

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

مهدي حيدري

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

علیرضا علی نژاد (نویسنده مسئول)

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

email: alalinezhad@gmail.com

بهنام وحدانی

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

تاریخ دریافت: ۱۴۰۲/۰۴/۱۰ تاریخ پذیرش: ۱۴۰۲/۰۸/۱۷

چکیده

به کارگیری الگوهای کنترل کیفیت چندمتغیره - چندمرحله‌ای در صنایع تولید پیوسته از اقدامات ضروری می‌باشد. در روش تولید پیوسته این پژوهش، استفاده از الگوهای چندمتغیره در بهبود روند شاخص کیفی محصول نهایی، مؤثر است. به کارگیری الگوریتم‌های یادگیری عمیق در راستای روش‌های کنترل کیفیت چندمتغیره - چندمرحله‌ای در صنعت روغن موتور، باعث کاهش هزینه‌های کنترل کیفیت، کاهش زمان سیکل تولید، کم شدن هزینه‌های تولید و افزایش رضایت‌مندی مشتریان می‌شود که این رضایت‌مندی می‌تواند متأثر از کاهش خرابی قطعات موتوری وسایل نقلیه باشد. در این مقاله، نوآوری اساسی در استفاده از الگوریتم‌های ترکیبی خودرمزگذار LSTM-CNN برای تشخیص خطا در داده‌های عددی و الگوریتم ResNet-DenseNet برای داده‌های تصویری نمایان می‌شود. برای بهبود پارامترهای مدل، از الگوریتم فراابتکاری GBC استفاده شده است. این نوآوری‌ها، منجر به بهبود موثری در تشخیص و کنترل خطا در فرآیندهای این پژوهش می‌شود. مطالعه موردی این پژوهش در شرکت روغن موتور الموت انجام شده است. در خاتمه الگوریتم ترکیبی LSTM-CNN ۱۵٪ نسبت به الگوریتم CNN، ۸٪ نسبت به الگوریتم LSTM، در فرآیند تشخیص خطا از شاخص بهتری برخوردار بوده است. فرآیند تشخیص نوع خطا، الگوریتم ترکیبی LSTM-CNN نسبت به الگوریتم CNN ۸٪ و الگوریتم LSTM ۱۰٪ عملکرد بهتری داشته است. در مؤلفه‌های تصویری، الگوریتم ترکیبی ResNet-DenseNet نسبت به الگوریتم ResNet ۱۰٪ و DensNet ۴٪ بهتر بوده است.

کلیدواژه‌ها: کنترل کیفیت؛ یادگیری عمیق؛ تشخیص خطا؛ خود رمزگذار.

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

Mehdi Heydari

Ph.D.Candidate in Industrial Engineering, Department of Industrial Engineering, Qazvin Branch, Islamic Azad University, Qazvin, Iran.

Alireza Alinezhad

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

Behnam Vahdani

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

Abstract

The utilization of multivariate-multistage quality control patterns is a crucial necessity in continuous manufacturing industries. Within the context of continuous production processes, this research highlights the significant impact of incorporating multivariate control strategies to enhance the trajectory of final product quality. Integrating deep learning algorithms into the framework of multivariate-multistage quality control methods in the motor oil industry results in noteworthy benefits, including cost reduction in quality control, shortened production cycle times, decreased manufacturing expenses, and heightened customer satisfaction. This enhanced satisfaction can be attributed to the reduction in failures of engine components in vehicles. This paper introduces a substantial innovation by leveraging concatenated LSTM-CNN autoencoder algorithms for fault detection in numerical data and utilizing ResNet-DenseNet algorithms for analyzing image-based data. The

optimization of model parameters is realized through the application of the GBC metaheuristic algorithm. Collectively, these innovations significantly improve Fault detection and control processes within the scope of this research. A practical case study of this research has been conducted at "Almoot," a motor oil manufacturing company. In summary, the proposed LSTM-CNN hybrid algorithm demonstrates a 15% improvement over the CNN algorithm and an 8% improvement over the LSTM algorithm in error detection processes. In the task of identifying Fault types, the LSTM-CNN hybrid algorithm outperforms the CNN algorithm by 8% and the LSTM algorithm by 10%. In the realm of visual components, the composite ResNet-DenseNet algorithm showcases a 10% enhancement compared to the standalone ResNet approach and a 4% improvement compared to the individual utilization of the DensNet algorithm.

Keywords: QualityControl; Deep Learning; Fault Detection; Auto Encoder.

۱. مقدمه

امروزه استفاده از فناوری‌های هوشمند در فرآیندهای داده محور، از ارکان مهم موفقیت در صنایع تولیدی است. رقابت فزاینده موجب شده تا تولیدکنندگان به دنبال راهی برای جذب بیشتر مشتریان باشند، در این بین اطمینان دادن به مشتری که کالای خریداری شده وی کیفیت لازم را دارد و آن طور که انتظار دارد کار می‌کند، عنصری حیاتی به شمار می‌آید [۵]. در تولیدات پیوسته مانند تولید روغن موتور، این موضوع بیشتر جلب توجه می‌کند [۳۱]. 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، نرمال نبودن 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 آن استفاده کند احساس می‌شود. پیشرفت‌هایی که در زمینه توسعه هوش مصنوعی، مخصوصاً روش‌های یادگیری عمیق رخ داده است، شامل دستاوردهای موفق در زمینه کنترل مؤلفه‌های کیفی در تولید می‌باشد که تشخیص خطا، در فرآیند تولید و شناسایی نوع خطا اتفاق افتاده در سیستم را سریع‌تر و راحت‌تر می‌کند. استفاده از الگوریتم‌های یادگیری عمیق از جمله $LSTM^1$ و CNN^2 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 از کارایی مطلوبی برخوردار نباشد. به‌طور مثال، مهندسی کیفیت در این بخش تولید، اطلاعات کافی نسبت به متغیرهای متعدد کنترل کیفیت روغن موتور و به این نکته واقف هستند که در چند ایستگاه متنوع این متغیرها باید موردسنجش قرار بگیرند، برای ساده کردن فرآیند کنترل و دوری جستن از پیچیدگی‌های روش‌های چندمتغیره، هنوز از نمودارهای تک متغیره شوهارت استفاده می‌کنند [۶] در نتیجه، پایش و کنترل فرآیند نمی‌تواند کارایی مطلوبی داشته باشد و باعث افزایش هزینه‌های تولید، افزایش زمان سیکل تولید و کاهش رضایت‌مندی مشتریان در دو قسمت خریداران عمده و مصرف‌کنندگان می‌شود [۱] و در نهایت یک زنجیره تأمین معیوب برای برآورده شدن تقاضای جامعه ایجاد می‌شود [۷, ۳۲].

کنترل کیفیت در محصول روغن موتور نیازمند روشی است که بتواند متغیرهای کیفی فرآیند را به‌صورت هم‌زمان پایش کند. لازم به ذکر است که به جهت وجود همبستگی در داده‌های کیفی، استفاده از نمودار تک متغیره شوهارت نتیجه‌ای دور از واقعیت را به متخصصین ارائه می‌دهد. علاوه بر این

1. Long short-term memory
2. Convolution Neural Networks

وجود داده‌های غیر نرمال در مؤلفه‌های کیفیت از عواملی است که استفاده از روش‌های کلاسیک آماری را برای کنترل کیفیت این محصول غیرممکن می‌سازد [۲۰]. با توجه به مسائلی که مطرح گردید، نیاز به روشی که بتواند مشکلات مطرح‌شده را پوشش دهد، احساس می‌شود. 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 قابل قبولی 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 به هنگام خطا نشان می‌دهد [۳۹]. 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 می‌باشند و می‌توانند در صورت وجود خطا تشخیص به‌موقع ارائه دهند [۸]. در قسمت کنترل متغیرهای تصویری، در ابتدا الگوریتم‌های VGG¹-DensNet²-CNN-ResNet³ 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 [۱۹]. الگوریتم DensNet توانایی ضد نویز 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 قابل قبولی را در سیستم انجام دهد [۴۰].

نوآوری‌های مقاله به‌صورت خلاصه در ادامه ارائه شده است:

- ۱- استفاده از الگوریتم ترکیبی یادگیری عمیق LSTM-CNN برای تشخیص خطا^۴ و مشخص شدن نوع خطا^۵ در صنعت روغن موتور.
- ۲- استفاده از الگوریتم فرا ابتکاری^۶ (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.

1. Visual Graphics Group
 2. Dense Convolutional Network
 3. Residual Network
 4. Fault Detection
 5. Fault Type
 6. Genetic Bee Colony

۴- استفاده از خود رمزگذارها^۱ جهت استخراج^۲ ویژگی‌هایی که در ساخت مدل کیفی این پژوهش نقش مهمی دارند.

۲. مبانی نظری و پیشینه پژوهش

[۲۷] در این مقاله یک روش کنترل کیفیت چندمتغیره - چندمرحله‌ای بررسی شده است. در این روش تحلیل، تبعیض گذاری، رگرسیون خطی و نظریه نمودارهای کنترل، ترکیب شده‌اند تا بردار میانگین خصوصیات کیفیتی همبسته^۱ یک فرآیند که شامل چند مرحله است و کیفیت خروجی هر مرحله، به خروجی مرحله قبل و هم به خصوصیات مرحله جاری بستگی دارد، کنترل شود. [۲۶] روش‌های مبتنی بر آمار، شامل نمودار کنترل هاتلینگ^۲، T^2 ، MEWMA، MCUSUM، روبه‌های مبتنی بر طرح‌ریزی^۳ است. نمودار هاتلینگ T^2 به‌طور گسترده در کاربردهای صنعتی استفاده می‌شود.

پژوهش [۱۵] یادگیری ماشین القایی را برای انتخاب ویژگی‌های مناسب با قابلیت تشخیص ماشین‌های لباسشویی که دارای عیوب مکانیکی هستند، یا به‌اشتباه در خط تولید مونتاژ شده‌اند، ارائه می‌کنند. در دو پژوهش [۱۰] [۲۶] با توجه به برخی محدودیت‌هایی که در کنترل فرآیند آماری چندمتغیره سنتی وجود دارد رویکردهای داده‌کاوی راه‌حل مؤثری برای رفع محدودیت‌های روش‌های سنتی کنترل فرآیند آماری چندمتغیره می‌دانند، یعنی پیچیدگی و غیر پارامتری بودن فرآیندها را با ارائه روش‌های داده‌کاوی برطرف می‌کنند. مقاله‌های [۱۲] [۱۸] داده‌کاوی را یک فیلد چند رشته‌ای دانسته که شامل روش‌ها و ابزارهایی از چندین رشته، مانند: دستگاه‌های پایگاه داده، آمار و سیستم‌های یادگیری است. در مقاله [۲۶] به دلیل تحمل خوبی که نويز زدایی دارد، انعطاف‌پذیری بیشتر است و این امر نیاز به فرضیه‌ای در مورد توزیع آماری، یادگیری نظارت‌شده را مرتفع می‌سازد. در مقاله [۴۲] یک روش ترکیبی مبتنی بر الگوریتم‌های ماشین بردار پشتیبان^۴ و شبکه‌های عصبی کانولوشنی جهت تشخیص خطا^۵ و نظارت بر فرآیند چندمتغیره ارائه شده است. در مقاله^۶ ارائه شده [۱۳] یک خود رمزگذار پیچشی جدید، مبتنی بر داده‌های تک‌بعدی برای تشخیص خطا در فرآیندهای پیچیده چندمتغیره مطرح شده است. در این مقاله یک مدل جدید یادگیری عمیق خود رمزگذار پیچشی تک‌بعدی (ID-CAE^۶) برای تشخیص خطای فرآیندهای چندمتغیره پیشنهاد شده است. در پژوهش انجام شده [۳۳] بر اساس مدل‌های سری زمانی و کنترل فرآیند آماری چندمتغیره، روش جدیدی برای تشخیص خرابی معرفی شده است. در مقاله [۲۴] یک چارچوب جدید برای تشخیص خرابی عناصر غلتکی یاتاقان^۷ ارائه شده است که بر اساس روش‌های کنترل فرآیند آماری چندمتغیره اجرا می‌شود. در پژوهش انجام شده [۳۵]

7. Auto Encoders
8. Feature Extraction
1. Projection
2. Support Vector Machines
3. Fault Detection
4. One-Dimensional Convolutional Auto-Encoder
5. Rolling-Elements Bearing

استراتژی کنترل فرآیند آماری چندمتغیره برای نظارت بر خط تولید پیوسته قرص ConsiGmaTM-25 ارائه شده است. مقاله ارائه شده [۲۸] به مسئله کنترل فرآیند تولید چندمتغیره چندمرحله‌ای می‌پردازد و دلایل احتمالی سیگنال‌های خارج از کنترل را تشخیص می‌دهد.

در مقاله ارائه شده [۴۱]، یک مدل جدید یادگیری ویژگی عمیق، مبتنی بر خود رمزگذار پشته‌ای نوین زدا، برای نظارت و تشخیص خطاهای فرآیندهای تولید چندمتغیره پیشنهاد شده است. در مقاله ارائه شده [۳۶]، یک روش ساده بیزی، مبتنی بر نمونه، برای تفسیر سیگنال‌های خارج از کنترل فرآیندهای آماری چندمتغیره، پیشنهاد شده است.

پژوهش انجام شده [۲۹] بیان می‌کند که برای داده‌های با ابعاد بالا، خود همبسته^۱، غیرخطی و غیرثابت، روش تحلیل مؤلفه‌های اصلی انطباقی - پویا ($AD-PCA^2$)، همانند یا بهتر از روش‌های کاهش ابعاد غیرخطی در علامت‌گذاری داده‌های خارج از محدوده^۳ عمل می‌کند.

مقاله ارائه شده [۱۴]، به بررسی و بهبود استراتژی‌های فعلی ادغام داده‌ها^۴ در فناوری‌های آنالیز فرآیند (PAT^5) برای توسعه مدل‌های کنترل فرآیند آماری چندمتغیره با ترکیب تمام اطلاعات موجود مربوط به فرآیند می‌پردازد. در پژوهش انجام شده [۲۱] 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 جمع‌آوری شده که در سال‌های ۲۰۱۵ تا ۲۰۱۷ در تایوان استفاده شده است. در پژوهش انجام شده [۳۷] با استفاده از کنترل فرآیند آماری چندمتغیره، به بررسی و بازبینی سالانه محصولات غذایی و دارویی جهت بررسی ثبات فرآیند تولید و کیفیت محصول نهایی پرداخته شده است. در مقاله ارائه شده [۳۸] نویسندگان خرابی پره‌های توربین بادی را مدل‌سازی کرده و شواهد تحلیلی را پیدا کردند که نشان می‌داد قبل از شکستن پره‌ها، ترک‌های نامنظمی روی پره‌ها به وجود آمده است. سپس، از مدل‌های خود رمزگذار عمیق برای پیش‌بینی ترک خوردگی قریب‌الوقوع پره به کمک داده‌های نظارتی استفاده کرده‌اند. در روش پیشنهادی [۲۵]، یک الگوریتم تحلیلی جدید به نام آنالیز مؤلفه متمایزکننده اصلی ($PDCA^6$)، برای پیاده‌سازی قابلیت استخراج آنی ویژگی، پیشنهاد شده است تا انحراف بین داده‌های نظارت شده آنالیز و مجموعه داده‌های نرمال عملیاتی، به موقع، قابل کشف باشد.

-
1. Autocorrelated
 2. Adaptive-Dynamic Principal Component Analysis
 3. Outliers
 4. Data Fusion
 5. Process Analytical Technologies
 6. Principal Discriminative Component Analysis

جدول ۱. مقایسه روش پیشنهادی و مقالات موجود

نویسندگان	کنترل کیفیت چندمتغیره	کنترل کیفیت چندمرحله‌ای	نویز زدایی	یادگیری عمیق	ترکیبی چند فیلتری	بهینه‌سازی پارامترها	مجموعه داده واقعی
نیاکی و همکاران (۲۰۰۰)	✓					✓	
دونباس و همکاران (۲۰۰۱)			✓	✓			✓
نیاکی 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)					✓	✓	✓
البوریا و همکاران (۲۰۲۰)	✓	✓					✓
چن و همکاران (۲۰۲۰)	✓		✓	✓			
لی و همکاران (۲۰۲۱)	✓						✓
روش پیشنهادی	✓	✓	✓	✓	✓	✓	✓

۳. روش شناسی پژوهش

روغن موتور، ترکیبی از روغن پایه و افزودنی‌ها است. روغن پایه در واقع اساس اولیه ساخت روغن موتور و انواع رو انکارها می‌باشد. 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 تعیین شده 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 به صورت عددی باشد یا تصویری، کیفیت آن مؤلفه را قبول یا رد می‌کند. مشخصه‌های کیفی روغن موتور در سه ایستگاه کاری کنترل، مورد نظارت 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 SAE^1 - API^2 - MIL^3 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 داده‌ها و پژوهش ارائه شده است.

کنترل کیفیت چندمتغیره - چندمرحله‌ای:


فرآیندها و محصولاتی که مهندسین کیفیت درصدد کنترل آن‌ها هستند، در بسیاری از اوقات حکایت از چندمتغیره بودن 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 نه تنها به عملکرد عادی مرحله فعلی بستگی دارد، 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 [۲۸].

۲. شناسایی نوع خطا: تعیین مرحله‌ای که در شرایط خارج از کنترل قرار دارد.

1. Society of Automotive Engineers
2. American Petroleum Institute
3. Military Specifications

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



شکل ۱. سیستم تولید چندمرحله‌ای در صنعت روغن موتور

الگوریتم‌های یادگیری عمیق مورد استفاده در پژوهش

شبکه حافظه کوتاه مدت طولانی (LSTM): نوعی از شبکه‌های عصبی بازگشتی (RNN) محسوب می‌شوند. یکی از مشکلات شبکه‌های عصبی بازگشتی، ناتوانی آنها در یادگیری وابستگی بلندمدت است. برای رفع این مشکل (هاکریتز و همکاران ۱۹۹۷)، یک معماری برایشبکه‌های عصبی بازگشتی پیشنهاد کردند که به معماری حافظه طولانی کوتاه مدت 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 می‌کند و مشخص می‌نماید که چه داده‌هایی در توالی، مهم هستند و باید همچنان حفظ بشوند و چه داده‌هایی باید حذف بشوند. بدین شکل شبکه، اطلاعات مهم را در طول زنجیره توالی عبور می‌دهد تا خروجی مورد نظر را به دست آورد [۳]. مکانیسم حل الگوریتم LSTM بر پایه روابط شماره (۱ الی ۶) است:

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

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + b_i) \quad (2)$$

$$\hat{c}_t = \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c) \quad (3)$$

$$C_t = f_t * C_{t-1} + i_t * C_t \quad (4)$$

$$O_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + b_o) \quad (5)$$

$$\tanh \otimes C_t h_{t-1} = O_t \quad (6)$$

σ یک تابع سیگموئید لجستیک است، \otimes حاصل ضرب مؤلفه‌ای دو بردار است و $W_{xi}, W_{hi}, W_{xc}, W_{hc}, W_{xo}, W_{ho}, W_{xf}, W_{hf}$ نیز ماتریس وزن‌های شبکه هستند. همچنین b_0, b_f, b_i, b_c بردارهای بایاس و f_t, i_t, \hat{c}_t, O_t بردارهای مقادیر فعال‌سازی گیت فراموشی، گیت ورودی و گیت 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 [۱۶]. در این مقاله از یک شبکه عصبی کانولوشنی تک لایه در ساخت مدل‌های مبتنی بر داده‌های عددی و از یک شبکه عصبی کانولوشنی چندلایه برای پردازش تصویری نمونه‌های روغن موتور، استفاده شده است. یک مزیت بزرگ این روش 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 گرادینان^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 [۳۰].

شبکه (DenseNet): یکی از آخرین شبکه‌های عصبی است که برای تشخیص دقیق اشیاء، ارائه شده است. معماری این شبکه، مشابه معماری شبکه ResNet می‌باشد اما دارای چند تفاوت اساسی است. این معماری نسبت به سایر معماری‌های قبلی نرخ خطای کمتری بر روی دیتا بیس مسئله دارد [۲۲].

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. در شبکه VGG Net ابتدا یک عکس رنگی (RGB) با ابعاد ۲۲۴×۲۲۴ پیکسل را دریافت می‌کند و در اختیار لایه‌های بعدی قرار می‌دهد [۱۷].

1. Vanishing Gradient Problem

الگوریتم فرا ابتکاری GBC: روشی است که مبتنی بر دو الگوریتم الهام گرفته شده از طبیعت یعنی ABC^1 و GA^2 است. هدف هر الگوریتم فرا ابتکاری یافتن راه حل 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].

خود رمزگذار: (AE) نوع خاصی از شبکه عصبی چندلایه و از روش‌های یادگیری غیر نظارت شده است که به صورت سلسله مراتبی 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^۳ می‌باشند. در این شبکه‌ها معمولاً تعداد نورون‌های لایه ورودی و لایه خروجی یکسان بوده و معماری لایه‌ها متقارن است [۲۳].

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 درهم ریختگی در شکل (۲) نشان داده شده است. و ساختار آن در این شکل معلوم می‌باشد.

اگر نمونه، عضو کلاس مثبت باشد و عضو همین کلاس تشخیص داده شود (مثبت صحیح)^۴.

اگر نمونه، عضو کلاس مثبت باشد و عضو کلاس منفی تشخیص داده شود (منفی کاذب)^۵.

اگر نمونه، عضو کلاس منفی باشد و عضو همین کلاس تشخیص داده شود (منفی صحیح)^۶.

اگر نمونه، عضو کلاس منفی باشد و عضو کلاس مثبت تشخیص داده شود (مثبت کاذب)^۷.

صحت^۸: دقت دسته‌بندی، بیشتر بر تشخیص درست کلاس مثبت از منفی تمرکز دارد و به تعیین عملکرد کلی طبقه بند می‌پردازد و نشان می‌دهد که چه تعداد از کل موارد آزمایشی به درستی توسط طبقه بند، طبقه‌بندی شده است. صحت، به صورت رابطه^۷ بیان می‌شود.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (7)$$

دقت^۹: نشان‌دهنده قابلیت اطمینان طبقه بند است و بیانگر نسبت خطاهای تشخیص داده شده واقعی در بین خطاهای هشدار داده شده است و به صورت رابطه^۸ بیان می‌شود.

-
- 2. Artificial Bee Colony
 - 3. Genetic Algorithm
 - 1. Hidden Layer
 - 2. True Positive
 - 3. False Negative
 - 4. True Negative
 - 5. False Positive
 - 6. Accuracy
 - 7. Precision

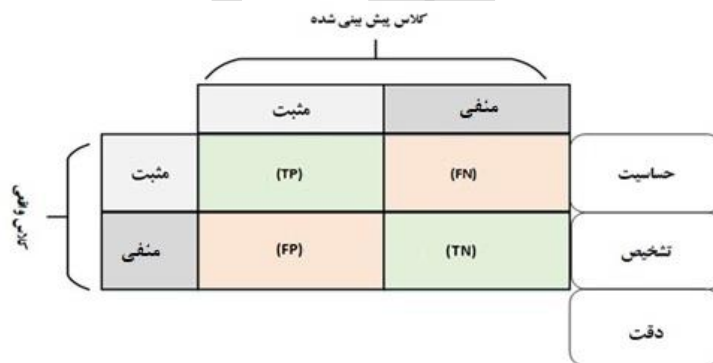
$$\text{Precision} = \frac{TP}{TP + FP} \quad (8)$$

پوشش (فراخوانی)^۱: به عنوان حساسیت^۲ و نرخ مثبت واقعی نیز شناخته می شود، نسبت خطاهای تشخیص داده شده توسط مدل را نشان می دهد. فراخوانی به صورت رابطه ۹ است.

$$\text{Recall} = \frac{TP}{TP + FN} \quad (9)$$

امتیاز $F1^3$: امتیاز (اف) معیاری برای ارزیابی دقت یک مدل طبقه بندی آماری است. این امتیاز به صورت رابطه ۱۰ است.

$$F1 = 2 \frac{\text{precision} \cdot \text{recall}}{\text{precision} + \text{recall}} \quad (10)$$



شکل ۲. ماتریس درهم ریختگی و معیارهای آن [۳۴]

مسئله مورد بررسی در این پژوهش

هدف این پژوهش، ایجاد مدل های 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 کند. در این مسئله متغیرهای بسیاری در سه مرحله کاری قرار گرفته اند که باید به صورت توأم (هم زمان) کنترل شوند. در یک چنین فرآیندهایی پیش و کنترل متغیرهای غیرمستقل، بسیار پیچیده تر از فرآیندهای تک متغیره است. همچنین نمی توان

1. Recall
2. Sensitivity
3. F1 score

از نمودارهای کنترل تک متغیره شوهرت در این مسائل استفاده کرد و باید از روش کنترل کیفیت چندمتغیره - چندمرحله‌ای استفاده شود. همچنین در روش پیشنهادی برای انطباق بیشتر مدل با مسائل موجود در دنیای واقعی، فرض شده که داده‌های مؤلفه‌های کیفی در این مسئله، داده‌های واقعی باشند.

لازم به ذکر است که با توجه به معیارهای بالا و شرایط مسئله، از الگوریتم‌های خود رمزگذار 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:

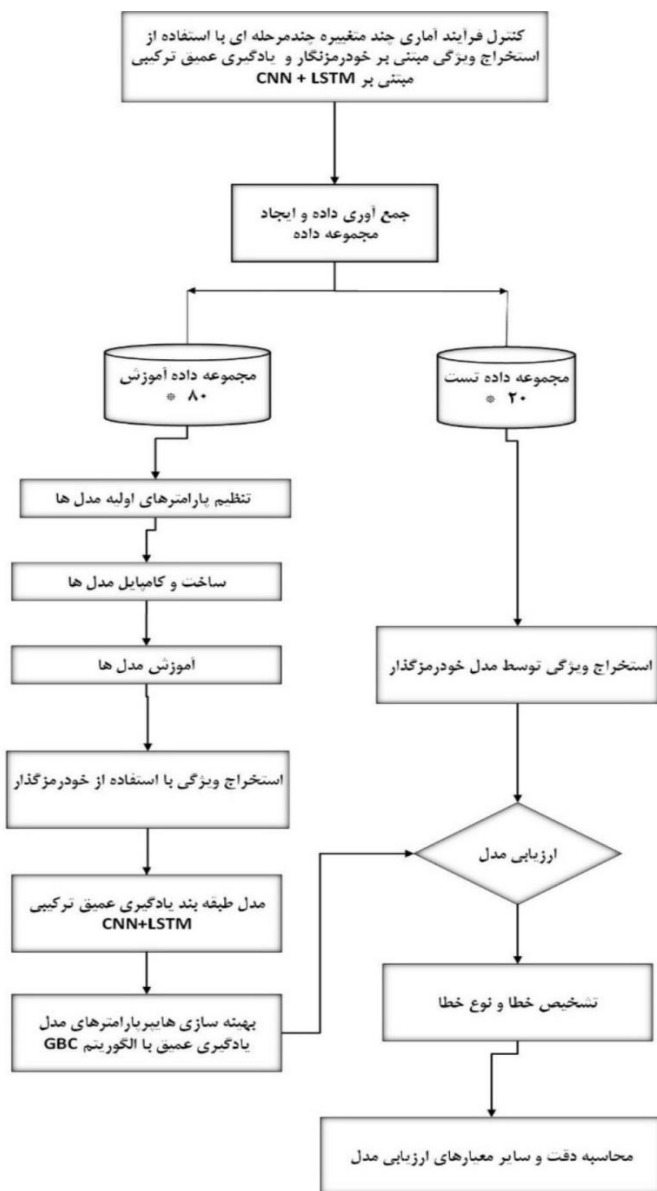
۱- بخشی از پژوهش که شامل متغیرهای عددی است.

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 برجسب قبول^۱ یا غیرقابل قبول^۲ در این سه مرحله استفاده شده است. ابتدا الگوریتم‌های (CNN, LSTM) به صورت جداگانه و یک الگوریتم ترکیبی^۳ بر اساس (LSTM-CNN) ساخته می‌شود و نتایج این سه مدل باهم مقایسه می‌شوند. مدلی که نتایج بهتری داشته باشد به وسیله خود رمزگذار، استخراج ویژگی^۴ می‌شود و سپس الگوریتم متاهیورستیک (GBC) پارامترهای مدل انتخابی را بهبود می‌دهد و الگوریتمی بر اساس پارامترهای جدید ایجاد می‌کند. روش بهبود یافته، 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 می‌باشند و باید به وسیله الگوریتم‌های یادگیری عمیقی که در پردازش تصویر کاربرد بیشتری دارند، مورد بررسی قرار گیرند. در این پژوهش از الگوریتم‌های (CNN, VGG, Res Net, DensNet) به صورت جداگانه و الگوریتم ترکیبی (ResNet-DensNet) استفاده شده است. روش حل مسئله به صورت فلوچارت، در شکل شماره (۳) به نمایش درآمده است.

-
1. Accept
 2. Unacceptable
 3. Hibrid
 4. Feauture Extraction
 5. Fault Detection
 6. Fault Type

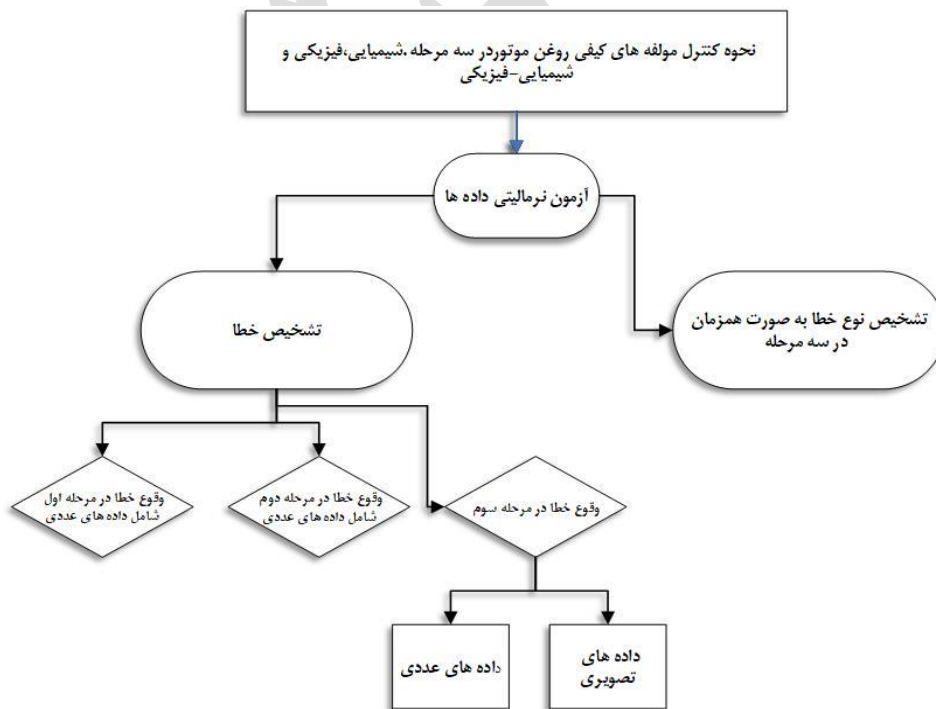


شکل ۳. فلوجارت حل مسئله

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 انجام می‌پذیرد و نحوه اجرای نمونه‌گیری با استفاده از روش استاندارد MIL-STD-105D انجام می‌شود. نمونه‌گیری از مخازن با حجم بالا (حدود ۵۰۰۰ لیتر) توصیه می‌شود. نمونه از قسمت‌های بالایی، میانی و کف به‌طور جداگانه تهیه و به‌صورت تفکیک‌شده، همراه با کد و علامت‌گذاری مشخص، به واحد کنترل کیفی، جهت آنالیز، ارسال می‌گردد. تعداد نمونه‌گیری، در ۱ روز از هر مخزن ۱۰۰۰۰ لیتری در سه نوبت و در ساعات‌های هشت، دوازده و هجده انجام می‌پذیرد. داده‌های هر متغیر کیفی، طی ۱۰۰ روز کاری لحاظ شده است.

در شکل شماره (۴) فرآیند کنترل کیفیت در مؤلفه‌های کیفی روغن موتور نمایش داده‌شده و چگونگی انجام فرآیند به ترتیب 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 شناخته شده 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 غیر پارامتری استفاده کرد. در این پژوهش از آزمون‌های هنز - زیکلر^۲، 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 ۰/۰۰۴ 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. شبه کد این آزمون نیز در شکل (۵) نشان داده شده است.

جدول ۲. آزمون نرمالیتیه داده‌های مسئله

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

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

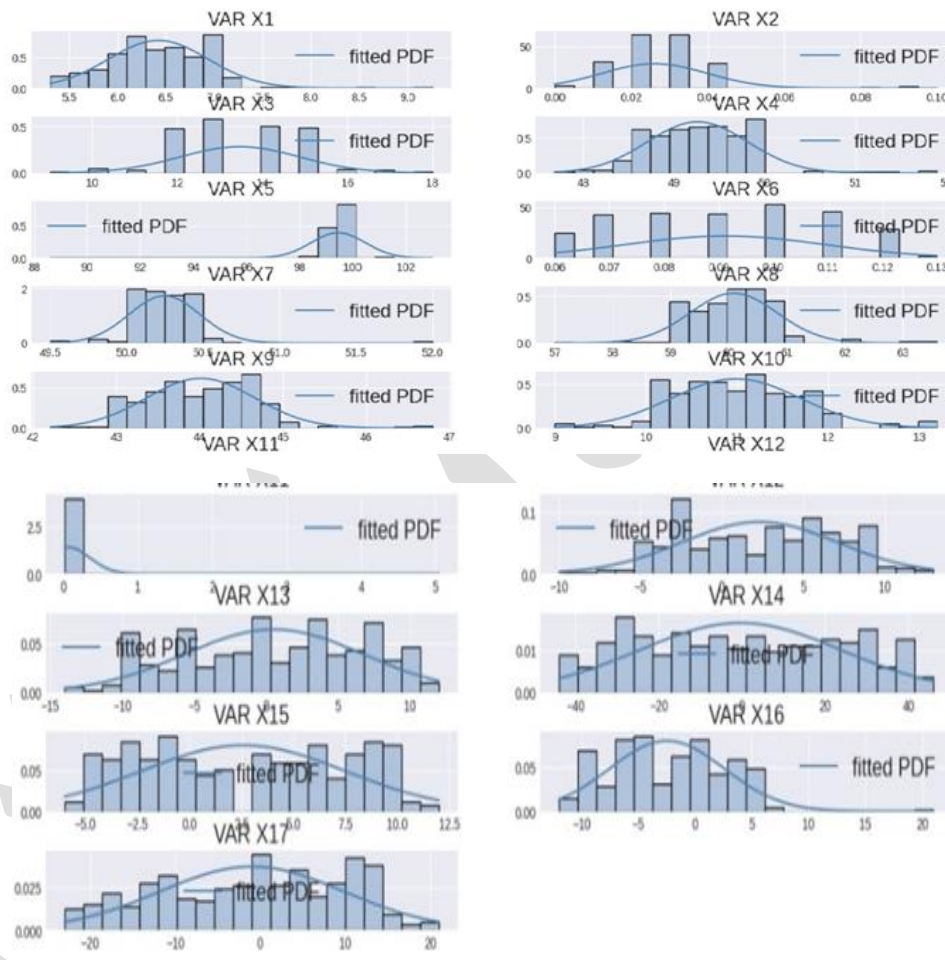
```

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."

```

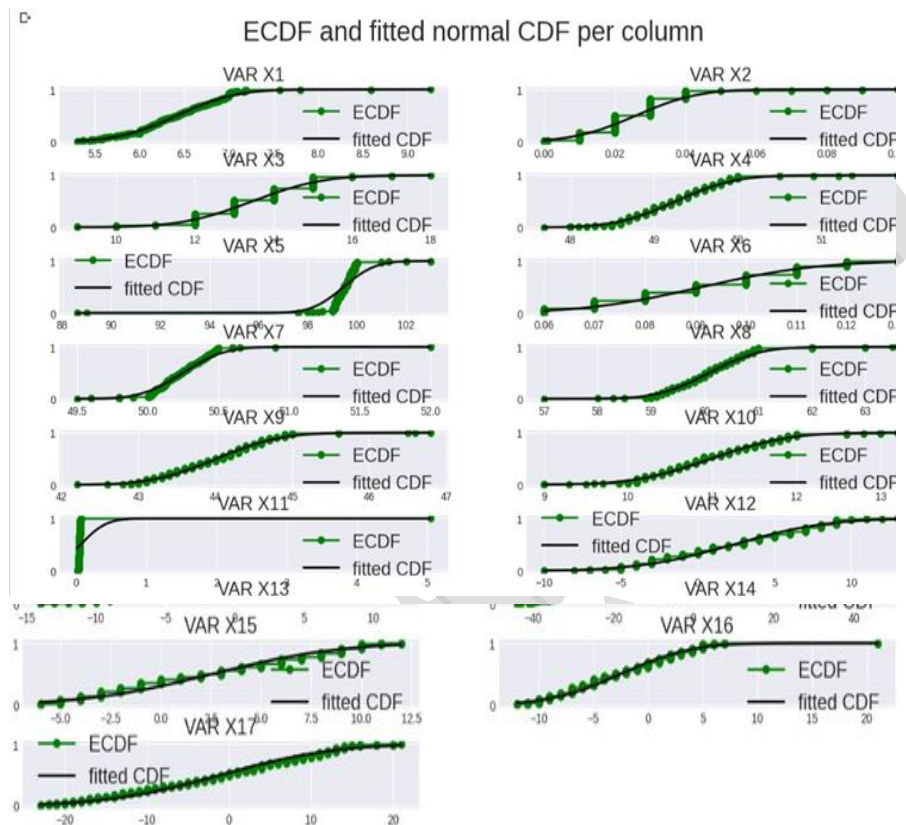
شکل ۵. شبیه کد آزمون نرمالیتی به روش هنز-زیکلر برای داده‌های مسئله

Histogram and fitted normal PDF per column



شکل ۶. نمودار هیستوگرام تشخیص نوع داده‌های مسئله

در شکل (۶)، محور افقی در نمودار هیستوگرام نمایانگر تعداد مشاهدات مختلفی است که از آزمون‌های نرمال‌یته به دست آمده‌اند، و محور عمودی نمایانگر مقادیر $p.value$ می‌باشد. از تحلیل شکل هیستوگرام، مشاهده می‌شود که برای هر سه آزمون، مقدار $p.value$ در اکثر نقاط کمتر از 0.05 می‌باشد و کمتر از آستانه تعیین شده در هر سه آزمون است. این نتیجه نشان می‌دهد که در مجموع داده‌ها توزیع نرمال ندارند و غیر نرمال می‌باشند.



شکل ۷. نمودار تجمعی 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 غیر خطی می‌باشد. این عدم همبستگی و غیرخطی بودن، میان منحنی $ECDF$ و منحنی تطابقی، در شکل (۷) نشان داده شده است. و بر غیر نرمال بودن داده‌ها اشاره می‌کند.

¹. Empirical Cumulative Distribution Function

پس از انجام آزمون هنز-زیکلر مقدار احتمال نرمال بودن داده‌ها، صفر تخمین زده شده است در نتیجه فرض نرمال بودن داده‌ها رد می‌شود 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 آنجایی که بسیاری از فرآیندهای واقعی در تولید دارای چندین مرحله کاری می‌باشند و هر مرحله کاری، شامل متغیرهای مهمی، برای کنترل مؤلفه‌های کیفی محصول است [۶]. نظارت بر فرآیند و شناسایی عامل یا عوامل ایجاد خطا در فرآیند، نیازمند استفاده از روش‌های کنترل چندمتغیره - چندمرحله‌ای است.

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 در جدول شماره (۳) اسامی و حدود کنترل هر متغیر آورده شده است. آزمون مرحله فیزیکی، شامل ۱۰ متغیر کیفی است که در جدول شماره (۴) اسامی و حدود کنترل هر متغیر آورده شده است. آزمون مرحله شیمیایی فیزیکی، شامل ۱۰ متغیر کیفی هست که اسامی و حدود کنترل هر متغیر در جدول شماره (۵) ذکر شده است. فرآیند کنترل به این صورت است که مراحل کاری باید به ترتیب مورد آنالیز 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 پایین	حد مجاز بالا	آزمون کیفی
D2896	۶	۷	عدد قلبیایی
D664	۰/۰۱	۰/۰۴	عدد اسیدی
D3780	۱۲	۱۵	فراریت
D1401	۴۸/۵	۵۰	قابلیت فیلتر شدن
D6594	۹۹	۱۰۰	جلوگیری از زنگ زدگی
D5185	۰/۰۶	۰/۱۲	میزان فسفر
D6795	۵۰	۵۰/۵	آزمون ای.او.وایت
D7097	۵۹	۶۱	اکسیداسیون ۳۳
D6335	۴۳	۴۵	اکسیداسیون تی ۴
D5133	۱۰	۱۲	شاخص ژلاتین
D9377	۰/۰۳	۰/۰۶	میزان گوگرد
D1298	-۵	۹	تغییر حجم
D524	-۱۰	۱۰	تغییر درجه سختی ۱
D6304	-۴۰	۴۰	تغییر استحکام کششی
D1289	-۵	۱۰	تغییر حجم ۲
D524	-۱۰	۵	تغییر درجه سختی ۲
D6304	-۲۰	۱۵	تغییر استحکام کششی ۲

جدول ۴. آزمون‌های فیزیکی در مرحله دوم

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

جدول ۵. آزمون های شیمیایی-فیزیکی در مرحله سوم

روش آزمون استاندارد	حد مجاز پایین	حد مجاز بالا	آزمون کیفی
D6595	۸۰	۱۸۰	آهن
D5185	۴	۲۸	کروم
D5185	۱۲	۲۴	قلع
D6195	۱۲	۵۵	آلومینیوم
D4951	۱	۳	نیکل
D5185	۵	۳۰	سدیم
D5185	۱۰	۳۰	سرب
D5185	۴	۲۰	مولیبدن
D5185	۱۵	۳۰	سیلیسیم
D5185	۲	۳۰	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 موردسنجش قرار می‌گیرند و متغیرهای تصویری که در آزمون‌های فیزیکی و شیمیایی (مرحله سوم سنجش کیفی) قرار گرفته‌اند، با روش پردازش تصاویر موردسنجش کیفی قرار می‌گیرند که متعاقباً به آن نیز پرداخته خواهد شد.

در ابتدا با هریک 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-CNN)، داده‌ها در تمامی مراحل و روش‌ها به دو گروه train با ظرفیت ۸۰٪ از کل داده‌ها و آزمون، با اختصاص ظرفیت ۲۰٪ داده‌ها به‌صورت تصادفی تقسیم می‌شوند. برای بالا بردن دقت مدل، عملیات تکنیک بیش‌نمونه‌گیری اقلیت مصنوعی^۲ را از روش smote انجام داده و نتایج چهار شاخص دقت، صحت، پوشش و معیار F1 از الگوریتم‌های (LSTM, CNN, LSTM-CNN) استخراج گردیده و نتیجه آن در جدول شماره (۶) به نمایش درآمده است.

1. Process Monitoring
3. Over-Sampling

جدول ۶. نتایج مدل‌های پیشنهادی

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


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

در مرحله اول، نتایج LSTM، CNN و LSTM-CNN مشابه هستند، که معمولاً در مسائل یادگیری عمیق اولیه رخ می‌دهد. در مرحله دوم، LSTM-CNN بهبود قابل توجهی 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 انتخاب شده است. نتایج پس از تنظیم، که در ستون LSTM-CNN TUNED در سمت راست جدول آمده است، بهبود قابل توجهی داشته‌اند و نتایج به سطوح قابل قبولی 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 قابل قبولی دارد. در جدول (۷) هایپر پارامترها و بازه موردنظر برای مقادیر بیشینه و کمینه هر یک نشان داده شده است.

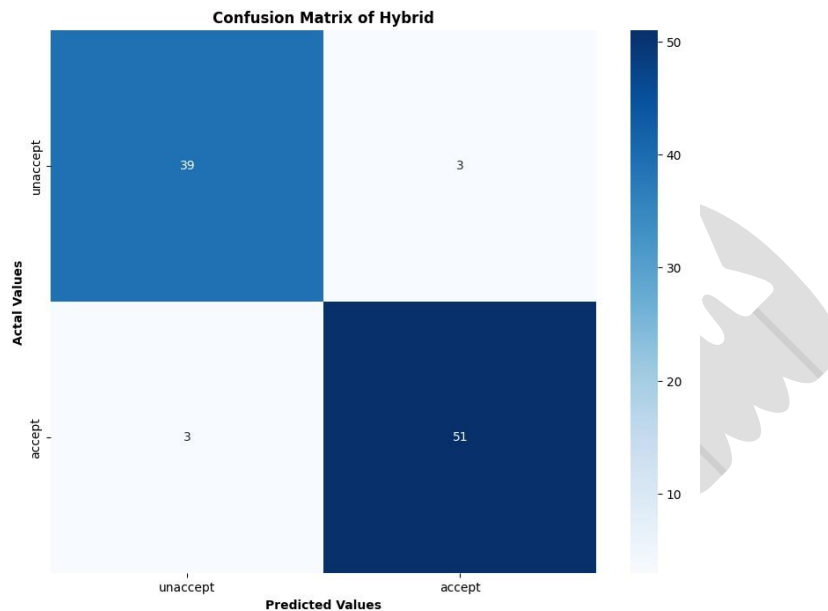
جدول ۷. نتایج تنظیم پارامترهای مدل ترکیبی تشخیص خطا در سه مرحله

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



شکل ۸. نمودار داده‌های آموزشی مدل منتخب

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



شکل ۹. ماتریس درهم ریختگی مدل ترکیبی منتخب

با توجه به شکل (۹)، مدل ترکیبی ۳ مورد را به اشتباه غیرقابل قبول اعلام کرده و ۳ مورد را که نباید قبول می کرده، به اشتباه قابل قبول اعلام کرده است. ولی در ۳۹ مورد دیگر، نمونه‌ها از نظر الگوریتم، غیرقابل قبول بوده است که به درستی تشخیص داده شده است و ۵۱ مورد قابل قبول بوده است که به درستی، 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 پیش آمده را تعیین کنیم و بدانیم که خطای فرآیند در کدامین مرحله اتفاق افتاده است. قبل از اجرای مدل‌ها ابتدا به وسیله خودمزم‌گذارها برای بالا بردن دقت مدل از تکنیک استخراج ویژگی جهت انتخاب متغیرهایی که از درجه اهمیت بیشتری برخوردار است، استفاده شده است.

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

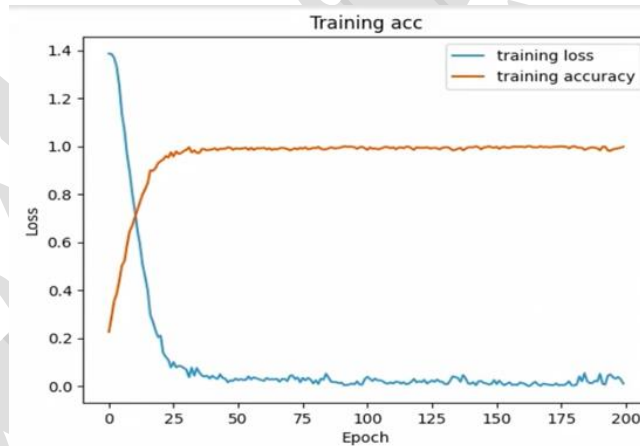
داده‌های کلیه مراحل به صورت هم‌زمان در مدل بارگذاری می‌شود. نتایج به دست آمده در جدول شماره (۸) نشان داده شده است:

جدول ۸. نتایج تشخیص نوع خطای احتمالی در مدل

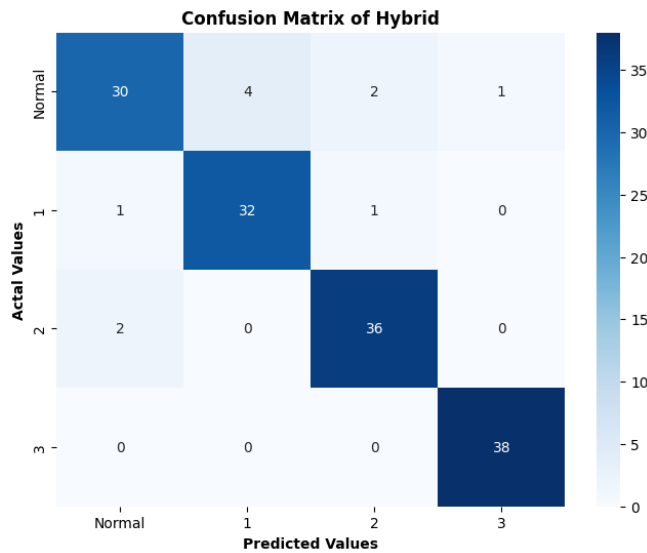
شاخص	LSTM	CNN	LSTM-CNN	LSTM-CNN _{TUNED}
صحت	۰/۸۲۳	۰/۸۴۴	۰/۸۹۶	۰/۹۲۵
دقت	۰/۸۳۶	۰/۸۴۳	۰/۸۹۴	۰/۹۲۴
فراخوان	۰/۸۰۸	۰/۸۴۸	۰/۸۹۹	۰/۹۲۵
معیار F1	۰/۸۴۳	۰/۸۴۳	۰/۸۹۵	۰/۹۲۳

چنان که در جدول شماره (۸) مشاهده می‌شود الگوریتم ترکیبی (LSTM-CNN) از شاخص‌های بهتری نسبت به روش‌هایی که از یک الگوریتم، ساخته شده است برخوردار است. به همین منظور از الگوریتم (GBC) جهت تنظیم پارامترهای مدل ترکیبی استفاده می‌شود. بعد از تنظیم پارامترهای مدل، الگوریتم مجدداً اجرا شده و نتایج آن در جدول (۸) در قسمت سمت راست، 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) نشان داده شده است.



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



شکل ۱۱. ماتریس درهم ریختگی مدل بهینه تشخیص نوع خطا

در ماتریس درهم ریختگی شکل (۱۱) نتایج به دست آمده بدین ترتیب است: در ۳۰ مورد فرآیند، بدون خطا بوده و مدل به درستی تشخیص داده است. ۱ مورد خطا در مرحله اول و ۲ مورد خطا در مرحله دوم به اشتباه پیش بینی شده است، در صورتی که فرآیند در شرایط واقعی خطایی نداشته است. در قطر اصلی ماتریس، مشاهده می شود که اکثر پیش بینی ها درست بوده و تعداد خطای فرآیند بسیار کم است.

نظارت و تشخیص خطا بر روی داده های تصویری^۱

در مرحله سوم کنترل مؤلفه های کیفی (آزمون های شیمیایی - فیزیکی) دو متغیر وجود دارد که داده های آن ها به صورت تصویری است و کنترل بر روی این متغیرها به وسیله مدل هایی که پردازش تصویر را انجام می دهند، صورت می پذیرد.

الگوریتم های یادگیری عمیق مورد استفاده در این قسمت عبارت اند از: (VGG, CNN, Res Net, Dens Net and Res Net-Dens Net).

دو متغیر در این بخش: ۱- رنگ نهایی روغن موتور^۲ - ۲- تغییر رنگ قطعات موتوری، در اثر مجاورت با ترکیبات مس موجود در روغن موتور. در ابتدا تمامی داده ها به دو گروه train و test به نسبت ۲۰ به ۸۰ به صورت تصادفی تقسیم می شوند. در تمامی الگوریتم ها مقدار تکرار اندازه دسته برابر با ۵۰ و اندازه تصاویر ۱۲۸*۱۲۸ در نظر گرفته شده است. تنظیم پارامتر الگوریتم های مورد استفاده در این بخش در جدول (۹) نشان داده شده است.

1. Image Data
2. Finish Color Motor Oil

جدول ۹. تنظیم پارامتر الگوریتم‌های تصویری

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

ابتدا پردازش تصویر بر مؤلفه رنگ‌روغن موتور انجام می‌شود. مجموعه‌ای از رنگ‌های روغن موتور با برچسب، قابل قبول^۱ و غیرقابل قبول^۲ در شکل شماره (۱۲) نشان داده شده است:



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


نتایج به دست آمده از اجرای الگوریتم‌های ترکیبی در جدول شماره (۱۰) آمده است:

جدول ۱۰. نتایج مدل‌های پیشنهادی برای متغیر، رنگ‌روغن

شاخص	VGG	CNN	ResNet	DensNet	Res-Dens
صحت	۰/۹۲۹	۰/۸۸۶	۰/۸۶۶	۰/۹۹۷	۰/۹۸۶
دقت	۰/۹۲۶	۰/۹۵	۰/۹۳۵	۰/۹۸۲	۰/۹۹۱
پوشش	۰/۸۶۶	۰/۸۱۲	۰/۷۵	۰/۹۲۸	۰/۹۶۹
معیار FI	۰/۸۹۱	۰/۸۵۸	۰/۷۹۹	۰/۹۵۸	۰/۹۷۹

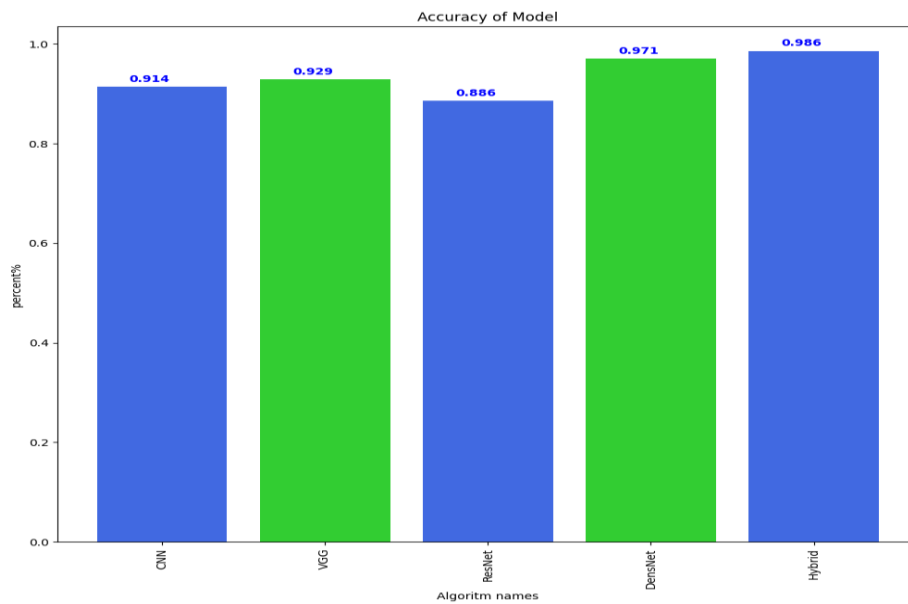
1. Acceptable
2. Unacceptable

چنان که در جدول (۱۰) نشان داده شده است، دو مدل ResNet و DensNet از دقت بالاتری نسبت به دو مدل VGG و CNN برخوردارند. مدل ترکیبی این دو الگوریتم با یکدیگر نیز موردسنجش قرار گرفته و نتیجه بهینه در مدل ترکیبی به دست آمده در سمت راست جدول نشان داده شده است. لازم به ذکر است که الگوریتم GBC در این روش ترکیبی، نمی تواند در تنظیم پارامترهای مدل، تأثیری داشته باشد، زیرا نتایج نشان می دهد خود مدل بهینه می باشد. ماتریس درهم ریختگی مدل ترکیبی در شکل (۱۳) نشان داده شده است. این مدل فقط در ۱ مورد به اشتباه داده تصویری را خطا تشخیص داده است.



شکل ۱۳. ماتریس درهم ریختگی مدل ترکیبی

نمودار میله ای میزان دقت عملکرد مدل های تصویری در شکل (۱۴) نشان داده شده است. همان طور که در شکل مشخص است دقت الگوریتم ترکیبی ResNet-DenseNet، بیشترین مقدار را دارد.



شکل ۱۴. نمودار دقت مدل منتخب رنگ روغن موتور

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

مجموعه رنگ قطعات موتوری در مجاورت عنصر مس در شکل (۱۵) آورده شده است.



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

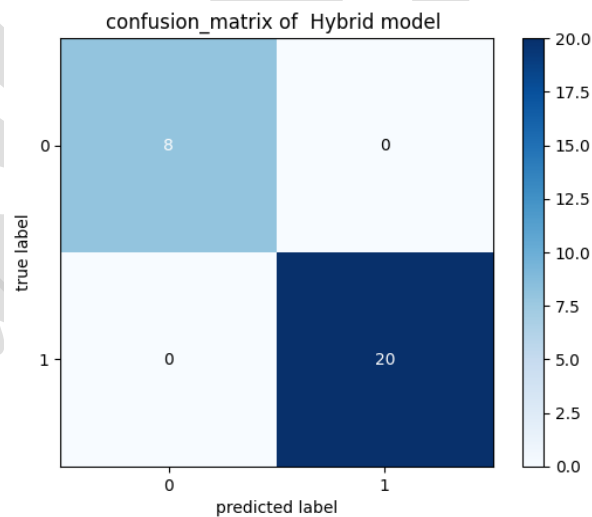
نتایج به دست آمده از الگوریتم‌های یادگیری عمیقی که برای پردازش مؤلفه های تصویری استفاده شده اند، در جدول شماره (۱۱) نشان داده شده است.

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

شاخص	VGG	CNN	ResNet	DensNet	Res-Dens
صحت	۰/۸۹۳	۰/۸۲۱	۰/۸۹۳	۰/۹۲۹	۱
دقت	۰/۸۸۱	۰/۹	۰/۹۳۵	۰/۹۵۵	۱
پوشش	۰/۸۵	۰/۶۸۸	۰/۸۱۲	۰/۸۷۵	۱
معیار F1	۰/۸۶۳	۰/۷۱۷	۰/۸۵	۰/۹۰۵	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 شاخص ها برابر ۱ است و این نتیجه، کارایی روش ترکیبی را در تشخیص خطای فرآیند نشان می دهد. ماتریس درهم ریختگی مدل ترکیبی در شکل (۱۶) نشان داده شده است:



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

در ماتریس درهم ریختگی، که در شکل (۱۶) نشان داده شده، ۸ مورد تصویر، غیر قابل قبول تشخیص داده شده که تمام ۸ مورد صحیح است، ۲۰ مورد تصویر در فرآیند قابل قبول، تشخیص داده شده که هر ۲۰ مورد صحیح می باشد.

نمودار میله ای 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

در این نمودار مشخص شده است که الگوریتم ترکیبی با دقت ۱ و امتیاز کامل، نسبت به بقیه الگوریتمها از دقت بالاتری برخوردار است. دقت الگوریتم دنس نت ۰/۹۲۹، دقت الگوریتم رزنت ۰/۸۹۳، دقت الگوریتم وی جی جی ۰/۸۹۳ و دقت الگوریتم سی ان ان ۰/۸۲۱ پیش بینی شده است.

معیار توقف الگوریتمها: در داده های تصویری (epoch50) و در داده های 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 می شود.

نتیجه گیری و پیشنهادها

در این پژوهش، نظارت و کنترل بر مؤلفه های کیفی در سه مرحله، به وسیله الگوریتم های یادگیری عمیق انجام شده است. با روش های ساخته شده توسط الگوریتم های ترکیبی، نظارت بر مؤلفه های کیفی، تشخیص خطا و تشخیص نوع خطا در فرآیند انجام می پذیرد. در این مطالعه، نظارت و کنترل بر اجزای کیفی در سه مرحله انجام شده است که از طریق الگوریتم های یادگیری عمیق انجام می شود. با استفاده از روش های ترکیبی توسط الگوریتم ها، نظارت بر اجزای کیفی، تشخیص خطا و طبقه بندی خطا در فرآیند انجام می شود. بخش نظارت و تشخیص خطا از سه مرحله، شامل آزمون های شیمیایی، آزمون های فیزیکی

و آزمون‌های شیمیایی-فیزیکی تشکیل شده است. در هر مرحله، ابتدا تجزیه و تحلیل فرآیند با استفاده از الگوریتم‌های CNN و LSTM انجام می‌شود. روش ترکیبی LSTM-CNN از دقت بیشتری نسبت به روش‌های تک الگوریتمی بهره‌مند است. اجزای فرآیند توسط الگوریتم ترکیبی LSTM-CNN تحت تجزیه و تحلیل قرار می‌گیرند. 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 به گونه‌ای بهینه می‌سازد که توانایی بیشتری در تشخیص خطا، کنترل کیفیت و بهبود عملکرد دارند. با بهره‌گیری از قابلیت‌های تکاملی و جمع‌سازی مشابه رفتار زنبورها، GBC می‌تواند بهبودهای قابل توجهی در دقت تشخیص خطا، کاهش هزینه‌های کنترل کیفیت، بهبود زمان سیکل تولید، و کاهش هزینه‌های تولید به ارمغان 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 می‌باشد.

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 مورد استفاده در پردازش تصویر شامل VGG، CNN، ResNet 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 می‌شوند. تمام داده‌های سه مرحله آزمون کیفی به‌طور همزمان در داخل الگوریتم‌ها بارگذاری می‌شوند. مدل ترکیبی LSTM-CNN نسبت به سایر الگوریتم‌ها از دقت بیشتری برخوردار است. پارامترهای این الگوریتم ترکیبی به وسیله الگوریتم GBC بهبود داده می‌شوند 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٪ هزینه کنترل کیفیت و کاهش ۲۰٪ هزینه تولید و هزینه‌های اضافی است. همچنین، رضایت مشتریان به میزان ۵۰٪ افزایش یافته و فروش به میزان ۶۰٪ 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٪ 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، استفاده نمایند. توانایی الگوریتم‌های یادگیری عمیق در تسریع فرآیند تولید و افزایش دقت کنترل، موضوعی است که برای پژوهش‌گران قابل توجه است.

1. Abbasi, R., Jamipour, M. & Ghasemlou, M. (2021). Analyzing the Factors Causing Customer Dissatisfaction with Food Ordering Applications. *Business Management Perspectives in Management Perspective*. 20(47): p. 111-136.
2. Adalat, M.H., Azmi, R. & Bagherinejad, J. (2020). An Enhanced LSTM Method to Improve the Accuracy of the Business Process Prediction. *Journal of Industrial Management Perspective*. 10(3): p. 71-97. (in Persian)
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: p. 49-60.
5. Asgharizadeh, E., Moghadam, M.R.S., Safari, H. & Neshan, M.S. (2019). The Effects of Customers' Decision Making with Different Risk Preferences on Warranty Providers: Agent Based Modeling. *Journal of Industrial Management Perspective*. 9(1): p. 31-59. (in Persian)
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(4): p.
8. Baghbanpourasl, A., Lughofer, E., Meyer-Heye, P., Zörrer, H. & Eitzinger, C. (2019). *Virtual Quality Control Using Bidirectional LSTM Networks and Gradient Boosting*. in *2019 IEEE 17th International Conference on Industrial Informatics (INDIN)*. 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: p. 982-987.
10. Bersimis, S., Psarakis, S. & Panaretos, J. (2007). Multivariate Statistical Process Control Charts: An Overview. *Quality and Reliability Engineering International*. 23(5): p. 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. 13(22): p. 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: p. 54-67.
13. Chen, Z., Yeo, C.K., Lee, B.S. & Lau, C.T. (2018). *Autoencoder-Based Network Anomaly Detection*. in *Wireless Telecommunications Symposium (WTS)*.
14. de Oliveira, R.R., Avila, C., Bourne, R., Muller, F. & de Juan, A. (2020). Data Fusion Strategies to Combine Sensor and Multivariate Model Outputs for Multivariate Statistical Process Control. *Analytical and Bioanalytical Chemistry*. 412(9): p. 2151-2163.

15. 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): p. 325-336.
16. Esmaeili, M., Olfat, L., Amiri, M. & Vanani, I.R. (2023). Classification and Allocation of Suppliers to Customers in Resilience Supply Chains Using Machine Learning. *Journal of Industrial Management Perspective*. 13(3): p. 39-70. (in Persian)
17. Gan, Y., Yang, J. & Lai, W. (2019) *Video Object Forgery Detection Algorithm Based on Vgg-11 Convolutional Neural Network*. in *2019 International Conference on Intelligent Computing, Automation and Systems (ICICAS)*.
18. 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): p. 475-493.
19. 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.
20. 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*. Elsevier.
21. Hsu, J.Y., Wang, Y.F., Lin, K.C., Chen, M.Y. & Hsu, J.H.Y. (2020). Wind Turbine Fault Diagnosis and Predictive Maintenance through Statistical Process Control and Machine Learning. *IEEE Access*. 8: p. 23427-23439.
22. Huang, G., Liu, Z., Van Der Maaten, L. & Weinberger, K.Q. (2019) *Densely Connected Convolutional Networks*. in *Proceedings of the IEEE conference on computer vision and pattern recognition*.
23. Jin, X., Fan, J. & Chow, T.W. (2018). Fault Detection for Rolling-Element Bearings Using Multivariate Statistical Process Control Methods. *IEEE Transactions on Instrumentation Measurement*. 68(9): p. 3128-3136.
24. 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): p. 3128-3136.
25. Li, S., Chen, Y. & Tong, C. (2021). Multivariate Statistical Process Monitoring Based on Principal Discriminative Component Analysis. *Journal of the Franklin Institute*. 358(15): p. 7900-7915.
26. 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): p. 8553-8564.
27. 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): p. 49-64.
28. 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): p. 251-271.
29. 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): p. 880-892.
30. Pustokhin, D., Pustokhina, I., Dinh, P., Phan, S., Nhu, N., Joshi, G.P. & K, S. (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: p. 1-18.
31. 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: p. 52-75.
32. Rezai Dolatabadi, H., Zaineli, Z. & Shekarchizadeh, Z. (2011). Investigating the Impact of Competitive Intelligence in Creating a Competitive Advantage. *Business Management Perspective*. 10(6): p. -.
33. Santos-Fernández, E. (2012) *Multivariate Statistical Quality Control Using R*. Vol. 14. 2012: Springer Science & Business Media.
34. Shin, T. (2020). Towards Data Science. Retrieved from Medium: <https://towards-data-science.com/under-standing-the-confusion-matrix-and-how-to-implement-it-in-python-319202e0fe4d>.
35. Silva, A.F., Sarraguça, M.C., Fonteyne, M., Vercruyse, J., De Leersnyder, F., Vanhoorne, V., Bostijn, N., Verstraeten, M., Vervaet, C., Remon, J.P., De Beer, 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): p. 242-252.
36. 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): p. 53-77.
37. Tôrres, A.R., de Oliveira, A.D.P., Grangeiro, S. & Fragoso, W.D. (2018). Multivariate Statistical Process Control in Annual Pharmaceutical Product Review. *Journal of Process Control*. 69: p. 97-102.
38. Wang, L., Zhang, Z., Xu, J. & Liu, R. (2018). Wind Turbine Blade Breakage Monitoring with Deep Autoencoders. *IEEE Transactions on Smart Grid*. 9(4): p. 2824-2833.
39. 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: p. 3465-3471.
40. 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).
41. Yu, J., Zheng, X. & Wang, S. (2019). Stacked Denoising Autoencoder-Based Feature Learning for out-of-Control Source Recognition in Multivariate Manufacturing Process. *Quality and Reliability Engineering International*. 35(1): p. 204-223.
42. 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 2018*. Singapore: Springer Singapore.