

A Machine Learning-based Control Chart for Monitoring the Dispersion of High-Dimensional Data Streams in Phase II

Mir Milad Ghazvini¹ , Ali Salmasnia^{2,*} 

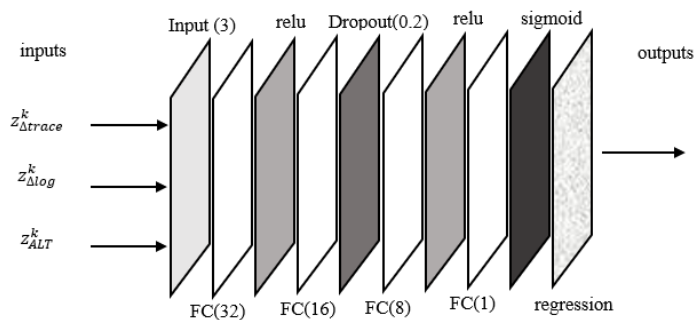
¹ Ph.D. Student, Faculty of Industrial Engineering, University of Eyvanekey, Eyvanekey, Iran

² Associate Professor, Faculty of Engineering, University of Qom, Qom, Iran

HIGHLIGHTS

- Monitor the dispersion of high-dimensional processes using a neural network
- Study the effect of sensitizing rules on run length properties.
- Usability when statistical assumptions are violated

GRAPHICAL ABSTRACT



ARTICLE INFO

Article history:

Article Type: Research paper

Received: 18 July 2025

Revised: 17 August 2025

Accepted: 3 September 2025

Available online: 3 September 2025

*Correspondence:

a.salmasnia@qom.ac.ir

How to cite this article:

Ghazvini, M. M., Salmasnia, A. (2026). A Machine learning-based control chart for monitoring the dispersion of high-dimensional data streams in phase II. *System Engineering and Productivity*, 6 (1), 163-191.

Keywords:

Dispersion monitoring

High-dimensional process

Neural network-based control chart

Regularization

Sensitizing rule

Random removal layer

ABSTRACT

This fully connected neural network-based control chart is developed for monitoring the dispersion of multivariate processes with two important features: (1) the ability to be used for monitoring the dispersion of processes with high-dimensional data streams, and (2) the absence of the need to establish restrictive statistical assumptions, such as normality of the quality characteristics under study and the independence of observations in the samples taken. An important challenge that we usually face in training neural networks is overfitting or generalization failure. In this study, two tools of dropout layer and weight regularization are used in network design to face the mentioned challenge. In addition, in order to better train the neural network and unlike most control charts based on learning tools that use a two-class pattern of zero and one as target values, in this study the target values are determined based on the size and number of shifted components, so that as the shift size and the number of shifted components increase, the target values also increase. Next, in order to increase the power of the developed control chart in detecting disturbances in the covariance matrix elements, an improved version is presented with the help of two sensitizing rules 2 out of 3 and 4 out of 5. The performance of the proposed approaches is compared with two control charts ATL and RPLR using a numerical example. The results show that the approach equipped with sensitizing rules performs better than the competing charts in terms of two indices ARL and SDRL.

1. Introduction

In today's competitive environment, manufacturers and service providers are under pressure to monitor a vast number of quality characteristics to ensure customer satisfaction. Concurrently, technological advancements—particularly in sensor technologies—have made it possible to access and store large volumes of data streams, which include numerous variables that influence the quality of products and services. However, due to economic and time constraints, it is often not feasible to collect samples that are as large as the number of quality characteristics. Consequently, the monitoring of high-dimensional processes is a growing challenge for quality professionals (Saemian et al., 2022; Safikhani et al., 2023; Jafari et al., 2023; Amiri et al., 2023; Mallikarjun et al., 2024).

An increase in process dispersion indicates a decline in quality. Consequently, the primary objective of dispersion monitoring is the timely detection of incremental shifts in both the diagonal and off-diagonal components of the covariance matrix. In this regard, Abdella et al. in 2019 (Abdella et al., 2019) developed an adaptive variable selection-based control chart, known as the adaptive Lasso threshold chart, to monitor changes in the covariance matrix. Fan et al. in 2021 (Fan et al., 2021) presented an eigenvalue-based control chart for monitoring the dispersion matrix of high-dimensional processes in Phase I. Their approach is based on comparing the eigenvalues of the sample and target covariance matrices to detect an in-control process.

Adegoke et al. in 2022 (Adegoke et al., 2022) investigated the performance of multivariate coefficient of variation control charts under data constraints. They proposed two one-way control charts based on the Lasso statistic and shrinkage estimation, which they evaluated using data from a carbon fiber tube production process. Finally, Salmasnia et al. in 2025 (Salmasnia et al., 2025a, 2025b) developed a double-sampling approach using the adaptive Lasso threshold statistic; this method detects sustained disturbances more quickly and its sensitivity improves as the problem dimension increases.

In light of the identified research gaps, this paper addresses two primary challenges: (1) the reliance on restrictive statistical assumptions, such as the normality of quality characteristics and the independence of observations, and (2) the effective monitoring of dispersion in high-dimensional data streams. To accomplish this, a high-power artificial neural network-based control chart is developed to detect deviations in the components of the covariance matrix. The proposed model utilizes a fully connected neural network, incorporating both dropout layer and weight regularization to mitigate overfitting. Finally, the control chart's power is enhanced through the integration of two sensitizing rules called 2 out of 3 and 4 out of 5.

2. Methodology

In this study, feature engineering is used to create new inputs for the neural network, allowing it to better identify subtle patterns in the data. The goal is to monitor the dispersion of high-dimensional processes, and as such, the features are carefully selected to capture changes in process variability. Three main features are used, with the first being Δtrace . This feature is based on the difference between the traces of two matrices: the product of the true precision matrix and the sample covariance matrix, and the product of the estimated precision matrix and the sample covariance matrix. The second input for the neural network is the difference in the logarithm of the determinant between the sample-based estimated precision matrix and the in-control precision matrix. Finally, the third feature used as a neural network input is the adaptive Lasso threshold statistic, as detailed by Abdullah et al. (2019). This statistic effectively quantifies the difference between the sample covariance matrix and the in-control covariance matrix, presenting it in a scalar format.

Data scaling is crucial for optimizing the performance of deep learning models. In this study, to enhance the estimation accuracy of the neural network, the three defined features were normalized using the Z-Score method. This technique transforms the data so that it has a mean of zero and a standard deviation of one, which can significantly improve model convergence and performance. The input layer of the proposed network receives the normalized values of the three features. The network architecture then consists of four fully connected layers:

- The first hidden layer has 32 neurons, which transform the inputs into a higher-dimensional space.
- The second hidden layer has 16 neurons, which reduce the dimensionality and focus on the most important features.
- The third fully connected layer contains 8 neurons, gradually transforming the extracted features into a lower-dimensional space.
- The final layer is a single neuron that produces the final regression output.

In the proposed network, a dropout layer with a rate of 0.2 is placed between two fully connected layers with 16 and 8 neurons. Thus, this layer randomly deactivates 20% of the neurons in each training period. To prevent the network from learning specific patterns of the training data instead of generalizable patterns, L2 weight regularization is applied. This technique adds a penalty to the loss function that is proportional to the square of the magnitude of the weights.

The output of the trained neural network is a value between 0 and 1, where 0 represents the in-control state and larger values correspond to an out-of-

control state. Consequently, the monitoring process utilizes only an upper control limit (UCL). If the network's output exceeds this limit, an out-of-control warning is issued. The UCL value is determined through Monte Carlo simulation to ensure that the average run length (ARL) for the in-control process is equal to a predetermined target value.

Finally, an improved version of the proposed neural network-based control chart is developed by equipping it with two sensitizing rules of 2 out of 3 and 4 out of 5. For this purpose, two upper warning limits are used. Thus, the control chart issues an out-of-control alarm in two cases: (1) a point is above the upper control limit and (2) non-random trends are observed in consecutive samples.

3. Results and Discussion

In statistical process control, the performance of Phase II monitoring approaches is evaluated based on the run length properties in the out-of-control state, specifically the Average Run Length (ARL) and the Standard Deviation of the Run Length (SDRL).

The simulation results present the ARL and SDRL for four distinct dispersion monitoring approaches: two neural network-based control charts, the ATL method, and the RPLR method. The performance of these approaches is evaluated for seven different out-of-control patterns, with six different shift sizes (Δ) ranging from 0.1 to 1.0. The seven out-of-control patterns are designed with two principles in mind: (1) to include both sparse and non-sparse deviations, and (2) to cover all three categories of diagonal, non-diagonal, and joint diagonal/non-diagonal disturbances. The results in **Table 1** are reported using an a/b/c/d format. Within this structure, the variables a, b, c, and d denote the frequencies with which a given monitoring approach achieved a ranking of first, second, third, and fourth, respectively. Two key aspects of the table are noteworthy. First, the rankings for the monitoring approaches are reported separately for both the ARL and SDRL. Second, because the results are based on a Monte Carlo simulation, two approaches are ranked differently only if their performance differs by at least 0.5%. Otherwise, the difference is considered to be within the margin of simulation error, and the approaches are assigned the same rank. **Table 1** presents a comprehensive performance analysis of four monitoring approaches—NN-RR, NN, ATL, and RPLR. Overall, the NN-RR and NN approaches consistently demonstrate the best performance in detecting process disturbances.

Performance Across Different Shift Patterns is:

- **Diagonal Shifts:** For these patterns, one of the neural network-based approaches (NN-RR or NN) consistently ranks first. In contrast, the RPLR statistic generally ranks third, while the ATL statistic is consistently ranked fourth.

- **Off-Diagonal Shifts:** The performance ranking for off-diagonal changes differs significantly. The RPLR statistic has the highest frequency of a rank 4 performance, indicating it is the least effective. The NN-RR approach maintains the highest frequency of a rank 1 performance, proving to be the most effective. The ATL statistic most frequently achieves a rank 2, and the NN approach most often ranks third.
- **Sparse Shifts:** When sparse shifts occur, the rankings are clearly defined, with the highest frequency of ranks 1 through 4 assigned to NN-RR, NN, ATL, and RPLR, respectively.
- **Non-Sparse Shifts:** For non-sparse shifts, the NN-RR approach shows the best performance, while the RPLR statistic clearly performs the worst.

In summary, the NN-RR approach consistently outperforms the other methods, particularly for detecting non-sparse shifts. The RPLR statistic, on the other hand, frequently shows the weakest performance, especially with off-diagonal changes.

4. Conclusions

This study introduced an artificial neural network-based control chart for monitoring the dispersion of high-dimensional processes. This approach performs well under various conditions—including abnormal processes and sample dependencies—due to its independence from conventional assumptions. To increase the control chart's power, sensitizing rules are applied; these rules improve the ability to detect process disturbances by adding supplementary conditions for issuing out-of-control warnings. To prevent overfitting of the neural network, techniques consisting of dropout layer and weight regularization are employed. These techniques enable the neural network to generalize better from process patterns and improve its performance when encountering new data.

The simulation results showed that neural network-based approaches outperformed conventional methods such as RPLR and ATL. Specifically, the NN-RR approach was the most effective for detecting most out-of-control cases and was identified as the best method for detecting assignable causes. The study also revealed that the performance advantage of neural network-based methods over conventional statistical approaches becomes more pronounced as the number of components affected by assignable cause increases. Ultimately, this research demonstrated that machine learning tools can be an effective solution for monitoring high-dimensional processes, thereby improving quality and reducing waste across various industries.

For future research, the development of machine learning-based approaches for simultaneous monitoring of the mean vector and covariance

matrix in high-dimensional processes is suggested. Additionally, improving the neural network architecture by incorporating LSTM layers for monitoring processes with autocorrelated quality characteristics could be an intriguing topic. Furthermore, the use of hybrid deep learning and reinforcement learning algorithms could help address challenges in monitoring nonlinear processes. Investigating the impact of measurement errors on the performance of control charts based on machine learning tools could also emerge as a new research area. Moreover, developing self-starting methods based on neural networks for scenarios without reference data could enhance applicability. The use of more advanced sensitizing rules and parameter optimization with metaheuristic algorithms is also recommended. Finally, comparing the performance of these methods with classical approaches under various industrial conditions could provide new insights.

Funding

This research received no external funding.

Author contributions

Mir Milad Ghazvini: Conceptual research model, Literature review and theoretical background, Data analysis, Statistical analysis draft, Drafting the manuscript, Preliminary review of the report, Research methodology development, and Text revision; **Ali Salmasnia:** Conceptual research model, Literature review and theoretical background, Data analysis, Statistical analysis draft, Drafting the manuscript, Preliminary review of the report, Research methodology development, and Text revision.

Conflicts of interest

There are no conflicts of interest associated with this research.

Acknowledgments

We are grateful to all colleagues who provided insights and expertise that greatly assisted this research. We also thank the anonymous reviewers for their valuable suggestions to improve the paper.

References

- Abdella, G. M., Kim, J., Kim, S., Al-Khalifa, K. N., Jeong, M. K., Hamouda, A. M., & Elsayed, E. A. (2019). An adaptive thresholding-based process variability monitoring. *Journal of Quality Technology*, 51(3), 242–256. <https://doi.org/10.1080/00224065.2019.1569952>
- Adegoke, N. A., Dawod, A., Adeoti, O. A., Sanusi, R. A., & Abbasi, S. A. (2022). Monitoring multivariate coefficient of variation for high-dimensional processes. *Quality and Reliability Engineering International*, 38(5), 2606–2621. <https://doi.org/10.1002/qre.3094>
- Amiri, A., Salmasnia, A., Zarifi, M., & Maleki, M. R. (2023). Adaptive Shewhart control charts under fuzzy parameters with tuned particle swarm optimization algorithm. *Journal of Industrial Integration and Management*, 8(2), 241–276. <https://doi.org/10.1142/S2424862221500226>
- Fan, J., Shu, L., Yang, A., & Li, Y. (2021). Phase I analysis of high-dimensional covariance matrices based on sparse leading eigenvalues. *Journal of Quality Technology*, 53(4), 333–346. <https://doi.org/10.1080/00224065.2020.1746212>
- Jafari, M., Maleki, M. R., & Salmasnia, A. (2023). A high-dimensional control chart for monitoring process variability under gauge imprecision effect. *Production Engineering*, 17(3), 547–564. <https://doi.org/10.1007/s11740-022-01166-3>
- Mallikarjun, N. S., Tayyapa, J. B., Moshayedi, A. J., & Kisanrao, S. S. (2024). Performance analysis of ANN control chart for monitoring the individual measurements of manufacturing process. In *Proceedings of the 2024 3rd International Symposium on Robotics, Artificial Intelligence and Information Engineering* (pp. 130–135). <https://doi.org/10.1145/3689299.3689323>
- Saemian, M., Salmasnia, A., & Maleki, M. R. (2022). A generalized multiple dependent state sampling chart based on ridge penalized likelihood ratio for high-dimensional covariance matrix monitoring. *Scientia Iranica*. <https://doi.org/10.24200/SCI.2022.60169.6640>
- Safikhani, E., Salmasnia, A., & Maleki, M. R. (2023). A ridge penalized likelihood ratio chart for Phase II monitoring of high-dimensional process dispersion under measurement system inaccuracy. *International Journal of Industrial Engineering*, 34(2), 1–17. <https://doi.org/10.22068/ijiepr.34.2.12>
- Salmasnia, A., Asghari, A., & Maleki, M. R. (2025a). Effect of parameter estimation on Phase II performance of ridge penalized likelihood ratio control chart for monitoring high-dimensional process variability. *Journal of Data, Information and Management*, 7(3), 265–286. <https://doi.org/10.1007/s42488-025-00152-5>
- Salmasnia, A., Maleki, M. R., & Mirzaei, M. (2025b). Double sampling adaptive thresholding LASSO variability chart for Phase II monitoring of high-dimensional data streams. *Journal of Industrial Integration and Management*, 10(2), 277–299. <https://doi.org/10.1142/S242486222350001X>

Table 1. Number of ranks obtained by each monitoring approach in each type of out-of-control pattern

Method	Criterion	Diagonal	Off-diagonal	Joint	Sparse	Non-sparse
RPLR	ARL	0/1/9/2	0/0/1/11	0/2/2/14	0/2/6/10	0/1/6/17
	SDRL	0/1/9/2	0/0/1/11	0/3/2/13	0/1/7/10	0/3/5/16
ATL	ARL	0/1/1/10	3/7/1/1	4/4/8/2	0/5/6/7	7/7/4/6
	SDRL	0/1/1/10	3/8/0/1	5/5/6/2	0/6/5/7	8/8/2/5
NN	ARL	5/7/0/0	4/0/8/0	4/11/3/0	7/8/3/0	6/10/8/0
	SDRL	5/7/0/0	3/1/8/0	4/9/5/0	5/10/3/0	6/8/10/0
NN-RR	ARL	8/3/1/0	6/4/2/0	12/4/1/0	12/3/3/0	14/8/2/0
	SDRL	8/3/1/0	6/4/2/0	13/3/1/0	13/2/3/0	14/8/2/0

طراحی نمودار کنترل مبتنی بر یادگیری ماشین برای پایش پراکندگی جریان داده‌های با ابعاد بالا در فاز ۲


میرمیلاذ قزوینی^۱، علی سلماس‌نیا^{۲*} 

^۱ دانشجوی دکتری، دانشکده مهندسی صنایع، دانشگاه ایوان‌کی، ایوان‌کی، ایران
^۲ دانشیار، دانشکده فنی و مهندسی، دانشگاه قم، قم، ایران

برجسته‌ها

- پایش پراکندگی فرآیندهای ابعاد بالا با شبکه عصبی
- مطالعه اثر قوانین حساس‌سازی بر ویژگی‌های طول دنباله
- قابلیت استفاده در شرایط نقض مفروضات آماری

چکیده گرافیکی



مشخصات مقاله

تاریخچه مقاله:

نوع مقاله: پژوهشی

دریافت: ۱۴۰۴/۰۴/۲۷

بازنگری: ۱۴۰۴/۰۵/۲۶

پذیرش: ۱۴۰۴/۰۶/۱۲

ارائه برخط: ۱۴۰۴/۰۶/۱۲

*نویسنده مسئول:

a.salmasnia@qom.ac.ir

کلیدواژه‌ها:

پایش پراکندگی
فرآیند ابعاد بالا
نمودار کنترل مبتنی بر شبکه عصبی تنظیم
تنظیم‌سازی
قانون حساس‌سازی
لایه حذف تصادفی

چکیده

این یک نمودار کنترل مبتنی بر شبکه عصبی کاملاً متصل برای پایش پراکندگی فرآیندهای چند متغیره با دو ویژگی مهم توسعه داده می‌شود: (۱) قابلیت استفاده برای پایش پراکندگی فرآیندها با جریان داده ابعاد بالا، و (۲) عدم نیاز به برقراری مفروضات آماری محدودکننده از جمله نرمال بون مشخصه‌های کیفی تحت مطالعه و مستقل بودن مشاهدات در نمونه‌های اخذشده. چالش مهمی که معمولاً در آموزش شبکه‌های عصبی با آن مواجه هستیم بیش برآزش یا شکست تعمیم است. در این مطالعه برای مواجهه با چالش ذکرشده از دو ابزار لایه حذف تصادفی و منظم‌سازی وزن در طراحی شبکه استفاده می‌شود. به‌علاوه جهت آموزش بهتر شبکه عصبی و برخلاف بیشتر نمودارهای کنترل مبتنی بر ابزارهای یادگیری که از الگوی دو کلاسه صفر و یک به‌عنوان مقادیر هدف بهره می‌برند، در این مطالعه مقادیر هدف بر اساس اندازه و تعداد مؤلفه‌های شیف‌یافته تعیین شده‌اند، به‌گونه‌ای که با افزایش اندازه شیف و تعداد مؤلفه‌های شیف‌یافته، مقادیر هدف نیز افزایش یابند. در ادامه، به‌منظور افزایش توان نمودار کنترل توسعه داده‌شده در کشف اختلالات رخ داده در مؤلفه‌های ماتریس کوواریانس، نسخه بهبودیافته‌ای از آن به کمک دو قانون حساس‌سازی ۲ از ۳ و ۴ از ۵ ارائه می‌شود. عملکرد رویکردهای پیشنهادی با استفاده از یک مثال عددی با دو نمودار کنترل ATL و RPLR مقایسه می‌شوند. نتایج نشان می‌دهد که رویکرد مجهز شده به قوانین حساس‌سازی عملکرد بهتری از نمودارهای رقیب برحسب دو شاخص ARL و SDRL دارد.

۱- مقدمه

در دنیای رقابتی امروز از یک طرف تولیدکنندگان و ارائه‌دهندگان خدمات به منظور جلب رضایت مشتری ملزم به پایش تعداد زیاد مشخصه‌های کیفی هستند و از طرف دیگر با پیشرفت تکنولوژی و توسعه فناوری‌های حسگر امکان دسترسی و ذخیره‌سازی حجم زیادی از جریان‌های داده شامل تعداد زیادی از متغیرهای مؤثر بر محصول یا خدمت به وجود آمده است. مواجهه با شرایط ذکرشده با گذر زمان در بسیاری از صنایع از جمله سیستم‌های سلامت و مالی در حال بدل شدن به یک امر عادی است. اگرچه در بیشتر موارد به عللی از جمله محدودیت‌های اقتصادی و زمانی امکان جمع‌آوری نمونه‌هایی به بزرگی تعداد مشخصه‌های کیفی موردنظر امکان‌پذیر نیست؛ بنابراین مسئله پایش فرآیندهای با ابعاد بالا موضوعی است که متخصصین حوزه کیفیت به‌طور روزافزون با آن مواجه هستند درحالی‌که عمده روش‌های مرسوم در ادبیات پایش فرآیند از نفرین ابعادی^۱ رنج می‌برند که معادل با کاهش حساسیت آن‌ها به اختلالات رخ داده در فرآیند با افزایش بعد مسئله است. برای مقابله با این چالش، محققان روش‌های مختلفی توسعه داده‌اند که برخی از مهم‌ترین آن‌ها عبارت‌اند از:

جیانگ و همکاران (Jiang et al., 2012) از ترکیب آماره میانگین متحرک موزون نمایی چندمتغیره و روش انتخاب متغیر برای شناسایی عوامل انحراف استفاده کردند. عبدلا و همکاران (Abdella et al., 2017) یک نمودار کنترل جمع تجمعی چندمتغیره مبتنی بر انتخاب متغیر برای افزایش حساسیت به اختلالات ارائه کردند. فنگ و همکاران (Feng et al., 2020) با استفاده از استراتژی تقسیم و غلبه، رویکردی برای محاسبه آماره‌ها در زیر بردارها با ابعاد کوچک توسعه دادند. مابودو (Maboudou-Tchao, 2021) از مدل فضای تنسور^۲ برای پایش میانگین فرآیندهای با ابعاد بالا استفاده کرد. گومز و همکاران (Gómez et al., 2022) با بهره‌گیری از استراتژی نمونه‌گیری تطبیقی، رویکردی جدید برای پایش فرآیندهای ابعاد بالا ارائه دادند که شامل تغییر بعد فرآیند و توسعه طرح نمونه‌گیری تطبیقی بود. درنهایت، عبادی و

همکاران (Ebadi et al., 2023) یک روش استوار برای پایش فرآیندهای ابعاد بالا تحت شرایط محدود بودن داده‌ها توسعه دادند که به وجود داده‌های پرت^۳ یا آلوده^۴ مقاوم است. تمامی مقالات ذکرشده بر کشف اختلالات در بردار میانگین فرآیند متمرکز شده‌اند درحالی‌که پایش پراکندگی تأثیر به‌سزایی بر کاهش نرخ تولید محصولات نامنطبق و متعاقباً کاهش هزینه‌های تحمیل‌شده به سیستم دارد.

قابل‌ذکر است که افزایش پراکندگی فرآیند مؤید کاهش سطح کیفی آن است؛ بنابراین، در پایش پراکندگی فرآیندها تمرکز صرفاً بر کشف به‌موقع شیفت‌های افزایشی در مؤلفه‌های قطری و غیر قطری ماتریس کوواریانس خواهد بود. در این راستا کیم و همکاران (Kim et al., 2019) یک رویکرد پایش مبتنی بر آماره نسبت درست‌نمایی توانیده لبه‌ای^۵ (RPLR) برای کشف اختلالات در عناصر ماتریس کوواریانس توسعه دادند. این رویکرد حساسیت بالایی به هر دو نوع اختلالات پراکنده و غیرپراکنده دارد.

عبدلا و همکاران (Abdella et al., 2019) نسخه تطبیقی از نمودارهای کنترل مبتنی بر انتخاب متغیر را تحت عنوان نمودار حد آستانه تطبیقی لاسو برای پایش تغییرات در ماتریس کوواریانس توسعه دادند. فن و همکاران (Fan et al., 2021) یک نمودار کنترل مبتنی بر مقادیر ویژه^۶ برای پایش ماتریس پراکندگی فرآیندهای با ابعاد بالا در فاز ۱ ارائه کردند. ایده اصلی آن‌ها برای تشخیص وضعیت تحت کنترل بودن فرآیند بر اساس مقایسه مقادیر ویژه ماتریس‌های کوواریانس نمونه‌ای و هدف بود. ادگوک و همکاران (Adegoke et al., 2022) عملکرد نمودار کنترل ضریب تغییر چندمتغیره^۷ را در شرایط محدودیت داده‌ها بررسی کردند و دو نمودار کنترل یک‌طرفه بر مبنای آماره لاسو و تخمین انقباضی ارائه دادند که با داده‌های فرآیند تولید لوله‌های فیبر کربنی ارزیابی شدند. جعفری و همکاران (Jafari et al., 2023) توان نمودار حد آستانه تطبیقی لاسو را در پایش پراکندگی فرآیندهای با ابعاد بالا بررسی کردند و نشان دادند استفاده از رویکرد سنجش

³ Outlier⁴ Contaminated⁵ Ridge penalized likelihood ratio⁶ Eigen values⁷ Multivariate coefficient of variation¹ Curse of dimensionality² Tensor space model

زمینه می‌توان به SVM، SVR، MLP و CNN اشاره کرد که معمولاً از هسته‌های^۵ خطی یا تابع پایه شعاعی^۶ استفاده می‌کنند. در ادامه، معروف‌ترین و جدیدترین رویکردهای پایش مبتنی بر یادگیری ماشین مرور می‌شوند.

در دو دهه اخیر، رویکردهای پایش مبتنی بر هوش مصنوعی به‌طور گسترده در پایش فرآیندهای تک‌متغیره و شناسایی الگوها مورد توجه قرار گرفته‌اند (Arkati et al., 2007) و (Abbasi & Niaki, 2007). یگانه و شادمان (Yeganeh et al., 2021a) نمودارهای کنترل مبتنی بر شبکه‌های عصبی برای پایش پروفایل‌های لجستیک و خطی توسعه دادند و از قوانین حساس‌سازی برای افزایش توان آن‌ها استفاده کردند. کیم و ها (Kim & Ha., 2022) نمودار کنترل باقی‌مانده مبتنی بر یادگیری عمیق^۷ برای پایش متغیرهای پاسخ شمارشی^۸ ارائه کردند. یگانه و همکاران (Yeganeh et al., 2022) رویکردی ترکیبی از شبکه عصبی تابع پایه شعاعی^۹ و یادگیری گروهی^{۱۰} برای پایش پروفایل‌های خطی توسعه دادند که عملکرد بهتری نسبت به روش‌های سنتی داشت. یگانه و همکاران (Yeganeh et al., 2023a) شش نمودار کنترل مبتنی بر ابزارهای یادگیری ماشین برای پایش پروفایل‌های همبسته ارائه کردند که در بین آن‌ها نمودار مبتنی بر سیستم استنتاج نرو-فازی انطباقی^{۱۱} برتری داشت. یگانه و همکاران (Yeganeh et al., 2023b) نمودار کنترلی برای مشخصه‌های کیفی باینری پیشنهاد کردند که از الگوریتم بهینه‌سازی ازدحام ذرات^{۱۲} برای تنظیم پارامترها استفاده کردند. صباح‌نو و امیری (Sabahno & Amiri, 2023) سه نمودار کنترل مبتنی بر شبکه عصبی، رگرسیون بردار پشتیبان^{۱۳} و جنگل تصادفی^{۱۴} برای پایش پروفایل‌های مدل خطی تعمیم‌یافته^{۱۵} توسعه دادند. سان و همکاران (Sun et al., 2023) نمودار کنترل باقیمانده^{۱۶} مبتنی بر

چندگانه، پراکندگی ناشی از خطای اندازه‌گیری را کاهش می‌دهد که کاربرد آن با داده‌های فرآیند تولید چرخ‌دنده تست شد. صفی‌خانی و همکاران (Safikhani et al., 2023) با ترکیب مدل جمعی خطا و آماره نسبت درست‌نمایی توانیده لبه‌ای، رویکردی برای پایش پراکندگی فرآیندهای ابعاد بالا توسعه دادند و از تکنیک سنجش چندگانه برای کاهش اثر خطای اندازه‌گیری بهره بردند. تنگ و همکاران (Tang et al., 2023) دو نمودار میانگین متحرک موزون نمایی مستقل از توزیع برای پایش هم‌زمان پارامترهای مکانی و مقیاس ارائه دادند که عملکرد آن‌ها با داده‌های فرآیند تولید نیمه‌هادی مقایسه شد. صائمیان و همکاران (Saemian et al., 2022) با تجهیز نمودار نسبت درست‌نمایی توانیده لبه‌ای به تکنیک‌های MDS و GMDS، سرعت کشف انحرافات را افزایش دادند. سلماس‌نیا و همکاران (Salmasnia et al., 2025a) رویکردی با استفاده از نمونه‌گیری دوگانه و آماره حد آستانه تطبیقی لاسو توسعه دادند که اختلالات پایدار را سریع‌تر کشف می‌کند و با افزایش بعد مسئله، حساسیت آن بهبود می‌یابد. سلماس‌نیا و همکاران (Salmasnia et al., 2025b) اثر خطای تخمین پارامتر در فاز ۱ را بر ویژگی‌های متوسط طول دنباله ارزیابی کردند و حداقل تعداد نمونه مرجع موردنیاز را تعیین کردند. تمامی مطالعات مرور شده بر توسعه رویکردهای آماری برای پایش فرآیندهای آماری متمرکز شده‌اند و بر اساس یک سری محدودیت آماری از جمله نرمال بودن مشخصه‌های کیفی و استقلال نمونه‌های اخذ شده بنانهاده شده‌اند.

از آنجایی که در فرآیندهای ابعاد بالا به علت افزایش تعداد مشخصه‌های کیفی و همچنین پیچیده بودن فرآیند احتمال نقض فرضیات آماری ذکر شده افزایش می‌یابد، نمودارهای کنترل مبتنی بر الگوریتم‌های یادگیری ماشین^۱ مورد توجه قرار گرفته‌اند. روش‌های یادگیری ماشین به سه دسته بانظارت^۲، بدون نظارت^۳ و تقویتی^۴ تقسیم می‌شوند که پایش فرآیند در دسته بانظارت قرار می‌گیرد. در یادگیری بانظارت، مدل با داده‌های برچسب‌دار آموزش داده می‌شود تا رابطه بین ورودی و خروجی را یاد بگیرد. از جمله ابزارهای پرکاربرد در این

⁵ Kernels

⁶ Radial basis function

⁷ Deep learning

⁸ Count response

⁹ Radial basis function

¹⁰ Ensemble learning

¹¹ Adaptive neuro-fuzzy inference system

¹² Particle swarm optimization algorithm

¹³ Support vector regression

¹⁴ Random forest regression

¹⁵ Generalized linear model

¹⁶ Residual control chart

¹ Machine learning

² Supervised learning

³ Unsupervised learning

⁴ Reinforcement learning

راکیتزیس (Antzoulakos & Rakitzis, 2008) قوانین m از n را برای بهبود عملکرد نمودارهای شوهرت در شناسایی تغییرات کوچک و متوسط ارائه کردند. ریاض و همکاران (Riaz et al., 2011) رویکردی ترکیبی از نمودار کنترل جمع تجمعی و قوانین حساس‌سازی ارائه کردند. ترن (Tran, 2017) نمودارهای کنترل میانه را با قوانین حساس‌سازی توسعه داد. آدوتی و ماللا-ماجیکا (Adeoti & Malela-Majika, 2020) عملکرد نمودار میانگین متحرک موزون نمایی دوگانه را بهبود دادند. چو و همکاران (Chew et al., 2021) نمودارهای کنترل برای فرآیندهای چندمتغیره با سیکل کوتاه ارائه کردند. ترن و همکاران (Tran, 2017) دو نمودار یکطرفه برای پایش ضریب تغییر طراحی کردند. محمود و همکاران (Mehmood et al., 2021) از استراتژی نمونه‌گیری مجموعه رتبه‌دار استفاده کردند. امیری و همکاران (Amiri et al., 2023) نمودار شوهرت تطبیقی طراحی کردند و خیلازه و شرک (Khilare & Shirke, 2023) نمودار کسری نامنطبق^۷ را به کمک قوانین حساس‌سازی بهبود دادند. کینیو و همکاران (Quinino et al., 2023) قانونی جدید برای رفع نقص قانون دو از دو ارائه کردند. وودال و همکاران (Woodall et al., 2023) عملکرد نمودار کنترل را تحت دو شرایط استفاده از استراتژی نمونه‌گیری حالت وابسته چندگانه و قوانین حساس‌سازی مقایسه کردند. دفنیس و همکاران (Dafnis et al., 2024) عملکرد نمودار مربع کی را با تجهیز آن به قانون حساس‌سازی ضعیف^۸ بهبود دادند. احمدی کاراویج و امیری (Ahmadi Karavigh & Amiri, 2024) سه نمودار MEWMA، MEWMA/ χ^2 و DMEWMA مجهز شده به قوانین حساس‌سازی را برای پایش پروفایل چندمتغیره پیشنهاد کردند.

با توجه به شکاف‌های تحقیقاتی شناسایی شده، هدف اصلی این مقاله پاسخ به دو چالش ذیل در نظر گرفته شده است:

- ۱) عدم برقراری مفروضات آماری محدودکننده از جمله نرمال بون مشخصه‌های کیفی تحت مطالعه و مستقل بودن مشاهدات در نمونه‌های اخذ شده

شبکه عصبی برای فرآیندهای چندمتغیره خودهمبسته^۱ ارائه کردند. اخرین و همکاران (Okhrin et al., 2025) نمودار کنترل مبتنی بر شبکه عصبی کانولوشنی^۲ برای پایش تصاویر توسعه دادند که عملکرد بهتری نسبت به روش‌های سنتی داشت. رونلاس-سانتویو و همکاران (Ruelas-Santoyo et al., 2024) نمودار کنترل جمع تجمعی چندمتغیره را با شبکه عصبی ترکیب کردند و در صنعت برد مدار چاپی مورد آزمایش قرار دادند. مالی‌کارجون و همکاران (Mallikarjun et al., 2024) نمودار کنترل مبتنی بر شبکه عصبی برای مشاهدات انفرادی^۳ ارائه کردند. هریک و صباح‌نو (Hric & Sabahno., 2024) رویکردی نوآورانه برای پایش پروفایل‌های مدل خطی تعمیم‌یافته پیشنهاد کردند. صباح‌نو و خداداد (Sabahno & Khodadad, 2025) چارچوب دومرحله‌ای برای پایش تصاویر^۴ ارائه کردند که در آن از تحلیل الگوی نقطه‌ای^۵ و تحلیل p -مقدار^۶ استفاده کردند. عمران و همکاران (Imran et al., 2024) مدلی مبتنی بر شبکه عصبی پرسپترون چندلایه برای تفسیر سیگنال‌های خارج از کنترل ارائه کردند که قادر به شناسایی متغیرهای مسئول انحراف بود. همان‌طور که مشاهده می‌شود، با وجود موفقیت نمودارهای کنترل مبتنی بر یادگیری ماشین در پایش فرآیندهای مختلف، پایش پراکندگی فرآیندهای ابعاد بالا در شرایط نقض محدودیت‌های آماری مرسوم به‌وضوح مورد غفلت قرار گرفته است.

موضوع مهم دیگر در ادبیات کنترل کیفیت، افزایش حساسیت نمودارهای کنترل به اختلالات رخ داده در فرآیند است. یک روش مرسوم برای این موضوع استفاده از قوانین حساس‌سازی است. از معروف‌ترین مطالعات انجام‌شده در این زمینه می‌توان به کلین (Klein, 2000)، خو (Khoo, 2003)، کوتراس و همکاران (Koutras et al., 2007) و آنتزیلاکوس و راکیتزیس (Antzoulakos & Rakitzis, 2008) اشاره کرد. قوانین دو از دو و دو از سه توسط کلین (Klein, 2000) معرفی شدند و در مطالعات مختلف توسعه یافتند. آنتزیلاکوس و

¹ Autocorrelated

² Convolutional neural network

³ Individual observations

⁴ Image monitoring

⁵ Speckle pattern analysis

⁶ P-value

⁷ Fraction nonconforming control chart

⁸ Weak-run rule

مبتنی بر یادگیری ماشین، اگرچه محاسبات سنگین‌تری را می‌طلبد، اما قادرند بدون نیاز به مفروضات سخت‌گیرانه، الگوهای پیچیده و غیرخطی را شناسایی کنند. با این حال، توسعه رویکردهای ترکیبی مبتنی بر روش‌های آماری و الگوریتم‌های یادگیری ماشین که نقاط قوت هر دو رویکرد را به کارگیرند، هنوز به‌طور کامل مورد بررسی قرار نگرفته است؛ بنابراین، در این بخش یک روش نوین مبتنی بر شبکه عصبی کاملاً متصل برای پایش پراکندگی فرآیندهای ابعاد بالا ارائه می‌شود.

۲-۱- شناسایی ورودی‌ها و مقادیر اهداف

فرآیند آموزش شبکه عصبی از طریق یادگیری نظارت‌شده^۳ انجام می‌شود که در آن جفت‌های ورودی-هدف به شبکه داده می‌شوند تا خطا به حداقل برسد؛ بنابراین، اولین گام طراحی شبکه، تعیین ورودی‌ها و مقادیر هدف است.

در نگاه اول، مسئله این تحقیق یک مسئله طبقه‌بندی^۴ دو کلاسه تحت کنترل و خارج از کنترل به نظر می‌رسد. درحالی‌که این رویکرد بین الگوهای خارج از کنترل متفاوت و همچنین مقادیر شیفت مختلف تفاوتی قائل نمی‌شود که در نتیجه منجر به طراحی نمودار کنترل با دقت بسیار پایین در شناسایی شیفت‌های کوچک به‌خصوص هنگامی که تعداد پارامترهای منحرف‌شده کم باشند خواهد شد. برای رهایی از چنین مشکلی، در این مطالعه، مسئله پایش ماتریس کوواریانس فرآیند ابعاد بالا به‌جای یک مسئله طبقه‌بندی دو کلاسه، یک مسئله رگرسیون^۵ در نظر گرفته می‌شود. در این رویکرد، مقدار هدف نمونه‌های حاصل از یک فرآیند تحت کنترل مشابه قبل صفر در نظر گرفته می‌شود. درحالی‌که مقدار هدف الگوهای مختلف خارج از کنترل متناسب با اندازه شیفت مقادیری بین صفر و یک تعیین می‌شوند. به‌طوری‌که با افزایش مقدار شیفت و تعداد مؤلفه‌های شیفت یافته مقدار هدف یک روند افزایشی داشته باشد. برای این منظور ابتدا الگوهای خارج از کنترل معرفی می‌شوند و سپس نحوه محاسبه مقدار هدف جفت الگو-مقدار شیفت شرح داده می‌شود.

۲) پایش پراکندگی فرآیندها با جریان داده ابعاد بالا.

برای این منظور یک نمودار کنترل مبتنی بر شبکه عصبی مصنوعی با توان بالا در کشف انحرافات رخ داده در مؤلفه‌های ماتریس کوواریانس فرآیندهای با ابعاد بالا توسعه داده می‌شود. در این ارتباط، یک شبکه عصبی کاملاً متصل طراحی می‌شود که در آن از دو ابزار لایه حذف تصادفی^۱ و منظم‌سازی وزن^۲ برای جلوگیری از بیش‌برازش شبکه استفاده می‌شود. در نهایت، به‌منظور افزایش توان نمودار کنترل توسعه داده‌شده در کشف اختلالات در پراکندگی فرآیند، نسخه بهبودیافته‌ای از آن به کمک دو قانون حساس‌سازی^۲ از ۳ و ۴ از ۵ ارائه می‌شود.

ادامه مقاله بدین شرح است که در بخش ۲ گام‌های مقدماتی برای طراحی شبکه عصبی شامل شناسایی ورودی‌ها و مقادیر هدف، پایش‌پردازش داده‌ها، تقسیم داده‌ها به مجموعه‌های آموزش، اعتبارسنجی و آزمون، و نرمال‌سازی داده‌ها ارائه می‌شوند. در بخش ۳ یک نمودار کنترل مبتنی بر شبکه عصبی توسعه داده می‌شود و در بخش ۴ نسخه بهبودیافته نمودار توسعه داده‌شده با تجهیز آن به قوانین حساس‌سازی^۲ از ۳ و ۴ از ۵ ارائه می‌شود. در بخش ۵، نمودارهای کنترل توسعه داده‌شده با دو نمودار مرسوم آماری برای پایش پراکندگی فرآیندهای ابعاد بالا مقایسه می‌شوند. در نهایت نتیجه‌گیری و پیشنهادها برای تحقیقات آتی در بخش ۶ گزارش می‌شوند.

۲- گام‌های مقدماتی برای طراحی شبکه عصبی به‌منظور پایش پراکندگی فرآیندهای ابعاد بالا

در عصر صنعت ۵.۰، پایش دقیق فرآیندهای ابعاد بالا به دلیل افزایش پیچیدگی محصولات و محدودیت‌های منابع، ضرورتی اجتناب‌ناپذیر است. روش‌های سنتی مانند نمودارهای کنترل آماری به دلیل وابستگی به مفروضاتی مانند توزیع نرمال داده‌ها و استقلال مشاهدات، در بسیاری از شرایط واقعی ناکارآمد هستند. از سوی دیگر، روش‌های

³ Supervised learning

⁴ Classification

⁵ Regression

¹ Dropout layer

² Weight regularization

ماتریس را تحت تأثیر قرار می‌دهد، با یک الگوی خارج از کنترل پراکنده مواجه هستیم.

$$\Sigma_{1,3} = \begin{bmatrix} 1 + \Delta^2 & \Delta & 0 & \dots & 0 \\ \Delta & 1 + \Delta^2 & 0 & \dots & 0 \\ 0 & 0 & 1 & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & 1 \end{bmatrix}_{10 \times 10} \quad (3)$$

• **الگو ۴:** تحت این الگوی خارج از کنترل، رخداد انحراف با دلیل تنها بر عناصر قطری ماتریس واریانس-کوواریانس اثر می‌گذارد. به عبارت دیگر، مقدار واریانس همه مشخصه‌های کیفی تحت مطالعه از ۱ به $1 + \Delta^2$ افزایش می‌یابد حال آنکه مؤلفه‌های متناظر با کوواریانس بین مشخصه‌های کیفی بدون تغییر در مقدار صفر باقی می‌مانند. در نتیجه، با یک الگوی قطری غیرپراکنده مواجه هستیم.

$$\Sigma_{1,4} = \begin{bmatrix} 1 + \Delta^2 & 0 & \dots & 0 \\ 0 & 1 + \Delta^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 1 + \Delta^2 \end{bmatrix}_{10 \times 10} \quad (4)$$

• **الگو ۵:** مطابق با رابطه (۵)، تحت این الگوی خارج از کنترل، از میان ۱۰۰ عنصر ماتریس واریانس-کوواریانس، تنها واریانس مشخصه کیفی اول از ۱ به $1 + \Delta^2$ منحرف خواهد شد. به عبارت دیگر همانند الگوی ۴ با یک الگوی خارج از کنترل قطری ولی پراکنده مواجه هستیم.

$$\Sigma_{1,5} = \begin{bmatrix} 1 + \Delta^2 & 0 & \dots & 0 \\ 0 & 1 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 1 \end{bmatrix}_{10 \times 10} \quad (5)$$

• **الگو ۶:** مطابق با رابطه (۶)، عناصر کوواریانس مرتبط با پنج مشخصه کیفی اول فرآیند به مقدار Δ واحد افزایش می‌یابند. به عبارت دیگر، برخلاف الگوهای خارج از کنترل قبلی، با یک الگوی غیرقطری غیرپراکنده مواجه هستیم.

$$\Sigma_{1,6} = \begin{bmatrix} 1 & \Delta & \dots & \Delta & 0 & \dots & 0 \\ \Delta & 1 & \dots & \Delta & 0 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ \Delta & \Delta & \dots & 1 & 0 & \dots & 0 \\ 0 & 0 & \dots & 0 & 1 & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 0 & 0 & \dots & 1 \end{bmatrix}_{10 \times 10} \quad (6)$$

• **الگو ۷:** مشابه با الگوی قبل با یک الگوی غیر قطری مواجه هستیم با این تفاوت که وقوع

در این بخش، هفت الگوی خارج از کنترل با در نظر گرفتن دو اصل طراحی شده‌اند: (۱) هر دو دسته انحرافات پراکنده^۱ و غیرپراکنده شامل شوند و (۲) هر سه دسته تغییرات قطری، غیرقطری و توأم قطری-غیرقطری پوشش داده شوند. در ادامه با فرض آنکه ماتریس واریانس-کوواریانس تحت کنترل به صورت $\Sigma_0 = I_p$ و بعد مسئله برابر $p = 10$ است، الگوهای خارج از کنترل به‌طور مفصل تشریح می‌شوند.

• **الگو ۱:** تحت این الگو عناصر قطری یا به عبارتی واریانس مشخصه‌های کیفی تحت مطالعه از مقدار ۱ به $1 + \Delta^2$ افزایش می‌یابند در حالی که عناصر غیرقطری یا به عبارتی کوواریانس بین مشخصه‌های کیفی از مقدار اسمی صفر به Δ منحرف می‌شوند؛ بنابراین الگوی ۱ معادل با رخداد یک شیفت توأم قطری-غیرقطری غیرپراکنده است.

$$\Sigma_{1,1} = \begin{bmatrix} 1 + \Delta^2 & \Delta & \dots & \Delta \\ \Delta & 1 + \Delta^2 & \dots & \Delta \\ \vdots & \vdots & \ddots & \vdots \\ \Delta & \Delta & \dots & 1 + \Delta^2 \end{bmatrix}_{10 \times 10} \quad (1)$$

• **الگو ۲:** مطابق با رابطه (۲)، این الگو مشابه با الگوی قبلی است یا به عبارتی معادل با رخداد یک شیفت توأم قطری-غیرقطری غیرپراکنده است. با این تفاوت که صرفاً مؤلفه‌های قطری و غیرقطری متناظر با پنج مشخصه کیفی اول از مقادیر اسمی‌شان منحرف می‌شوند.

$$\Sigma_{1,2} = \begin{bmatrix} 1 + \Delta^2 & \Delta & \dots & \Delta & 0 & \dots & 0 \\ \Delta & 1 + \Delta^2 & \dots & \Delta & 0 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ \Delta & \Delta & \dots & 1 + \Delta^2 & 0 & \dots & 0 \\ 0 & 0 & \dots & 0 & 1 & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 0 & 0 & \dots & 1 \end{bmatrix}_{10 \times 10} \quad (2)$$

• **الگو ۳:** این الگو مشابه با دو الگوی قبلی منجر به انحراف توأم عناصر قطری و غیر قطری ماتریس واریانس-کوواریانس می‌شود با این تفاوت که مطابق با معادله (۳) صرفاً بر عناصر متناظر با دو مشخصه کیفی اول اثرگذار است. به عبارت دیگر، از آنجایی که تحت این الگو رخداد انحراف با دلیل صرفاً ۴ عنصر از ۱۰۰ عنصر

^۱ Sparse Shift

با توجه به توضیحات ارائه‌شده، روند تغییرات RPLR دقیقاً منطبق با منطق مدنظر ما برای تعیین مقادیر هدف زوج الگو-اندازه شیفت است؛ بنابراین برای تعیین مقادیر هدف به شرح زیر عمل می‌کنیم:

• برای هر زوج الگو-اندازه شیفت ۱۰۰۰۰ نمونه تولید می‌کنیم.
برای هر نمونه $\hat{\Omega}_{RPLR}$ و بر مبنای آن RPLR محاسبه می‌شود.

از ۱۰۰۰۰ مقدار RPLR محاسبه‌شده برای هر زوج الگو-اندازه شیفت، میانگین حسابی گرفته می‌شود. به راحتی قابل درک است که دامنه تغییرات RPLR بین صفر و مثبت بی‌نهایت است. از آنجایی که هر چه دامنه تغییرات خروجی شبکه محدودتر باشد، فرآیند آموزش شبکه بهتر انجام خواهد شد و در نتیجه خطای کمتری دارد، به جای استفاده از میانگین‌های حسابی به دست آمده به عنوان مقدار هدف، با تقسیم هر یک از آن‌ها به بزرگ‌ترین مقدار، دامنه تغییرات مقادیر هدف به بازه بین صفر و یک تغییر خواهد کرد. با اجرای گام‌های ذکر شده، برچسب‌های به دست آمده برای ۴۲ زوج اندازه شیفت-الگوی خارج از کنترل به شرح جدول ۱ خواهد بود.

۲-۲- پیش پردازش داده‌ها

در مسائل رگرسیون، مقیاس داده‌ها تأثیر زیادی بر عملکرد مدل‌های یادگیری عمیق دارد. اگر داده‌ها در مقیاس‌های مختلف باشند، مدل ممکن است به طور نادرست وزن‌دهی کند و در نتیجه دقت پیش‌بینی کاهش یابد. انتخاب ویژگی‌های مناسب و مقیاس‌بندی آن‌ها می‌تواند به مدل کمک کند تا روابط بین ورودی‌ها و خروجی‌ها را بهتر درک کند. مهندسی ویژگی^۲ فرآیندی است که در آن ویژگی‌های جدید از داده‌های موجود استخراج یا تبدیل می‌شوند تا مدل بتواند الگوها و روابط پنهان را بهتر تشخیص دهد. در ادامه سه ویژگی مورد استفاده به عنوان ورودی‌های شبکه عصبی توسعه داده‌شده در این مطالعه معرفی می‌شوند. از آنجایی که در این مطالعه به دنبال پایش پراکندگی فرآیندهای ابعاد بالا هستیم، trace ماتریس کوواریانس نمونه‌ای^۳ (S) و

انحراف با دلیل صرفاً کوواریانس بین مشخصه‌های کیفی اول و دوم را تحت تأثیر قرار می‌دهد؛ بنابراین این الگو تداعی‌کننده یک ساختار غیرقطری پراکنده خواهد بود.

$$\Sigma_{1,7} = \begin{bmatrix} 1 & \Delta & 0 & \dots & 0 \\ \Delta & 1 & 0 & \dots & 0 \\ 0 & 0 & 1 & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & 1 \end{bmatrix}_{10 \times 10} \quad (7)$$

با در نظر گرفتن ۶ اندازه شیفت $\Delta \in \{0, 0.1, 0.2, 0.3, 0.5, 0.75, 1\}$ می‌توان نتیجه گرفت که با ۴۲ زوج الگو-مقدار شیفت مواجه هستیم. همان‌طور که پیش‌تر بیان شد، به دنبال یافتن مقادیر هدف برای هر یک از ۴۲ زوج الگو-مقدار شیفت هستیم به طوری که هر چه تعداد مؤلفه‌های شیفت پیدا کرده و اندازه شیفت بزرگ‌تر شد، مقدار هدف بزرگ‌تر شود. به منظور تحقق این موضوع از آماره RPLR به شرح زیر بهره می‌بریم.

$$RPLR = \text{tr}(\Omega_0 S) + \ln |\hat{\Omega}_{RPLR}| - \ln |\Omega_0| - \text{tr}(\hat{\Omega}_{RPLR} S) \quad (8)$$

در رابطه (۸)، $\Omega_0 = \Sigma_0^{-1}$ معکوس ماتریس کوواریانس تحت کنترل، S ماتریس کوواریانس نمونه و عملگر $\text{tr}()$ حاصل جمع مؤلفه‌های قطر اصلی ماتریس ورودی را محاسبه می‌کند. به علاوه، $\hat{\Omega}_{RPLR}$ ماتریس دقت برآورد شده است که با استفاده از رابطه (۹) محاسبه می‌شود.

$$\hat{\Omega}_{RPLR} = \left\{ \left(\theta I_p + \frac{1}{4} (S - \theta \Omega_0)^2 \right)^{\frac{1}{2}} + \frac{1}{2} (S - \theta \Omega_0) \right\} \quad (9)$$

در رابطه (۹)، I_p یک ماتریس همانی با اندازه p (تعداد مشخصه‌های کیفی) است. همچنین θ پارامتر جریمه رویکرد تخمین RPLR بر مبنای جریمه نرم ۲ است.

نکته قابل تأمل در مورد رابطه (۸) آن است که با نزدیک شدن ماتریس کوواریانس نمونه‌ای S به ماتریس کوواریانس تحت کنترل Σ_0 ، ماتریس دقت تخمین زده‌شده $\hat{\Omega}_{RPLR}$ به سمت ماتریس دقت تحت کنترل Ω_0 میل خواهد کرد. در چنین شرایطی مقدار RPLR به سمت صفر خواهد رفت. در مقابل، با فاصله گرفتن ماتریس S از Σ_0 که می‌تواند ماحصل افزایش تعداد مؤلفه‌های شیفت پیدا کرده یا افزایش اندازه شیفت باشد، مقدار RPLR بیشتر خواهد شد.

¹ Preprocessing

² Feature Engineering

³ Sample covariance matrix

مخلفه سطر i و ستون j آن به صورت d_{ij} نمایش داده می‌شود.

$$D = S - \Sigma_0 \quad (12)$$

از آنجایی که ماتریس S تابعی از نمونه است و مؤلفه‌های آن حتی در شرایط تحت کنترل هم دقیقاً برابر با مقادیر مؤلفه‌های متناظر در Σ_0 نمی‌شود، ماتریس \hat{D} با هدف صفر شدن مقادیر مؤلفه‌های تحت کنترل به صورت معادله (۱۳) تعریف می‌شود.

$$\hat{d}_{ij} = d_{ij}(1 - |\gamma_{ij} / d_{ij}|^n)_+; i, j = 1, \dots, p \quad (13)$$

در رابطه بالا $(\cdot)_+$ عملگری است که خروجی آن در صورت مثبت بودن ورودی برابر مقدار ورودی است. در غیر این صورت، مقدار صفر را برمی‌گرداند. همچنین η یک پارامتر ثابت از پیش تعیین شده است درحالی که γ_{ij} بیانگر حد آستانه در نظر گرفته شده بر صفر کردن عناصر ماتریس \hat{D} است که به صورت زیر محاسبه خواهد شد:

$$\gamma_{ij} = \varphi \sqrt{\frac{\theta_{ij} \log p}{n}} \quad (14)$$

به طوری که φ یک ثابت غیر منفی بوده که پارامتر تنظیم نامیده می‌شود، n اندازه نمونه گرفته شده برای محاسبه ماتریس S و p تعداد مشخصه‌های کیفی تحت مطالعه یا به عبارتی اندازه ماتریس Σ_0 را نشان می‌دهند. به علاوه، θ_{ij} واریانس متغیر تصادفی \hat{d}_{ij} است که به صورت زیر برحسب مؤلفه‌های ماتریس Σ_0 محاسبه می‌شود:

$$\text{Var}(\hat{d}_{ij}) = \sigma_i^2 \sigma_j^2 + \sigma_{ij}^2 \quad (15)$$

در رابطه (۱۵)، σ_i^2 و σ_j^2 به ترتیب نشان دهنده واریانس مشخصه‌های کیفی i و j هستند. درحالی که σ_{ij} بیانگر کوواریانس بین آن‌ها است. در نهایت، آماره حد آستانه تطبیقی لاسو مطابق به شرح زیر محاسبه می‌شود:

$$\text{ATL} = n^{-1} \sum_{i=1}^p \sum_{j=1}^p \left(\frac{\hat{d}_{ij}^2}{\theta_{ij}} \right) \quad (16)$$

قابل ذکر است که ATL در بازه صفر تا مثبت بی‌نهایت تغییر می‌کند. در شرایطی که فرآیند در حالت تحت کنترل باشد معمولاً مقادیر کوچک و نزدیک به صفر خواهد شد. در مقابل هر چه تعداد مؤلفه‌های منحرف شده از مقادیر اسمی افزایش یابد یا اندازه شیفت بزرگ شود، ATL مقادیر بزرگ تری به خود می‌گیرد.

ماتریس دقت (Ω) که نشان دهنده میزان پراکندگی داده‌ها در فضای مشخصه‌های کیفی هستند مورد توجه قرار گرفتند. یادآوری می‌شود که با نزدیک شدن ماتریس کوواریانس نمونه‌ای S به ماتریس کوواریانس تحت کنترل Σ_0 ، ماتریس دقت تخمین زده شده $\hat{\Omega}_{\text{RPLR}}$ به سمت ماتریس دقت تحت کنترل Ω_0 میل خواهد کرد. در این شرایط هر دو عبارت $\Omega_0 S$ و $\hat{\Omega}_{\text{RPLR}} S$ به سمت همانی میل می‌کنند و در نتیجه اختلاف آن‌ها به سمت ماتریس صفر میل خواهد کرد. در مقابل، ماتریس S حاصل از نمونه اخذ شده از فرآیند خارج از کنترل فاصله معناداری از ماتریس Σ_0 خواهد داشت. در این شرایط $\text{tr}(\Omega_0 S) - \text{tr}(\hat{\Omega}_{\text{RPLR}} S)$ اختلاف معناداری از صفر پیدا می‌کند. بنابراین در این مطالعه Δtrace که به شرح رابطه (۱۰) محاسبه می‌شود به عنوان اولین ویژگی در طراحی شبکه عصبی مورد استفاده قرار می‌گیرد.

$$\Delta \text{trace} = \text{tr}(\Omega_0 S) - \text{tr}(\hat{\Omega}_{\text{RPLR}} S) \quad (10)$$

اختلاف لگاریتم دترمینان دو ماتریس دقت تخمین زده شده بر مبنای نمونه $\hat{\Omega}_{\text{RPLR}}$ و دقت تحت کنترل Ω_0 که به شرح زیر محاسبه می‌شود به عنوان ورودی دوم در طراحی شبکه عصبی مورد استفاده قرار می‌گیرد.

$$\Delta \log = \log(\det(\hat{\Omega}_{\text{RPLR}})) - \log(\det(\Omega_0)) \quad (11)$$

رابطه (۱۱) نشان دهنده میزان انطباق بین پراکندگی در توزیع تحت کنترل و توزیعی است که از آن نمونه اخذ شده است. اگر این اختلاف کوچک باشد، نشان دهنده آن است که نمونه از فرآیند تحت کنترل اخذ شده است. در مقابل هر چه مقدار $\Delta \log$ بزرگ تر شود، نشان دهنده آن است که انحراف با دلیل رخ داده منجر به انحراف بیشتر مؤلفه‌های ماتریس کوواریانس از مقادیر اسمی متناظرشان شده است. ویژگی سومی که به عنوان ورودی شبکه عصبی در نظر گرفته شده است، آماره حد آستانه تطبیقی لاسو^۱ است که در مطالعه عبدالله و همکاران (۲۰۱۹) ارائه شده است و به خوبی اختلاف بین ماتریس کوواریانس نمونه‌ای S و ماتریس کوواریانس تحت کنترل Σ_0 را در قالب یک اسکار بازنمایی می‌کند. به منظور محاسبه آماره مذکور، ابتدا ماتریس اختلاف^۲ از تفاوت ماتریس‌های کوواریانس نمونه‌ای و تحت کنترل به شرح زیر به دست می‌آید و

¹ Adaptive thresholding LASSO

² Difference matrix

$$z_{\Delta \log}^k = \frac{\Delta \log_k - \overline{\Delta \log}}{S_{\Delta \log}} \quad (18)$$

$$z_{\Delta TL}^k = \frac{ALT_k - \overline{ALT}}{S_{ALT}} \quad (19)$$

در روابط بالا $\Delta \log_k$ ، $\Delta trace_k$ و ALT_k مقادیر ویژگی‌های متناظر با نمونه k ام هستند. به علاوه $\overline{\Delta \log}$ ، $\overline{\Delta trace}$ و \overline{ALT} مقادیر میانگین حسابی ویژگی‌ها متناظر با داده‌های آموزش و اعتبارسنجی را نشان می‌دهند، درحالی‌که که $S_{\Delta \log}$ ، $S_{\Delta trace}$ و S_{ALT} انحراف معیار نمونه‌ای ویژگی‌ها متناظر با داده‌های آموزش و اعتبارسنجی هستند.

۳- طراحی شبکه عصبی پیشنهادی

در این بخش شبکه عصبی پیشنهادی برای پایش پراکندگی فرایندهای ابعاد بالا معرفی می‌شود. همان‌طور که در شکل ۱ مشاهده می‌شود، لایه ورودی^۱ در شبکه پیشنهادی سه مقدار نرمال شده سه ویژگی که در زیربخش ۲-۲ به آن‌ها پرداخته شد را دریافت می‌کند. اولین لایه پنهان^۲ کاملاً متصل^۳ شامل ۳۲ نورون است که ورودی‌ها را به فضایی با ابعاد بالاتر تبدیل می‌کند. این افزایش ابعاد به شبکه اجازه می‌دهد تا الگوهای پیچیده‌تری را استخراج کند. لایه دوم شامل ۱۶ نورون است که وظیفه آن کاهش ابعاد و تمرکز بر ویژگی‌های مهم‌تر است. سومین لایه کاملاً متصل نیز دارای ۸ نورون است که به تدریج ویژگی‌های استخراج شده را به فضایی با ابعاد کوچک‌تر تبدیل می‌کند. آخرین لایه از این نوع هم حاوی یک نورون است که خروجی نهایی رگرسیون را تولید می‌کند.

بیش‌برازش یک چالش رایج در یادگیری عمیق است که در آن یک شبکه عصبی روی داده‌های آموزشی عملکرد خوبی دارد اما از دقت تخمین پایینی هنگام مواجه با داده‌های جدید و دیده نشده برخوردار است. یکی از تکنیک‌های مؤثر برای مقابله با این مشکل، استفاده از لایه حذف تصادفی^۴ است. لایه مذکور با حذف تصادفی نورون‌ها در یک شبکه عصبی در طول آموزش، از بیش‌برازش جلوگیری می‌کند. در مدل پیشنهادی جهت لایه حذف تصادفی با نرخ ۰/۲ بین دو لایه کاملاً متصل با

۲-۲-۱- تقسیم داده‌ها به مجموعه‌های آموزش، اعتبارسنجی و آزمون

در این پژوهش، داده‌ها به سه مجموعه اصلی تقسیم شده‌اند: مجموعه آموزش، مجموعه اعتبارسنجی و مجموعه آزمون. این فرآیند در دو مرحله انجام شده است: مرحله اول: تقسیم داده‌ها به دو بخش آموزش+اعتبارسنجی (۸۰٪) و آزمون (۲۰٪) ابتدا کل داده‌ها به دو بخش اصلی تقسیم شده‌اند:

- مجموعه آموزش+اعتبارسنجی: این مجموعه شامل ۸۰٪ داده‌ها است و برای آموزش مدل و تنظیم پارامترهای آن استفاده می‌شود.
- مجموعه آزمون: این مجموعه شامل ۲۰٪ داده‌ها است و برای ارزیابی نهایی عملکرد مدل استفاده می‌شود.

مرحله دوم: تقسیم مجموعه آموزش+اعتبارسنجی به دو بخش آموزش (۷۰٪) و اعتبارسنجی (۳۰٪) در این مرحله، مجموعه آموزش+اعتبارسنجی به دو بخش تقسیم شده است:

- مجموعه آموزش: این مجموعه شامل ۷۰٪ داده‌ها است و برای آموزش مدل استفاده می‌شود. مدل با استفاده از این داده‌ها الگوها و روابط موجود در داده‌ها را یاد می‌گیرد.
- مجموعه اعتبارسنجی: این مجموعه شامل ۳۰٪ داده‌ها است و برای تنظیم پارامترهای مدل و ارزیابی عملکرد مدل در طول آموزش استفاده می‌شود.

۲-۲-۲- نرمال‌سازی داده‌ها با استفاده از روش

Z-Score

انتخاب روش نرمال‌سازی در پیش‌پردازش داده‌ها به منظور بهبود عملکرد مدل‌های یادگیری ماشین بسیار حائز اهمیت است. روش Z-Score داده‌ها را به گونه‌ای تغییر مقیاس می‌دهد که میانگین آن‌ها صفر و انحراف معیار آن‌ها یک شود. مقادیر نرمال شده سه ویژگی $\Delta trace$ ، $\Delta \log$ و ATL به ترتیب با استفاده از روابط (۱۷) تا (۱۹) محاسبه می‌شوند.

$$z_{\Delta trace}^k = \frac{\Delta trace_k - \overline{\Delta trace}}{S_{\Delta trace}} \quad (17)$$

¹ Input layer


² hidden layer

³ Fully connected

⁴ Dropout layer

غیرفعال می‌کند.

۱۶ و ۸ تورون قرار داده شده است. بدین ترتیب این لایه به‌طور تصادفی ۲۰٪ از نورون‌ها را در هر دوره آموزش



شکل ۱. ساختار شبکه پیشنهادی.

Figure 1. Proposed network structure.

لایه، لایه رگرسیون^۴ نام دارد. این لایه با استفاده از تابع فعال‌سازی سیگموئید، خروجی را به بازه [۰,۱] محدود می‌کند و به شبکه اجازه می‌دهد تا یک مقدار عددی پیوسته را به‌عنوان خروجی پیش‌بینی کند.

برای آموزش شبکه عصبی، از گزینه‌های آموزشی^۵ به‌عنوان آرگومان ورودی به شبکه استفاده کردیم تا با تنظیم آن‌ها به بهینه‌سازی عملکرد شبکه کمک کنیم. از این‌رو، برای بهینه‌سازی وزن‌های شبکه، از بهینه‌ساز یا الگوریتم تکثیر میانگین مربعات ریشه^۶ (RMSProp) استفاده شده است. لازم به ذکر است که تعداد دوره‌های آموزش^۷، اندازه دسته‌ها^۸ و نرخ یادگیری اولیه^۹ به ترتیب برابر با ۵۰، ۱۰۲۴ و ۰/۰۰۱ تنظیم شده‌اند. نرخ یادگیری، به نرخی اشاره دارد که یک الگوریتم با آن به یک راه‌حل همگرا می‌شود.

همان‌طور که در زیربخش ۲-۲-۱ اشاره شد، داده‌ها به سه دسته آموزشی، اعتبارسنجی و آزمون تقسیم شده‌اند؛ بنابراین برای جلوگیری از بیش‌برازش، داده‌های اعتبارسنجی در هر دوره آموزش بررسی می‌شوند و اگر خطای اعتبارسنجی به مدت ۲۰ دوره بهبود نیابد، آموزش

هنگام ساخت یک شبکه عصبی، یکی از تصمیمات کلیدی، انتخاب لایه یا تابع فعال‌سازی^۱ برای لایه‌های پنهان و لایه خروجی است. این یک تابع ریاضی است که بر خروجی یک نورون اعمال می‌شود. این تابع، غیرخطی بودن را به مدل وارد می‌کند و به شبکه اجازه می‌دهد الگوهای پیچیده در داده‌ها را یاد بگیرد. بدون این ویژگی، یک شبکه عصبی صرف‌نظر از تعداد لایه‌هایش، مانند یک مدل رگرسیون خطی رفتار خواهد کرد. در شبکه پیشنهادی از دو نوع تابع فعال‌سازی به نام‌های واحد خطی یک‌سوساز^۲ (ReLU) و سیگموئید^۳ استفاده شده است. تابع ReLU یک تابع خطی تکه‌ای است که اگر ورودی مثبت باشد، آن را مستقیماً خروجی می‌دهد؛ در غیر این صورت، صفر را خروجی می‌دهد. درحالی‌که تابع فعال‌سازی سیگموئید یک خروجی پیوسته را تضمین می‌کند که برای روش‌های بهینه‌سازی مبتنی بر گرادیان ضروری است. از آنجایی که مقدار هدف در نظر گرفته شده برای داده‌های تحت کنترل صفر و ۴۲ نوع داده خارج از کنترل مقادیری بین صفر و یک در نظر گرفته شده است، بنابراین استفاده از این تابع فعال‌سازی در لایه آخر شبکه کاملاً سازگار با ماهیت مسئله خواهد بود. با توجه به مطالب ذکر شده، لایه خروجی شبکه دارای یک نورون است که خروجی نهایی رگرسیون را تولید می‌کند، این

⁴ Regression layer

⁵ Training options

⁶ Root Mean Square Propagation

⁷ Epochs

⁸ Batch Size

⁹ Initial Learning Rate

¹ Activation Function

² Rectified Linear Unit

³ Sigmoid

MSE معیاری است که برای اندازه‌گیری میانگین مربعات اختلاف بین مقادیر پیش‌بینی‌شده و مقادیر واقعی در مجموعه داده‌ها استفاده می‌شود و مطابق با رابطه (۲۱) محاسبه می‌شود.

$$MSE = \frac{1}{n} \sum_{k=1}^n (y_k - \hat{y}_k)^2 \quad (21)$$

فرمول‌های (۲۲)، (۲۳) و (۲۴) نیز به ترتیب مقادیر مربوط به MAE، RMSE و R-squared هستند. لازم به ذکر است که در فرمول (۲۴)، SSR نشان‌دهنده مجموع مربعات اختلاف بین مقادیر پیش‌بینی‌شده و میانگین مشاهدات است، درحالی‌که SST نشان‌دهنده مجموع کل مربعات است که واریانس کل در متغیر وابسته را اندازه‌گیری می‌کند. موردتوجه است که معیار MAE میزان اختلاف مطلق بین مقادیر واقعی یک مجموعه داده و مقادیر پیش‌بینی‌شده را اندازه‌گیری می‌کند، درحالی‌که معیار R-squared درصد تغییرات متغیر وابسته را که متغیرهای مستقل شبکه در آن نقش دارند، کمی می‌کند. این معیار یک آماره مفید برای ارزیابی اثربخشی کلی و قدرت توضیحی یک مدل رگرسیون است. معیار RMSE برای اندازه‌گیری دقت یا خوبی برازش یک شبکه پیش‌بینی‌کننده است، به‌خصوص زمانی که پیش‌بینی‌ها مقادیر عددی پیوسته باشند.

$$MSE = \frac{1}{n} \sum_{k=1}^n |y_k - \hat{y}_k| \quad (22)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{k=1}^n (y_k - \hat{y}_k)^2} \quad (23)$$

$$R - \text{squared} = 1 - \frac{SSR}{SST} \quad (24)$$

۴- طراحی فرآیند پایش مبتنی بر شبکه عصبی پراکندگی فرآیندهای ابعاد بالا و مجهز کردن آن به قوانین حساس‌سازی

یادآوری می‌شود که دامنه تغییرات خروجی شبکه عصبی آموزش داده‌شده در بخش قبل بازه ۰ و ۱ است. به‌طوری‌که صفر به‌عنوان مقدار هدف داده‌های تحت کنترل و ۴۲ مقدار ارائه‌شده در جدول ۱ مقادیر هدف زوج‌های الگو-اندازه شیفت مختلف در نظر گرفته شدند. در نتیجه هنگامی که مقدار خروجی شبکه آموزش داده‌شده

متوقف می‌شود. علاوه بر این، از منظم‌سازی^۱ L₂ برای جلوگیری از یادگیری الگوهای خاص داده‌های آموزش به‌جای الگوهای عمومی توسط شبکه استفاده‌شده است. فرمول (۲۰)، معادله کلی منظم‌سازی L₂ را نشان می‌دهد؛ که در آن n تعداد نمونه‌ها، m تعداد ویژگی‌ها یعنی متغیرهای پیش‌بینی‌کننده، y_k مقدار واقعی هدف برای kامین نمونه، \hat{y}_k مقدار پیش‌بینی‌شده هدف برای kامین نمونه، w_l ضرایب ویژگی‌ها و λ پارامتر منظم‌سازی که قدرت منظم‌سازی را کنترل می‌کند. بنابراین با قرار دادن پارامتر جریمه λ برابر با ۰/۰۰۰۱ و اضافه کردن عبارت منظم‌سازی L₂ به تابع زیان، از رشد بیش‌ازحد وزن‌ها در شبکه پیشنهادی جلوگیری می‌شود.

$$\text{loss} = \frac{1}{n} \sum_{k=1}^n (y_k - \hat{y}_k)^2 + \lambda \sum_{l=1}^m w_l^2 \quad (20)$$

از آنجایی‌که در این مطالعه، شبکه عصبی برای حل یک مسئله رگرسیون مورد استفاده قرار گرفته است، در صورت عدم استفاده از منظم‌سازی L₂، میانگین مربعات خطا^۲ یا به عبارتی جمله اول رابطه (۲۰) به‌عنوان تابع زیان در نظر گرفته می‌شد. به‌عبارت‌دیگر، وزن‌های شبکه به‌وسیله الگوریتم RMSProp به‌گونه‌ای تنظیم می‌شدند که صرفاً میانگین مربع خطا مینیمم شود. استفاده از منظم‌سازی L₂ معادل اضافه شدن جمله دوم رابطه (۲۰) به تابع زیان است. تحت این شرایط، وزن‌های شبکه به‌گونه‌ای انتخاب می‌شوند که تحت کوچک‌ترین مقیاس ممکن آن‌ها، میانگین مربعات خطا حداقل شود.

۳-۱- ارزیابی عملکرد شبکه پیشنهادی

ارزیابی عملکرد یک شبکه عصبی شامل سنجش میزان موفقیت آن در تعمیم به داده‌های دیده نشده و برآورده کردن الزامات مسئله است. در مسئله رگرسیون معمولاً با استفاده از چهار شاخص میانگین مربعات خطا (MSE)، میانگین خطای مطلق^۳ (MAE)، جذر میانگین مربعات خطا^۴ (RMSE) و ضریب تعیین^۵ (R-squared) خطاهای پیش‌بینی را کمی می‌کنند. در ادامه شاخص‌های ذکرشده به‌طور اجمالی معرفی می‌شوند.

¹ L2 regularization

² Mean square error

³ mean absolute error

⁴ Root Mean Squared Error

⁵ Coefficient of Determination

استفاده از نسخه بهبودیافته رویکرد پایش مبتنی بر شبکه عصبی شرح داده شده است.

۵- مطالعه شبیه‌سازی عملکرد نمودارهای پیشنهادی مبتنی بر شبکه عصبی برای پایش پراکندگی فرآیندهای ابعاد بالا

در کنترل فرآیند آماری، عملکرد رویکردهای پایش در فاز ۲ بر اساس ویژگی‌های طول دنباله (متوسط و انحراف معیار) در حالت خارج از کنترل ارزیابی می‌شود. طول دنباله نشان‌دهنده تعداد نمونه‌ها تا صدور هشدار است و مقادیر کمتر آن به معنای شناسایی سریع‌تر انحرافات است. این بخش به مقایسه عملکرد نمودارهای کنترل مبتنی بر شبکه‌های عصبی با روش‌های حد آستانه تطبیقی لاسو و نسبت درست‌نمایی توانیده لبه‌ای می‌پردازد. برای این منظور، شاخص‌های مذکور بر اساس ۱۰۰۰۰ تکرار شبیه‌سازی مونت‌کارلو در نرم‌افزار متلب نسخه ۲۰۲۳ محاسبه می‌شوند. همچنان که در بخش قبل ذکر شد، فرض می‌شود که خروجی فرآیند بر اساس ۱۰ مشخصه کیفی نرمال توصیف می‌شود و وقوع انحراف با دلیل صرفاً پراکندگی مشخصه‌های کیفی مورد مطالعه را تغییر می‌دهد. به عبارت دیگر، بردار میانگین برابر با $\mu_{10 \times 1} = (0, 0, \dots, 0)^T$ در نظر گرفته می‌شود در حالی که ماتریس کوواریانس فرآیند صرفاً در شرایطی که فرآیند در حالت تحت کنترل آماری باشد به صورت

$$\Sigma_0 = \begin{pmatrix} 1 & 0 & \dots & 0 \\ 0 & 1 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 1 \end{pmatrix}$$

می‌باشد. پارامترهای انقباض و

تنظیم آماره ATL به ترتیب برابر $\eta = 4$ و $\varphi = 1$ در نظر گرفته می‌شوند، حال آنکه پارامتر جریمه آماره RPLR برابر $\theta = 10$ لحاظ می‌شود. در نهایت قابل ذکر است که در هر بار نمونه‌گیری، نمونه‌ای به اندازه $n = 5$ اخذ می‌شود.

به منظور انجام مقایسات عادلانه، ابتدا مقدار حد کنترل بالای هر چهار نمودار به گونه‌ای تعیین می‌شود که مقدار متوسط طول دنباله تحت کنترل برابر با $ARL_0 = 200$ شود. تحت شرایط مذکور، به طور متوسط یک هشدار اشتباه در هر ۲۰۰ بار نمونه‌گیری صادر می‌شود. نتایج حاصل برای رویکردهای پایش RPLR و ATL بر اساس

کوچک باشد قاعداً فرآیند باید تحت کنترل قلمداد شود، در حالی که افزایش خروجی آن از یک حد آستانه منجر به صدور هشدار خارج از کنترل شود. به عبارت دیگر فرآیند پایش مبتنی بر شبکه عصبی آموزش داده شده فقط شامل یک حد کنترل بالا^۱ (UCL) خواهد شد. در این مطالعه، مقدار حد کنترل بالا با استفاده از شبیه‌سازی مونت‌کارلو طوری تعیین می‌شود که مقدار متوسط طول دنباله^۲ تحت کنترل فرآیند پایش برابر با مقدار از پایش تعیین شده $ARL_0 = \frac{1}{\alpha}$ شود. قابل ذکر است که α مقدار احتمال خطای نوع ۱ را نشان می‌دهد که بر اساس نظر مهندس کنترل کیفیت تعیین می‌شود. قوانین حساس‌سازی در نمودارهای کنترل برای شناسایی الگوهای غیر تصادفی در داده‌ها استفاده می‌شوند. این قوانین به تشخیص تغییرات روندها و سایر الگوهای غیرمعمول فراتر از آنچه از تغییرات تصادفی انتظار می‌رود، کمک می‌کنند. از این رو در این بخش، نسخه بهبودیافته‌ای از نمودار کنترل پیشنهادی مبتنی بر شبکه عصبی، با مجهز کردن آن به دو قانون حساس‌سازی برگرفته از قوانین وسترن الکتریک توسعه داده شده است. در این ارتباط مطابق با شکل ۲، دو حد هشدار بالا^۳ $UWL_1 = \frac{2}{3} \times UCL$ و $UWL_2 = \frac{1}{3} \times UCL$ مورد استفاده قرار می‌گیرند. یادآوری می‌شود که در نمودار کنترل اولیه پیشنهادی فقط زمانی هشدار خارج از کنترل صادر می‌شود که خروجی شبکه عصبی متناظر با یک نمونه تصادفی بالاتر از UCL قرار گیرد. حال آنکه در نسخه بهبودیافته همان‌طور که در شکل ۲ قابل مشاهده است، این هشدار علاوه بر شرایط ذکر شده در دو حالت دیگر نیز صادر خواهد شد: ۱- خروجی شبکه عصبی متناظر با دو نمونه از سه نمونه آخر بالاتر از UWL_1 قرار گیرند، که از این پس این قانون را قانون ۲ از ۳ می‌نامیم؛ ۲- خروجی شبکه عصبی متناظر با چهار نمونه از پنج نمونه آخر بالاتر از UWL_2 قرار گیرد، که از این پس آن را قانون ۴ از ۵ می‌نامیم. قابل ذکر است که از این پس رویکرد پایش مجهز شده به دو قانون حساس‌سازی توسعه داده شده به صورت NN-RR نام‌گذاری می‌شود. در نهایت در جدول ۲ شبه کد مرتبط با نحوه محاسبه متوسط طول دنباله^۴ (ARL) و انحراف معیار طول دنباله^۵ (SDRL) با

¹ Upper control limit

² Average run length

³ Upper warning limit

⁴ Average run length

⁵ Standard deviation of run length

معیار طول دنباله به صورت مجزا گزارش شده است و (۲) از آنجایی که نتایج به دست آمده بر اساس شبیه‌سازی مونت کارلو است، رتبه دو رویکرد پایش در صورتی متفاوت از هم قلمداد شده است که حداقل ۰.۵ درصد با یکدیگر تفاوت داشته باشند. در غیر این صورت اختلاف موجود خطای ناشی از شبیه‌سازی در نظر گرفته شده و به دو رویکرد رتبه یکسان داده می‌شود.

نتایج گزارش شده در جداول ۳ و ۴ نشان می‌دهند که تحت الگوی خارج از کنترل ۱ که منجر به شیفت‌های توأم غیرپراکنده می‌شود، هنگام رخداد شیفت‌های کوچک (یعنی $\Delta = 0.1, 0.2$) استفاده از آماره ATL منجر به کشف سریع‌تر رخداد انحراف با دلیل در مقایسه با سه رویکرد دیگر می‌شود. درحالی‌که به ازای شیفت‌های متوسط (یعنی $\Delta = 0.3, 0.5$) رویکرد پایش NN-RR بهترین عملکرد را از خود نشان می‌دهد. به ازای شیفت‌های بزرگ (یعنی $\Delta = 0.75, 1$) به طور مشترک بهترین عملکرد را دو رویکرد پایش مبتنی بر شبکه عصبی NN و NN-RR از خود نشان می‌دهند. نتایج ارائه شده در جداول ۵ و ۶ تأیید می‌کنند که به ازای تمامی اندازه شیفت‌ها ضعیف‌ترین عملکرد را نمودار RPLR در کشف الگوی خارج از کنترل ۲ داشته است. در مقابل، بهترین عملکرد به ازای اندازه شیفت‌های $\Delta = 0.1$ و $\Delta = 0.2$ را به ترتیب رویکردهای پایش NN و ATL داشته‌اند. درحالی‌که به ازای اندازه شیفت‌های متوسط و بزرگ بهترین عملکرد به رویکرد پایش NN-RR تعلق دارد. با دقت به نتایج جداول ۳ تا ۶ و یادآوری این موضوع که دو الگوی خارج از کنترل ۱ و ۲ معادل با شیفت‌های توأم غیرپراکنده هستند با این تفاوت که تحت الگوی ۲ تعداد کمتری از عناصر ماتریس واریانس-کوواریانس از مقادیر اسمی منحرف می‌شوند، می‌توان به نتایج زیر دست یافت: از یک طرف با افزایش تعداد مؤلفه‌های ماتریس که تحت تأثیر رخداد انحراف با دلیل قرار می‌گیرند و از طرف دیگر با کاهش اندازه شیفت، نمودار ATL عملکرد بهتری نسبت به رقبا از خود نشان می‌دهد. در مقابل هر چه تعداد مؤلفه‌های شیفت پیدا کرده کاهش پیدا کنند و اندازه شیفت افزایش یابد، دو رویکرد پایش مبتنی بر شبکه عصبی NN و NN-RR عملکرد بهتری در مقایسه با رقبا خواهند داشت.

از آنجایی که تفاوت الگوی خارج از کنترل ۳ با دو الگوی اول فقط کاهش چشمگیر تعداد مؤلفه‌های متأثر از رخداد

شبیه‌سازی مونت کارلو با ۱۰۰۰۰ بار تکرار به ترتیب برابر با ۴/۸۱۰۴، ۹/۲۱۶۹ می‌شود. از آنجایی که زمان اجرای الگوریتم‌های NN و NN-RR کمی طولانی است، به منظور کاهش زمان لازم برای پیدا کردن حد کنترل بالای مناسب، ابتدا یک مقدار اولیه برای آن‌ها محاسبه می‌کنیم. برای این منظور ابتدا ۱۰۰۰۰ نمونه تحت کنترل تولید می‌شود و مقادیر سه ویژگی Δtrace ، $\Delta \log$ و ATL به ازای هر نمونه محاسبه می‌شوند. سپس، مقادیر به دست آمده نرمال می‌شوند و به عنوان ورودی به شبکه عصبی آموزش داده شده وارد می‌شوند. مقادیر خروجی از کوچک به بزرگ مرتب می‌شوند و ۹۹۵۰ امین عنصر به عنوان مقدار اولیه حد کنترل بالای نمودارهای NN و NN-RR در نظر گرفته می‌شود. با اجرای گام‌های ذکر شده مقدار اولیه حد کنترل بالا برابر با ۰/۳۲۸۵ به دست می‌آید. حال با انجام تعداد بار کمتری از فرآیند سعی و خطا^۱ بر اساس ۱۰۰۰۰ بار شبیه‌سازی مونت کارلو مقدار حد کنترل بالای نمودارهای NN و NN-RR به ترتیب برابر با ۰/۳۳۴۱ و ۰/۳۸۲۱ به دست می‌آید. مطابق انتظار حد کنترل بالای رویکرد پایش NN-RR از NN مقدار بیشتری شد چراکه در رویکرد پایش NN فقط زمانی سیگنال خارج از کنترل صادر می‌شود که خروجی شبکه متناظر با یک نمونه بیشتر از حد کنترل بالا شود درحالی‌که در رویکرد NN-RR در سه حالت فرآیند خارج از کنترل قلمداد می‌شود: (۱) خروجی شبکه فراتر از حد کنترل بالا رود، (۲) حداقل دو خروجی از سه خروجی آخر شبکه بالاتر از حد هشدار اول باشند و (۳) حداقل چهار خروجی از پنج خروجی آخر شبکه بالاتر از حد هشدار دوم باشند.

مقادیر متوسط و انحراف معیار طول دنباله چهار رویکرد پایش پراکندگی به ازای $\Delta \in \{0, 0.1, 0.2, 0.3, 0.5, 0.75, 1\}$ تحت الگوهای خارج از کنترل ۱ تا ۷ به ترتیب در جداول ۳، ۵، ۷، ۹، ۱۱، ۱۳ و ۱۵ خلاصه شده است. به علاوه در جداول ۴، ۶، ۸، ۱۰، ۱۲، ۱۴ و ۱۶، رتبه عملکردی هر یک از چهار رویکرد پایش تحت همان مقادیر شیفت ذکر شده به ترتیب به ازای الگوهای خارج از کنترل ۱ تا ۷ گزارش شده است. در مورد جداول مذکور دو نکته حائز اهمیت است: (۱) رتبه رویکردهای پایش به ازای دو شاخص متوسط و انحراف

^۱ Try and error

انحراف با دلیل است، بر اساس نتیجه گرفته‌شده از توان نمودارهای کنترل تحت مطالعه برای کشف شیفت‌های توأم غیرپراکنده قابل پیش‌بینی است که عملکرد رویکردهای پایش NN و NN-RR به‌خصوص با افزایش اندازه شیفت برای شناسایی شیفت‌های توأم پراکنده بهتر از دو نمودار رقیب RPLR و ATL باشد. نتایج ارائه‌شده در جداول ۷ و ۸ پیش‌بینی ذکرشده را به‌طور دقیق تأیید می‌کنند. همچنان که مشاهده می‌شود در شرایطی که مقدار شیفت $\Delta = 0.1$ است بهترین عملکرد را رویکرد پایش NN داشته است درحالی‌که به ازای سایر مقادیر Δ ، نمودار NN-RR سریع‌تر از سایر رویکردها رخداد انحراف با دلیل تحت الگو خارج از کنترل توأم پراکنده ۳ را کشف کرده است.

با بررسی نتایج گزارش‌شده در جداول ۹ تا ۱۲ می‌توان نتیجه گرفت که رویکردهای پایش مبتنی بر شبکه عصبی توسعه داده‌شده در این مطالعه به‌طور محسوسی توان بالاتری از نمودارهای کنترل رقیب RPLR و ATL برای کشف شیفت‌های قطری دارند. تقریباً به ازای تمامی مقادیر شیفت تحت هر دو الگو قطری ۴ و ۵، بهترین و بدترین عملکرد برحسب هر دو شاخص میانگین و انحراف معیار طول دنباله به ترتیب به رویکردهای NN-RR و ATL تعلق دارد. نتایج جداول ۳ تا ۱۲ نشان می‌دهند که درصد بهبود عملکرد نمودارهای NN و NN-RR در مقایسه با نمودارهای RPLR و ATL هنگام رخداد الگوهای قطری به‌مراتب محسوس‌تر از الگوهای توأم است.

نتایج جداول ۱۳ و ۱۴ نشان می‌دهند که هنگام رخداد الگوی غیرقطری غیرپراکنده بهترین عملکرد بین نمودارهای کنترل رقیب به ازای اندازه شیفت کوچک $\Delta = 0.1$ به رویکرد پایش NN تعلق دارد. درحالی‌که نمودار ATL در زودترین زمان اندازه شیفت‌های متوسط $\Delta = 0.2, 0.3, 0.5$ را کشف می‌کند و نهایتاً توان نمودار NN-RR برای کشف شیفت‌های بزرگ $\Delta = 0.75, 1$ از بقیه رویکردهای پایش بیشتر است.

مقادیر متوسط و انحراف معیار طول دنباله نمودارهای رقیب تحت الگوی خارج از کنترل غیرقطری پراکنده در جداول ۱۵ و ۱۶ گزارش‌شده‌اند. نتایج به‌دست‌آمده حساسیت بیشتر نمودار NN به رخداد شیفت‌ها با اندازه

در جدول ۱۷ یک الگوی گزارش به‌صورت $d/c/b/a$ مورد استفاده قرار گرفته است. در این ساختار a, b, c و d به ترتیب نشان‌دهنده تعداد دفعاتی است که یک رویکرد پایش به ترتیب حائز رتبه‌های ۱، ۲، ۳ و ۴ شده است. نتایج جدول ۱۷ نشان می‌دهد که به‌طور کلی رویکردهای پایش NN-RR، NN، ATL و RPLR به ترتیب بهترین عملکرد را در کشف انحراف با دلیل رخ داده برحسب هر دو شاخص متوسط و انحراف معیار طول دنباله داشته‌اند. به‌طور خاص، در الگوهای خارج از کنترل قطری (الگوهای ۴ و ۵) همواره یکی از دو رویکرد مبتنی بر شبکه عصبی NN-RR یا NN حائز رتبه ۱ شده‌اند. آماره RPLR معمولاً رتبه ۳ و آماره ATL رتبه ۴ را کسب کرده‌اند. به‌عبارت‌دیگر در شرایطی که رخداد انحراف با دلیل صرفاً منجر به تغییر در واریانس مشخصه‌های کیفی تحت مطالعه می‌شود، رویکرد پایش NN-RR به‌طور معناداری حائز بیشترین رتبه ۱ شده است. عملکرد رویکردهای پایش برای کشف تغییرات غیر قطری به‌طور کامل با الگوهای خارج از کنترل قطری متفاوت است. آماره RPLR با اختلاف معناداری حائز بیشترین رتبه ۴ در میان رویکردهای پایش تحت مطالعه برای کشف تغییرات غیر قطری است حال‌آنکه همچنان رویکرد پایش NN-RR از بیشترین رتبه ۱ برخوردار است. آماره ATL به ازای بیشتر اندازه شیفت‌ها دارای رتبه ۲ و رویکرد پایش NN بیشترین تعداد رتبه ۳ را به خود اختصاص داده است. در مورد شیفت‌های توأم قطری-غیرقطری قابل‌ذکر است که مشابه با شیفت‌های قطری رویکردهای پایش NN و NN-RR به ترتیب حائز بیشترین رتبه‌های ۱ و ۲ هستند درحالی‌که در اکثر موارد رتبه‌های ۳ و ۴ به ترتیب به آماره‌های ATL و RPLR اختصاص داده شده است. هنگام رخداد شیفت‌های پراکنده یا به عبارتی در شرایطی که رخداد انحراف با دلیل منجر به انحراف تعداد کمی از مؤلفه‌های ماتریس واریانس-کوواریانس از مقادیر اسمی متناظرشان می‌شود، بیشترین تعداد رتبه‌های ۱ تا ۴ به رویکردهای پایش NN-RR، NN، ATL و RPLR اختصاص داده می‌شود.

با بررسی نتایج گزارش‌شده در جداول ۹ تا ۱۲ می‌توان نتیجه گرفت که رویکردهای پایش مبتنی بر شبکه عصبی توسعه داده‌شده در این مطالعه به‌طور محسوسی توان بالاتری از نمودارهای کنترل رقیب RPLR و ATL برای کشف شیفت‌های قطری دارند. تقریباً به ازای تمامی مقادیر شیفت تحت هر دو الگو قطری ۴ و ۵، بهترین و بدترین عملکرد برحسب هر دو شاخص میانگین و انحراف معیار طول دنباله به ترتیب به رویکردهای NN-RR و ATL تعلق دارد. نتایج جداول ۳ تا ۱۲ نشان می‌دهند که درصد بهبود عملکرد نمودارهای NN و NN-RR در مقایسه با نمودارهای RPLR و ATL هنگام رخداد الگوهای قطری به‌مراتب محسوس‌تر از الگوهای توأم است.

نتایج جداول ۱۳ و ۱۴ نشان می‌دهند که هنگام رخداد الگوی غیرقطری غیرپراکنده بهترین عملکرد بین نمودارهای کنترل رقیب به ازای اندازه شیفت کوچک $\Delta = 0.1$ به رویکرد پایش NN تعلق دارد. درحالی‌که نمودار ATL در زودترین زمان اندازه شیفت‌های متوسط $\Delta = 0.2, 0.3, 0.5$ را کشف می‌کند و نهایتاً توان نمودار NN-RR برای کشف شیفت‌های بزرگ $\Delta = 0.75, 1$ از بقیه رویکردهای پایش بیشتر است.

مقادیر متوسط و انحراف معیار طول دنباله نمودارهای رقیب تحت الگوی خارج از کنترل غیرقطری پراکنده در جداول ۱۵ و ۱۶ گزارش‌شده‌اند. نتایج به‌دست‌آمده حساسیت بیشتر نمودار NN به رخداد شیفت‌ها با اندازه

نتایج جداول ۱۳ و ۱۴ نشان می‌دهند که هنگام رخداد الگوی غیرقطری غیرپراکنده بهترین عملکرد بین نمودارهای کنترل رقیب به ازای اندازه شیفت کوچک $\Delta = 0.1$ به رویکرد پایش NN تعلق دارد. درحالی‌که نمودار ATL در زودترین زمان اندازه شیفت‌های متوسط $\Delta = 0.2, 0.3, 0.5$ را کشف می‌کند و نهایتاً توان نمودار NN-RR برای کشف شیفت‌های بزرگ $\Delta = 0.75, 1$ از بقیه رویکردهای پایش بیشتر است.

مقادیر متوسط و انحراف معیار طول دنباله نمودارهای رقیب تحت الگوی خارج از کنترل غیرقطری پراکنده در جداول ۱۵ و ۱۶ گزارش‌شده‌اند. نتایج به‌دست‌آمده حساسیت بیشتر نمودار NN به رخداد شیفت‌ها با اندازه

از شبیه‌سازی نشان داد که رویکردهای مبتنی بر شبکه عصبی (NN و NN-RR) عملکرد بهتری نسبت به روش‌های مرسوم مانند RPLR و ATL دارند. به‌طور خاص، NN-RR به ازای بیشتر زوج اندازه شیفت-الگو خارج از کنترل بهترین عملکرد را داشته و به‌عنوان برترین رویکرد برای کشف انحرافات با دلیل شناخته شد. علاوه بر این، نتایج نشان می‌دهند که بهبود عملکرد رویکردهای مبتنی بر شبکه عصبی نسبت به روش‌های آماری مرسوم با افزایش تعداد مؤلفه‌های تحت تأثیر انحراف با دلیل محسوس‌تر می‌شود. درنهایت، این پژوهش نشان می‌دهد که استفاده از ابزارهای یادگیری ماشین می‌تواند به‌عنوان یک راه‌حل مؤثر برای مقابله با چالش‌های پایش فرآیندهای با ابعاد بالا مطرح شود و به بهبود کیفیت و کاهش ضایعات در صنایع مختلف کمک کند.

برای تحقیقات آینده، توسعه رویکردهایی مبتنی بر ابزارهای یادگیری ماشین برای پایش توأم بردار میانگین و ماتریس کوواریانس فرآیندهای ابعاد بالا پیشنهاد می‌شود. همچنین، بهبود معماری شبکه عصبی با به‌کارگیری لایه‌های LSTM برای پایش فرآیندها با مشخصه‌های کیفی خودهمبسته می‌تواند موضوعی جذاب محسوب شود. علاوه بر این، استفاده از الگوریتم‌های ترکیبی یادگیری عمیق و تقویتی می‌تواند به حل چالش‌های موجود در پایش فرآیندهای غیرخطی کمک کند. بررسی تأثیر خطاهای اندازه‌گیری بر عملکرد نمودارهای کنترل مبتنی بر ابزارهای یادگیری ماشین نیز می‌تواند به‌عنوان یک زمینه تحقیقاتی جدید مطرح شود. همچنین، توسعه روش‌های خودآغازگر بر اساس شبکه‌های عصبی برای شرایط بدون داده مرجع می‌تواند کاربردپذیری را افزایش دهد. استفاده از قوانین حساس‌سازی پیشرفته‌تر و بهینه‌سازی پارامترها با الگوریتم‌های فراابتکاری نیز پیشنهاد می‌شود. درنهایت، مقایسه عملکرد این روش‌ها با رویکردهای کلاسیک در شرایط مختلف صنعتی می‌تواند بینش‌های جدیدی ارائه دهد.

مشارکت‌های نویسندگان

همه نویسندگان در مقاله نقش و سهم یکسان داشته‌اند. **میلاذ قزوینی:** طراحی مدل مفهومی پژوهش، بررسی پیشینه و مبانی نظری، تحلیل داده‌ها، نگارش پیش‌نویس

درنهایت قابل‌ذکر است که در شناسایی شیفت‌های غیرپراکنده رویکرد پایش NN-RR و آماره RPLR به ترتیب به‌طور واضحی بهترین و ضعیف‌ترین عملکرد را در میان رویکردهای پایش تحت مطالعه از خود نشان داده‌اند درحالی‌که دو رویکرد پایش NN و ATL نسبتاً عملکرد پایایی از خود نشان داده‌اند.

۶- نتیجه‌گیری

با پیشرفت فناوری و افزایش تعداد مشخصه‌های کیفی در فرآیندهای تولیدی و خدماتی، پایش دقیق پراکندگی به یکی از چالش‌های اصلی در حوزه کنترل کیفیت آماری تبدیل شده است. به‌ویژه فرآیندهای با ابعاد بالا که در آن تعداد مشخصه‌های کیفی بیشتر از اندازه نمونه‌های قابل جمع‌آوری است، در این زمینه دشواری‌های خاص خود را دارند. در چنین فرآیندهایی، احتمال نقض محدودیت‌های آماری از جمله نرمال بودن توزیع داده‌ها و استقلال نمونه‌ها که روش‌های سنتی پایش کیفیت مبتنی بر آن‌ها بنا نهاده شده‌اند بسیار بالا است. این موضوع منجر به کاهش دقت و حساسیت نمودارهای کنترل در کشف انحرافات با دلیل می‌شود؛ بنابراین، توسعه روش‌هایی که بتوانند بدون وابستگی به این فرضیات محدودکننده، عملکرد قابل قبولی در پایش پراکندگی فرآیندهای با ابعاد بالا ارائه دهند، از اهمیت بالایی برخوردار است.

در این پژوهش، یک نمودار کنترل مبتنی بر شبکه عصبی مصنوعی برای پایش پراکندگی فرآیندهای با ابعاد بالا ارائه شده است. این رویکرد به دلیل عدم وابستگی به فرضیات مرسوم، قادر است در شرایط مختلفی از جمله فرآیندهای غیرنرمال و وابستگی نمونه‌ها عملکرد قابل قبولی از خود نشان دهد. علاوه بر این، برای افزایش توان نمودار کنترل، از قوانین حساس‌سازی استفاده شده است. این قوانین با اضافه کردن شرایط اضافی برای صدور هشدار خارج از کنترل، توانایی کشف اختلالات رخ داده در فرآیند را بهبود می‌بخشند. همچنین، برای جلوگیری از بیش‌برازش شبکه عصبی، از تکنیک‌هایی مانند لایه حذف تصادفی و منظم‌سازی وزن استفاده شده است. این تکنیک‌ها به شبکه عصبی اجازه می‌دهند تا الگوهای عمومی فرآیند را بهتر درک کند و عملکرد بهتری در مواجهه با داده‌های جدید از خود نشان دهد. نتایج حاصل

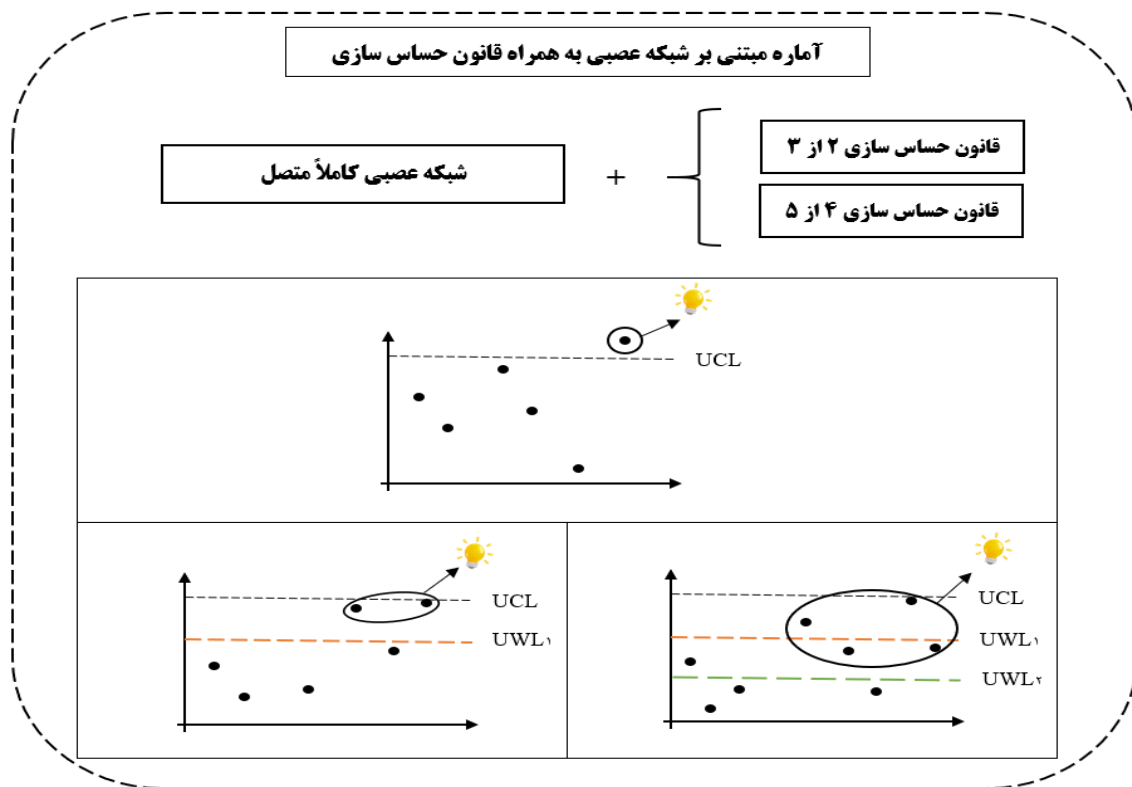
تضاد منافع

نویسندگان اعلام می‌کنند که هیچ‌گونه تضاد منافع مرتبط با تحقیق حاضر ندارند و نتایج به‌صورت بی‌طرفانه و بدون دخالت منافع شخصی یا حرفه‌ای به‌دست‌آمده است.

قدردانی

نویسندگان از عوامل اجرایی نشریه مهندسی سیستم و بهره‌وری قدردانی می‌نمایند.

تحلیل آماری، نگارش نسخه اولیه مقاله، بازبینی اولیه گزارش، توسعه روش‌شناسی پژوهش، و بازنگری متن. **علی سلماس‌نیا:** طراحی مدل مفهومی پژوهش، بررسی پیشینه و مبانی نظری، تحلیل داده‌ها، نگارش پیش‌نویس تحلیل آماری، نگارش نسخه اولیه مقاله، بازبینی اولیه گزارش، توسعه روش‌شناسی پژوهش، و بازنگری متن.



شکل ۲. نسخه بهبودیافته‌ای از نمودار کنترل پیشنهادی مبتنی شبکه عصبی با مجهز شدن به دو قانون حساس‌سازی.

Figure 2. An improved version of the proposed neural network-based control chart equipped with two sensitization rules.

جدول ۱. مقادیر هدف در فرآیند آموزش شبکه‌های عصبی به ازای ترکیب‌های مختلف اندازه شیفت-الگوی خارج از کنترل

Table 1. Target values in the neural network training process for different out-of-control pattern-shift size combinations

Δ	۱	۲	۳	۴	۵	۶	۷
۰/۱	۰/۱۹۳۵	۰/۱۸۶۵	۰/۱۸۵۰	۰/۱۸۵۴	۰/۱۸۳۶	۰/۱۸۴۰	۰/۱۸۱۹
۰/۲	۰/۲۲۶۲	۰/۱۹۶۰	۰/۱۸۶۸	۰/۱۹۷۰	۰/۱۸۴۴	۰/۱۹۰۹	۰/۱۸۳۹
۰/۳	۰/۲۸۰۳	۰/۲۱۴۹	۰/۱۹۰۴	۰/۲۱۷۱	۰/۱۸۵۷	۰/۱۹۸۷	۰/۱۸۵۴
۰/۵	۰/۴۲۲۸	۰/۲۷۰۰	۰/۲۰۶۳	۰/۲۸۳۰	۰/۱۹۲۴	۰/۲۲۴۵	۰/۱۸۶۸
۰/۷۵	۰/۶۸۴۳	۰/۳۸۱۲	۰/۲۳۸۰	۰/۴۴۴۲	۰/۲۰۶۲	۰/۲۶۹۲	۰/۱۹۴۵
۱/۰	۱/۰۰۰۰	۰/۵۳۵۴	۰/۲۸۹۹	۰/۷۲۲۰	۰/۲۲۷۱	۰/۳۳۳۶	۰/۲۰۰۲

جدول ۲. رویکرد پیش NN-RR

Table 2. NN-RR monitoring approach

<p>(۴) شبیه‌سازی و ارزیابی عملکرد</p> <ul style="list-style-type: none"> • برای هر تکرار (Q بار): • تا زمانی که شرایط خروج برقرار نباشد (هیچ یک از سه شرط صدور هشدار رخ نداده باشد): • تولید داده‌های جدید با استفاده از توزیع نرمال چندمتغیره. • استخراج ویژگی‌ها ($\Delta \log$, Δtrace, ΔATL). • نرمال‌سازی ویژگی‌ها. • پیش‌بینی با استفاده از شبکه عصبی. • شمارش تعداد تکرارها تا رسیدن به شرط خروج (RL). 	<p>(۱) مقاردهای اولیه</p> <ul style="list-style-type: none"> • تنظیم پارامترهای اولیه (اندازه نمونه، تعداد مشخصه‌های کیفی، پارامترهای آماره‌های ATL و RPLR، بردار میانگین و ماتریس کوواریانس داده‌های تحت کنترل). • تعیین حدود کنترل (UCL, JWL_1, JWL_2, UCL) و تعداد تکرارها (Q)
<p>(۵) محاسبه معیارهای ارزیابی</p> <ul style="list-style-type: none"> • محاسبه میانگین طول دنباله (ARL) و انحراف معیار طول دنباله (SDRL). 	<p>(۲) تعریف ماتریس کوواریانس خارج از کنترل</p> <ul style="list-style-type: none"> • ساخت ماتریس کوواریانس بر اساس یک الگوی خارج از کنترل مشخص.
<p>(۶) نمایش نتایج</p> <ul style="list-style-type: none"> • چاپ مقادیر ARL، SDRL. • بازگرداندن نتایج ارزیابی. 	<p>(۳) بارگذاری شبکه آموزش دیده</p> <ul style="list-style-type: none"> • بارگذاری شبکه عصبی آموزش دیده.

جدول ۳. مقایسه ARL و SDRL رویکردهای RPLR، ATL، NN و NN-RR در شرایط $n = 5$ و $p = 10$ تحت الگو ۱

Table 3. Comparison of ARL and SDRL of RPLR, ATL, NN and NN-RR approaches in conditions of $n=5$ and $p=10$ under model 1

رویکرد پیش	شاخص	Δ					
		۰	۰/۱	۰/۲	۰/۳	۰/۵	۰/۷۵
RPLR	ARL	۲۰۰/۰۲۷۴	۷۱/۸۰۸۹	۱۸/۹۲۳۶	۷/۹۳۱۵	۳/۲۰۸۴	۱/۳۰۳۶
	SDRL	۱۹۸/۳۷۶۸	۶۹/۲۳۰۸	۱۸/۵۰۸۴	۷/۵۴۴۹	۲/۶۹۸۱	۰/۶۱۷۲
ATL	ARL	۲۰۰/۱۴۸۶	۶۶/۰۶۴۶	۱۶/۷۰۴۷	۷/۷۲۳۲	۳/۱۱۴۸	۱/۳۱۰۷
	SDRL	۱۹۹/۶۶۷۲	۶۶/۶۰۷۲	۱۶/۴۳۴۹	۷/۵۶۲۱	۲/۳۳۲۷	۰/۶۳۸۰
NN	ARL	۱۹۹/۷۰۸۹	۷۱/۱۰۸۹	۱۸/۷۳۳۳	۷/۷۲۰۴	۳/۲۰۶۵	۱/۲۹۸۴
	SDRL	۱۹۹/۶۸۲۴	۶۹/۲۳۶۱	۱۸/۱۳۸۵	۷/۵۴۸۲	۲/۶۸۵۲	۰/۶۰۴۷
NN-RR	ARL	۱۹۹/۶۹۴۸	۷۰/۴۵۵۲	۱۸/۴۶۰۴	۷/۷۱۸۱	۳/۱۰۹۵	۱/۲۹۴۲
	SDRL	۱۹۹/۶۳۶۱	۶۹/۲۱۵۷	۱۷/۲۷۴۵	۶/۷۵۱۳	۲/۳۲۶۲	۰/۶۰۱۸

جدول ۴. رتبه رویکردهای RPLR، ATL، NN و NN-RR بر حسب ARL و SDRL تحت الگو ۱

Table 4. Ranking of RPLR, ATL, NN and NN-RR approaches in terms of ARL and SDRL under Model 1

رویکرد پیش	شاخص	Δ					
		۰	۰/۱	۰/۲	۰/۳	۰/۵	۰/۷۵
RPLR	ARL	۴	۴	۴	۴	۲	۳
	SDRL	۲	۲	۴	۲	۴	۳
ATL	ARL	۱	۱	۱	۲	۲	۴
	SDRL	۱	۱	۱	۲	۲	۴
NN	ARL	۲	۲	۳	۲	۲	۱
	SDRL	۲	۲	۳	۲	۳	۱
NN-RR	ARL	۲	۲	۲	۱	۱	۱
	SDRL	۲	۲	۲	۱	۱	۱

جدول ۵. مقایسه ARL و SDRL رویکردهای RPLR، ATL، NN و NN-RR در شرایط $n = 5$ و $p = 10$ تحت الگو ۲

Table 5. Comparison of ARL and SDRL of RPLR, ATL, NN and NN-RR approaches in conditions of $n=5$ and $p=10$ under model 2

رویکرد پایش	شاخص	Δ					
		۰	۰/۱	۰/۲	۰/۳	۰/۵	۰/۷۵
RPLR	ARL	۲۰۰/۰۲۷۴	۱۵۱/۷۱۵۴	۷۳/۴۵۹۲	۳۳/۲۷۲۷	۱۰/۲۰۸۶	۳/۹۷۰۲
	SDRL	۱۹۸/۳۷۶۸	۱۵۶/۹۳۵۹	۷۵/۵۴۵۴	۳۳/۱۰۸۱	۹/۶۷۰۹	۳/۳۴۲۷
ATL	ARL	۲۰۰/۱۴۸۶	۱۴۵/۳۲۶۴	۶۵/۱۸۸۷	۲۹/۳۳۷۷	۹/۱۵۴۷	۳/۸۹۴۸
	SDRL	۱۹۹/۶۶۷۲	۱۴۴/۴۷۲۷	۶۵/۶۱۹۸	۲۸/۷۴۴۲	۸/۸۷۲۳	۳/۱۶۵۲
NN	ARL	۱۹۹/۷۰۸۹	۱۴۵/۰۱۳۸	۷۱/۶۱۵۵	۳۲/۴۳۹۱	۹/۰۵۸۳	۳/۸۱۲۴
	SDRL	۱۹۹/۶۸۲۴	۱۴۴/۰۷۲۶	۷۱/۳۸۳۴	۳۱/۶۸۴۱	۹/۴۸۹۲	۳/۳۰۴۶
NN-RR	ARL	۱۹۹/۶۹۴۸	۱۴۸/۲۲۴۷	۶۸/۴۰۹۹	۲۹/۳۵۶۴	۹/۰۳۱۱	۳/۸۰۹۹
	SDRL	۱۹۹/۶۳۶۱	۱۴۶/۳۱۱۶	۶۷/۲۹۹۷	۲۸/۷۵۴۷	۷/۹۱۱۲	۲/۸۹۴۹

جدول ۶. رتبه رویکردهای RPLR، ATL، NN و NN-RR بر حسب ARL و SDRL تحت الگو ۲

Table 6. Ranking of RPLR, ATL, NN and NN-RR approaches in terms of ARL and SDRL under Model 2

رویکرد پایش	شاخص	Δ					
		۰/۱	۰/۲	۰/۳	۰/۵	۰/۷۵	۱
RPLR	ARL	۴	۴	۴	۴	۴	۴
	SDRL	۴	۴	۴	۴	۴	۴
ATL	ARL	۲	۱	۱	۳	۳	۲
	SDRL	۲	۱	۱	۲	۳	۲
NN	ARL	۱	۳	۳	۲	۲	۲
	SDRL	۱	۳	۳	۳	۲	۲
NN-RR	ARL	۳	۲	۱	۱	۱	۱
	SDRL	۳	۲	۱	۱	۱	۱

جدول ۷. مقایسه ARL و SDRL رویکردهای RPLR، ATL، NN و NN-RR در شرایط $n = 5$ و $p = 10$ تحت الگو ۳

Table 7. Comparison of ARL and SDRL of RPLR, ATL, NN and NN-RR approaches in conditions of $n=5$ and $p=10$ under model 3

رویکرد پایش	شاخص	Δ					
		۰	۰/۱	۰/۲	۰/۳	۰/۵	۰/۷۵
RPLR	ARL	۲۰۰/۰۲۷۴	۱۸۲/۴۶۲۸	۱۶۷/۴۴۵۷	۱۳۴/۴۵۵۹	۶۲/۵۹۸۵	۲۳/۳۵۷۶
	SDRL	۱۹۸/۳۷۶۸	۱۸۱/۰۲۶۴	۱۶۷/۱۵۵۳	۱۳۱/۰۳۶۳	۶۴/۵۶۳۲	۲۲/۷۹۳۵
ATL	ARL	۲۰۰/۱۴۸۶	۱۸۹/۹۷۸۸	۱۶۱/۹۱۹۱	۱۲۶/۹۶۶۵	۶۱/۶۶۲۵	۲۲/۹۱۶۵
	SDRL	۱۹۹/۶۶۷۲	۱۸۶/۷۸۰۲	۱۶۰/۴۷۱۵	۱۲۵/۸۴۱۱	۶۱/۳۶۸۴	۲۲/۹۰۴۳
NN	ARL	۱۹۹/۷۰۸۹	۱۸۲/۰۲۳۲	۱۶۱/۲۸۸۲	۱۲۶/۳۰۰۹	۶۱/۴۶۵۲	۲۲/۵۶۵۲
	SDRL	۱۹۹/۶۸۲۴	۱۸۱/۱۱۶۱	۱۵۹/۰۵۹۱	۱۲۵/۸۷۴۳	۶۱/۱۳۲۶	۲۲/۶۰۵۶
NN-RR	ARL	۱۹۹/۶۹۴۸	۱۸۸/۷۱۱۸	۱۵۹/۰۳۷۱	۱۱۸/۵۴۶۵	۵۴/۸۳۱۵	۱۹/۵۸۲۴
	SDRL	۱۹۹/۶۳۶۱	۱۸۶/۴۷۲۸	۱۵۶/۴۰۲۶	۱۱۵/۶۴۲۰	۵۲/۸۲۸۶	۱۷/۹۴۷۱

جدول ۸. رتبه رویکردهای RPLR، ATL، NN و NN-RR بر حسب ARL و SDRL تحت الگو ۳

Table 8. Ranking of RPLR, ATL, NN and NN-RR approaches in terms of ARL and SDRL under Model 3

رویکرد پیش	شاخص	Δ				
		۰/۱	۰/۲	۰/۳	۰/۵	۰/۷۵
RPLR	ARL	۲	۴	۴	۴	۴
	SDRL	۲	۴	۴	۴	۴
ATL	ARL	۳	۳	۳	۳	۳
	SDRL	۳	۳	۳	۳	۳
NN	ARL	۱	۲	۲	۲	۲
	SDRL	۱	۲	۲	۲	۲
NN-RR	ARL	۳	۱	۱	۱	۱
	SDRL	۳	۱	۱	۱	۱

جدول ۹. مقایسه ARL و SDRL رویکردهای RPLR، ATL، NN و NN-RR در شرایط $n = 5$ و $p = 10$ تحت الگو ۴

Table 9. Comparison of ARL and SDRL of RPLR, ATL, NN and NN-RR approaches in conditions of $n=5$ and $p=10$ under model 4

رویکرد پیش	شاخص	Δ					.
		۰/۱	۰/۲	۰/۳	۰/۵	۰/۷۵	
RPLR	ARL	۱۸۱/۳۳۷۱	۱۱۲/۳۷۶۴	۶۱/۳۰۲۶	۱۳/۴۸۱۲	۲/۷۴۵۴	۲۰۰/۰۲۷۴
	SDRL	۱۸۴/۰۶۷۲	۱۱۱/۱۳۲۳	۶۱/۰۲۲۳	۱۲/۸۸۴۱	۲/۱۳۱۱	۱۹۸/۳۷۶۸
ATL	ARL	۱۷۰/۷۱۹۴	۱۱۴/۲۴۷۷	۶۲/۱۹۶۶	۱۴/۲۳۵۴	۲/۸۹۳۵	۲۰۰/۱۴۸۶
	SDRL	۱۷۰/۶۸۴۱	۱۱۲/۳۰۸۴	۶۱/۳۹۱۶	۱۳/۶۲۴۴	۲/۳۵۸۲	۱۹۹/۶۶۷۲
NN	ARL	۱۶۷/۳۲۸۷	۱۱۰/۰۳۳۲	۵۶/۷۷۷۵	۱۲/۰۲۸۲	۲/۵۸۸۱	۱۹۹/۷۰۸۹
	SDRL	۱۶۵/۲۶۲۵	۱۰۹/۵۹۵۱	۵۶/۳۱۱۰	۱۱/۶۲۸۸	۲/۰۴۶۵	۱۹۹/۶۸۲۴
NN-RR	ARL	۱۶۸/۵۸۰۹	۹۹/۰۱۸۸	۴۶/۹۶۱۷	۹/۱۷۹۳	۲/۵۲۶۰	۱۹۹/۶۹۴۸
	SDRL	۱۶۷/۰۷۸۸	۹۶/۵۸۷۶	۴۴/۰۹۴۴	۷/۳۹۸۸	۱/۶۲۷۱	۱۹۹/۶۳۶۱

جدول ۱۰. رتبه رویکردهای RPLR، ATL، NN و NN-RR بر حسب ARL و SDRL تحت الگو ۴

Table 10. Ranking of RPLR, ATL, NN and NN-RR approaches in terms of ARL and SDRL under Model 4

رویکرد پیش	شاخص	Δ				
		۰/۱	۰/۲	۰/۳	۰/۵	۰/۷۵
RPLR	ARL	۴	۳	۳	۳	۳
	SDRL	۴	۳	۳	۳	۳
ATL	ARL	۳	۴	۴	۴	۴
	SDRL	۳	۴	۴	۴	۴
NN	ARL	۱	۲	۲	۲	۲
	SDRL	۱	۲	۲	۲	۲
NN-RR	ARL	۲	۱	۱	۱	۱
	SDRL	۲	۱	۱	۱	۱

جدول ۱۱. مقایسه ARL و SDRL رویکردهای RPLR، ATL، NN و NN-RR در شرایط $n = 5$ و $p = 10$ تحت الگو δ

Table 11. Comparison of ARL and SDRL of RPLR, ATL, NN and NN-RR approaches in conditions of $n=5$ and $p=10$ under model 5

رویکرد پایش	شاخص	Δ					
		۰	۰/۱	۰/۲	۰/۳	۰/۵	۰/۷۵
RPLR	ARL	۲۰۰/۰۲۷۴	۱۹۳/۰۸۴۴	۱۹۰/۵۰۷۲	۱۷۲/۳۰۱۸	۱۳۱/۰۱۸۹	۷۵/۲۰۳۸
	SDRL	۱۹۸/۳۷۶۸	۱۹۳/۳۸۱۸	۱۹۰/۱۳۰۵	۱۷۲/۲۲۶۴	۱۲۸/۴۱۶۲	۷۴/۹۹۴۴
ATL	ARL	۲۰۰/۱۴۸۶	۱۹۶/۴۵۱۹	۱۸۷/۹۴۲۵	۱۷۸/۲۸۴۷	۱۳۵/۷۵۷۷	۷۹/۱۱۰۶
	SDRL	۱۹۹/۶۶۷۲	۱۹۵/۲۱۵۳	۱۸۷/۸۰۱۴	۱۷۹/۰۰۴۶	۱۳۷/۹۶۹۲	۷۸/۶۳۳۶
NN	ARL	۱۹۹/۷۰۸۹	۱۹۲/۳۱۵۳	۱۸۷/۵۵۸۴	۱۷۱/۹۹۹۱	۱۳۰/۰۹۸۵	۷۴/۹۰۰۴
	SDRL	۱۹۹/۶۸۲۴	۱۹۲/۵۷۶۹	۱۸۷/۵۹۴۱	۱۶۹/۵۴۵۹	۱۲۷/۶۰۶۳	۷۳/۷۶۴۰
NN-RR	ARL	۱۹۹/۶۹۴۸	۱۹۳/۲۶۰۵	۱۸۹/۵۸۷۴	۱۷۲/۱۵۱۴	۱۲۴/۱۱۲۳	۶۵/۷۴۶۶
	SDRL	۱۹۹/۶۳۶۱	۱۹۲/۰۱۴۸	۱۸۸/۵۴۰۲	۱۷۱/۴۱۹۹	۱۲۱/۹۰۵۷	۶۳/۸۳۴۱

جدول ۱۲. رتبه رویکردهای RPLR، ATL، NN و NN-RR بر حسب ARL و SDRL تحت الگو δ

Table 12. Ranking of RPLR, ATL, NN and NN-RR approaches in terms of ARL and SDRL under Model 5

رویکرد پایش	شاخص	Δ					
		۰	۰/۱	۰/۲	۰/۳	۰/۵	۰/۷۵
RPLR	ARL	۲	۴	۳	۳	۳	۳
	SDRL	۳	۴	۴	۳	۳	۳
ATL	ARL	۴	۲	۲	۴	۴	۴
	SDRL	۴	۴	۲	۴	۴	۴
NN	ARL	۱	۱	۱	۱	۲	۲
	SDRL	۲	۲	۱	۱	۲	۲
NN-RR	ARL	۲	۳	۳	۲	۱	۱
	SDRL	۱	۱	۳	۲	۱	۱

جدول ۱۳. مقایسه ARL و SDRL رویکردهای RPLR، ATL، NN و NN-RR در شرایط $n = 5$ و $p = 10$ تحت الگو ϵ

Table 13. Comparison of ARL and SDRL of RPLR, ATL, NN and NN-RR approaches in conditions of $n=5$ and $p=10$ under model 6

رویکرد پایش	شاخص	Δ					
		۰	۰/۱	۰/۲	۰/۳	۰/۵	۰/۷۵
RPLR	ARL	۲۰۰/۰۲۷۴	۱۶۱/۵۶۹۹	۹۲/۹۴۹۸	۴۷/۳۱۵۷	۱۶/۹۱۹۰	۷/۹۱۲۷
	SDRL	۱۹۸/۳۷۶۸	۱۶۱/۰۳۶۸	۹۰/۷۱۵۶	۴۵/۵۰۹۱	۱۶/۵۹۹۰	۷/۴۸۷۲
ATL	ARL	۲۰۰/۱۴۸۶	۱۵۳/۵۵۵۶	۷۹/۶۴۳۸	۴۰/۷۴۵۸	۱۴/۳۳۷۸	۶/۵۶۰۱
	SDRL	۱۹۹/۶۶۷۲	۱۵۳/۹۰۶۹	۸۰/۶۸۷۳	۴۰/۸۴۹۴	۱۴/۰۱۵۷	۶/۱۲۴۹
NN	ARL	۱۹۹/۷۰۸۹	۱۵۳/۱۷۲۴	۸۷/۶۷۱۷	۴۶/۸۳۰۷	۱۶/۳۰۸۲	۷/۸۰۴۹
	SDRL	۱۹۹/۶۸۲۴	۱۵۳/۲۲۲۴	۸۶/۵۸۶۸	۴۵/۱۳۳۵	۱۶/۰۹۳۹	۷/۴۷۴۷
NN-RR	ARL	۱۹۹/۶۹۴۸	۱۶۱/۱۷۰۶	۸۷/۱۰۸۷	۴۵/۲۴۶۵	۱۶/۴۸۲۵	۶/۴۴۰۸
	SDRL	۱۹۹/۶۳۶۱	۱۶۰/۴۱۶۵	۸۵/۴۹۰۶	۴۲/۹۴۰۴	۱۵/۰۴۲۲	۵/۹۶۱۰

جدول ۱۴. رتبه رویکردهای RPLR، ATL، NN و NN-RR بر حسب ARL و SDRL تحت الگو ۶

Table 14. Ranking of RPLR, ATL, NN and NN-RR approaches in terms of ARL and SDRL under Model 6

رویکرد پایش	شاخص	Δ				
		۰/۱	۰/۲	۰/۳	۰/۵	۰/۷۵
RPLR	ARL	۴	۴	۴	۴	۴
	SDRL	۴	۴	۴	۴	۴
ATL	ARL	۲	۱	۱	۱	۲
	SDRL	۲	۱	۱	۱	۲
NN	ARL	۱	۳	۳	۳	۳
	SDRL	۱	۳	۳	۳	۳
NN-RR	ARL	۳	۲	۲	۲	۱
	SDRL	۳	۲	۲	۲	۱

جدول ۱۵. مقایسه ARL و SDRL رویکردهای RPLR، ATL، NN و NN-RR در شرایط $n = 5$ و $p = 10$ تحت الگو ۷

Table 15. Comparison of ARL and SDRL of RPLR, ATL, NN and NN-RR approaches in conditions of $n=5$ and $p=10$ under model 7

رویکرد پایش	شاخص	Δ					
		۰/۱	۰/۲	۰/۳	۰/۵	۰/۷۵	۱
RPLR	ARL	۲۰۰/۰۲۷۴	۱۹۴/۶۴۱۷	۱۸۶/۲۲۸۵	۱۷۵/۷۲۳۳	۱۲۷/۳۴۳۹	۸۰/۹۶۲۹
	SDRL	۱۹۸/۳۷۶۸	۱۹۴/۸۱۰۲	۱۸۷/۸۲۲۷	۱۷۲/۵۵۱۸	۱۲۴/۶۲۶۳	۷۸/۲۷۱۲
ATL	ARL	۲۰۰/۱۴۸۶	۱۹۵/۱۷۲۱	۱۸۴/۱۴۰۹	۱۶۷/۱۹۲۶	۱۲۰/۹۰۷۶	۷۶/۱۳۸۹
	SDRL	۱۹۹/۶۶۷۲	۱۹۵/۲۲۰۸	۱۸۰/۵۵۶۸	۱۶۶/۷۰۵۱	۱۲۰/۳۹۳۵	۷۶/۴۶۶۷
NN	ARL	۱۹۹/۷۰۸۹	۱۹۲/۸۵۶۶	۱۸۲/۸۰۱۵	۱۶۶/۱۸۴۵	۱۲۴/۹۷۲۰	۸۰/۰۲۷۸
	SDRL	۱۹۹/۶۸۲۴	۱۹۱/۷۶۵۰	۱۷۸/۹۳۷۳	۱۶۶/۹۱۹۹	۱۲۳/۵۸۹۴	۸۰/۱۷۷۲
NN-RR	ARL	۱۹۹/۶۹۴۸	۱۹۴/۴۷۷۳	۱۸۵/۳۷۱۵	۱۶۶/۱۰۵۷	۱۲۰/۷۵۸۳	۷۶/۰۱۵۲
	SDRL	۱۹۹/۶۳۶۱	۱۹۴/۲۹۵۶	۱۸۴/۶۴۱۱	۱۶۵/۴۹۸۴	۱۲۰/۳۰۷۲	۷۶/۲۷۷۵

جدول ۱۶. رتبه رویکردهای RPLR، ATL، NN و NN-RR بر حسب ARL و SDRL تحت الگو ۷

Table 16. Ranking of RPLR, ATL, NN and NN-RR approaches in terms of ARL and SDRL under Model 7

رویکرد پایش	شاخص	Δ				
		۰/۱	۰/۲	۰/۳	۰/۵	۰/۷۵
RPLR	ARL	۳	۴	۴	۴	۴
	SDRL	۳	۴	۴	۴	۴
ATL	ARL	۴	۲	۳	۲	۲
	SDRL	۴	۲	۲	۲	۲
NN	ARL	۱	۱	۱	۳	۳
	SDRL	۱	۱	۲	۳	۳
NN-RR	ARL	۲	۳	۱	۱	۱
	SDRL	۲	۳	۱	۱	۱

جدول ۱۷. تعداد رتبه‌های کسب‌شده هر رویکرد پایش در هر نوع الگوی خارج از کنترل

Table 17. Number of ranks obtained by each monitoring approach in each type of out-of-control pattern

غیرپراکنده	پراکنده	توأم	غیرقطری	قطری	شاخص	رویکرد پایش
۱۷/۶/۱/۰	۱۰/۶/۲/۰	۱۴/۲/۲/۰	۱۱/۱/۰/۰	۲/۹/۱/۰	ARL	RPLR
۱۶/۵/۳/۰	۱۰/۷/۱/۰	۱۳/۲/۳/۰	۱۱/۱/۰/۰	۲/۹/۱/۰	SDRL	
۶/۴/۷/۷	۷/۶/۵/۰	۲/۸/۴/۴	۱/۱/۷/۳	۱۰/۱/۱/۰	ARL	ATL
۵/۲/۸/۸	۷/۵/۶/۰	۲/۶/۵/۵	۱/۰/۸/۳	۱۰/۱/۱/۰	SDRL	
۰/۸/۱۰/۶	۰/۳/۸/۷	۰/۳/۱۱/۴	۰/۸/۰/۴	۰/۰/۷/۵	ARL	NN
۰/۱۰/۸/۶	۰/۳/۱۰/۵	۰/۵/۹/۴	۰/۸/۱/۳	۰/۰/۷/۵	SDRL	
۰/۲/۸/۱۴	۰/۳/۳/۱۲	۰/۱/۴/۱۲	۰/۲/۴/۶	۰/۱/۳/۸	ARL	NN-RR
۰/۲/۸/۱۴	۰/۳/۲/۱۳	۰/۱/۳/۱۳	۰/۲/۴/۶	۰/۱/۳/۸	SDRL	

مراجع

- Amiri, A., Salmasia, A., Zarifi, M., & Maleki, M. R. (2023). Adaptive Shewhart control charts under fuzzy parameters with tuned particle swarm optimization algorithm. *Journal of Industrial Integration and Management*, 8(2), 241–276. <https://doi.org/10.1142/S2424862221500226>
- Antzoulakos, D. L., & Rakitzis, A. C. (2008). The modified r out of m control chart. *Communications in Statistics—Simulation and Computation*, 37(2), 396–408. <https://doi.org/10.1080/03610910701501906>
- Arkat, J., Niaki, S. T. A., & Abbasi, B. (2007). Artificial neural networks in applying MCUSUM residuals charts for AR(1) processes. *Applied Mathematics and Computation*, 189(2), 1889–1901. <https://doi.org/10.1016/j.amc.2006.12.081>
- Chew, X., Khoo, M. B. C., Khaw, K. W., & Lee, M. H. (2021). An improved Hotelling's T² chart for monitoring a finite horizon process based on run rules schemes: A Markov-chain approach. *Applied Stochastic Models in Business and Industry*, 37(3), 577–591. <https://doi.org/10.1002/asmb.2596>
- Dafnis, S. D., Perdikis, T., & Papadopoulos, G. K. (2024). Improved chi-square control charts with weak-run rules. *Communications in Statistics—Theory and Methods*, 53(14), 5248–5264. <https://doi.org/10.1080/03610926.2023.2215357>
- Ebadi, M., Chenouri, S., & Steiner, S. H. (2023). Phase I analysis of high-dimensional processes in the presence of outliers. *Journal of Quality Technology*, 55(4), 469–488. <https://doi.org/10.1080/00224065.2023.2196034>
- Fan, J., Shu, L., Yang, A., & Li, Y. (2021). Phase I analysis of high-dimensional covariance matrices based on sparse leading eigenvalues. *Journal of Quality Technology*, 53(4), 333–346. <https://doi.org/10.1080/00224065.2020.1746212>
- Abbasi, B., & Niaki, S. T. A. (2007). Monitoring high-yields processes with defects count in nonconforming items by artificial neural network. *Applied mathematics and computation*, 188(1), 262–270. <https://doi.org/10.1016/j.amc.2006.09.114>
- Abdella, G. M., Al-Khalifa, K. N., Kim, S., Jeong, M. K., Elsayed, E. A., & Hamouda, A. M. (2017). Variable selection-based multivariate cumulative sum control chart. *Quality and Reliability Engineering International*, 33(3), 565–578. <https://doi.org/10.1002/qre.2041>
- Abdella, G. M., Kim, J., Kim, S., Al-Khalifa, K. N., Jeong, M. K., Hamouda, A. M., & Elsayed, E. A. (2019). An adaptive thresholding-based process variability monitoring. *Journal of Quality Technology*, 51(3), 242–256. <https://doi.org/10.1080/00224065.2019.1569952>
- Adegoke, N. A., Dawod, A., Adeoti, O. A., Sanusi, R. A., & Abbasi, S. A. (2022). Monitoring multivariate coefficient of variation for high-dimensional processes. *Quality and Reliability Engineering International*, 38(5), 2606–2621. <https://doi.org/10.1002/qre.3094>
- Adeoti, O. A., & Malela-Majika, J. C. (2020). Double exponentially weighted moving average control chart with supplementary runs-rules. *Quality Technology & Quantitative Management*, 17(2), 149–172. <https://doi.org/10.1080/16843703.2018.1560603>
- Ahmadi Karavigh, M. H., & Amiri, A. (2024). MEWMA-based control charts with runs rules for monitoring multivariate simple linear regression profiles in Phase II. *Communications in Statistics—Simulation and Computation*, 53(3), 1107–1134. <https://doi.org/10.1080/03610918.2022.2028833>

- Koutras, M. V., Bersimis, S., & Maravelakis, P. (2007). Statistical process control using Shewhart control charts with supplementary runs rules. *Methodology and Computing in Applied Probability*, 9(2), 207–224. <https://doi.org/10.1007/s11009-007-9016-8>
- Maboudou-Tchao, E. M. (2021). High-dimensional data monitoring using support machines. *Communications in Statistics—Simulation and Computation*, 50(7), 1927–1942. <https://doi.org/10.1080/03610918.2019.1588312>
- Mallikarjun, N. S., Tayyapa, J. B., Moshayedi, A. J., & Kisanrao, S. S. (2024). Performance analysis of ANN control chart for monitoring the individual measurements of manufacturing process. In *Proceedings of the 2024 3rd International Symposium on Robotics, Artificial Intelligence and Information Engineering* (pp. 130–135). <https://doi.org/10.1145/3689299.3689323>
- Mehmood, R., Riaz, M., Ali, I., & Lee, M. H. (2021). Generalized Hotelling T² control chart based on bivariate ranked set techniques with runs rules. *Transactions of the Institute of Measurement and Control*, 43(10), 2180–2195. <https://doi.org/10.1177/0142331221992670>
- Okhrin, Y., Schmid, W., & Semeniuk, I. (2025). A control chart for monitoring image processes based on convolutional neural networks. *Statistica Neerlandica*, 79(1), e12366. <https://doi.org/10.1111/stan.12366>
- Quinino, V. B., Ho, L. L., Cruz, F. R. B., & Quinino, R. C. (2023). A simple procedure to improve the performance of Klein's 2-of-2 run rule in the Shewhart \bar{X} control chart. *Quality and Reliability Engineering International*, 39(7), 3014–3029. <https://doi.org/10.1002/qre.3412>
- Riaz, M., Abbas, N., & Does, R. J. M. M. (2011). Improving the performance of CUSUM charts. *Quality and Reliability Engineering International*, 27(4), 415–424. <https://doi.org/10.1002/qre.1124>
- 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>
- Sabahno, H., & Amiri, A. (2023). New statistical and machine learning-based control charts with variable parameters for monitoring generalized linear model profiles. *Computers & Industrial Engineering*, 184, 109562. <https://doi.org/10.1016/j.cie.2023.109562>
- Sabahno, H., & Khodadad, D. (2025). A spatiotemporal scheme for process control
- Feng, L., Ren, H., & Zou, C. (2020). A setwise EWMA scheme for monitoring high-dimensional datastreams. *Random Matrices: Theory and Applications*, 9(2), 2050004. <https://doi.org/10.1142/S2010326320500045>
- Gómez, A. M. E., Li, D., & Paynabar, K. (2022). An adaptive sampling strategy for online monitoring and diagnosis of high-dimensional streaming data. *Technometrics*, 64(2), 253–269. <https://doi.org/10.1080/00401706.2021.1967198>
- Hric, P., & Sabahno, H. (2024). Developing machine learning-based control charts for monitoring different GLM-type profiles with different link functions. *Applied Artificial Intelligence*, 38(1), 2362511. <https://doi.org/10.1080/08839514.2024.2362511>
- Imran, M., Dai, H. L., Zaidi, F. S., Hu, X., Tran, K. P., & Sun, J. (2024). Analyzing out-of-control signals of T² control chart for compositional data using artificial neural networks. *Expert Systems with Applications*, 238, 122165. <https://doi.org/10.1016/j.eswa.2023.122165>
- Jafari, M., Maleki, M. R., & Salmasnia, A. (2023). A high-dimensional control chart for monitoring process variability under gauge imprecision effect. *Production Engineering*, 17(3), 547–564. <https://doi.org/10.1007/s11740-022-01166-3>
- Jiang, W., Wang, K., & Tsung, F. (2012). A variable-selection-based multivariate EWMA chart for process monitoring and diagnosis. *Journal of Quality Technology*, 44(3), 209–230. <https://doi.org/10.1080/00224065.2012.11917896>
- Khilare, S. K., & Shirke, D. T. (2023). The fraction nonconforming m-of-m control chart with warning limits. *Thailand Statistician*, 21(2), 435–449.
- Khoo, M. B. C. (2003). Design of runs rules schemes. *Quality Engineering*, 16(1), 27–43. <https://doi.org/10.1081/QEN-120020769>
- Kim, J. M., & Ha, I. D. (2022). Deep learning-based residual control chart for count data. *Quality Engineering*, 34(3), 370–381. <https://doi.org/10.1080/08982112.2022.2044049>
- Kim, J., Abdella, G. M., Kim, S., Al-Khalifa, K. N., & Hamouda, A. M. (2019). Control charts for variability monitoring in high-dimensional processes. *Computers & Industrial Engineering*, 130, 309–316. <https://doi.org/10.1016/j.cie.2019.02.012>
- Klein, M. (2000). Two alternatives to the Shewhart \bar{X} control chart. *Journal of Quality Technology*, 32(4), 427–431. <https://doi.org/10.1080/00224065.2000.11980028>

- Applications*, 35(22), 16321–16340.
<https://doi.org/10.1007/s00521-023-08483-3>
- Yeganeh, A., Shadman, A., Shongwe, S. C., & Abbasi, S. A. (2023b). Employing evolutionary artificial neural network in risk-adjusted monitoring of surgical performance. *Neural Computing and Applications*, 35(14), 10677–10693.
<https://doi.org/10.1007/s00521-023-08257-x>
- Yeganeh, A., Pourpanah, F., & Shadman, A. (2021a). An ANN-based ensemble model for change point estimation in control charts. *Applied Soft Computing*, 110, 107604.
<https://doi.org/10.1016/j.asoc.2021.107604>
- Yeganeh, A., & Shadman, A. (2021b). Monitoring linear profiles using artificial neural networks with run rules. *Expert Systems with Applications*, 168, 114237.
<https://doi.org/10.1016/j.eswa.2020.114237>
- Yeganeh, A., Shadman, A., & Abbasi, S. A. (2022). Enhancing the detection ability of control charts in profile monitoring by adding RBF ensemble model. *Neural Computing and Applications*, 34(12), 9733–9757.
<https://doi.org/10.1007/s00521-022-07109-4>
- using image analysis of speckle patterns. *Quality and Reliability Engineering International*, 41(5), 1773–1788.
<https://doi.org/10.1002/qre.3758>
- Saemian, M., Salmasnia, A., & Maleki, M. R. (2022). A generalized multiple dependent state sampling chart based on ridge penalized likelihood ratio for high-dimensional covariance matrix monitoring. *Scientia Iranica*.
<https://doi.org/10.24200/SCI.2022.60169.6640>
- Safikhani, E., Salmasnia, A., & Maleki, M. R. (2023). A ridge penalized likelihood ratio chart for Phase II monitoring of high-dimensional process dispersion under measurement system inaccuracy. *International Journal of Industrial Engineering*, 34(2), 1–17.
<https://doi.org/10.22068/ijiepr.34.2.12>
- Salmasnia, A., Asghari, A., & Maleki, M. R. (2025a). Effect of parameter estimation on Phase II performance of ridge penalized likelihood ratio control chart for monitoring high-dimensional process variability. *Journal of Data, Information and Management*, 7(3), 265–286.
<https://doi.org/10.1007/s42488-025-00152-5>
- Salmasnia, A., Maleki, M. R., & Mirzaei, M. (2025b). Double sampling adaptive thresholding LASSO variability chart for Phase II monitoring of high-dimensional data streams. *Journal of Industrial Integration and Management*, 10(02), 277–299.
<https://doi.org/10.1142/S242486222350001X>
- Sun, J., Zhou, S., & Veeramani, D. (2023). A neural network-based control chart for monitoring and interpreting autocorrelated multivariate processes using layer-wise relevance propagation. *Quality Engineering*, 35(1), 33–47.
<https://doi.org/10.1080/08982112.2022.2087041>
- Tang, A., Mukherjee, A., & Wang, X. (2023). Distribution-free Phase-II monitoring of high-dimensional industrial processes via origin and modified interpoint distance-based algorithms. *Computers & Industrial Engineering*, 179, 109161.
<https://doi.org/10.1016/j.cie.2023.109161>
- Tran, K. P. (2017). Run rules median control charts for monitoring process mean in manufacturing. *Quality and Reliability Engineering International*, 33(8), 2437–2450.
<https://doi.org/10.1002/qre.2201>
- Woodall, W. H., Saleh, N. A., & Mahmoud, M. A. (2023). Equivalences between multiple dependent state sampling, chain sampling, and control chart runs rules. *Quality Engineering*, 35(1), 142–151.
<https://doi.org/10.1080/08982112.2022.2102428>
- Yeganeh, A., Johannssen, A., Chukhrova, N., Abbasi, S. A., & Pourpanah, F. (2023a). Employing machine learning techniques in monitoring autocorrelated profiles. *Neural Computing and*