



Original Article

Application of Deep Learning Networks to Design Quality Control Process in the Motor Oil Industry

Mehdi Heydari*^{ID}
Alireza Alinezhad**^{ID}
Behnam Vahdani***^{ID}

Abstract

Introduction: In light of recent advancements in the modern world, multivariate-multistage quality control patterns are increasingly recognized as vital and indispensable in manufacturing industries. This study delves into the significance and necessity of multivariate-multistage quality control in manufacturing, specifically focusing on motor oil production. As a foundational factor, motor oil quality considerably influences engine performance, lifespan, customer satisfaction, and market positioning.

Methods: This research employs deep learning algorithms for monitoring and fault detection in quality components. The primary rationale for opting for deep learning algorithms over conventional statistical methods is the non-normal distribution of data and the large sample sizes, which can lead to inaccurate estimations and unstable analyses. Conversely, the unique capabilities of deep learning algorithms in handling complex data and extracting meaningful features from extensive motor oil production data justify their selection. To bolster accuracy and effective quality control, a combination of deep learning algorithms is utilized, including Long Short-Term Memory (LSTM) networks, Convolutional Neural Networks (CNN), and hybrid models such as LSTM-CNN, as well as Residual Networks (ResNet) with Dense Networks (DenseNet). The LSTM-CNN algorithm is applied to control numerical quality variables and identify temporal and sequential patterns in the data. Meanwhile, ResNet-DenseNet manages and analyzes visual data with non-uniform and intricate distributions.

Received: Jun. 01, 2023; Revised: Oct. 18, 2023; Accepted: Nov. 08, 2023; Published Online: Nov. 21, 2023.

* Ph.D. Candidate in Industrial Engineering, Department of Industrial Engineering, Qazvin Branch, Islamic Azad University, Qazvin, Iran.
Corresponding Author: alinezhad@qiau.ac.ir

** Associate Professor, Department of Industrial Engineering, Qazvin Branch, Islamic Azad University, Qazvin, Iran.

*** Associate Professor, Department of Industrial Engineering, Qazvin Branch, Islamic Azad University, Qazvin, Iran.

Original Article

Results and discussion: By integrating LSTM networks, CNNs, and residual connections, these algorithms excel at extracting meaningful features and capturing complex relationships within the data. This enhances performance and efficiency in quality control processes and facilitates intelligent decision-making. Such an approach is adept at uncovering latent patterns and intricate relationships between variables and quality attributes, enhancing quality control procedures and intelligent decision-making. The amalgamation of these algorithmic capabilities enhances the efficacy of quality control processes, outperforming single-algorithm approaches. Additionally, the Bee Colony Clonal Algorithm (BCC) is employed to fine-tune the parameters of the LSTM-CNN and ResNet-DenseNet algorithms. This hybrid approach harnesses the Artificial Bee Colony (ABC) and Genetic Algorithm (GA) strengths, markedly improving the performance of deep learning algorithms in quality control and reducing the time required to achieve desired outcomes. To illustrate the practical applicability of the proposed algorithms, a case study in the motor oil production industry is examined. The proposed LSTM-CNN hybrid algorithm in fault detection demonstrated superior results compared to standalone CNN and LSTM algorithms, achieving performance improvements of approximately 15% and 8%, respectively. Furthermore, the proposed ResNet-DenseNet hybrid algorithm exhibited higher accuracy in visual components, enhancing performance by approximately 10% and 15% compared to ResNet and DenseNet algorithms, respectively.

Conclusions: From both academic and practical standpoints, this research scrutinizes deep learning algorithms' influence on enhancing motor oil quality and efficiency. Advanced data analysis methods, particularly hybrid deep learning algorithms, are employed to identify quality patterns in production data.

Keywords: Auto-Encoder; Deep learning; Fault Detection; Metaheuristic Algorithm; Quality control.

How to Cite: Heydari, Mehdi; Alinezhad, Alireza; Vahdani, Behnam (2024). Application of Deep Learning Networks to Design Quality Control Process in the Motor Oil Industry. *Ind. Manag. Persp.*, 14(1), 211-237 (*In Persian*).



کاربرد شبکه‌های یادگیری عمیق برای طراحی فرآیند کنترل کیفیت در صنعت روغن موتور

مه‌دی حیدری*

علیرضا علی‌نژاد**

بهنام وحدانی***

چکیده

مقدمه و اهداف: با توجه به پیشرفت‌های جدید در دنیای مدرن، استفاده از الگوهای کنترل کیفیت چندمتغیره-چندمرحله‌ای در صنایع تولید به عنوان موضوعی حیاتی و ضروری مطرح می‌شود. این پژوهش به بررسی اهمیت و ضرورت کنترل کیفیت چندمتغیره-چندمرحله‌ای در صنایع تولیدی با تاکید بر تولید روغن موتور پرداخته است. کیفیت روغن موتور به عنوان یک عامل بنیادین، تأثیر قابل توجهی بر عملکرد، عمر موتور، رضایت مشتریان و موقعیت محصول در بازار دارد. در این تحقیق، برای مانیتورینگ و تشخیص خطا در مولفه‌های کیفی، استفاده از الگوریتم‌های یادگیری عمیق، مد نظر قرار گرفته است. علت اصلی انتخاب الگوریتم‌های یادگیری عمیق به جای روش‌های کلاسیک آماری، نرمال نبودن داده‌ها و حجم بزرگ نمونه‌ها بوده است. این مشکلات می‌توانند باعث عدم دقت تخمین‌ها و ناپایداری تحلیل‌ها شوند. از طرفی، توانمندی‌های منحصر به فرد الگوریتم‌های یادگیری عمیق در تجزیه و تحلیل داده‌های پیچیده و استخراج ویژگی‌های معنادار از داده‌های گسترده تولید روغن موتور، دلیل اصلی بر انتخاب این الگوریتم‌ها است.

روش‌ها: در این پژوهش، به منظور افزایش دقت و کنترل کیفیت مؤثر، از الگوریتم‌های یادگیری عمیق ترکیبی از جمله شبکه عصبی با حافظه طولانی-کوتاه مدت و شبکه عصبی پیچشی، LSTM-CNN و شبکه باقیمانده - شبکه عصبی پیچشی متصل و ResNet-DenseNet برای کنترل مؤلفه‌های کیفی استفاده شده است. در این پژوهش، با توجه به نیاز به تحلیل و کنترل داده‌های پیچیده و چندمتغیره، از الگوریتم LSTM-CNN برای کنترل کیفی متغیرهای عددی و تشخیص الگوهای زمانی و توالی در داده‌ها استفاده شده است. همچنین، برای مدیریت و تجزیه و تحلیل داده‌های بصری که توزیع‌های غیریکنواخت و پیچیده‌ای دارند، از الگوریتم ResNet-DenseNet استفاده شده است. این الگوریتم‌ها با استفاده از ترکیبی از شبکه‌های عصبی با حافظه طولانی-کوتاه مدت و شبکه‌های پیچشی، قادر به استخراج ویژگی‌های معنادار و ارتباطات پیچیده میان داده‌ها هستند، که این امر باعث بهبود عملکرد و کارایی در فرایندهای کنترل کیفیت و تصمیم‌گیری هوشمند می‌شود. این روش قادر به تشخیص الگوهای پنهان و ارتباطات پیچیده بین متغیرها و ویژگی‌های کیفیتی موجود در داده‌ها است و قابلیت بهبود فرایندهای کنترل کیفیت و تصمیم‌گیری هوشمند را تسهیل می‌کند.

تاریخ دریافت: ۱۴۰۲/۰۴/۱۰، تاریخ بازنگری: ۱۴۰۲/۰۵/۲۷، تاریخ پذیرش: ۱۴۰۲/۰۸/۱۷، تاریخ اولین انتشار: ۱۴۰۲/۰۸/۳۰.

* دانشجوی دکتری مهندسی صنایع، دانشگاه آزاد اسلامی، واحد قزوین، قزوین، ایران.

نویسنده مسئول: alinezhad@qiau.ac.ir

** دانشیار، گروه مهندسی صنایع، دانشگاه آزاد اسلامی، واحد قزوین، قزوین، ایران.

*** دانشیار، گروه مهندسی صنایع، دانشگاه آزاد اسلامی، واحد قزوین، قزوین، ایران.

یافته‌ها: ترکیب قابلیت‌های این الگوریتم‌ها، عملکرد فرایند کنترل کیفیت را بهبود می‌بخشد و نتایج بهتری نسبت به روش‌های تک‌الگوریتمی به دست می‌آورد؛ به علاوه از الگوریتم کلونی زنبور عسل (GBC) برای تنظیم پارامترهای الگوریتم‌های یادگیری عمیق LSTM-CNN و ResNet-DenseNet استفاده شده است. این الگوریتم به عنوان یک رویکرد ترکیبی عمل می‌کند و از مزایای الگوریتم کلونی زنبور عسل مصنوعی (ABC) و الگوریتم ژنتیک (GA) بهره می‌برد. این ترکیب به میزان زیادی عملکرد الگوریتم‌های یادگیری عمیق را در فرایندهای کنترل کیفیت بهبود می‌بخشد و زمان رسیدن به نتیجه مطلوب را کاهش می‌دهد. به منظور نمایش کاربرد عملی الگوریتم‌های ارائه شده در جهان واقعی، یک مطالعه موردی از صنعت تولید روغن موتور بررسی شده است. الگوریتم ترکیبی LSTM-CNN پیشنهادی در فرایند تشخیص خطا، نتیجه بهتری نسبت به الگوریتم‌های تک‌ CNN و LSTM داشته و عملکرد نتایج را به ترتیب به میزان ۱۵ و ۸ درصد ارتقا داده است؛ همچنین در مؤلفه‌های تصویری، الگوریتم ترکیبی پیشنهادی ResNet-DenseNet نسبت به الگوریتم‌های ResNet و DenseNet به ترتیب با دقت بالاتری، به میزان ۱۰ و ۱۵ درصد عمل کرده است.

نتیجه‌گیری: از نظر علمی و عملی، در این پژوهش تأثیر الگوریتم‌های یادگیری عمیق در بهبود کیفیت و کارایی روغن موتور را مورد بررسی قرار گرفته و از روش‌های پیشرفته تجزیه و تحلیل داده، به ویژه الگوریتم‌های ترکیبی عمیق، برای شناسایی الگوهای کیفی در داده‌های تولید استفاده شده است.

کلیدواژه‌ها: خودرمزگذار؛ یادگیری عمیق؛ تشخیص خطا؛ الگوریتم فراابتکاری؛ کنترل کیفیت.

استناددهی: حیدری، مهدی؛ علی‌نژاد، علیرضا؛ وحدانی، بهنام (۱۴۰۳). کاربرد شبکه‌های یادگیری عمیق برای طراحی فرایند کنترل کیفیت در صنعت روغن موتور. چشم‌انداز مدیریت صنعتی، ۱۴(۱)، ۲۱۱-۲۳۷.



۱. مقدمه

امروزه استفاده از فناوری‌های هوشمند در فرآیندهای داده‌محور، از ارکان مهم موفقیت در صنایع تولیدی به‌شمار می‌رود. رقابت فزاینده موجب شده است تا تولیدکنندگان به دنبال راهی برای جذب بیشتر مشتریان باشند. در این میان، اطمینان‌دادن به مشتری که کالای خریداری شده وی کیفیت لازم را دارد و آنطور که انتظار دارد کار می‌کند، عنصری حیاتی به‌شمار می‌آید [۵]. در تولیدات پیوسته مانند تولید روغن موتور، این موضوع بیشتر جلب‌توجه می‌کند [۲۹]. در صنایع تولید روغن موتور برای کنترل مؤلفه‌های کیفی و بهبود عملکرد سیستم تولید از روش‌های کنترل کیفیت چندمتغیره - چندمرحله‌ای استفاده می‌شود. حجم بالای داده‌ها، وابستگی متغیرهای کیفی به یکدیگر، اهمیت زمان در فرآیند تولید و نرمال‌نبودن داده‌ها باعث می‌شود که روش‌های کلاسیک آماری نتوانند بازده خوبی در این صنعت داشته باشند و ضرورت استفاده از یک سیستم هوشمند که بتواند با شناخت ویژگی داده‌ها، در ساخت مدل از آن‌ها استفاده کند، احساس می‌شود. پیشرفت‌هایی که در زمینه توسعه هوش مصنوعی، به‌خصوص روش‌های یادگیری عمیق رخ داده، شامل دستاوردهای موفق در زمینه کنترل مؤلفه‌های کیفی در تولید است که تشخیص خطا، در فرآیند تولید و شناسایی نوع خطای اتفاق افتاده در سیستم را سریع‌تر و راحت‌تر می‌کند. استفاده از الگوریتم‌های یادگیری عمیق از جمله LSTM¹ و CNN² می‌تواند از مؤثرترین روش‌های تشخیص خطا و نوع خطا در صنعت روغن موتور باشد.

اگرچه گسترش روش‌های مبتنی بر یادگیری عمیق در حوزه صنعت از دستاوردهای علمی در این زمینه است، ولی هنوز چالش‌های متعددی در رابطه با کنترل مؤلفه‌های کیفی در تولید روغن موتور وجود دارد که باعث می‌شود کنترل کیفیت در تولید این محصول، کارایی مطلوبی نداشته باشد. برای مثال، مهندسان کیفیت در این بخش تولید، اطلاعات کافی نسبت به متغیرهای متعدد کنترل کیفیت روغن موتور دارند و به این نکته واقف هستند که در چند ایستگاه متنوع این متغیرها باید موردسنجش قرار بگیرند. برای ساده‌کردن فرآیند کنترل و دوری‌جستن از پیچیدگی‌های روش‌های چندمتغیره، هنوز از نمودارهای تک‌متغیره شوهارت استفاده می‌شود [۶]؛ در نتیجه پایش و کنترل فرآیند نمی‌تواند کارایی مطلوبی داشته باشد و باعث افزایش هزینه‌های تولید، افزایش زمان چرخه تولید و کاهش رضایت‌مندی مشتریان در دو قسمت خریداران عمده و مصرف‌کنندگان می‌شود و در نهایت یک زنجیره تأمین معیوب برای برآورده‌شدن تقاضای جامعه شکل می‌گیرد [۱، ۷، ۳۰].

کنترل کیفیت در محصول روغن موتور نیازمند روشی است که بتواند متغیرهای کیفی فرآیند را به‌صورت هم‌زمان پایش کند. یادآوری این نکته ضروری است که به‌دلیل وجود همبستگی در داده‌های کیفی، استفاده از نمودار تک‌متغیره شوهارت نتیجه‌ای دور از واقعیت را به متخصصان ارائه می‌دهد؛ همچنین وجود داده‌های غیرنرمال در مؤلفه‌های کیفیت از عواملی است که استفاده از روش‌های کلاسیک آماری را برای کنترل کیفیت این محصول غیرممکن می‌سازد [۱۹]. با توجه به مسائلی که مطرح شد، روشی که بتواند مشکلات مطرح‌شده را پوشش دهد، ضروری است. با توجه به کارکرد الگوریتم‌های یادگیری عمیق در قسمت‌های مختلف صنایع و بررسی تمام شکاف‌های تکنیکی در این حوزه، استفاده از الگوریتم‌های CNN و LSTM در کنترل متغیرهای عددی این مسئله، پیشنهاد می‌شود و از جمله دلایلی که می‌توان برای این انتخاب، بیان کرد این است که الگوریتم یک‌بعدی CNN (1D-CAE) کارایی قابل‌قبولی در تشخیص خطا در فرآیندهای چندمتغیره دارد و در فرآیندهایی با متغیرهای بسیار، مورد استفاده قرار می‌گیرد و از طریق کاهش نویز سیگنال‌های فرآیند، تأثیر مثبت خود را در تشخیص بهنگام خطا نشان می‌دهد [۳۷]. الگوریتم LSTM می‌تواند یک مدل پیش‌بینی دقیق در کنترل مؤلفه‌های کیفی ارائه دهد و با افزایش کیفیت پیش‌بینی، می‌تواند اقدامات پیشگیرانه را در زمان مناسب انجام دهد؛ همچنین با توجه به اهمیت زمان، در تولید روغن موتور هر دو الگوریتم قادر به پیش‌بینی شاخص کیفیت فرآیند، به‌ویژه روند اساسی آن در طول زمان هستند و می‌توانند در صورت وجود خطا تشخیص به‌موقع ارائه دهند [۸]. در قسمت کنترل متغیرهای تصویری، ابتدا الگوریتم‌های VGG³، DensNet⁴، CNN و ResNet⁵ پیشنهاد شده و از جمله دلایل انتخاب این الگوریتم‌ها، این است که الگوریتم CNN چندلایه، احتمال بروز خطا را در هر مکانی در تصویر پیش‌بینی می‌کند [۱۸]. الگوریتم DensNet توانایی ضدنویز قوی دارد [۹]. مزیت استفاده از الگوریتم ResNet این است که می‌تواند با ایجاد مجموعه داده‌های بزرگ، تبدیل‌های غیرخطی کافی ایجاد کند و استخراج ویژگی قابل‌قبولی را در سیستم انجام دهد [۳۸].

1. Long Short-Term Memory
2. Convolution Neural Networks
3. Visual Graphics Group
4. Dense Convolutional Network
5. Residual Network

نوآوری‌های پژوهش حاضر به صورت خلاصه در ادامه ارائه شده است:

۱. استفاده از الگوریتم ترکیبی یادگیری عمیق LSTM-CNN برای تشخیص خطا^۱ و مشخص شدن نوع خطا^۲ در صنعت روغن موتور؛
۲. استفاده از الگوریتم فرا ابتکاری^۳ (GBC) برای تنظیم پارامترهای الگوریتم ترکیبی LSTM-CNN؛
۳. استفاده از الگوریتم ترکیبی یادگیری عمیق (ResNet-DensNet) برای تشخیص خطا و نوع خطا در متغیرهایی که داده‌های تصویری دارند؛
۴. استفاده از خود رمزگذارها^۴ برای استخراج^۵ ویژگی‌هایی که در ساخت مدل کیفی این پژوهش نقش مهمی دارند.

۲. مبانی نظری و پیشینه پژوهش

معین‌زاده و همکاران، (۲۰۰۱)، یک روش کنترل کیفیت چندمتغیره - چندمرحله‌ای را بررسی کردند. در این پژوهش، روش تحلیل، تبعیض‌گذاری، رگرسیون خطی و نظریه نمودارهای کنترل، ترکیب شدند تا بردار میانگین خصوصیات کیفیتی همبسته یک فرآیند که شامل چند مرحله است و کیفیت خروجی هر مرحله، به خروجی مرحله قبل و به خصوصیات مرحله جاری بستگی دارد، کنترل شود [۲۵]. ماسودا و همکاران، (۲۰۱۴) روش‌های مبتنی بر آمار، شامل نمودار کنترل هاتلینگ^۲، MCUSUM و MEWMA که رویه‌های مبتنی بر طرح‌ریزی^۷ است را بررسی کردند. نمودار هاتلینگ^۲ به طور گسترده در صنعت کاربرد دارد [۲۴].

دونیاس و همکاران^۸، (۲۰۰۱)، یادگیری ماشین القایی را برای انتخاب ویژگی‌های مناسب با قابلیت تشخیص عیوب در ماشین‌های لباسشویی بررسی کردند. آن‌ها راهکارهایی برای ماشین‌هایی که به اشتباه در خط تولید مونتاژ شده‌اند، ارائه دادند [۱۴]. با توجه به پژوهش‌های برسمیس و همکاران، (۲۰۰۷) و اسماعیلی و همکاران، (۲۰۲۳)، با توجه به برخی محدودیت‌هایی که در کنترل فرآیند آماری چندمتغیره سنتی وجود دارد رویکردهای داده‌کاوی را راه‌حل مؤثری برای رفع محدودیت‌های روش‌های سنتی کنترل فرآیند آماری چندمتغیره می‌دانند؛ یعنی پیچیدگی و غیرپارامتری بودن فرآیندها را با ارائه روش‌های داده‌کاوی برطرف می‌کنند [۱۵، ۱۰]. چن و همکاران^۹، (۲۰۲۰) و گو و همکاران، (۲۰۰۸)، داده‌کاوی را یک حوزه چندرشته‌ای دانسته‌اند که شامل روش‌ها و ابزارهایی از چندین رشته، مانند دستگاه‌های پایگاه داده، آمار و سیستم‌های یادگیری است [۱۷، ۱۲]. ماسودا و همکاران، (۲۰۱۴)، در پژوهشی اظهار کردند که به دلیل تحمل خوبی که نوپرزدایی دارد، انعطاف‌پذیری بیشتری را در یادگیری ماشین وجود دارد که این امر نیاز به فرضیه‌هایی که در مورد توزیع‌های آماری است را به وسیله یادگیری نظارت‌شده، مرتفع می‌سازد [۲۶]. ژنگ و همکاران^{۱۰}، (۲۰۱۹)، یک روش ترکیبی مبتنی بر الگوریتم‌های ماشین بردار پشتیبان^{۱۱} و شبکه‌های عصبی کانولوشنی برای تشخیص خطا^{۱۲} و نظارت بر فرآیند چندمتغیره ارائه کردند [۴۰]. در پژوهش چن و همکاران، (۲۰۱۸)، یک خود رمزگذار پیچشی جدید، مبتنی بر داده‌های تک‌بعدی برای تشخیص خطا در فرآیندهای پیچیده چندمتغیره مطرح شده است. در این پژوهش یک مدل جدید یادگیری عمیق خودرمزگذار پیچشی تک‌بعدی (ID-CAE^{۱۳}) برای تشخیص خطای فرآیندهای چندمتغیره پیشنهاد شده است [۱۳]. در پژوهش سانتوس^{۱۴}، (۲۰۱۲)، بر اساس مدل‌های سری زمانی و کنترل فرآیند آماری چندمتغیره، روش جدیدی برای تشخیص خرابی معرفی شده است [۳۱]. جین و همکاران^{۱۵}، (۲۰۱۹)، یک چارچوب جدید برای تشخیص خرابی عناصر غلتکی یاتاقان^{۱۶} ارائه کردند که بر اساس روش‌های کنترل فرآیند آماری چندمتغیره اجرا می‌شود [۲۳]. سیلوا و همکاران^{۱۷}، (۲۰۱۷)، یک استراتژی کنترل فرآیند آماری چندمتغیره برای نظارت بر خط تولید پیوسته قرص ConsiGmaTM-25 ارائه کردند [۳۳]. نیاکی و همکاران، (۲۰۰۹) به مسئله کنترل فرآیند تولید چندمتغیره چندمرحله‌ای پرداختند و دلایل احتمالی سیگنال‌های خارج از کنترل را تشخیص دادند [۲۶]. در پژوهش یو و همکاران^{۱۸}، (۲۰۱۹)، یک مدل جدید یادگیری ویژگی عمیق،

1. Fault Detction
2. Fault Type
3. Genetic Bee Colony
4. Auto Encoders
5. Feature Extraction
6. Masuda, et al
7. Projection
8. Dounias, et al
9. Chen, et al
10. Zheng, et al
11. Support Vector Machines
12. Fault Detection
13. One-Dimensional Convolutional Auto-Encoder
14. Santos, et al
15. Jin, et al
16. Rolling-elements bearing
17. Silva, et al
18. Yu, et al

مبتنی بر خود رمزگذار پشته‌ای نوینزدا، برای نظارت و تشخیص خطاهای فرآیندهای تولید چندمتغیره پیشنهاد شده است [۳۹]. سونگ و همکاران^۱، (۲۰۱۷)، یک روش ساده بیزی مبتنی بر نمونه برای تفسیر سیگنال‌های خارج از کنترل فرآیندهای آماری چندمتغیره، پیشنهاد کردند [۳۴]. نتایج پژوهش ادوم و همکاران، (۲۰۱۸)، نشان داد که برای داده‌های با ابعاد بالا، خودهمبسته^۲، غیرخطی و غیرثابت، روش تحلیل مؤلفه‌های اصلی انطباقی - پویا (AD-PCA^۳)، همانند یا بهتر از روش‌های کاهش ابعاد غیرخطی در علامت‌گذاری داده‌های خارج از محدوده^۴ عمل می‌کند [۲۷]. الیویرا و همکاران^۵، (۲۰۲۰)، به بررسی و بهبود استراتژی‌های فعلی ادغام داده‌ها^۶ در فناوری‌های تحلیل فرآیند (PAT^۷) برای توسعه مدل‌های کنترل فرآیند آماری چندمتغیره با ترکیب تمام اطلاعات موجود مربوط به فرآیند پرداختند [۲۰]. اچ سو و همکاران^۸، (۲۰۲۰)، از روش‌های آماری کنترل فرآیند و یادگیری ماشین برای تشخیص خرابی توربین بادی و پیش‌بینی، لزوم تعمیر و نگهداری از طریق تجزیه و تحلیل ۲/۸ میلیون داده حسگر، از ۳۱ توربین بادی که در سال‌های ۲۰۱۵ تا ۲۰۱۷ در تایوان جمع‌آوری شده بود، استفاده کردند [۲۱]. سونگ و همکاران^۹، (۲۰۱۷) با استفاده از کنترل فرآیند آماری چندمتغیره، به بررسی و بازیابی سالانه محصولات غذایی و دارویی برای بررسی ثبات فرآیند تولید و کیفیت محصول نهایی پرداختند [۳۵]. تورس و همکاران^{۱۰}، (۲۰۱۸)، در پژوهش خود خرابی پره‌های توربین بادی را مدل‌سازی کردند و به شواهد تحلیلی دست یافتند که نشان می‌داد قبل از شکستن پرها، ترک‌های نامنظمی روی پرها به وجود آمده است. آن‌ها از مدل‌های خودرمزگذار عمیق برای پیش‌بینی ترک خوردگی قریب‌الوقوع پره به کمک داده‌های نظارتی استفاده کردند [۳۶]. در روش پیشنهادی جین و همکاران^{۱۱}، (۲۰۱۹)، یک الگوریتم تحلیلی جدید به نام تحلیل مؤلفه متمایزکننده اصلی^{۱۲} (PDCA)، برای پیاده‌سازی قابلیت استخراج آنی ویژگی، پیشنهاد شده است تا انحراف بین داده‌های نظارت‌شده آنلاین و مجموعه داده‌های نرمال عملیاتی، به موقع قابل کشف باشد [۳۳].

جدول ۱. مقایسه روش پیشنهادی و مقاله‌های موجود

پژوهشگر (سال)	کنترل کیفیت چندمتغیره	کنترل کیفیت چندمرحله‌ای	نوینزدایی	یادگیری عمیق	ترکیبی چندفیلتری	بهینه‌سازی پارامترها	مجموعه داده واقعی
نیایکی و همکاران، (۲۰۰۰)	✓					✓	✓
دونیاس و همکاران، (۲۰۰۱)			✓	✓			✓
نیایکی و همکاران، (۲۰۰۹)	✓	✓		✓			✓
ماسودا و همکاران، (۲۰۱۴)	✓					✓	✓
سانگ و همکاران، (۲۰۱۷)	✓		✓	✓			✓
سیلوا و همکاران، (۲۰۱۷)	✓		✓				✓
اودوم و همکاران، (۲۰۱۸)	✓	✓					✓
تورس و همکاران، (۲۰۱۸)	✓		✓				✓
جین و همکاران، (۲۰۱۸)	✓						✓
فرناندز و همکاران، (۲۰۱۸)	✓		✓			✓	✓
وانگ و همکاران، (۲۰۱۸)			✓	✓			✓
ژنگ و یو، (۲۰۱۸-۲۰۱۹)		✓	✓	✓		✓	✓
یو و همکاران، (۲۰۱۹)	✓		✓	✓			✓
اچ سو و همکاران، (۲۰۲۰)					✓	✓	✓
الیویرا و همکاران، (۲۰۲۰)	✓	✓					✓
چن و همکاران، (۲۰۲۰)	✓		✓	✓			✓
لی و همکاران، (۲۰۲۱)	✓						✓
روش پیشنهادی	✓	✓	✓	✓	✓	✓	✓

1. Song, et al

2. Autocorrelated

3. Adaptive-Dynamic Principal Component Analysis

4. Outliers

5. Oliveira, et al

6. Data Fusion

7. Process Analytical Technologies

8. Hsu, et al

9. Song, et al

10. Tôrres, et al

11. Jin, et al

12. Principal Discriminative Component Analysis

۳. روش‌شناسی پژوهش

روغن موتور، ترکیبی از روغن پایه و افزودنی‌ها است. روغن پایه اساس اولیه ساخت روغن موتور و انواع روانکارها به‌شمار می‌رود. «پالایشگاه نفت آبادان مسئول» تأمین روغن پایه «شرکت الموت» است و این محصول را از طریق تانکرهای مخصوص در اختیار این شرکت قرار می‌دهد. افزودنی‌های روغن موتور که نقش مهمی در تولید محصول نهایی دارند، از طریق بازرگانی‌های مختلف از کشورهای ایتالیا، چین و کره خریداری می‌شوند. این افزودنی‌ها، مشخصات استاندارد هر روغن موتوری را تأمین می‌کنند. کیفیت روغن موتور در شرکت‌های سازنده، منوط به استفاده درست و مطابق استاندارد تعیین‌شده از طرف سازمان استاندارد است. کنترل کیفیت در صنعت روغن موتور شامل روش‌هایی است که از شروع تولید تا محصول نهایی، تمامی مؤلفه‌های شیمیایی و فیزیکی را کنترل می‌کند و با توجه به میزان استاندارد هر متغیر، چه به‌صورت عددی باشد یا تصویری، کیفیت آن مؤلفه را قبول یا رد می‌کند. مشخصه‌های کیفی روغن موتور در سه ایستگاه کاری کنترل، موردنظارت قرار می‌گیرد و نتایج آن بررسی می‌شود این سه عبارت‌اند از: ایستگاه آزمون‌های شیمیایی؛ ایستگاه آزمون‌های فیزیکی و ایستگاه آزمون‌های شیمیایی - فیزیکی. استانداردهای روغن موتور توسط سه شرکت ¹SAE، ²API و ³MIL تدوین شده است. در ایران و تمامی نقاط دنیا، شرکت‌های تولید روغن موتور باید از این استانداردها در ساخت محصولات خود پیروی کنند. این استانداردها و نام آن‌ها در جداول قسمت تحلیل داده‌های پژوهش ارائه شده است.

کنترل کیفیت چندمتغیره - چندمرحله‌ای: فرآیندها و محصولات که مهندسان کیفیت درصدد کنترل آن‌ها هستند، در بسیاری از اوقات حکایت از چندمتغیره‌بودن آن‌ها دارد [۶]. بسیاری از فرآیندهای تولید شامل چندین مرحله متوالی با یک یا چند ویژگی کیفی هستند که باید در هر مرحله هم‌زمان کنترل شوند. تغییر در ویژگی‌های کیفی در هر مرحله بر ویژگی‌های کیفی مراحل بعدی تأثیر می‌گذارد؛ اما بر مراحل قبل تأثیری ندارد؛ در نتیجه کیفیت یک محصول در پایان هر مرحله نه‌تنها به عملکرد عادی مرحله فعلی، بلکه به عملکرد مراحل قبلی نیز بستگی دارد. دو وظیفه اساسی در کنترل فرآیند چندمتغیره - چندمرحله‌ای وجود دارد:

۱. تشخیص خطا: تعیین مشخصه‌هایی که باعث خارج شدن فرآیند از کنترل شده است [۲۶]؛
۲. شناسایی نوع خطا: تعیین مرحله‌ای که در شرایط خارج از کنترل قرار دارد.

روند یک سیستم تولید چندمرحله‌ای در صنعت ساخت روغن موتور در شکل ۱، نشان داده شده است.



شکل ۱. سیستم تولید چندمرحله‌ای در صنعت روغن موتور

الگوریتم‌های یادگیری عمیق مورد استفاده در پژوهش

شبکه حافظه کوتاه‌مدت طولانی (LSTM): نوعی از شبکه‌های عصبی بازگشتی^۱ (RNN) محسوب می‌شوند. یکی از مشکلات شبکه‌های عصبی بازگشتی، ناتوانی آن‌ها در یادگیری وابستگی بلندمدت است. برای رفع این مشکل، هاگرت و همکاران^۲ (۱۹۹۷)، نوعی معماری برای شبکه‌های عصبی بازگشتی پیشنهاد کردند که به معماری حافظه طولانی کوتاه‌مدت معروف شد و قادر بود تا نقصان فراموشی ذکر شده را جبران کند [۲]. LSTM مشکل حافظه بلندمدت شبکه RNN را با اضافه کردن یک قسمت به حافظه در شبکه‌های RNN حل کرده و مشخص می‌کند که چه داده‌هایی در توالی، مهم هستند و باید همچنان حفظ شده و چه داده‌هایی باید حذف شوند. بدین شکل شبکه، اطلاعات مهم را در طول زنجیره توالی عبور می‌دهد تا خروجی مورد نظر را به دست آورد [۳]. سازوکار حل الگوریتم LSTM بر پایه روابط ۱ تا ۶ است.

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + b_f) \quad \text{رابطه (۱)}$$

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + b_i) \quad \text{رابطه (۲)}$$

$$\hat{c}_t = \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c) \quad \text{رابطه (۳)}$$

$$C_t = f_t * C_{t-1} + i_t * \hat{c}_t \quad \text{رابطه (۴)}$$

$$O_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + b_o) \quad \text{رابطه (۵)}$$

$$\tanh \otimes C_t h_t = O_t \quad \text{رابطه (۶)}$$

σ یک تابع سیگموئید لجستیک است، \otimes حاصل ضرب مؤلفه‌ای دو بردار است و W_{hc} و W_{xc} ، W_{ho} ، W_{xo} ، W_{hf} ، W_{xf} ، W_{xi} ، W_{hi} و b_0 ، b_f ، b_i ، b_c بردارهای بایاس و f_t ، i_t و O_t بردارهای مقادیر فعال‌سازی درگاه فراموشی، درگاه ورودی و درگاه خروجی هستند.

شبکه‌های عصبی کانولوشنی: دسته‌ای از شبکه‌های عصبی عمیق هستند که معمولاً برای انجام تحلیل‌های تصویری یا گفتاری در یادگیری ماشین استفاده می‌شوند. یادگیری ماشین کاربرد الگوریتم‌هایی است که حجم عظیمی از داده را به دانش تبدیل می‌کند؛ همچنین برنامه‌ای طراحی می‌کند که از داده‌ها آموزش ببیند. الگوریتم‌ها این قابلیت را به ماشین می‌دهند تا رفتارشان را بر اساس داده‌ها تغییر دهند [۱۵]. در این مقاله از یک شبکه عصبی کانولوشنی تک‌لایه در ساخت مدل‌های مبتنی بر داده عددی و از یک شبکه عصبی کانولوشنی چندلایه برای پردازش تصویری نمونه‌های روغن موتور، استفاده شده است. مزیت بزرگ این روش این است که نیازی به انجام بسیاری از مراحل پردازش روی تصویر را ندارد [۱۱].

شبکه ResNet: قبل از معرفی این شبکه، استفاده از شبکه‌های عصبی با تعداد لایه‌های زیاد مشکلات فراوانی داشت. با افزایش تعداد لایه‌ها، شبکه دچار مشکل محوشدگی گرادیان^۱ می‌شد. شبکه رزنت توانست با ارائه راه‌حلی این مشکل را تا حد زیادی برطرف کند؛ به همین دلیل این شبکه می‌تواند تا ۱۵۲ لایه داشته باشد [۲۸].

شبکه DenseNet: یکی از آخرین شبکه‌های عصبی است که برای تشخیص دقیق اشیا ارائه شده است. معماری این شبکه، مشابه معماری شبکه ResNet است؛ اما دارای چند تفاوت اساسی است. این معماری نسبت به سایر معماری‌های قبلی نرخ خطای کمتری بر روی دیتا بیس مسئله دارد [۲۱].

شبکه VGG: شبکه عصبی کانولوشنی است. این شبکه نسخه‌های مختلفی دارد و این نسخه‌ها از ۱۱ لایه تا ۱۹ لایه دارند. در این شبکه، توجه اصلی معطوف به تأثیر عمق شبکه روی توان دقیق بودن آن است. شبکه VGG Net ابتدا یک عکس رنگی (RGB) با ابعاد ۲۲۴×۲۲۴ پیکسل را دریافت می‌کند و در اختیار لایه‌های بعدی قرار می‌دهد [۱۶].

الگوریتم فراابتکاری GBC: روشی است که مبتنی بر دو الگوریتم الهام‌گرفته‌شده از طبیعت یعنی ABC^۲ و GA^۳ است. هدف هر الگوریتم فراابتکاری یافتن راه‌حل بهینه است. برای رسیدن به این هدف باید به تعادلی بین بهره‌وری و اکتشاف رسید. این روش برای تنظیم الگوریتم‌های یادگیری عمیقی که دچار Over-Fitting یا Under-Fitting می‌شوند، به کار می‌رود [۴].

خودرمزگذار: AE نوع خاصی از شبکه عصبی چندلایه و از روش‌های یادگیری غیرنظارت‌شده است که به صورت سلسله‌مراتبی به کاهش بُعد داده‌های ورودی می‌پردازد. این شبکه یک شبکه عصبی بدون نظارت است که یاد می‌گیرد ورودی را به خودش نگاشت کند. این شبکه‌ها دارای یک لایه ورودی، یک لایه خروجی و یک لایه پنهان^۴ هستند. در این شبکه‌ها معمولاً تعداد نورون‌های لایه ورودی و لایه خروجی یکسان بوده و معماری لایه‌ها متقارن است [۲۲].

معیارهای ارزیابی. برای هر نمونه داده، یکی از چهار حالتی که در ادامه بیان شده، ممکن است اتفاق بیفتد. به وسیله این چهار حالت، ارزیابی عملکرد دقیقی، برای هر داده بیان می‌شود. ماتریس درهم‌ریختگی در شکل ۲، نشان داده شده و ساختار آن در این شکل معلوم است.

- اگر نمونه، عضو کلاس مثبت باشد و عضو همین کلاس تشخیص داده شود، مثبت صحیح^۵.
- اگر نمونه، عضو کلاس مثبت باشد و عضو کلاس منفی تشخیص داده شود، منفی کاذب^۶.
- اگر نمونه، عضو کلاس منفی باشد و عضو همین کلاس تشخیص داده شود، منفی صحیح^۷.
- اگر نمونه، عضو کلاس منفی باشد و عضو کلاس مثبت تشخیص داده شود، مثبت کاذب^۸.

صحت^۹: دقت دسته‌بندی، بیشتر بر تشخیص درست کلاس مثبت از منفی تمرکز دارد و به تعیین عملکرد کلی طبقه‌بند می‌پردازد و نشان می‌دهد که چه تعداد از کل موارد آزمایشی به درستی توسط طبقه‌بند، طبقه‌بندی شده است. صحت، به صورت رابطه^۷، نشان داده می‌شود.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad \text{رابطه (۷)}$$

دقت^{۱۰}: نشان‌دهنده قابلیت اطمینان طبقه‌بند و نمایانگر نسبت خطاهای تشخیص داده‌شده واقعی در بین خطاهای هشدار داده‌شده است و به صورت رابطه^۸، نشان داده می‌شود.

$$\text{Precision} = \frac{TP}{TP + FP} \quad \text{رابطه (۸)}$$

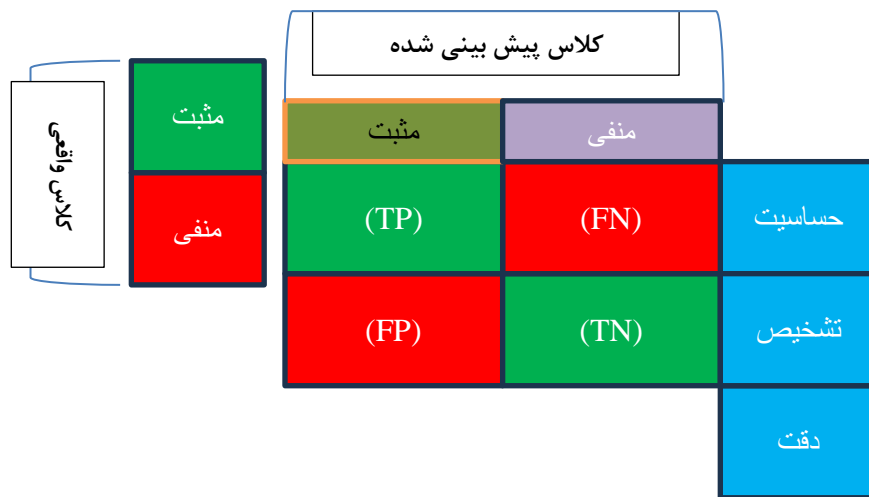
1. Vanishing Gradient Problem
 2. Artificial Bee Colony
 3. Genetic Algorithm
 4. Hidden Layer
 5. True Positive
 6. False Negative
 7. True Negative
 8. False Positive
 9. Accuracy
 10. Precision

پوشش (فراخوانی)^۱: به‌عنوان حساسیت^۲ و نرخ مثبت واقعی نیز شناخته می‌شود، نسبت خطاهای تشخیص داده‌شده توسط مدل را نشان می‌دهد. فراخوانی به‌صورت رابطه^۹، است.

$$\text{Recall} = \frac{TP}{TP + FN} \quad \text{رابطه (۹)}$$

امتیاز $F1^3$: امتیاز معیاری برای ارزیابی دقت یک مدل طبقه‌بندی آماری است. این امتیاز به‌صورت رابطه^{۱۰}، نشان داده می‌شود.

$$F1 = 2 \frac{\text{precision} \cdot \text{recall}}{\text{precision} + \text{recall}} \quad \text{رابطه (۱۰)}$$



شکل ۲. ماتریس درهم‌ریختگی و معیارهای آن [۳۲]

مسئله مورد بررسی در این پژوهش. هدف این پژوهش، ایجاد مدل‌های ترکیبی بهینه، LSTM-CNN و ResNet-DensNet است که برای نظارت بر روند کنترل کیفیت فرآیند تولید، تشخیص خطا در حین فرآیند و تعیین نوع خطای سیستم از این دو الگوریتم استفاده می‌کند. در این مسئله، متغیرهای بسیاری در سه مرحله کاری قرار گرفته‌اند که باید به‌صورت توأم (هم‌زمان) کنترل شوند. در چنین فرآیندهایی پایش و کنترل متغیرهای غیرمستقل، بسیار پیچیده‌تر از فرآیندهای تک‌متغیره است؛ همچنین نمی‌توان از نمودارهای کنترل تک‌متغیره شوهارت در این مسائل استفاده کرد و باید از روش کنترل کیفیت چندمتغیره - چندمرحله‌ای استفاده شود. در روش پیشنهادی برای انطباق بیشتر مدل با مسائل موجود در دنیای واقعی، فرض شده است که داده‌های مؤلفه‌های کیفی در این مسئله، داده‌های واقعی هستند.

با توجه به معیارهای بالا و شرایط مسئله، از الگوریتم‌های خودم‌گذار ترکیبی یادگیری عمیق LSTM-CNN برای تشخیص خطا و نظارت بر مؤلفه‌های کیفی استفاده شده است. بعد از مقایسه الگوریتم‌های CNN و VGG و ResNet و Dens Net، از الگوریتم ترکیبی ResNet-DenNet برای کنترل مؤلفه‌های کیفی تصویری استفاده شده است.

روش حل. در این پژوهش، روش حل از دو قسمت تشکیل شده است:


۱. بخشی از پژوهش که شامل متغیرهای عددی است؛

۲. بخشی از پژوهش که شامل متغیرهای تصویری است.

عملیات نظارت، تشخیص خطا و تشخیص نوع خطا در سه مرحله کنترل کیفی (آزمون‌های شیمیایی، آزمون‌های فیزیکی، آزمون‌های شیمیایی - فیزیکی) انجام شده است. در متغیرهای عددی و تصویری از برچسب قبول^۱ یا غیرقابل قبول^۲ در این سه مرحله استفاده شده است. ابتدا الگوریتم‌های CNN و LSTM به صورت جداگانه و یک الگوریتم ترکیبی^۳ بر اساس LSTM-CNN ساخته می‌شود و نتایج این سه مدل با هم مقایسه می‌شوند. مدلی که نتایج بهتری داشته باشد، به وسیله خودرمزگذار، استخراج ویژگی^۴ می‌شود و سپس الگوریتم متاهیورستیک GBC پارامترهای مدل انتخابی را بهبود می‌دهد و الگوریتمی بر اساس پارامترهای جدید ایجاد می‌کند. روش بهبودیافته، فرایند کنترل کیفیت روغن موتور را از لحاظ تشخیص خطا^۵ و نوع خطای احتمالی^۶ بررسی می‌کند.

در قسمتی از آزمون‌های فیزیکی - شیمیایی (مرحله سوم)، متغیرهایی وجود دارند که داده‌های آن‌ها تصویری هستند و باید به وسیله الگوریتم‌های یادگیری عمیقی که در پردازش تصویر کاربرد بیشتری دارند، بررسی شوند. در این پژوهش از الگوریتم‌های CNN، VGG، ResNet، DensNet و Net به صورت جداگانه و الگوریتم ترکیبی ResNet-DensNet استفاده شده است. روش حل مسئله به صورت فلوچارت، در شکل

۳، مشاهده می‌شود



شکل ۳. فلوچارت حل مسئله

1. Accept
2. Unacceptable
3. Hybrid
4. Feature Extraction
5. Fault Detection
6. Fault Type

۴. تحلیل داده‌ها و یافته‌های پژوهش

با توجه به تعریف مسئله، نحوه نمونه‌گیری در این پژوهش از اهمیت ویژه‌ای برخوردار است، نمونه‌گیری در «شرکت پالایش الموت» بر اساس استانداردهای الزامی سازمان استاندارد ایران صورت گرفت و نحوه اجرای نمونه‌گیری با استفاده از روش استاندارد MIL-STD-105D انجام شد. نمونه‌گیری از مخازن با حجم بالا (حدود ۵۰۰۰ لیتر) توصیه می‌شود. نمونه از قسمت‌های بالایی، میانی و کف به‌طور جداگانه تهیه و به‌صورت تفکیک شده، همراه با کد و علامت‌گذاری مشخص، به واحد کنترل کیفی، برای تحلیل ارسال شد. تعداد نمونه‌گیری، طی ۱ روز از هر مخزن ۱۰۰۰۰ لیتری در سه نوبت و در ساعت‌های هشت، دوازده و هجده صورت گرفت. داده‌های هر متغیر کیفی، طی ۱۰۰ روز کاری لحاظ شده است.

فرآیند کنترل کیفیت در مؤلفه‌های کیفی روغن موتور در شکل ۴، نشان داده شده و چگونگی انجام فرآیند به‌ترتیب ذکر شده است.



شکل ۴. فرآیند کنترل کیفیت در مطالعه موردی

در ابتدا برای حل مسئله و اینکه چرا از روش‌های یادگیری عمیق در این پژوهش استفاده شده است، از آزمون تست نرمال^۱ برای بررسی وضعیت نرمال بودن داده‌ها در سه مرحله آزمون کیفی استفاده می‌شود. در روش‌های آماری پارامتری فرض بر این است که داده‌ها دارای توزیع شناخته‌شده و معینی هستند. در بیشتر موارد، در آمار کلاسیک این توزیع برای داده‌ها، توزیع گاوسی یا نرمال در نظر گرفته می‌شود. ولی اگر توزیع این داده‌ها گاوسی یا نرمال نباشد پیش‌فرض‌های مربوط به آزمون‌ها و تحلیل‌های آماری پارامتری و کلاسیک، نقض شده و باید از روش‌های آماری غیرپارامتری استفاده شود.

در این پژوهش از آزمون‌های هنز - زیکلر^۲، استفاده شده است. در این آزمون برای تأیید نرمال بودن داده‌ها، مقدار احتمال^۳ آزمون باید بیشتر از ۰/۵ باشد. جدول ۳، نتایج آزمون‌های نرمالیتیه برای مجموعه داده را نشان می‌دهد. روش هنز - زیکلر مقدار p کمتر از ۰/۰۴ داشت که نشان می‌دهد داده‌ها آزمون نرمالیتیه را پاس نکرده‌اند؛ بنابراین می‌توان نتیجه گرفت که مجموعه داده آزمون‌های نرمالیتیه را پاس نکرده است. نتایج آزمون نرمالیتیه در جدول ۲، ارائه شده است. شبه‌کد این آزمون نیز در شکل ۵، نشان داده شده است.

1. Normality Test
2. Henze-Zirkler Test Method
3. P-Value

جدول ۲. آزمون نرمالیتی داده‌های مسئله

Test For Normal Distribution	P. Value	Passed Normality Test
Henz zikler Method	<0.004	No

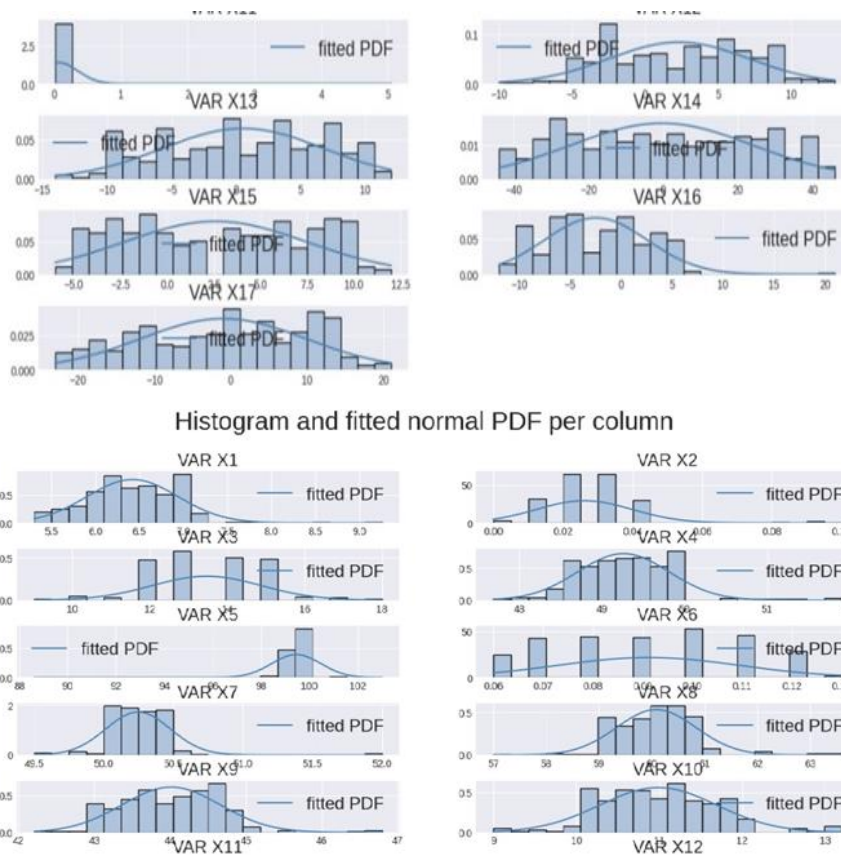
```

Pseudo code for the Henze-Zirkler Normality Test
Input: A list of data points named 'data'
Output: Result of the Henze-Zirkler Normality Test
Calculate the number of data points
input(n), n=length(data)
# Calculate the ranks of the data points using the rank data () function
ranks = rank data(data)
# Calculate the mean rank
mean_rank =  $\frac{\sum ranks}{n}$ 
# Calculate the z-scores for each data point
z_scores = [(rank - mean_rank) / sqrt(n) for rank in ranks]
# Calculate the squared z-scores sum
S = sum([z ** 2 for z in z_scores])
# Calculate the value of k using S and n
k = sqrt((S - n + 1) / n)
# Calculate the test statistic
test_statistic = (n - 1) * (1 - k ** 2)
# Input: Significance threshold 'threshold'
threshold = 0.05
if test_statistic > threshold:
# Output: "The data does not follow a normal distribution according to the Henze-Zirkler
test."
else:
# Output: "The data follows a normal distribution according to the Henze-Zirkler test."

```


شکل ۵. شبه‌کد آزمون نرمالیتی به روش هنر-زیکلر برای داده‌های مسئله

در شکل ۶، محور افقی در نمودار هیستوگرام نمایانگر تعداد مشاهدات مختلفی است که از آزمون‌های نرمالیتیته به‌دست آمده‌اند و محور عمودی نمایانگر مقادیر P-Value است. از تحلیل شکل هیستوگرام، مشاهده می‌شود که برای هر سه آزمون، مقدار P-Value در بیشتر نقاط کمتر از ۰/۰۵ بوده و کمتر از آستانه تعیین‌شده در هر سه آزمون است. این نتیجه نشان می‌دهد که در مجموع داده‌ها توزیع نرمال ندارند و غیرنرمال هستند.



شکل ۶. نمودار هیستوگرام تشخیص نوع داده‌های مسئله

در شکل ۷، نمودار $ECDF^1$ (تابع توزیع تجمعی تجربی) و منحنی تطابقی (Fitted CDF) نشان داده شده است. از این دو نمودار برای بررسی توزیع داده‌ها استفاده می‌شود. در صورتی که داده‌ها از یک توزیع نرمال پیروی نکنند، منحنی $ECDF$ با منحنی تطابقی مطابقت ندارد و غیرخطی است. این عدم همبستگی و غیرخطی بودن، میان منحنی $ECDF$ و منحنی تطابقی، در شکل ۷، نشان داده شده است و بر غیرنرمال بودن داده‌ها اشاره می‌کند.



شکل ۷. نمودار تجمعی تشخیص نوع داده‌های مسئله

پس از انجام آزمون هنز - زیگلر، مقدار احتمال نرمال بودن داده‌ها، صفر تخمین زده شده است؛ در نتیجه فرض نرمال بودن داده‌ها رد و غیرنرمال بودن داده‌ها ثابت می‌شود. در این شرایط استفاده از روش‌های یادگیری عمیق برای کنترل مؤلفه‌های کیفی، پیشنهاد می‌شود.

پیاده‌سازی مدل و الگوریتم پیشنهادی در یک مطالعه موردی. از آنجاکه بسیاری از فرآیندهای واقعی در تولید دارای چندین مرحله کاری هستند و هر مرحله کاری شامل متغیرهای مهمی برای کنترل مؤلفه‌های کیفی محصول است، نظارت بر فرآیند و شناسایی عامل یا عوامل ایجاد خطا در فرآیند، نیازمند استفاده از روش‌های کنترل چندمتغیره - چندمرحله‌ای است [۶].

در این پژوهش، مورد مطالعاتی شامل سه مرحله کاری شیمیایی، فیزیکی و شیمیایی - فیزیکی است. آزمون مرحله شیمیایی شامل ۱۷ متغیر کیفی^۱ است که اسامی و حدود کنترل هر متغیر در جدول ۳، آورده شده است. آزمون مرحله فیزیکی، شامل ۱۰ متغیر کیفی است که اسامی و حدود کنترل هر متغیر در جدول ۴، آورده شده است. آزمون مرحله شیمیایی فیزیکی شامل ۱۰ متغیر کیفی است که اسامی و حدود کنترل هر متغیر در جدول ۵، ذکر شده است. فرآیند کنترل به این صورت است که مراحل کاری باید به ترتیب مورد تحلیل قرار بگیرند و نتایج هر مرحله در مرحله بعدی تأثیرگذار است. استاندارد مورد نیاز برای هر متغیر در سمت راست هر سه جدول درج شده است.

جدول ۳. آزمون‌های شیمیایی در مرحله اول

روش آزمون استاندارد	حد مجاز بالا	حد مجاز پایین	آزمون کیفی
D2896	۷	۶	عدد قلبیایی
D664	۰/۰۴	۰/۰۱	عدد اسیدی
D3780	۱۵	۱۲	فراریت
D1401	۵۰	۴۸/۵	قابلیت فیلتر شدن
D6594	۱۰۰	۹۹	جلوگیری از زنگ زدگی
D5185	۰/۱۲	۰/۰۶	میزان فسفر
D6795	۵۰/۵	۵۰	آزمون ای.او. وایت
D7097	۶۱	۵۹	اکسیداسیون ۳۳
D6335	۴۵	۴۳	اکسیداسیون تی ۴
D5133	۱۲	۱۰	شاخص ژلاتین
D9377	۰/۰۶	۰/۰۳	میزان گوگرد
D1298	۹	-۵	تغییر حجم
D524	۱۰	-۱۰	تغییر درجه سختی ۱
D6304	۴۰	-۴۰	تغییر استحکام کششی
D1289	۱۰	-۵	تغییر حجم ۲
D524	۵	-۱۰	تغییر درجه سختی ۲
D6304	۱۵	-۲۰	تغییر استحکام کششی ۲

جدول ۴. آزمون‌های فیزیکی در مرحله دوم

روش آزمون استاندارد	حد مجاز بالا	حد مجاز پایین	آزمون کیفی
D2270	۱۲۰	۸۰	شاخص گرانیروی
D445	۱۶	۱۲	گرانیروی ظاهری
D892	۱۰	۰	آزمون کف در ۳۴°C
D6082	۵۰	۰	آزمون کف در ۹۳°C
D892	۱۰	۰	آزمون کف در ۲۴°C
D97	-۳۰	-۳۵	نقطه ریزش
D9378	۲۰۰	۵۰	آزمون کف در ۱۵۰°C
D5293	۳۴۲	۳۳۸	آزمون کف در دمای پایین (سی سی اس)
INSO196	۷۰۰۰	۶۹۰۰	آزمون کف هنگام روشن کردن موتور
INSO196	۶۰۰۰۰	۵۹۰۰۰	آزمون کف هنگام پمپاژ روغن (حداکثر)

جدول ۵. آزمون‌های شیمیایی - فیزیکی در مرحله سوم

روش آزمون استاندارد	حد مجاز بالا	حد مجاز پایین	آزمون کیفی
D6595	۱۸۰	۸۰	آهن
D5185	۲۸	۴	کروم
D5185	۲۴	۱۲	قلج
D6195	۵۵	۱۲	آلومینیوم
D4951	۳	۱	نیکل
D5185	۳۰	۵	سدیم
D5185	۳۰	۱۰	سرب
D5185	۲۰	۴	مولیبدن
D5185	۳۰	۱۵	سیلیسیم
D5185	۳۰	۲	پتاسیم

نظارت بر مؤلفه‌های کیفی^۱ و تشخیص خطای احتمالی در متغیرها. داده‌های مؤلفه‌های کیفی در این پژوهش از دو بخش عددی و تصویری تشکیل شده است. داده‌های عددی در سه مرحله کاری، جداگانه سنجیده می‌شوند و متغیرهای تصویری که در آزمون‌های فیزیکی و شیمیایی (مرحله سوم سنجش کیفی) قرار گرفته‌اند، با روش پردازش تصاویر موردسنجش کیفی قرار می‌گیرند.

ابتدا با هری ک از الگوریتم‌های CNN و LSTM به‌طور جداگانه، یک مدل ساخته می‌شود. مدل ترکیبی LSTM-CNN ایجاد می‌گردد، در آخر نتایج به‌دست‌آمده از هر الگوریتم موردبررسی قرار می‌گیرد.

پس از ساخت روش‌ها بر اساس الگوریتم‌های LSTM-CNN، LSTM و CNN داده‌ها در تمامی مراحل و روش‌ها به دو گروه Train با ظرفیت ۸۰ درصد از کل داده‌ها و آزمون، با اختصاص ظرفیت ۲۰ درصد داده‌ها به‌صورت تصادفی تقسیم می‌شوند. برای بالابردن دقت مدل، عملیات تکنیک بیش‌نمونه‌گیری اقلیت مصنوعی^۲ از روش smote انجام شده و نتایج چهار شاخص دقت، صحت، پوشش و معیار F1 از الگوریتم‌های LSTM-CNN، LSTM و CNN استخراج شد که نتیجه آن در جدول ۶ نشان داده شده است.

جدول ۶. نتایج مدل‌های پیشنهادی


شاخص	LSTM-CNN	CNN	LSTM	LSTM-CNN _{tuned}
صحت	۰/۸۹۶	۰/۸۴۴	۰/۸۲۳	۰/۹۳۸
دقت	۰/۸۹۴	۰/۸۴۳	۰/۸۳۶	۰/۹۳۷
فراخوان	۰/۸۹۹	۰/۸۴۸	۰/۸۰۸	۰/۹۳۷
معیار F1	۰/۸۹۵	۰/۸۴۳	۰/۸۱۴	۰/۹۳۷
صحت	۰/۸۹۲	۰/۷۵۹	۰/۸۸	۰/۹۱۶
دقت	۰/۸۹	۰/۷۵۷	۰/۸۸۲	۰/۹۱۶
فراخوان	۰/۸۹۴	۰/۷۵۹	۰/۸۸۶	۰/۹۱۳
معیار F1	۰/۸۹۱	۰/۷۵۷	۰/۸۷۹	۰/۹۱۴
صحت	۰/۹۴۹	۰/۸۷۲	۰/۹۱	۰/۹۷۴
دقت	۰/۹۵	۰/۸۸۳	۰/۹۱۱	۰/۹۷۴
فراخوان	۰/۹۵۲	۰/۸۷۹	۰/۹۰۹	۰/۹۷۶
معیار F1	۰/۹۴۲	۰/۸۷۲	۰/۹۱	۰/۹۷۴

با توجه به جدول ۶، نتایج حاصل از الگوریتم ترکیبی LSTM-CNN نسبت به روش‌هایی که از روش تک‌الگوریتمی برای تشخیص خطا استفاده شده، بهتر است. برای بهینه‌سازی مدل ترکیبی، پارامترهای آن با استفاده از الگوریتم فراابتکاری GBC که نقش مهمی در بهبود الگوریتم‌های یادگیری عمیق دارد، تنظیم شده و سپس مدل اجرا می‌شود [۶]. این فرآیند تکراری تا زمانی ادامه دارد که پارامترهای مدل ترکیبی به‌گونه‌ای تغییر کنند که بهبود قابل‌مشاهده‌ای در عملکرد حاصل شود. جدول نتایج، اجرای الگوریتم‌های یادگیری عمیق در سه مرحله مختلف را نمایش می‌دهد.

در مرحله اول، نتایج LSTM، LSTM-CNN و CNN مشابه هستند که معمولاً در مسائل یادگیری عمیق اولیه رخ می‌دهد. در مرحله دوم، LSTM-CNN بهبود زیادی در دقت داشته و به حدی در سایر معیارها نیز بهبود داشته است. در مرحله سوم، الگوریتم‌های ترکیبی LSTM-CNN در معیارهای ارزیابی نسبت به دو الگوریتم دیگر عملکرد بهتری داشته‌اند. با توجه به این نتایج، الگوریتم ترکیبی LSTM-CNN برای تنظیم پارامترها با استفاده از الگوریتم GBC انتخاب شده است. نتایج پس از تنظیم که در ستون LSTM-CNN_{TUNED} در سمت راست جدول آمده است، بهبود قابل‌توجهی داشته‌اند و نتایج به سطوح قابل‌قبولی ارتقا یافته‌اند. با توجه به این تجزیه و تحلیل، می‌توان نتیجه گرفت که الگوریتم ترکیبی LSTM-CNN پس از بهینه‌سازی با استفاده از الگوریتم GBC بهبود چشمگیری در کیفیت دستیابی به نتایج حاصل کرده است. با توجه به این نتایج، دقت تشخیص خطا در مراحل مختلف افزایش قابل‌قبولی دارد. جدول ۷، هایپرپارامترها و بازه موردنظر برای مقادیر بیشینه و کمینه هر یک را نشان می‌دهد.

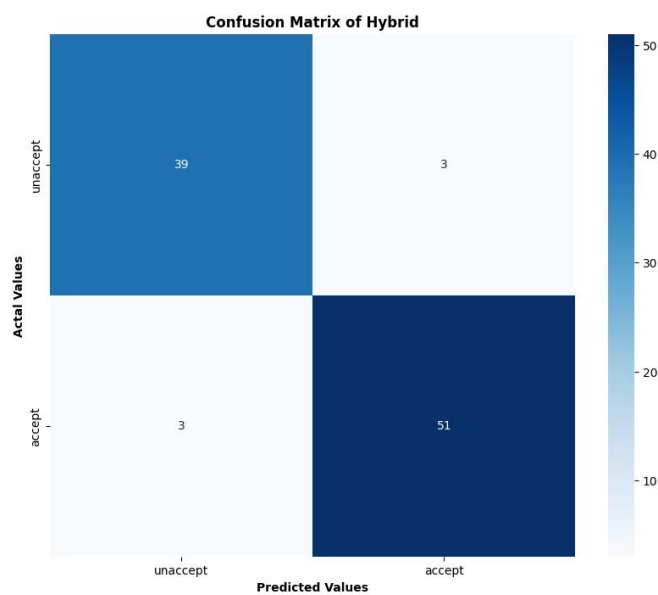
جدول ۷. نتایج تنظیم پارامترهای مدل ترکیبی تشخیص خطا در سه مرحله

مقدار کمیته	مقدار بیشینه	هایپر پارامتر
۰/۰۰۰۱	۰/۰۱	نرخ یادگیری
۱	۳	بهینه‌ساز
۱۰	۱۰۰	اندازه ورودی
۵	۶۰۰	تعداد نورون‌های لایه‌ها
۰/۳	۰/۷	مقدار Dropout لایه‌ها



شکل ۸. نمودار داده‌های آموزشی مدل منتخب

اجرای داده‌های آموزشی در شکل ۸، نشان داده شده است. همگرایی داده‌ها در تکرار ۵۰ به بعد نمایانگر تنظیم مدل است و از این تکرار به بعد بهبود عملکرد ثابت است.



شکل ۹. ماتریس درهم‌ریختگی مدل ترکیبی منتخب

با توجه به شکل ۹، مدل ترکیبی ۳ مورد را به‌اشتباه غیرقابل قبول اعلام کرده و ۳ مورد را که نباید قبول می‌کرده، به‌اشتباه قابل قبول اعلام کرده است؛ ولی در ۳۹ مورد دیگر، نمونه‌ها از نظر الگوریتم غیرقابل قبول بوده که به‌درستی تشخیص داده شده است و ۵۱ مورد قابل قبول بوده که به‌درستی، الگوریتم، آن‌ها را قابل قبول اعلام کرده است.

تشخیص نوع خطای رخ داده در مراحل کنترل کیفی (شیمیایی، فیزیکی و شیمیایی - فیزیکی). بعد از تشخیص خطا در مراحل کنترل کیفی، نوبت به آن می‌رسد که نوع خطای احتمالی پیش‌آمده تعیین شود تا مشخص شود خطای فرآیند در کدامین مرحله اتفاق افتاده است. قبل از اجرای مدل‌ها ابتدا به‌وسیله خودمزم‌گذارها برای بالابردن دقت مدل از تکنیک استخراج ویژگی به‌منظور انتخاب متغیرهایی که از درجه اهمیت بیشتری برخوردار هستند، استفاده شده است.


در بخش تشخیص خطا از دو الگوریتم CNN و LSTM و ترکیب دوتایی این الگوریتم‌ها استفاده شده و با مقایسه نتایج تمام حالت‌ها، الگوریتمی که از شاخص‌های بهتری برخوردار باشد، انتخاب می‌شود؛ سپس با استفاده از الگوریتم فراابتکاری GBC پارامترهای الگوریتم، تنظیم و مدل مجدداً اجرا می‌شود.

داده‌های کلیه مراحل به‌صورت هم‌زمان در مدل بارگذاری می‌شود. نتایج به‌دست‌آمده در جدول شماره ۸، نشان داده شده است.

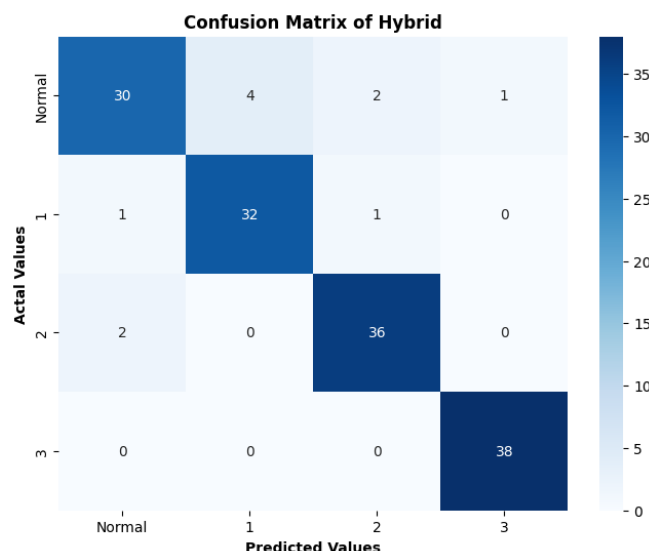
جدول ۸. نتایج تشخیص نوع خطای احتمالی در مدل

شاخص	LSTM-CNN	CNN	LSTM	LSTM-CNN _{TUNED}
صحت	۰/۸۹۶	۰/۸۴۴	۰/۸۲۳	۰/۹۲۵
دقت	۰/۸۹۴	۰/۸۴۳	۰/۸۳۶	۰/۹۲۴
فراخوان	۰/۸۹۹	۰/۸۴۸	۰/۸۰۸	۰/۹۲۵
F1معیار	۰/۸۹۵	۰/۸۴۳	۰/۸۴۳	۰/۹۲۳

با توجه به جدول ۸، الگوریتم ترکیبی LSTM-CNN از شاخص‌های بهتری نسبت به روش‌هایی که از یک الگوریتم، ساخته شده، برخوردار است. به همین منظور از الگوریتم GBC برای تنظیم پارامترهای مدل ترکیبی استفاده می‌شود. بعد از تنظیم پارامترهای مدل، الگوریتم مجدداً اجرا شده و نتایج آن در جدول ۸، نشان داده شده است. مشاهده می‌شود که شاخص‌ها بعد از تنظیم مدل ترکیبی در تکرار ۲۵، به همگرایی رسیده‌اند. اجرای داده‌های آموزشی در شکل شماره ۱۰، مشاهده می‌شود.



شکل ۱۰. اجرای داده‌های آموزشی برای مدل بهینه تشخیص نوع خطا



شکل ۱۱. ماتریس درهم‌ریختگی مدل بهینه تشخیص نوع خطا

در ماتریس درهم‌ریختگی شکل ۱۱، نتایج به‌دست‌آمده بدین ترتیب است: در ۳۰ مورد فرآیند، بدون خطا بوده و مدل به‌درستی تشخیص داده است. ۱ مورد خطا در مرحله اول و ۲ مورد خطا در مرحله دوم به‌اشتباه پیش‌بینی شده است؛ در صورتی که فرآیند در شرایط واقعی خطایی نداشته است. در قطر اصلی ماتریس، مشاهده می‌شود که بیشتر پیش‌بینی‌ها درست بوده و تعداد خطای فرآیند بسیار کم است. **نظارت و تشخیص خطا بر روی داده‌های تصویری^۱**. در مرحله سوم کنترل مؤلفه‌های کیفی (آزمون‌های شیمیایی - فیزیکی) دو متغیر وجود دارد که داده‌های آن‌ها به‌صورت تصویری است و کنترل بر روی این متغیرها به‌وسیله مدل‌هایی که پردازش تصویر را انجام می‌دهند، صورت می‌پذیرد. لگوریتم‌های یادگیری عمیق مورد استفاده در این قسمت عبارت‌اند از: VGG؛ CNN؛ Res Net؛ Dens Net و Res Net-Dens Net.


دو متغیر در این بخش عبارت‌اند از: ۱. رنگ نهایی روغن موتور^۲؛ ۲. تغییر رنگ قطعات موتوری، در اثر مجاورت با ترکیبات مس موجود در روغن موتور. ابتدا تمامی داده‌ها به دو گروه Train و Test به نسبت ۲۰ به ۸۰ به‌صورت تصادفی تقسیم شدند. در تمامی الگوریتم‌ها مقدار تکرار اندازه دسته برابر با ۵۰ و اندازه تصاویر ۱۲۸*۱۲۸ در نظر گرفته شد. تنظیم پارامتر الگوریتم‌های مورد استفاده در این بخش در جدول ۹، نشان داده شده است.

جدول ۹. تنظیم پارامتر الگوریتم‌های تصویری

تنظیم های پارامترهای الگوریتم‌های به‌کاررفته در این پژوهش					
ResNet-DensNet	CNN	VGG	ResNet	DensNet	مقدار بهینه ابر پارامتر
۰/۰۰۱	۰/۰۰۱	۰/۰۰۱	۰/۰۰۱	۰/۰۰۱	نرخ یادگیری
ADAM	ADAM	ADAM	ADAM	ADAM	بهینه‌ساز
۵۰	۵۰	۵۰	۵۰	۵۰	اندازه ورودی
[۵۰۰,۲۰۰,۵۰]	[۶۴,۳۲,۱۶]	[۱۰۰,۵۰]	[۱۰۰,۵۰]	[۱۰۰,۵۰]	تعداد نورون هر لایه
۰/۲	۰/۵	۰/۵	۰/۲	۰/۲	لایه‌ها Dropout مقدار
-	[۱۰۰,۵۰]	-	-	-	تعداد فیلترهای لایه Convolution

ابتدا پردازش تصویر بر مؤلفه رنگ روغن موتور انجام می‌شود. مجموعه‌ای از رنگ‌های روغن موتور با برچسب قابل قبول^۳ و غیرقابل قبول^۴ در شکل ۱۲، نشان داده شده است.

1. Image Data
2. Finish Color Motor Oil
3. Acceptable
4. Unacceptable




شکل ۱۲. نمونه رنگ روغن موتور (قابل قبول و غیر قابل قبول)

نتایج به دست آمده از اجرای الگوریتم‌های ترکیبی در جدول ۱۰، ارائه شده است.

جدول ۱۰. نتایج مدل‌های پیشنهادی برای متغیر، رنگ روغن


شاخص	DensNet	ResNet	CNN	VGG	Res-Dens
صحت	۰/۹۹۷	۰/۸۶۶	۰/۸۸۶	۰/۹۳۹	۰/۹۸۶
دقت	۰/۹۸۲	۰/۹۳۵	۰/۹۵	۰/۹۲۶	۰/۹۹۱
پوشش	۰/۹۲۸	۰/۷۵	۰/۸۱۲	۰/۸۶۶	۰/۹۶۹
معیار F1	۰/۹۵۸	۰/۷۹۹	۰/۸۵۸	۰/۸۹۱	۰/۹۷۹

با توجه به جدول ۱۰، دو مدل ResNet و DensNet از دقت بالاتری نسبت به دو مدل VGG و CNN برخوردار هستند. مدل ترکیبی این دو الگوریتم با یکدیگر نیز مورد سنجش قرار گرفته و نتیجه بهینه در مدل ترکیبی به دست آمده در جدول نشان داده شده است. الگوریتم GBC در این روش ترکیبی نمی‌تواند در تنظیم پارامترهای مدل، تأثیری داشته باشد؛ زیرا نتایج نشان می‌دهد خود مدل بهینه است. ماتریس درهم‌ریختگی مدل ترکیبی در شکل ۱۳، مشاهده می‌شود. این مدل فقط در ۱ مورد به اشتباه داده تصویری را خطا تشخیص داده است.



شکل ۱۳. ماتریس درهم‌ریختگی مدل ترکیبی

نمودار میله‌ای میزان دقت عملکرد مدل‌های تصویری در شکل ۱۴، نشان داده شده است. با توجه به این شکل، دقت الگوریتم ترکیبی ResNet-DenseNet، بیشترین مقدار را دارد.



شکل ۱۴. نمودار دقت مدل منتخب رنگ روغن موتور

در ادامه، مؤلفه تغییر رنگ قطعات موتوری در اثر مجاورت با ذرات مس معلق در روغن موتور بررسی شده است. داده‌های این متغیر نیز به دو بخش، به نسبت ۸۰ به ۲۰ به صورت تصادفی تقسیم شده‌اند و از الگوریتم ترکیبی ResNet-DensNet برای ساخت مدل بهینه استفاده شده است. مجموعه رنگ قطعات موتوری در مجاورت عنصر مس در شکل ۱۵، مشاهده می‌شود.



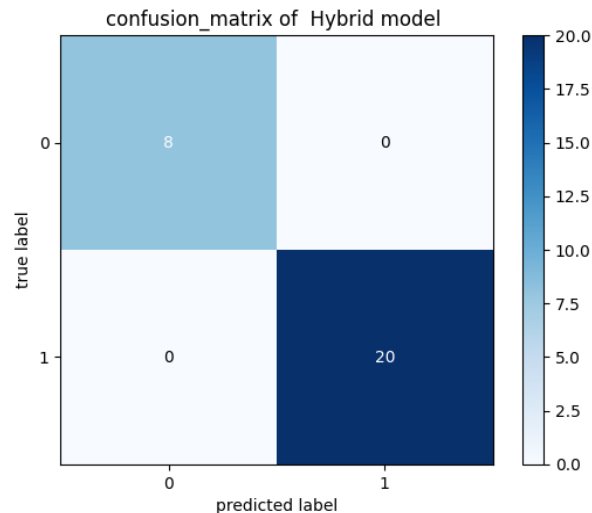
شکل ۱۵. نمونه رنگ، خوردگی قطعات موتوری در اثر عنصر مس موجود در روغن موتور

نتایج به دست آمده از الگوریتم‌های یادگیری عمیقی که برای پردازش مؤلفه‌های تصویری استفاده شده‌اند، در جدول ۱۱، مشاهده می‌شود.

جدول ۱۱. نتایج روش‌های پیشنهادی برای مؤلفه، تغییر رنگ قطعات موتوری در اثر ذرات مس

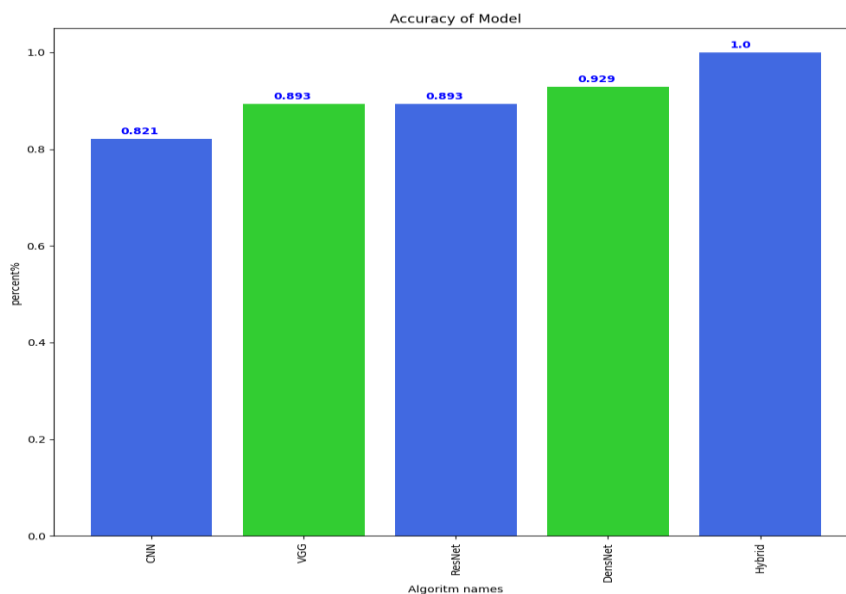
شاخص	DensNet	ResNet	CNN	VGG	Res-Dens
صحت	۰/۹۲۹	۰/۸۹۳	۰/۸۲۱	۰/۸۹۳	۱
دقت	۰/۹۵۵	۰/۹۳۵	۰/۹	۰/۸۸۱	۱
پوشش	۰/۸۷۵	۰/۸۱۲	۰/۶۸۸	۰/۸۵	۱
معیار F1	۰/۹۰۵	۰/۸۵	۰/۷۱۷	۰/۸۶۳	۱

با توجه به جدول شماره ۱۱، بعد از ساختن و اجرای روش DensNet تنها عاملی که باعث شد روش ترکیبی ResNet-DensNet ایجاد شود، پایین بودن شاخص پوشش در روش DensNet بود. مقدار این شاخص در جدول ۱۱، ۰/۸۷۵ برآورد شده است. نتایج مدل ترکیبی ResNet-DensNet، در تمامی شاخص‌ها برابر ۱ است و این نتیجه، کارایی روش ترکیبی را در تشخیص خطای فرآیند نشان می‌دهد. ماتریس درهم‌ریختگی مدل ترکیبی در شکل ۱۶، نشان داده شده است.



شکل ۱۶. ماتریس درهم‌ریختگی مدل منتخب برای متغیر رنگ قطعات در اثر خوردگی مس

در ماتریس درهم‌ریختگی که در شکل ۱۶، نشان داده شده است، ۸ مورد تصویر، غیرقابل قبول تشخیص داده شد که تمام ۸ مورد صحیح است. ۲۰ مورد تصویر در فرآیند نیز قابل قبول تشخیص داده شد که هر ۲۰ مورد صحیح است. نمودار میله‌ای شاخص دقت مدل ترکیبی در شکل ۱۷، نشان داده شده است.



شکل ۱۷. نمودار شاخص دقت برای متغیر رنگ، خوردگی قطعات در اثر عنصر مس

همان‌طور که در نمودار شکل ۱۷، مشاهده می‌شود، الگوریتم ترکیبی با دقت ۱ و امتیاز کامل، نسبت به بقیه الگوریتم‌ها از دقت بالاتری برخوردار است. دقت الگوریتم دنس‌نت ۰/۹۲۹، دقت الگوریتم رزنت ۰/۸۹۳، دقت الگوریتم وی‌جی‌جی ۰/۸۹۳ و دقت الگوریتم سی‌ان‌ان ۰/۸۲۱ پیش‌بینی شده است.

معیار توقف الگوریتم‌ها: در داده‌های تصویری epoch50 و در داده‌های غیر تصویری epoch200 است؛ همچنین در طی فرآیند تنظیم پارامترهای مدل با الگوریتم GBC، چنانچه الگوریتم در پانزده epoch پشت سرهم، بهبود در کاهش خطا نداشته باشد، الگوریتم متوقف می‌شود.

۵. نتیجه‌گیری و پیشنهادها

در این پژوهش، نظارت و کنترل بر مؤلفه‌های کیفی در سه مرحله به‌وسیله الگوریتم‌های یادگیری عمیق انجام شده است. با روش‌های ساخته‌شده توسط الگوریتم‌های ترکیبی، نظارت بر مؤلفه‌های کیفی، تشخیص خطا و تشخیص نوع خطا در فرآیند انجام می‌پذیرد. در این مطالعه، نظارت و کنترل بر اجزای کیفی در سه مرحله صورت گرفت که از طریق الگوریتم‌های یادگیری عمیق انجام شد. با استفاده از روش‌های ترکیبی توسط الگوریتم‌ها، نظارت بر اجزای کیفی، تشخیص خطا و طبقه‌بندی خطا در فرآیند صورت گرفت. بخش نظارت و تشخیص خطا از سه مرحله شامل آزمون‌های شیمیایی، آزمون‌های فیزیکی و آزمون‌های شیمیایی-فیزیکی تشکیل شده است. در هر مرحله، ابتدا تجزیه و تحلیل فرآیند با استفاده از الگوریتم‌های CNN و LSTM انجام شد. روش ترکیبی LSTM-CNN از دقت بیشتری نسبت به روش‌های تک‌الگوریتمی برخوردار است. اجزای فرآیند توسط الگوریتم ترکیبی LSTM-CNN بررسی و تحلیل شد. نقش اصلی الگوریتم GBC در این مسئله به تنظیم پارامترها و بهبود کارایی مدل‌های ترکیبی LSTM-CNN مرتبط است. این الگوریتم با اجرای چرخه‌های تکاملی و تغییر ترکیب‌های پارامترها، مدل LSTM-CNN را به‌گونه‌ای بهینه می‌سازد که توانایی بیشتری در تشخیص خطا، کنترل کیفیت و بهبود عملکرد داشته باشد. با بهره‌گیری از قابلیت‌های تکاملی و جمع‌سازی مشابه رفتار زنبورها، GBC می‌تواند بهبودهای قابل‌توجهی در دقت تشخیص خطا، کاهش هزینه‌های کنترل کیفیت، بهبود زمان چرخه تولید و کاهش هزینه‌های تولید به‌ارمغان آورد. به‌طور کلی، نقش این الگوریتم در فرآیند کلیدی این مطالعه، بهینه‌سازی مدل‌های ترکیبی برای بهبود کنترل کیفیت و تشخیص خطا در فرآیند تولید محصولات است.

در مرحله سوم آزمون‌های شیمیایی - فیزیکی، علاوه بر متغیرهای عددی، دو مؤلفه تصویری نیز وجود دارند که از طریق روش‌های تجزیه و تحلیل بصری کنترل می‌شوند. الگوریتم‌های یادگیری عمیق مورداستفاده در پردازش تصویر شامل VGG، CNN، ResNe و DensNet هستند که روش ترکیبی ResNet-DensNet از دقت بیشتری نسبت به سایر الگوریتم‌ها برخوردار است.

در قسمت تشخیص نوع خطا، مجدداً الگوریتم‌های LSTM و CNN، همراه با مدل ترکیبی این دو الگوریتم، اجرا شدند. تمام داده‌های سه مرحله آزمون کیفی به‌طور همزمان در داخل الگوریتم‌ها بارگذاری شد. مدل ترکیبی LSTM-CNN نسبت به سایر الگوریتم‌ها از دقت بیشتری برخوردار است. پارامترهای این الگوریتم ترکیبی به‌وسیله الگوریتم GBC بهبود داده شده و در تشخیص نوع خطا در فرآیند بهینه می‌شوند. یک نتیجه مهم که از استفاده از روش‌های یادگیری عمیق در این پژوهش به‌دست آمده، کاهش ۳۰ درصد هزینه کنترل کیفیت و کاهش ۲۰ درصد هزینه تولید و هزینه‌های اضافی است؛ همچنین رضایت مشتریان به میزان ۵۰ درصد افزایش یافته و فروش به میزان ۶۰ درصد کاهش یافته است.

از جمله موفقیت‌های مدیریت راهبردی در این مطالعه موردی، کاهش ضایعات در طی فرآیند تولید و کاهش ضایعات مواد اولیه است که این امر موجب می‌شود مدیران تصمیم به اجرای ساخت فاز دوم تولید بگیرند و پس از بهره برداری از فاز دوم، درآمد سالانه به میزان ۲۰ درصد افزایش یابد. پژوهشگران باید توجه داشته باشند که با استفاده از روش‌های یادگیری عمیق در فرآیند تشخیص خطا، امکان کاهش درصد اشتباه محاسباتی در کل فرآیند تولید وجود دارد؛ همچنین این روش مبتنی بر استفاده از الگوریتم‌های ترکیبی یادگیری عمیق را می‌توان به مهندسان کیفیت و پژوهشگران این حوزه پیشنهاد داد تا در بهبود فرآیندهای کنترلی که امکان ارزیابی کیفیت آن‌ها از طریق پردازش تصویری نیز وجود دارد، از این روش استفاده کنند. توانایی الگوریتم‌های یادگیری عمیق در تسریع فرآیند تولید و افزایش دقت کنترل، موضوعی است که برای پژوهشگران قابل‌توجه است.

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

منابع

1. Abbasi, R., Jamipour, M. & Ghasemlou, M. (2021). Analyzing the Factors Causing Customer Dissatisfaction with Food Ordering Applications. *Business Management Perspective*, 20(47) 111-136.
2. Adalat, M.H., Azmi, R. & Bagherinejad, J. (2020). An Enhanced Lstm Method to Improve the Accuracy of the Business Process Prediction. *The Journal of Industrial Management Perspective*, 10(3), 71-97.
3. Alla, S. & Adari, S.K. (2019). *Beginning Anomaly Detection Using Python-Based Deep Learning*. 2019: Springer.
4. Alshamlan, H.M., Badr, G.H. & Alohal, Y.A. (2015). Genetic Bee Colony (Gbc) Algorithm: A New Gene Selection Method for Microarray Cancer Classification. *Computational biology and chemistry*, 56, 49-60.
5. Asgharizadeh, E., Moghadam, M.R.S., Safari, H. & Neshan, (2019). The Effects of Customers' Decision Making with Different Risk Preferences on Warranty Providers: Agent Based Modeling. *The Journal of Industrial Management Perspective*, 9(1), 31-59.
6. Atashgar, K. (2015). Monitoring Multivariate Environments Using Artificial Neural Network Approach: An Overview.
7. Azar, A. & Mohammadlou, M.A. (2011). Designing a Service Quality Model in the Supply Chain: Explaining the Concept of Two-Way Service Quality. *Business Management Perspective*, 9(4), 9-24.
8. Baghbanpourasl, A., Lughofer, E., Meyer-Heye, P., Zörrer, H. & Eitzinger, C. (2019). *Virtual Quality Control Using Bidirectional Lstm Networks and Gradient Boosting*. *IEEE 17th International Conference on Industrial Informatics (INDIN)*. 2019. IEEE.
9. Bai, H., Tang, B., Cheng, T. & Liu, H. (2022). High Impedance Fault Detection Method in Distribution Network Based on Improved Emanuel Model and Densenet. *Energy Reports*, 8, 982-987.
10. Bersimis, S., Psarakis, S. & Panaretos, J. (2007). Multivariate Statistical Process Control Charts: An Overview. *Quality and Reliability Engineering International*, 23(5), 517-543.
11. Chen, L., Li, S., Bai, Q., Yang, J., Jiang, S. & Miao, Y. (2021). Review of Image Classification Algorithms Based on Convolutional Neural Networks. *Remote Sensing*, 13(22), 4712.
12. Chen, S., Yu, J. & Wang, S. (2020). One-Dimensional Convolutional Auto-Encoder-Based Feature Learning for Fault Diagnosis of Multivariate Processes. *Journal of Process Control*, 87 54-67.
13. Chen, Z., Yeo, C.K., Lee, B.S. & Lau, C.T. (2018). *Autoencoder-Based Network Anomaly Detection*. in *2018 Wireless Telecommunications Symposium (WTS)*.
14. Dounias, G., Tselentis, G. & Moustakis, V. (2001). Machine Learning Based Feature Extraction for Quality Control in a Production Line. *Integrated Computer-Aided Engineering*, 8(4) 325-336.
15. Esmaeili, M., Olfat, L., Amiri, M. & Vanani, I.R. (2023). Classification and Allocation of Suppliers to Customers in Resilience Supply Chains Using Machine Learning. *The Journal of Industrial Management Perspective*, 13(3), 39-70.
16. Gan, Y., Yang, J., & Lai, W. (2019) *Video Object Forgery Detection Algorithm Based on Vgg-11 Convolutional Neural Network*. *International Conference on Intelligent Computing, Automation and Systems (ICICAS)*.
17. Guh, R.-S. & Shiue, Y.-R. (2008). An Effective Application of Decision Tree Learning for on-Line Detection of Mean Shifts in Multivariate Control Charts. *Computers & Industrial Engineering*, 55(2), 475-493.
18. Guo, B., Li, L. & Luo, Y. (2018). *A New Method for Automatic Seismic Fault Detection Using Convolutional Neural Network*. in *2018 SEG International Exposition and Annual Meeting*. OnePetro.
19. Harrou, F., Sun, Y., Hering, A.S. & Madakyaru, M. (2020) *Statistical Process Monitoring Using Advanced Data-Driven and Deep Learning Approaches: Theory and Practical Applications*. 2020: Elsevier.
20. Hsu, J.-Y., Wang, Y.-F., Lin, K.-C. & Chen, M.-Y. (2020). Wind Turbine Fault Diagnosis and Predictive Maintenance through Statistical Process Control and Machine Learning. *Ieee Access*, 8, 23427-23439.
21. Huang, G., Liu, Z., Van Der Maaten, L. & Weinberger, K.Q. (2017). *Densely Connected Convolutional Networks*. in *Proceedings of the IEEE conference on computer vision and pattern recognition*.
22. Jin, X., Fan, J. & Chow, T.W. (2018). Fault Detection for Rolling-Element Bearings Using Multivariate Statistical Process Control Methods. *IEEE Transactions on Instrumentation and Measurement*, 68(9), 3128-3136.
23. Jin, X., Fan, J. & Chow, T.W.S. (2019). Fault Detection for Rolling-Element Bearings Using Multivariate Statistical Process Control Methods. *IEEE Transactions on Instrumentation and Measurement*, 68(9), 3128-3136.
24. Masuda, Y., Kaneko, H., & Funatsu, K. (2014). Multivariate Statistical Process Control Method Including Soft Sensors for Both Early and Accurate Fault Detection. *Industrial & Engineering Chemistry Research*, 53(20), 8553-8564.
25. Moeinzadeh, B., Houshmand, A.A. & Niaki, S.T.A. (2001). On the Performance of a Multivariate Control Chart in Multistage Environment. *International Journal of Engineering*, 14(1), 49-64.
26. Niaki, S.T.A. & Davoodi, M. (2009). Designing a Multivariate-Multistage Quality Control System Using Artificial Neural Networks. *International Journal of Production Research*, 47(1), 251-271.
27. Odom, G.J., Newhart, K.B., Cath, T.Y. & Hering, A.S. (2018). Multistate Multivariate Statistical Process Control. *Applied stochastic models in business industry*, 34(6), 880-892.
28. Pustokhin, D., Pustokhina, I., Dinh, P., Phan, S., Nhu, N., Joshi, G.P. & K, Shankar. (2020). An Effective Deep Residual Network Based Class Attention Layer with Bidirectional Lstm for Diagnosis and Classification of Covid-19. *Journal of Applied Statistics*, 50, 1-18.
29. Qureshi, K.M., Lup, A.N.K., Khan, S., Abnisa, F. & Daud, W.M.A.W. (2018). A Technical Review on Semi-Continuous and Continuous Pyrolysis Process of Biomass to Bio-Oil. *Journal of Analytical Applied Pyrolysis*, 131 52-75.

30. Rezaei Dolatabadi, H., Zaineli, Z. & Shekarchizadeh, Z. (2011). Investigating the Impact of Competitive Intelligence in Creating a Competitive Advantage. *Business Management Perspective*, 10(6), 9-25.
31. Santos-Fernández, E. (2012) *Multivariate Statistical Quality Control Using R*. Vol. 14. 2012: Springer Science & Business Media.
32. Shin, T. (2020). Towards Data Science. Retrieved from Medium: <https://towardsdatascience.com/understanding-the-confusionmatrix-and-how-to-implement-it-in-python-319202e0fe4d>.
33. Silva, A.F., Sarraguça, M.C., Fonteyne, M., Vercruyse, J., De Leersnyder, F., Vanhoorne, V., Bostijn, N., Verstraeten, M., Vervaet, C., Remon, J.P., DeBeer, T. & Lopes, J.A. (2017). Multivariate Statistical Process Control of a Continuous Pharmaceutical Twin-Screw Granulation and Fluid Bed Drying Process. *International Journal of Pharmaceutics*, 528(1), 242-252.
34. Song, H., Xu, Q., Yang, H. & Fang, J. (2017). Interpreting out-of-Control Signals Using Instance-Based Bayesian Classifier in Multivariate Statistical Process Control. *Communications in Statistics - Simulation and Computation*. 46(1), 53-77.
35. Song, H., Xu, Q., Yang, H. & Fang, J. (2017). Interpreting out-of-Control Signals Using Instance-Based Bayesian Classifier in Multivariate Statistical Process Control. *Communications in Statistics-Simulation Computational biology and chemistry*, 46(1), 53-77.
36. Wang, L., Zhang, Z., Xu, J. & Liu, R. (2018). Wind Turbine Blade Breakage Monitoring with Deep Autoencoders. *IEEE Transactions on Smart Grid*, 9(4), 2824-2833.
37. Wang, T., Chen, Y., Qiao, M. & Snoussi, H. (2018). A Fast and Robust Convolutional Neural Network-Based Defect Detection Model in Product Quality Control. *The International Journal of Advanced Manufacturing Technology*, 94 3465-3471.
38. Yu, H., Miao, X. & Wang, H. (2022). Bearing Fault Reconstruction Diagnosis Method Based on Resnet-152 with Multi-Scale Stacked Receptive Field. *Sensors (Basel)*. 22(5), 1705.
39. Yu, J., Zheng, X. & Wang, S.J.Q. (2019). Stacked Denoising Auto encoder-Based Feature Learning for out-of-Control Source Recognition in Multivariate Manufacturing Process. *Quality and Reliability Engineering International*, 35(1), 204-223.
40. Zheng, X. & Yu, J. (2019). *Multivariate Process Monitoring and Fault Identification Using Convolutional Neural Networks*. in *Proceeding of the 24th International Conference on Industrial Engineering and Engineering Management* Singapore: Springer Singapore.