبط با مدل و الگوریتم، شامل پیچیدگی محاسباتی، نیاز به تنظیم پارامترها و محدودیت تعمیم‌پذیری، در ۹ مطالعه (۵/۲۲ درصد) مشاهده شده است.

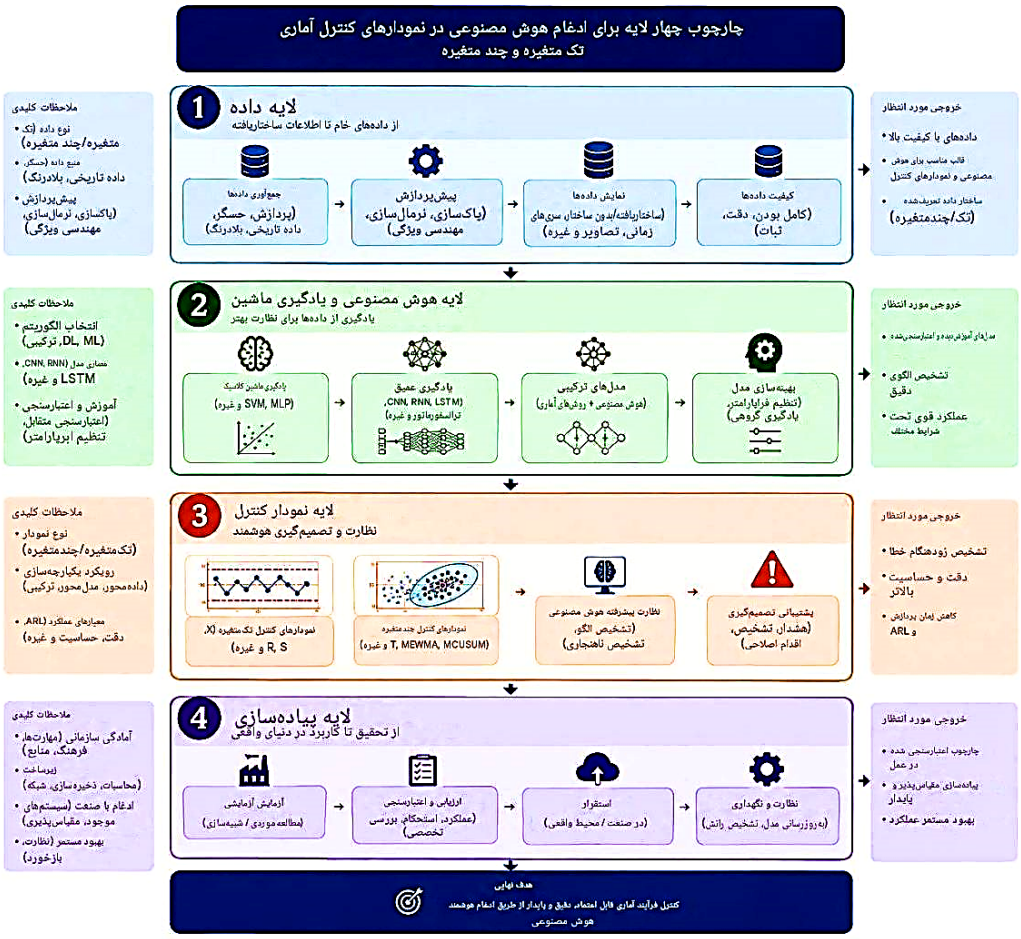
در مجموع، تحلیل کمی مطالعات منتخب نشان می‌دهد که مسیر توسعه این حوزه از هوشمندسازی تشخیص الگو آغاز شده و به سمت تحلیل داده، پایش هوشمند و کنترل تطبیقی حرکت کرده است؛ اما هنوز خلأهایی در زمینه زیرساخت استقرار، یکپارچگی سامانه‌ها و تبدیل خروجی مدل‌های هوشمند به تصمیم‌های عملیاتی وجود دارد. بر همین اساس، چارچوب پیشنهادی پژوهش حاضر با هدف پوشش همزمان ابعاد فنی، داده‌ای، کنترلی و سازمانی ارائه شده است.

چارچوب مفهومی پیشنهادی

بر اساس یافته‌های مطالعات بررسی‌شده، ادغام هوش مصنوعی با کنترل آماری فرایند را نمی‌توان صرفاً به جایگزینی روش‌های آماری سنتی با الگوریتم‌های یادگیری ماشین محدود کرد. این ادغام می‌تواند در مراحل مختلف چرخه پایش و کنترل فرایند، از آماده‌سازی و بازنمایی داده‌ها تا تشخیص الگو، تولید و تفسیر سیگنال‌های کنترل و پشتیبانی از تصمیم‌گیری، صورت گیرد. بر همین اساس، چارچوب مفهومی پیشنهادی این پژوهش، ادغام هوش مصنوعی و نمودارهای کنترل آماری را در چهار لایه اصلی شامل لایه داده، لایه هوش مصنوعی و یادگیری ماشین، لایه نمودار کنترل و لایه پیاده‌سازی سازمان‌دهی می‌کند. در لایه داده، داده‌های فرایندی، حسگرها و سوابق تاریخی پس از پاک‌سازی، نرمال‌سازی و استخراج ویژگی، به ساختاری مناسب برای تحلیل آماری و الگوریتم‌های هوش مصنوعی تبدیل می‌شوند. (Boaventura et al., 2022; Yeganeh et al., 2025; Atashgar & Adelian, 2023). در لایه هوش مصنوعی و یادگیری ماشین، روش‌هایی نظیر یادگیری ماشین کلاسیک، یادگیری عمیق و مدل‌های ترکیبی برای شناسایی الگوهای غیرعادی، طبقه‌بندی وضعیت فرایند، پیش‌بینی و بهبود عملکرد پایش به کار گرفته می‌شوند. (Cheng & Fu, 2024; Ruelas-Santoyo et al., 2024; Santoyo & et al., 2023; Chiu Salgado, 2020). در لایه نمودار کنترل، خروجی مدل‌های هوش مصنوعی با روش‌های

کنترل آماری یک‌متغیره یا چندمتغیره تلفیق شده و می‌تواند در انتخاب یا تنظیم نمودار کنترل، تشخیص سریع‌تر انحرافات، تفسیر سیگنال‌ها و کاهش خطاهای تشخیص نقش داشته باشد. در نهایت، لایه پیاده‌سازی بر تبدیل خروجی تحلیلی به تصمیم قابل استفاده در محیط واقعی، ارزیابی عملکرد، استقرار، پایش مستمر و بهبود مدل تمرکز دارد. (Atashgar & Boush, 2024; Zhang et al., 2019; Flores et al., 2021; Chiang et al., 2021). نکته کلیدی این چارچوب، در نظر گرفتن هوش مصنوعی به‌عنوان یک قابلیت مکمل و چندنقطه‌ای برای تقویت چرخه SPC است، نه صرفاً یک الگوریتم جایگزین برای روش‌های آماری. در این چارچوب، جریان اطلاعات از داده به مدل و از مدل به سیستم پایش و تصمیم‌گیری حرکت می‌کند و بازخورد حاصل از عملکرد فرایند و نتایج تصمیم‌گیری می‌تواند برای به‌روزرسانی داده‌ها، مدل‌ها و سازوکار پایش مورد استفاده قرار گیرد. بنابراین، چارچوب پیشنهادی تلاش می‌کند ارتباط میان کیفیت داده، انتخاب و آموزش مدل، سازوکار کنترل آماری و الزامات پیاده‌سازی را در یک ساختار یکپارچه نشان دهد. (Bekkum et al., 2021; Jüngling et al., 2022; Anjum et al., 2024;). برای نشان دادن کارکرد عینی و قابلیت اجرایی این چارچوب، می‌توان پایش فرآیند در صنعت فولاد را به‌عنوان یک سناریوی نمونه و کاربردی در نظر گرفت؛ حوزه‌ای که بر اساس تجربیات مستند پیشین، بهره‌گیری از داده‌های فرآیندی و مدل‌های داده‌محور در آن ارزیابی شده است .(Kano & Nakagawa, 2008) در این سناریو، داده‌های حسگرهای خط تولید در «لایه داده» گردآوری و پاک‌سازی می‌شوند؛ روابط پیچیده میان پارامترها در «لایه هوش مصنوعی» استخراج می‌گردد؛ خروجی مدل‌ها در «لایه نمودار کنترل» برای تشخیص انحرافات پنهان به کار می‌رود؛ و در نهایت در «لایه پیاده‌سازی»، هشدارهای سیستم به تصمیمات اصلاحی کیفی تبدیل می‌شوند تا چارچوب از حالت صرفاً مفهومی خارج گردد.شکل 2 نمای کلی این چارچوب مفهومی و ارتباط میان چهار لایه، نقاط ورود هوش مصنوعی به چرخه کنترل آماری فرایند، ملاحظات کلیدی هر لایه و خروجی مورد انتظار از هر مرحله را نشان می‌دهد.

شکل شماره 2- چارچوب مفهومی پیشنهادی برای کنترل فرآیند آماری هوشمند



نوآوری چارچوب پیشنهادی صرفاً در تفکیک لایه‌های فناورانه نیست، بلکه در تبیین ارتباط میان قابلیت‌های داده‌ای، روش‌های هوش مصنوعی و سازوکارهای کنترل فرآیند آماری است. برخلاف چارچوب‌های عمومی تحلیل داده که معمولاً بر چرخه جمع‌آوری داده، تحلیل و تصمیم‌گیری تمرکز دارند، چارچوب حاضر بر مسیر تبدیل داده‌های فرآیندی به اطلاعات قابل استفاده برای پایش، تشخیص انحراف و تصمیم‌گیری اصلاحی در محیط کنترل آماری تأکید دارد. همچنین، در این چارچوب نقش عوامل سازمانی و زیرساختی به‌عنوان پیش‌نیازهای استقرار پایدار سیستم‌های کنترل آماری مبتنی بر هوش مصنوعی در نظر گرفته شده است.

بحث و نتیجه‌گیری

بحث

هدف این پژوهش، مرور نظام‌مند و تحلیل انتقادی ادغام هوش مصنوعی با نمودارهای کنترل آماری تک‌متغیره و چندمتغیره بود. یافته‌های پژوهش نشان داد که این حوزه در سال‌های اخیر با رشد قابل توجهی مواجه شده است؛ به‌گونه‌ای که بخش مهمی از مطالعات منتخب در سال‌های اخیر منتشر شده‌اند. این روند نشان‌دهنده افزایش توجه پژوهشگران به ظرفیت‌های هوش مصنوعی برای ارتقای قابلیت‌های پایش، تشخیص و پیش‌بینی در سیستم‌های کنترل فرآیند آماری است. در ادامه، یافته‌های پژوهش در مقایسه با مطالعات پیشین مورد بحث قرار می‌گیرد.

یافته‌های پژوهش در حوزه مدل‌های ترکیبی نشان داد که برخی مطالعات با ترکیب روش‌های آماری و هوش مصنوعی، توانسته‌اند قابلیت تشخیص انحرافات کوچک و پایش فرآیند را در شرایط آزمایشی بهبود دهند. برای مثال، مدل‌های ترکیبی مبتنی بر تحلیل مؤلفه‌های اصلی، نمای هموار موزون نمایی چندمتغیره و مجموع تجمعی چندمتغیره، در مطالعات منتخب عملکرد مطلوبی نسبت به روش‌های مبنا گزارش کرده‌اند. این یافته با پژوهش‌های پیشین که بر مزیت رویکردهای ترکیبی در افزایش حساسیت تشخیص تأکید داشته‌اند، هم‌سو است (Zaman et al., 2022; Yang et al., 2023). با این حال، به دلیل تفاوت میان مطالعات از نظر نوع داده، شرایط شبیه‌سازی، معیارهای ارزیابی و ساختار فرآیند، این نتایج باید در چارچوب همان شرایط آزمایش تفسیر شوند و نمی‌توان آن‌ها را به‌عنوان برتری مطلق یک روش نسبت به سایر روش‌ها در نظر گرفت.

در حوزه روش‌های غیرپارامتری، یافته‌ها نشان داد که این رویکردها در شرایطی مانند داده‌های غیرنرمال، چوله یا فرآیندهایی با مفروضات آماری محدود، همچنان نقش مهمی در کنترل فرآیند دارند. مطالعات منتخب نشان دادند که روش‌های غیرپارامتری می‌توانند بدون نیاز به فرض نرمال بودن داده‌ها، قابلیت تشخیص مناسبی ارائه دهند و در برخی شرایط، جایگزین مناسبی برای روش‌های کلاسیک باشند. این یافته با پژوهش‌های پیشین که بر اهمیت روش‌های مقاوم در مواجهه با داده‌های غیرنرمال تأکید کرده‌اند، هم‌خوانی دارد.

در حوزه ادغام هوش مصنوعی با نمودارهای کنترل، یافته‌ها نشان داد که معماری‌های یادگیری عمیق و مدل‌های ترکیبی در برخی مطالعات توانسته‌اند قابلیت مناسبی در تشخیص الگوهای انحراف نشان دهند. به‌عنوان نمونه، معماری‌های ترکیبی شبکه‌های کانولوشنی و حافظه کوتاه‌مدت بلندمدت در مطالعات منتخب برای تحلیل هم‌زمان ویژگی‌های مکانی و زمانی داده‌های فرآیندی استفاده شده‌اند و عملکرد مطلوبی در شرایط مورد بررسی همان مطالعات گزارش کرده‌اند. با این حال، به دلیل تفاوت در ساختار داده‌ها، تعداد الگوهای مورد بررسی، روش اعتبارسنجی و معیارهای ارزیابی، مقایسه مستقیم دقت گزارش‌شده میان مطالعات مختلف امکان‌پذیر نیست.

همچنین، مطالعات مربوط به روش‌های یادگیری ماشین نشان دادند که مدل‌هایی مانند شبکه‌های عصبی، ماشین بردار پشتیبان و روش‌های ترکیبی، ظرفیت مناسبی برای تشخیص الگو، استخراج ویژگی و پایش فرآیند دارند. با این وجود، انتخاب روش مناسب باید بر اساس ماهیت داده، هدف پایش و الزامات کاربردی فرآیند انجام شود و نمی‌توان یک الگوریتم مشخص را به‌عنوان بهترین روش عمومی برای همه شرایط معرفی کرد.

در حوزه کاربردهای صنعتی، یافته‌ها نشان داد که رویکردهای مبتنی بر هوش مصنوعی در حوزه‌هایی مانند داروسازی، تجهیزات پزشکی، خودروسازی و الکترونیک مورد استفاده قرار گرفته‌اند. با این حال، بررسی مطالعات نشان داد که بخش قابل توجهی از پژوهش‌ها همچنان در مرحله آزمایشگاهی یا شبیه‌سازی قرار دارند و فاصله میان توسعه مدل و استقرار پایدار صنعتی همچنان یکی از چالش‌های اصلی این حوزه است.

در مجموع، یافته‌های پژوهش نشان می‌دهد که هوش مصنوعی در همه شرایط جایگزین روش‌های کلاسیک نیست. در شرایطی مانند داده‌های کم‌حجم، محیط‌های کم‌منبع، نیاز به تفسیرپذیری بالا یا فرآیندهای دارای تغییرات گسترده، روش‌های کلاسیک و غیرپارامتری

همچنان می‌توانند عملکرد قابل قبولی ارائه دهند. بنابراین، انتخاب روش مناسب باید بر اساس ویژگی‌های داده، پیچیدگی فرآیند و هدف پایش انجام شود.

نتیجه‌گیری

این پژوهش با مرور نظام‌مند ۴۰ مقاله منتخب، به تحلیل و مقایسه رویکردهای مختلف ادغام هوش مصنوعی با نمودارهای کنترل آماری تک‌متغیره و چندمتغیره پرداخت. یافته‌ها نشان داد که نمودارهای کنترل کلاسیک همچنان به دلیل سادگی، تفسیرپذیری و قابلیت اعتماد در بسیاری از کاربردها مورد استفاده قرار می‌گیرند؛ با این حال، در مواجهه با داده‌های پیچیده، چندبعدی و دارای الگوهای غیرخطی، نیاز به رویکردهای هوشمند افزایش یافته است.

نتایج مرور نشان داد که مسیر توسعه این حوزه از استفاده اولیه هوش مصنوعی برای تشخیص و طبقه‌بندی الگوهای نمودارهای کنترل آغاز شده و به سمت تحلیل داده، پایش هوشمند، پیش‌بینی و کنترل تطبیقی حرکت کرده است. در این مسیر، روش‌های یادگیری ماشین و یادگیری عمیق توانسته‌اند قابلیت‌های جدیدی مانند استخراج خودکار ویژگی، تشخیص الگوهای پیچیده و سازگاری با شرایط متغیر فرآیند را فراهم کنند.

یکی از یافته‌های کلیدی این مرور، اهمیت تطابق میان روش هوش مصنوعی و ماهیت داده فرآیند است. معماری‌های مختلف هوش مصنوعی برای انواع متفاوتی از داده طراحی شده‌اند و انتخاب روش مناسب باید بر اساس ساختار داده، هدف پایش و محدودیت‌های عملیاتی انجام شود. بنابراین، ارزیابی عملکرد روش‌ها بدون توجه به زمینه کاربرد می‌تواند منجر به برداشت نادرست از قابلیت واقعی آن‌ها شود.

با وجود مزایای گزارش‌شده، یافته‌ها نشان داد که ادغام هوش مصنوعی با کنترل فرآیند آماری همچنان با چالش‌هایی مانند نیاز به داده‌های باکیفیت، تفسیرپذیری مدل‌ها، هزینه‌های محاسباتی، محدودیت‌های استقرار بلادرنگ و پایداری مدل در برابر تغییرات فرآیند مواجه است. همچنین، بخش قابل توجهی از مطالعات موجود بیشتر بر توسعه الگوریتم تمرکز داشته‌اند و ابعاد مرتبط با زیرساخت، پیاده‌سازی سازمانی و تحلیل اقتصادی کمتر مورد توجه قرار گرفته است.

در نهایت، این پژوهش با تجمیع یافته‌ها، یک چارچوب مفهومی چهارلایه متشکل از لایه داده (آماده‌سازی و مهندسی ویژگی)، لایه هوش مصنوعی (مدل‌سازی و شناسایی الگو)،

لایه نمودار کنترل (تلفیق آماری و پایش فرآیند) و لایه پیاده‌سازی (استقرار، تصمیم‌گیری و پایش مستمر) پیشنهاد داد که نقشه راهی ساختاریافته برای پژوهش‌های آتی و پیاده‌سازی‌های صنعتی فراهم می‌سازد.

محدودیت‌های پژوهش

پژوهش حاضر با محدودیت‌هایی مواجه بوده است که توجه به آن‌ها برای تفسیر یافته‌ها ضروری است. نخست، این پژوهش به مقالات نمایه‌شده در پایگاه‌های Scopus و Web of Science در بازه زمانی مورد بررسی محدود شده است و از ابزار Consensus صرفاً به‌عنوان ابزار مکمل برای شناسایی مقالات بالقوه و افزایش حساسیت جست‌وجو استفاده شد. بنابراین، ممکن است برخی پژوهش‌های ارزشمند منتشرشده در سایر منابع یا به زبان‌های دیگر در این مرور لحاظ نشده باشند. دوم، تفاوت میان مطالعات از نظر شرایط داده، معیارهای ارزیابی عملکرد، نحوه اعتبارسنجی مدل‌ها و میزان گزارش جزئیات داده‌ها، موجب ناهمگونی مطالعات شده و مقایسه مستقیم نتایج را با دشواری مواجه می‌سازد. سوم، بخش قابل توجهی از مطالعات مرورشده به داده‌های شبیه‌سازی‌شده متکی بوده‌اند و تعداد پژوهش‌های مبتنی بر داده‌های واقعی صنعتی محدود است. چهارم، فقدان تحلیل‌های اقتصادی و ارزیابی بازگشت سرمایه در مطالعات موجود، امکان قضاوت جامع درباره صرفه اقتصادی پیاده‌سازی این رویکردها را محدود می‌کند.

پیشنهادهای پژوهشی

بر اساس یافته‌های پژوهش و شکاف‌های شناسایی‌شده، پیشنهادهای زیر برای پژوهش‌های آتی ارائه می‌شود:

توسعه مدل‌های توضیح‌پذیر: طراحی الگوریتم‌هایی که هم‌زمان دقت بالایی داشته باشند و قابلیت تفسیرپذیری برای صنایع حساس (نظیر داروسازی و تجهیزات پزشکی) را فراهم کنند. این امر می‌تواند از طریق توسعه مدل‌های هوش مصنوعی توضیح‌پذیر و ترکیب آن‌ها با روش‌های آماری کلاسیک صورت گیرد.

پایداری بلندمدت و مقابله با رانش: بررسی روش‌های مقابله با رانش مدل و تغییر توزیع داده در محیط‌های صنعتی پویا و ارائه راهکارهایی برای آموزش مجدد به‌هنگام مدل‌ها. این امر به‌ویژه در صنایعی که داده‌های آن‌ها در طول زمان تغییر می‌کند، ضروری است.

تحلیل اقتصادی پیاده‌سازی: انجام پژوهش‌هایی که به تحلیل هزینه‌های جمع‌آوری داده، آموزش مدل‌ها، زیرساخت‌های محاسباتی و بازگشت سرمایه سیستم‌های کنترل فرآیند آماری هوشمند بپردازند تا امکان قضاوت درباره مقرون‌به‌صرفه بودن این رویکردها برای صنایع مختلف فراهم شود.

مطالعات موردی در صنایع متنوع: انجام پژوهش‌های تجربی در صنایع مختلف (مانند انرژی، حمل‌ونقل هوشمند و کشاورزی دقیق) برای اعتبارسنجی و بهبود چارچوب پیشنهادی و شناسایی چالش‌های خاص هر صنعت.

مقایسه نظام‌مند هوش مصنوعی و روش‌های غیرپارامتری: انجام پژوهش‌های مقایسه‌ای با شرایط کنترل‌شده برای تعیین دقیق مرزهای عملکردی هوش مصنوعی در برابر روش‌های غیرپارامتری و ارائه راهنمای انتخاب روش مناسب بر اساس ویژگی‌های داده و فرآیند.

ادغام با اینترنت‌اشیا و صنعت : 40 پژوهش در مورد چگونگی ادغام سیستم‌های کنترل فرآیند آماری هوشمند با زیرساخت‌های دیجیتال کارخانه‌های هوشمند و ارائه راهکارهای سبک‌وزن برای اجرای بلادرنگ در خطوط تولید.

تعارض منافع

نویسندگان هیچ گونه تعارض منافعی ندارند

سپاسگزاری

نویسندگان از کلیه پژوهشگران و متخصصانی که در تهیه و تدوین این مقاله مساعدت نموده‌اند، صمیمانه سپاسگزارند .

ORCID

Karim Atashgar https://orcid.org/0000-0003-3738-2703
Mahsa Akbari https://orcid.org/0000-0001-9603-523X
Reza Ahmadi* https://orcid.org/0000-0002-1721-2523

آماده انتشار

References

1. Ahmadi-Javid, A., & Ebadi, M. (2020). Economic design of memory-type control charts: The fallacy of the formula proposed by Lorenzen and Vance (1986). *Computational Statistics,* 36, 661–690. https://doi.org/10.1080/03610918.2018.1520872
2. Anjum, A., Hrairi, M., Shaikh, A. A., Yatim, N., & Ali, M. (2024). Integrating AI and statistical methods for enhancing civil structural practices. Frattura ed Integrità Strutturale. https://doi.org/10.3221/IGF-ESIS.71.12

استناد به این مقاله: نام خانوادگی نویسنده اول، نام. (سال). عنوان مقاله. *عنوان نشریه (ایتالیک)*، سال(شماره)، ص آغاز–ص پایان.

Name of Journal is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License.

3. Atashgar, K., & Abbassi, L. (2021). A new model to monitor very small effects of a polynomial profile. *International Journal of Quality & Reliability Management, 38*(4), 1023–1043. https://doi.org/10.1108/IJQRM-12-2019-0375
4. Atashgar, K., & Adelian, F. (2023). Multivariate statistical process control using wavelet approach. *Journal of Quality Engineering and Production Optimization, 8*(1), 57-68. https://doi.org/10.22070/jqepo.2023.16027.1230
5. Atashgar, K., & Boush, M. (2024). A convolutional neural network to identify the change point of a multistage process profile with cascade property. *International Journal of Quality & Reliability Management, 41*(9), 2232–2248. https://doi.org/10.1108/IJQRM-03-2023-0111
6. Atashgar, K., Saeedian, F., & NamAvar, Z. (2021). Monitoring combined multivariate process approaching hybrid kernel-CUSUM analysis. *Quality and Reliability Engineering International, 37*(8), 3600–3616. https://doi.org/10.1002/qre.2925
7. Bersimis, S., Psarakis, S., & Panaretos, J. (2007). Multivariate statistical process control charts: An overview. *Quality and Reliability Engineering International, 23*(5), 517–543. https://doi.org/10.1002/qre.829
8. Boaventura, L. L., Ferreira, P. H., & Fiaccone, R. L. (2022). On flexible Statistical Process Control with Artificial Intelligence: Classification control charts. *Expert Systems with Applications, 194*, 116492. https://doi.org/10.1016/j.eswa.2021.116492
9. Boaventura, L. L., Fiaccone, R. L., & Ferreira, P. H. (2024). Prediction control charts: a new and flexible artificial intelligence-based statistical process control approach. Annals of Data Science, 11(1), 273-300 https://doi.org/10.1007/s40745-022-00441-5
10. Capezza, C., Capizzi, G., Centofanti, F., Lepore, A., & Palumbo, B. (2025). An adaptive multivariate functional EWMA control chart. *Journal of Quality Technology*, 57(1), 1-15 https://doi.org/10.1080/00224065.2024.2383674
11. Carvalho, T. P., Soares, F. A. A. M. N., Vita, R., Francisco, R. P., Basto, J. P., & Alcalá, S. G. S. (2019). A systematic literature review of machine learning methods applied to predictive maintenance. *Computers & Industrial Engineering, 137*, 106024. https://doi.org/10.1016/j.cie.2019.106024
12. Chang, S., & Ghafariasl, P. (2025). A review of artificial intelligence impacting statistical process monitoring and future directions. arXiv. https://doi.org/10.48550/arXiv.2503.01858

13. Cheng, C. S., Chen, P. W., Hsieh, Y. C., & Wu, Y. T. (2023). Multivariate process control chart pattern classification using deep CNNs. Mathematics. https://doi.org/10.3390/math11153291
14. Chiang, J.-Y., Tsai, T.-R., Pham, H., & Yu, K. (2021). A new multivariate control chart for monitoring the quality of a process with the aid of auxiliary information. Journal of Statistical Computation and Simulation, 92(3), 645–666. https://doi.org/10.1080/00949655.2021.1969571
15. Chiu, J. E., & Fu, S. Z. (2024). On-line recognition of mixture control chart patterns using hybrid CNN and LSTM for auto-correlated processes. Computers & Industrial Engineering, 198, 110674. https://doi.org/10.1016/j.cie.2024.110674
16. Ebrahimzadeh, A., & Ranaee, V. (2010). Control chart pattern recognition using an optimized neural network and efficient features. *ISA Transactions, 49*(3), 387–393. https://doi.org/10.1016/j.cie.2024.110674
17. Flores, M., Fernández-Casal, R., Naya, S., & Tarrío-Saavedra, J. (2021). Statistical quality control with the qcr package.
18. Gama, J., Žliobaitė, I., Bifet, A., Pechenizkiy, M., & Bouchachia, A. (2014). A survey on concept drift adaptation. *ACM Computing Surveys*, 46(4), 44. https://doi.org/10.1145/2523813
19. Gauri, S. K., & Chakraborty, S. (2009). Recognition of control chart patterns using improved selection of features. *Computers & Industrial Engineering, 56*(4), 1577–1588. https://doi.org/10.1016/j.cie.2008.10.006
20. Ge, Z., Song, Z., & Gao, F. (2013). Review of recent research on data-based process monitoring. *Industrial & Engineering Chemistry Research, 52*(10), 3543–3562. https://doi.org/10.1021/ie302069q
21. Guh, R. S., & Hsieh, Y. C. (1999). A neural network approach for automatic control chart pattern recognition. *Computers & Industrial Engineering, 36*(1), 97–108. https://doi.org/10.1016/S0360-8352(98)00124-2
22. Guh, R. S., & Shiue, Y. R. (2005). On-line identification of control chart patterns using self-organizing approaches. *International Journal of Production Research, 43*(6), 1225–1254. https://doi.org/10.1080/00207540420002688 4
23. Hachicha, W., & Ghorbel, A. (2012). A survey of control-chart pattern-recognition literature (1991–2010) based on a new conceptual classification scheme. *Computers & Industrial Engineering, 63*(1), 204–222. https://doi.org/10.1016/j.cie.2012.03.002

24. Haq, A., & Khoo, M. (2022). Enhanced memory-type charts for monitoring the ratio of two normal random variables. *Communications in Statistics - Simulation and Computation,* 53, 2898–2916. https://doi.org/10.1080/03610918.2022.2092142
25. Hawkins, D. M., & Maboudou-Tchao, E. M. (2008). Multivariate exponentially weighted moving average control chart. *Technometrics, 50*(2), 199–209. https://doi.org/10.1198/004017008000000055
26. Hernández-Zamudio, G., Tercero-Gómez, V., Conover, W. J., Benavides-Vázquez, L., & Beruvides, M. (2024). On the power and robustness of phase I nonparametric Shewhart-type charts using sequential normal scores. *Journal of Industrial and Production Engineering, 41*(3), 276-305.https://doi.org/10.1080/21681015.2023.2292114
27. Hu, X., Sun, G., Xie, F., & Tang, A. (2022). Monitoring the ratio of two normal variables based on triple exponentially weighted moving average control charts with fixed and variable sampling intervals. *Symmetry, 14*(6), 1236.https://doi.org/10.3390/sym14061236
28. Hwarng, H. B., & Hubele, N. F. (1993). Back-propagation pattern recognizers for control charts: Methodology and performance. *Computers & Industrial Engineering, 24*(2), 219–235. https://doi.org/10.1016/0360-8352(93)90010-U
29. Jiang, P., Liu, D., & Zeng, Z. (2009). Recognizing control chart patterns with neural network and numerical fitting. *Journal of Intelligent Manufacturing, 20*, 625–635. https://doi.org/10.1007/s10845-008-0152-Y
30. Jüngling, S., Peraic, M., & Zhu, C. (2022). Using the Strategy Design Pattern for Hybrid AI System Design. In AAAI *Spring Symposium*: MAKE. https://ceur-ws.org/Vol-3121/paper5.pdf
31. Kano, M., & Nakagawa, Y. (2008). Data-based process monitoring, process control, and quality improvement: Recent developments and applications in steel industry. *Computers & Chemical Engineering, 32*(1–2), 12–24. https://doi.org/10.1016/j.compchemeng.2007.07.005
32. Kitchenham, B., Brereton, O. P., Budgen, D., Turner, M., Bailey, J., & Linkman, S. (2009). Systematic literature reviews in software engineering–a systematic literature review. Information and software technology, 51(1), 7-15. https://doi.org/10.1016/j.infsof.2008.09.009
33. Kourti, T., & MacGregor, J. F. (1996). Process analysis, monitoring and diagnosis, using multivariate projection methods. *Chemometrics and Intelligent Laboratory Systems, 28*(1), 3–21. https://doi.org/10.1016/0169-7439(95)00061-5

34. Kusiak, A. (2018). Smart manufacturing. *International Journal of Production Research, 56*(1–2), 508–517. https://doi.org/10.1080/00207543.2017.1351644
35. Lee, J., Kao, H. A., & Yang, S. (2014). Service innovation and smart analytics for Industry 4.0 and big data environment. *Procedia CIRP, 16*, 3–8.https://doi.org/10.1016/j.procir.2014.02.001
36. Lei, Y., Li, N., Guo, L., Li, N., Yan, T., & Lin, J. (2018). Machinery health prognostics: A systematic review from data acquisition to RUL prediction. *Mechanical Systems and Signal Processing, 104*, 799–834. https://doi.org/10.1016/j.ymssp.2017.11.016
37. Lowry, C. A., & Montgomery, D. C. (1995). A review of multivariate control charts. *IIE Transactions, 27*(6), 800–810. https://doi.org/10.1080/07408179508936797
38. Megahed, F. M., Ferris, J. A., Jones-Farmer, L. A., & others. (2023). How generative AI models such as ChatGPT can be (mis)used in SPC practice, education, and research: An exploratory study. *Quality Engineering*. https://doi.org/10.1080/08982112.2023.2206479
39. Montgomery, D. C. (2020). *Introduction to Statistical Quality Control* (8th ed.). Wiley.
40. DT, P. (1992). Control chart pattern recognition using neural networks. *Journal of Systems Engineering*, *2*, 256-262.
41. Psarakis, S. (2015). Adaptive control charts: Recent developments and extensions. *Quality and Reliability Engineering International*, 31(7), 1265–1281. https://doi.org/10.1002/qre.1850
42. Qin, S. J. (2003). Statistical process monitoring: Basics and beyond. *Journal of Chemometrics, 17*(8–9), 480–502. https://doi.org/10.1002/cem.800
43. Qin, S. J. (2012). Survey on data-driven industrial process monitoring and diagnosis. *Annual Reviews in Control, 36*(2), 220–234. https://doi.org/10.1016/j.arcontrol.2012.09.004
44. Raich, A., & Cinar, A. (1996). Statistical process monitoring and disturbance diagnosis in multivariable continuous processes. *AIChE Journal, 42*(4), 995–1009. https://doi.org/10.1002/aic.690420410
45. Ruelas-Santoyo, E. A., Figueroa-Fernández, V., Tapia-Esquivias, M., Pantoja-Pacheco, Y. V., Bravo-Santibáñez, E., & Cruz-Salgado, J. (2024). Monitoring and interpretation of process variability generated from the integration of the multivariate cumulative sum control chart and artificial intelligence. *Applied Sciences,* 14(21), 9705. https://doi.org/10.3390/app14219705
46. Santoyo, E. A. R., & Salgado, J. C. (2020). Statistical control of multivariant processes through the artificial neural network multilayer

perceptron and the MEWMA graphic analysis. IEEE Latin America Transactions, 18(06), 1041-1048.
https://doi.org/10.1109/TLA.2020.9099681
47. Shah, M., & Desai, S. (2022). Nonparametric control charts to jointly monitor scale and location parameters. Journal of Scientific Research, 66(4).
48. Smith, A. E. (1994). X-bar and R control chart interpretation using neural computing. *International Journal of Production Research, 32*(2), 309–320.
https://doi.org/10.1080/00207549408956935
49. Tao, F., Zhang, M., Liu, Y., & Nee, A. Y. C. (2019). Digital twin driven prognostics and health management for complex equipment. *CIRP Annals, 68*(1), 169–172.
https://doi.org/10.1016/j.cirp.2019.04.055
50. Tran, P. H., Nadi, A. A., Nguyen, T., Tran, K. D., & Tran, K. (2021). Application of machine learning in statistical process control charts: A survey and perspective. Springer Series in Reliability Engineering. https://doi.org/10.1007/978-3-030-83819-5_2
51. Tranfield, D., Denyer, D., & Smart, P. (2003). Towards a methodology for developing evidence-informed management knowledge by means of systematic review. *British Journal of Management, 14*(3), 207–222.
https://doi.org/10.1111/1467-8551.00375
52. van Bekkum, M., de Boer, M., van Harmelen, F., Meyer-Vitali, A., & ten Teije, A. (2021). Modular design patterns for hybrid learning and reasoning systems. Applied Intelligence, 51, 6528–6546.
https://doi.org/10.1007/s10489-021-02394-3
53. Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is all you need. *Advances in Neural Information Processing Systems, 30*.
https://doi.org/10.48550/arXiv.1706.03762
54. Wang, J., Ma, Y., Zhang, L., Gao, R. X., & Wu, D. (2018). Deep learning for smart manufacturing: Methods and applications. *Journal of Manufacturing Systems, 48*, 144–156.
https://doi.org/10.1016/j.jmsy.2018.01.003
55. Woodall, W. H. (2000). Controversies and contradictions in statistical process control. *Journal of Quality Technology, 32*(4), 341–350.
https://doi.org/10.1080/00224065.2000.11980010
56. Wuest, T., Weimer, D., Irgens, C., & Thoben, K. D. (2016). Machine learning in manufacturing: Advantages, challenges, and applications. *Production & Manufacturing Research, 4*(1), 23–45.
https://doi.org/10.1080/21693277.2016.1192517

57. Xie, X., & Qiu, P. (2023). A general framework for robust monitoring of multivariate correlated processes. Technometrics, 66(1), 40–54. https://doi.org/10.1080/00401706.2023.2224411
58. Yang, S. F., Yeh, A., & Chou, C. C. (2023). A phase II multivariate EWMA chart for monitoring multi-dimensional ratios. Computers & Industrial Engineering, 183, 109490. https://doi.org/10.1016/j.cie.2023.109490
59. Yeganeh, A., Hu, X., Shongwe, S. C., & Koning, F. F. (2025). Using the attention layer mechanism in construction of a novel ratio control chart: An application to Ethereum price prediction and automated trading strategy. *Engineering Applications of Artificial Intelligence, 141*, 109652. https://doi.org/10.1016/j.engappai.2024.109652
60. Yeganeh, A., Shadman, A. (2021). Using evolutionary artificial neural networks in monitoring binary and polytomous logistic profiles. *Journal of Manufacturing Systems, 61*, 546–561. https://doi.org/10.1016/j.jmsy.2021.10.001
61. Yeganeh, A., Shongwe, S. C. (2023). A novel application of statistical process control charts in financial market surveillance with the idea of profile monitoring. *PLOS ONE, 18*(7), e0288627. https://doi.org/10.1371/journal.pone.0288627
62. Yin, S., Ding, S. X., Xie, X., & Luo, H. (2014). A review on basic data-driven approaches for industrial process monitoring. *IEEE Transactions on Industrial Electronics, 61*(11), 6418–6428. https://doi.org/10.1109/TIE.2014.2306025
63. Yin, S., Li, X., Gao, H., & Kaynak, O. (2015). Data-based techniques focused on modern industry: An overview. *IEEE Transactions on Industrial Electronics, 62*(1), 657–667. https://doi.org/10.1109/TIE.2014.2322594
64. Zaman, B., Lee, M. H., Riaz, M., Abujiya, M. R., Mehmood, R., & Abbas, N. (2022). Adaptive memory control charts constructed on GLRT. Arabian Journal for Science and Engineering, 47, 15049–15081. https://doi.org/10.1007/s13369-022-06803-8
65. Zan, T., Jia, X., Guo, X., Wang, M., Gao, X., & Gao, P. (2025). Research on variable-length control chart pattern recognition based on sliding window method and SECNN-BiLSTM. *Scientific Reports, 15*, 5921. https://doi.org/10.1038/s41598-025-86849-4
66. Zhang, W., Yang, D., & Wang, H. (2019). Data-driven methods for predictive maintenance of industrial equipment: A survey. *IEEE Systems Journal, 13*(3), 2213–2227. https://doi.org/10.1109/JSYST.2019.2905565

67. Zhao, R., Yan, R., Chen, Z., Mao, K., Wang, P., & Gao, R. X. (2019). Deep learning and its applications to machine health monitoring. *Mechanical Systems and Signal Processing, 115*, 213–237. https://doi.org/10.1016/j.ymssp.2018.05.050
68. Zhou, B., et al. (2025). Machine Learning Control Charts for Monitoring Spatio-Temporal Data Streams. *Quality and Reliability Engineering International.* https://doi.org/10.1002/qre.3809
69. Zuo, L., He, Z., & Zhang, M. (2020). An EWMA and region growing based control chart for monitoring image data. *Quality Technology & Quantitative Management, 17*(4), 470–485. https://doi.org/10.1080/16843703.2019.1679260
70. Zwetsloot, I. M., Jones-Farmer, L. A., & Woodall, W. H. (2023). Monitoring univariate processes using control charts: Some practical issues and advice. *Quality Engineering*. https://doi.org/10.1080/08982112.2023.2238049

آماده انتشار