

پیش‌بینی آنی افت عملکرد مبدل‌های حرارتی در صنایع پتروشیمی با استفاده از شبکه عصبی LSTM چندحسگری

طه‌ورا شریفی^{۱*}، امیررضا پرتوی[†]

1- Tahoora.sharifi8@gmail.com

2- amirreza4567par@gmail.com

خلاصه

در این پژوهش، رویکردی مبتنی بر شبکه عصبی حافظه طولانی کوتاه‌مدت (LSTM) برای پیش‌بینی افت عملکرد مبدل‌های حرارتی، با استفاده از داده‌های چندحسگری دما، فشار، دبی و ارتعاش، ارائه می‌شود. با توجه به اهمیت حیاتی مبدل‌های حرارتی در صنایع پتروشیمی و هزینه‌های ناشی از افت عملکرد و توقف‌های برنامه‌ریزی نشده، توسعه روش‌های پیش‌بینی دقیق و آنی برای نگهداری پیشگیرانه ضروری است. داده‌های مورد استفاده در این مطالعه، به صورت شبیه‌سازی شده و طی یک دوره سه ماهه با بازه نمونه‌برداری ۵ دقیقه جمع‌آوری شده‌اند. در این فرآیند شبیه‌سازی، تلاش شده است تا واقع‌گرایانه بودن داده‌ها با لحاظ کردن نویزهای معمول سنسورها و همچنین گنجاندن رویدادهای ناگهانی که منجر به افت عملکرد می‌شوند، افزایش یابد. مدل LSTM به دلیل توانایی ذاتی خود در یادگیری وابستگی‌های زمانی بلندمدت و پردازش دنباله‌های داده، به عنوان گزینه اصلی انتخاب شده است. معماری مدل با دقت تنظیم شده و پارامترهای آن برای بهینه‌سازی عملکرد در پیش‌بینی افت عملکرد، تیون شده‌اند. نتایج حاصل از ارزیابی مدل نشان داد که LSTM توانایی پیش‌بینی افت عملکرد با دقت بسیار بالا، به طوریکه ضریب تعیین (R^2) حدود ۰.۹۵ را به دست آورده است. این دقت، بیانگر آن است که مدل قادر به توضیح حدود ۹۵ درصد از تغییرات در افت عملکرد است. علاوه بر این، عملکرد LSTM به طور قابل توجهی بهتر از مدل‌های کلاسیک سری زمانی مانند ARIMA (AutoRegressive Integrated Moving Average) و SVR (Support Vector Regression) که در مطالعات قبلی نیز مورد استفاده قرار گرفته‌اند، ارزیابی شد. این برتری در پیش‌بینی، به دلیل قابلیت LSTM در مدل‌سازی روابط غیرخطی پیچیده و درک وابستگی‌های زمانی طولانی که در داده‌های عملکردی مبدل‌های حرارتی وجود دارد، حاصل شده است.

کلمات کلیدی: شبکه عصبی LSTM، پیش‌بینی افت عملکرد، مبدل حرارتی، داده‌های چندحسگری، نگهداری پیشگیرانه، سری زمانی، ARIMA و SVR

* دانشجوی کارشناسی ارشد مهندسی شیمی دانشگاه صنعتی کرمانشاه
† دانشجوی کارشناسی ارشد مهندسی شیمی

۱. مقدمه

مبدل‌های حرارتی یکی از اجزای زیربنایی و کلیدی در اغلب فرآیندهای صنعتی، به ویژه در صنایع پتروشیمی، نفت و گاز، نیروگاهی و شیمیایی محسوب می‌شوند. این تجهیزات وظیفه انتقال حرارت بین دو سیال یا بین یک سیال و محیط اطراف را بر عهده دارند و نقش اساسی در کنترل دما، جداسازی اجزا و بهینه‌سازی مصرف انرژی ایفا می‌کنند. هرگونه افت در عملکرد این مبدل‌ها می‌تواند پیامدهای مخربی از جمله کاهش بازده کلی فرآیند، افزایش مصرف انرژی، کاهش کیفیت محصول نهایی و در نهایت، افزایش هزینه‌های عملیاتی و تعمیرات را به همراه داشته باشد. دلایل مختلفی می‌توانند منجر به افت عملکرد مبدل‌های حرارتی شوند، که از جمله مهم‌ترین آن‌ها می‌توان به موارد زیر اشاره کرد:

- رسوب‌گذاری (Fouling): تجمع مواد جامد، املاح، محصولات جانبی واکنش یا میکروارگانیسم‌ها بر روی سطوح تبادل حرارت، مقاومت حرارتی را افزایش داده و جریان سیال را مختل می‌کند.
- خوردگی (Corrosion): تخریب سطوح فلزی به دلیل واکنش‌های شیمیایی با سیالات در حال عبور، که می‌تواند منجر به نازک شدن دیواره‌ها، نشتی و کاهش انتقال حرارت شود.
- تغییر شرایط عملیاتی: انحراف پارامترهایی مانند دبی ورودی، دمای سیالات، فشار یا ترکیب شیمیایی سیالات از مقادیر طراحی شده، می‌تواند بر راندمان مبدل تأثیر بگذارد.
- انسداد (Blockage): گرفتگی در مسیر سیال به دلیل ذرات معلق بزرگتر یا تجمع مواد، جریان را محدود کرده و انتقال حرارت را کاهش می‌دهد.
- فرسودگی اجزا: از کار افتادگی یا خرابی اجزای مکانیکی مرتبط مانند پمپ‌ها یا فن‌ها نیز می‌تواند بر عملکرد مبدل حرارتی اثر بگذارد.

تشخیص زودهنگام و پیش‌بینی دقیق زمان و میزان افت عملکرد، امری حیاتی در پیاده‌سازی استراتژی‌های نگهداری پیشگیرانه (Preventive Maintenance) و نگهداری مبتنی بر وضعیت (Condition-Based Maintenance) است. این رویکردها به سازمان‌ها اجازه می‌دهند تا با برنامه‌ریزی صحیح، تعمیرات و نگهداری را در زمان‌های بهینه انجام دهند، از خرابی‌های ناگهانی و پرهزینه جلوگیری کنند و عمر مفید تجهیزات را افزایش دهند. در سال‌های اخیر، با پیشرفت چشمگیر در حوزه فناوری اطلاعات، حسگرها و الگوریتم‌های یادگیری ماشین، امکان جمع‌آوری حجم عظیمی از داده‌های عملیاتی از تجهیزات صنعتی فراهم شده است. این داده‌ها، که اغلب به صورت سری‌های زمانی (Time Series) هستند، حاوی اطلاعات ارزشمندی در مورد وضعیت و عملکرد تجهیزات می‌باشند. شبکه‌های عصبی، به ویژه شبکه‌های با قابلیت یادگیری الگوهای پیچیده و وابستگی‌های زمانی، ابزاری قدرتمند برای تحلیل این داده‌ها محسوب می‌شوند. در این میان، شبکه‌های حافظه طولانی کوتاه‌مدت (LSTM) به دلیل معماری خاص خود که قادر به یادگیری و به خاطر سپردن اطلاعات برای دوره‌های زمانی طولانی است، در تحلیل و پیش‌بینی سری‌های زمانی، به‌ویژه در حوزه‌هایی که وابستگی‌های بلندمدت نقش مهمی ایفا می‌کنند، بسیار موفق بوده‌اند. این پژوهش با هدف ارائه یک روش نوین و دقیق برای پیش‌بینی آنی افت عملکرد مبدل‌های حرارتی در صنایع پتروشیمی، با بهره‌گیری از داده‌های چندحسگری و معماری LSTM، انجام شده است.

۲. مرور ادبیات

پیش‌بینی عملکرد و تشخیص خرابی در تجهیزات صنعتی، به‌ویژه مبدل‌های حرارتی، همواره مورد توجه پژوهشگران بوده است. در طول سال‌ها، روش‌های مختلفی برای مدل‌سازی و پیش‌بینی رفتار این تجهیزات توسعه یافته‌اند. رویکردهای سنتی اغلب بر پایه مدل‌های آماری و تحلیل‌های رگرسیونی استوار بوده‌اند.

یکی از مدل‌های کلاسیک پرکاربرد در تحلیل سری‌های زمانی، مدل $ARIMA$ (AutoRegressive Integrated Moving Average) است. این مدل برای داده‌هایی که رفتار خطی دارند و از نویز کمتری برخوردارند، عملکرد مناسبی از خود نشان می‌دهد. با این حال، در مواجهه با داده‌های پیچیده صنعتی که اغلب دارای روابط غیرخطی، وابستگی‌های بلندمدت و تأثیرات خارجی نامشخص هستند، مدل $ARIMA$ محدودیت‌هایی دارد (Zhang et al., 2019). درک و مدل‌سازی اثرات متقابل چندین سنسور (مانند دما، فشار، دبی) به صورت همزمان در چارچوب $ARIMA$ نیز چالش‌برانگیز است.

روش SVR (Support Vector Regression) یکی دیگر از تکنیک‌های یادگیری ماشین است که برای مدل‌سازی روابط غیرخطی و پیش‌بینی به کار گرفته می‌شود. SVR با استفاده از تابع کرنل، داده‌ها را به فضایی با ابعاد بالاتر نگاشت می‌کند تا بتواند روابط غیرخطی را به صورت خطی مدل کند. این روش در مقایسه با مدل‌های خطی، عملکرد بهتری در پیش‌بینی داده‌های پیچیده صنعتی دارد. اما، SVR نیز در به تصویر کشیدن وابستگی‌های زمانی بسیار طولانی و حفظ حافظه برای گام‌های زمانی دورتر، با محدودیت‌هایی روبرو است. همچنین، تنظیم پارامترهای SVR برای دستیابی به بهترین عملکرد می‌تواند زمان‌بر باشد.

با ظهور یادگیری عمیق، به‌ویژه شبکه‌های عصبی بازگشتی (RNN - Recurrent Neural Networks)، تحول قابل توجهی در حوزه تحلیل سری‌های زمانی حاصل شد. RNN ها به طور ذاتی برای پردازش داده‌های دنباله‌ای طراحی شده‌اند و مکانیزم بازگشتی آن‌ها به شبکه اجازه می‌دهد تا اطلاعات مربوط به گام‌های زمانی قبلی را در حالت پنهان ($Hidden State$) خود حفظ کند. با این حال، RNN های ساده با مشکل "محو شدن گرادیان" ($Vanishing Gradient$) مواجه هستند که مانع از یادگیری وابستگی‌های بلندمدت می‌شود.

برای غلبه بر این مشکل، معماری LSTM (Long Short-Term Memory) توسط Hochreiter & Schmidhuber در سال ۱۹۹۷ معرفی شد (Hochreiter & Schmidhuber, 1997). LSTM ها نوع خاصی از RNN ها هستند که با استفاده از مکانیزم‌های دروازه‌ای (Gate Mechanisms) شامل گیت ورودی (Input Gate)، گیت فراموشی (Forget Gate) و گیت خروجی (Output Gate)، قادر به کنترل جریان اطلاعات و یادگیری مؤثر وابستگی‌های زمانی بلندمدت هستند. این مکانیزم‌ها به سلول LSTM اجازه می‌دهند تا اطلاعات مهم را برای مدت طولانی‌تری حفظ کرده و اطلاعات نامربوط را به صورت انتخابی فراموش کنند. به همین دلیل، LSTM ها در طیف وسیعی از کاربردهای مرتبط با سری‌های زمانی، از جمله تشخیص خرابی (Prognostics and Health Management - PHM)، پیش‌بینی آب و هوا، تحلیل بازارهای مالی و پردازش زبان طبیعی، موفقیت چشمگیری کسب کرده‌اند. استفاده از داده‌های چندحسگری (Multisensor Data) در مدل‌سازی عملکرد تجهیزات، رویکردی است که دقت و جامعیت پیش‌بینی را افزایش می‌دهد. هر حسگر جنبه متفاوتی از وضعیت تجهیز را منعکس می‌کند و ترکیب اطلاعات آن‌ها می‌تواند دیدی کامل‌تر از رفتار تجهیز ارائه دهد. ترکیب LSTM با داده‌های چندحسگری، امکان مدل‌سازی روابط پیچیده بین پارامترهای مختلف عملیاتی و تأثیر آن‌ها بر افت عملکرد را فراهم می‌آورد (Wang et al., 2020). این پژوهش با تکیه بر این دانش، به دنبال ارائه مدلی مبتنی بر LSTM چندحسگری برای پیش‌بینی آنی افت عملکرد مبدل‌های حرارتی است.

۳. مواد و روش‌ها

داده‌ها

مجموعه داده‌های مورد استفاده در این پژوهش به صورت شبیه‌سازی شده و با هدف بازنمایی دقیق‌تر شرایط عملیاتی واقعی یک مبدل حرارتی در صنایع پتروشیمی تولید شده است. فرآیند شبیه‌سازی به گونه‌ای طراحی شده است که پارامترهای کلیدی عملکردی مبدل را در طول زمان تحت تأثیر قرار دهد. این پارامترها که از طریق حسگرهای مختلف اندازه‌گیری می‌شوند، عبارتند از:

- دما : (Temperature) شامل دمای ورودی و خروجی سیال گرم و سیال سرد. تغییرات این پارامترها مستقیماً با میزان انتقال حرارت مرتبط است.
- فشار : (Pressure) فشار ورودی و خروجی سیالات. افت فشار می‌تواند نشان‌دهنده انسداد یا افزایش مقاومت جریان باشد.
- دبی : (Flow Rate) دبی حجمی یا جرمی سیالات گرم و سرد. تغییرات دبی بر راندمان انتقال حرارت تأثیرگذار است.
- ارتعاش : (Vibration) اندازه‌گیری سطح ارتعاشات مکانیکی در نقاط مختلف بدنه مبدل. افزایش ارتعاشات می‌تواند نشان‌دهنده مشکلات مکانیکی یا جریان غیرعادی باشد.

این داده‌ها طی یک دوره زمانی سه ماهه جمع‌آوری شده‌اند. بازه نمونه‌برداری (Sampling Interval) برای تمامی پارامترها ۵ دقیقه تعیین شده است. این بازه زمانی کوتاه، امکان رصد دقیق تغییرات دینامیکی در عملکرد مبدل را فراهم می‌آورد.

یکی از چالش‌های مهم در استفاده از داده‌های واقعی، وجود نویز در سیگنال‌های حسگر است. این نویزها می‌توانند ناشی از عوامل الکتریکی، تداخلات خارجی، یا محدودیت‌های ذاتی خود حسگرها باشند. در فرآیند شبیه‌سازی، نویز با

اضافه کردن مقادیر تصادفی (با توزیع نرمال) به داده‌های واقعی، به سیگنال‌ها اضافه شده است تا مدل با شرایط واقعی‌تری مواجه شود.

علاوه بر نویز، رویدادهای افت ناگهانی بازده (Sudden Efficiency Drops) که در اثر عوامل خارجی یا خرابی‌های ناگهانی رخ می‌دهند، نیز در داده‌های شبیه‌سازی شده گنجانده شده‌اند. این رویدادها برای ارزیابی توانایی مدل در تشخیص تغییرات سریع و غیرمنتظره عملکرد، بسیار حائز اهمیت هستند.

به طور خلاصه، مجموعه داده‌های شبیه‌سازی شده شامل دنباله‌های زمانی متعددی از پارامترهای دما، فشار، دبی و ارتعاش، با نرخ نمونه‌برداری ۵ دقیقه، طی سه ماه، و با لحاظ کردن نویز سنسور و رویدادهای افت عملکرد، آماده‌سازی شده است.

پیش‌پردازش

پیش‌پردازش داده‌ها مرحله‌ای حیاتی در آماده‌سازی داده‌ها برای ورود به مدل‌های یادگیری ماشین است. هدف از این مرحله، حذف اثرات نامطلوب، استانداردسازی داده‌ها و تبدیل آن‌ها به فرمتی مناسب برای ورودی مدل است. مراحل پیش‌پردازش شامل موارد زیر است:

۱. پاک‌سازی نویز (Noise Filtering): برای کاهش اثر نویزهای تصادفی که به سیگنال‌های حسگر اضافه شده بودند، از روش فیلتر میانگین متحرک (Moving Average Filter) استفاده شد. این فیلتر با محاسبه میانگین مقادیر در یک پنجره زمانی مشخص، به هموارسازی سیگنال و کاهش نوسانات ناخواسته کمک می‌کند. پنجره میانگین متحرک برای هر حسگر به صورت جداگانه و با توجه به ویژگی‌های نویز سیگنال آن تنظیم شد.

۲. نرمال‌سازی (Normalization): بسیاری از الگوریتم‌های یادگیری ماشین، به‌ویژه شبکه‌های عصبی، به داده‌های نرمال‌شده حساس هستند. نرمال‌سازی باعث می‌شود که تمامی ویژگی‌ها در یک مقیاس مشابه قرار گیرند و از تسلط ویژگی‌هایی با مقادیر بزرگتر بر فرآیند آموزش جلوگیری شود. از روش نرمال‌سازی Min-Max استفاده شد که مقادیر هر ویژگی را در بازه [۰, ۱] نگاشت می‌کند. فرمول آن به صورت زیر است:

$$X_{\text{normalized}} = \frac{X - X_{\min}}{X_{\max} - X_{\min}}$$

تمامی متغیرهای ورودی (دما، فشار، دبی، ارتعاش) انجام شد.

۳. ساخت دنباله‌های سری زمانی (Time Series Sequencing): مدل‌های LSTM برای پردازش داده‌های دنباله‌ای طراحی شده‌اند. برای تغذیه داده‌ها به مدل LSTM، لازم است که داده‌های خام به دنباله‌های ورودی (Input Sequences) و برچسب‌های خروجی (Output Labels) تبدیل شوند. در این پژوهش، از روش "پنجره متحرک (Sliding Window)" استفاده شد. با تعیین طول دنباله ورودی (Lookback Window)، تعداد مشخصی از نمونه‌های زمانی متوالی (مثلاً ۳۰ گام زمانی) به عنوان ورودی به مدل داده شد و مقدار مربوط به گام زمانی بعدی (گام ۳۱) به عنوان خروجی مورد انتظار (برچسب) در نظر گرفته شد. به عبارت دیگر، اگر دنباله ورودی از گام t تا $t+L-1$ باشد، خروجی مورد انتظار مقدار مربوط به گام $t+L$ است. طول دنباله ورودی (Lookback Window) برابر با ۳۰ گام (معادل ۳۰ * ۵ دقیقه = ۲.۵ ساعت) انتخاب شد تا مدل بتواند وابستگی‌های زمانی نسبتاً طولانی را پوشش دهد.

پس از این مراحل، داده‌ها به سه مجموعه آموزش (Training)، اعتبارسنجی (Validation) و تست (Test) تقسیم شدند. مجموعه آموزش برای یادگیری پارامترهای مدل، مجموعه اعتبارسنجی برای تنظیم هایپرپارامترها و


جلوگیری از بیش‌برازش (Overfitting)، و مجموعه تست برای ارزیابی نهایی عملکرد مدل پس از اتمام فرآیند آموزش استفاده شد.

مدل‌ها

۱. مدل LSTM چندحسگری (Multisensor LSTM Model):
 برای ارزیابی عملکرد مدل LSTM، این مدل با دو مدل کلاسیک دیگر مقایسه شد:
 • معماری: معماری مدل LSTM شامل دو لایه LSTM با تعداد واحدهای قابل تنظیم بود. این لایه‌ها به ترتیب برای یادگیری وابستگی‌های زمانی در سطوح مختلف انتزاع طراحی شده بودند. پس از لایه‌های LSTM، یک لایه Dropout با نرخ ۰.۲ برای جلوگیری از بیش‌برازش اضافه شد. در نهایت، یک لایه Dense (کاملاً متصل) با یک واحد خروجی برای پیش‌بینی مقدار افت عملکرد (یا یکی از پارامترهای اصلی عملکردی مانند ضریب انتقال حرارت کلی) در نظر گرفته شد.
 • تابع فعال‌سازی: تابع فعال‌سازی ReLU (Rectified Linear Unit) برای لایه‌های پنهان LSTM و خطی برای لایه خروجی استفاده شد.
 • بهینه‌ساز: بهینه‌ساز Adam با نرخ یادگیری (Learning Rate) مناسب انتخاب شد.
 • تابع هزینه: خطای میانگین مربعات (Mean Squared Error - MSE) به عنوان تابع هزینه برای فرآیند آموزش به کار رفت.
 ۲. مدل ARIMA (AutoRegressive Integrated Moving Average):
 • یک مدل ARIMA سری زمانی چندمتغیره (Multivariate ARIMA) با پارامترهای (p, d, q) مناسب که با استفاده از الگوریتم‌های بهینه‌سازی تعیین شدند، پیاده‌سازی شد. برای مدل‌سازی ارتباط بین متغیرها، از مدل VARIMA (Vector Autoregression Moving Average) استفاده شد.
 ۳. مدل SVR (Support Vector Regression):
 • مدل SVR با استفاده از هسته RBF (Radial Basis Function) که برای مدل‌سازی روابط غیرخطی مناسب است، پیاده‌سازی شد. پارامترهای C (ضریب تنظیم جریمه) و گاما (γ) با استفاده از جستجوی شبکه‌ای (Grid Search) و اعتبارسنجی متقابل (Cross-validation) تیون شدند.
- تمامی مدل‌ها بر روی مجموعه داده‌های آموزش دیده و سپس عملکرد آن‌ها بر روی مجموعه داده‌های تست با استفاده از معیارهای ارزیابی استاندارد سنجیده شد.

۴. نتایج و بحث

۱. روند واقعی در مقابل پیش‌بینی LSTM
 این بخش به مقایسه بصری عملکرد مدل LSTM در پیش‌بینی افت عملکرد با مقادیر واقعی می‌پردازد. شکل ۱، روند تغییرات افت عملکرد را در یک دوره زمانی مشخص، هم برای داده‌های واقعی و هم برای پیش‌بینی‌های انجام شده توسط مدل LSTM، نمایش می‌دهد.



شکل ۱


توضیحات شکل ۱:

در این نمودار، محور افقی نشان‌دهنده زمان (بر حسب گام‌های نمونه‌برداری یا ساعت) و محور عمودی نشان‌دهنده میزان افت عملکرد (که می‌تواند به صورت درصدی از عملکرد مطلوب یا معیاری دیگر تعریف شود) است. خط آبی رنگ، روند واقعی افت عملکرد را در داده‌های تست نشان می‌دهد. این خط نوسانات طبیعی و همچنین رویدادهای افت ناگهانی را به تصویر می‌کشد. خط نارنجی رنگ، پیش‌بینی‌های مدل LSTM را برای همان دوره زمانی نشان می‌دهد.

تحلیل: همانطور که در شکل ۱ مشاهده می‌شود، مدل LSTM توانسته است با دقت بسیار بالایی روند کلی افت عملکرد را دنبال کند. تطابق نزدیک بین خط آبی (واقعی) و خط نارنجی (پیش‌بینی) حاکی از توانایی مدل در یادگیری الگوهای پیچیده و وابستگی‌های زمانی داده‌ها است. مشاهده می‌شود که مدل LSTM قادر به پیش‌بینی صحیح نقاط عطف و تغییرات ناگهانی در افت عملکرد نیز می‌باشد، هرچند که ممکن است در پیش‌بینی دقیق قله‌ها یا دره‌های کوچک نوسانات، دارای خطای جزئی باشد. این همبستگی بالا نشان‌دهنده کارایی مدل LSTM در وظیفه پیش‌بینی است.

۲. مقایسه خطای مدل‌ها (RMSE)

برای ارزیابی کمی عملکرد مدل‌ها، از معیارهای مختلفی استفاده شده است. یکی از این معیارها، خطای میانگین مربعات ریشه‌ای (Root Mean Squared Error – RMSE) است که میزان انحراف استاندارد باقی‌مانده‌ها (خطای پیش‌بینی) را نشان می‌دهد. RMSE مقیاسی از دقت مدل است؛ مقادیر کمتر RMSE نشان‌دهنده عملکرد بهتر مدل است.




شکل ۲

توضیحات شکل ۲:

این نمودار میله‌ای، مقادیر RMSE را برای سه مدل LSTM، ARIMA و SVR بر روی مجموعه داده‌های تست مقایسه می‌کند. هر ستون نشان‌دهنده مقدار RMSE مربوط به یک مدل است. تحلیل: همانطور که از شکل ۲ پیداست، مدل LSTM دارای کمترین مقدار RMSE در بین سه مدل است. این بدان معناست که خطای پیش‌بینی مدل LSTM به طور میانگین کمتر از دو مدل دیگر بوده است. مدل SVR مقادیر RMSE پایین‌تری نسبت به ARIMA دارد، که نشان‌دهنده توانایی بهتر آن در مدل‌سازی روابط غیرخطی است. اما، LSTM با فاصله قابل توجهی از هر دو مدل دیگر، بهترین عملکرد را از نظر RMSE از خود نشان داده است. این برتری، تأییدی بر توانایی LSTM در پردازش مؤثر داده‌های سری زمانی پیچیده و چندحسگری است.

۳. تحلیل توزیع خطای پیش‌بینی

یکی دیگر از روش‌های ارزیابی کیفیت پیش‌بینی، بررسی توزیع خطای پیش‌بینی (تفاوت بین مقدار واقعی و پیش‌بینی شده) است. نمودار جعبه‌ای (Boxplot) ابزاری مناسب برای نمایش معیارهای آماری مانند میانه، چارک‌ها و نقاط پرت (Outliers) در توزیع خطا است.



شکل ۳


توضیحات شکل ۳:

این نمودار جعبه‌ای، توزیع خطای پیش‌بینی را برای هر سه مدل LSTM، ARIMA و SVR به تصویر می‌کشد. هر جعبه نشان‌دهنده بازه بین چارک اول (Q1) و چارک سوم (Q3) است. خط درون جعبه، میانه خطا را نشان می‌دهد. خطوط عمودی (Whisker) گسترش توزیع را تا مقادیر مشخصی نمایش می‌دهند و نقاط جداگانه، نشان‌دهنده نقاط پرت (Outliers) هستند.

تحلیل: جعبه مربوط به مدل LSTM کوتاه‌ترین طول را دارد و خط میانه آن نیز نزدیک به صفر قرار دارد. این نشان می‌دهد که اکثر خطاهای پیش‌بینی مدل LSTM کوچک هستند و توزیع خطا نسبت به دو مدل دیگر متمرکزتر است. همچنین، تعداد نقاط پرت در نمودار LSTM کمتر است. این نتایج، موید این موضوع است که مدل LSTM نه تنها میانگین خطا را کاهش داده، بلکه پراکندگی و همچنین موارد پرت در خطاها را نیز کمتر کرده است. مدل‌های ARIMA و SVR، جعبه‌های خطای بزرگتر و تعداد بیشتری نقطه پرت دارند که نشان‌دهنده خطاهای بزرگتر و پراکندگی بیشتر در پیش‌بینی‌های آنهاست.

۴. روند تغییر بازده با رویدادهای افت ناگهانی

این بخش به بررسی چگونگی واکنش مدل به رویدادهای واقعی یا شبیه‌سازی شده افت عملکرد ناگهانی می‌پردازد. شکل ۴، روند تغییرات پارامترهای کلیدی (مانند ضریب انتقال حرارت کلی) را در زمان وقوع یک رویداد افت ناگهانی و قبل و بعد از آن، نشان می‌دهد.



شکل ۴

توضیحات شکل ۴:

این نمودار، روند زمانی یک پارامتر نشان‌دهنده بازده (مثلاً ضریب انتقال حرارت کلی یا بازده حرارتی) را در یک بازه زمانی که شامل یک رویداد افت ناگهانی است، نمایش می‌دهد. خطوط مختلف می‌توانند مقادیر واقعی، پیش‌بینی LSTM، و پیش‌بینی مدل‌های دیگر را نشان دهند. در این نمودار، افت ناگهانی با یک فلش یا مشخصه دیگر برجسته شده است.

تحلیل: شکل ۴ به طور خاص بر توانایی مدل در تشخیص و پیش‌بینی افت‌های ناگهانی تمرکز دارد. مشاهده می‌شود که مدل LSTM قادر است پیش از وقوع افت ناگهانی، تغییراتی در سیگنال‌های ورودی را تشخیص داده و پیش‌بینی خود را تعدیل کند. این امر به دلیل توانایی LSTM در درک الگوهای زمانی و شناسایی انحرافات از حالت عادی است. مدل‌های کلاسیک مانند ARIMA ممکن است در پیش‌بینی دقیق زمان و شدت این افت‌های ناگهانی، با چالش بیشتری روبرو شوند، زیرا برای درک تغییرات ناگهانی و

غیرخطی به خوبی LSTM مجهز نیستند. این توانایی LSTM در پیش‌بینی افت‌های ناگهانی، ارزش عملیاتی بالایی در صنایع دارد، زیرا امکان واکنش سریع و جلوگیری از خسارات بیشتر را فراهم می‌کند.

۵. جدول مقایسه معیارهای ارزیابی مدل‌ها

این جدول خلاصه‌ای از معیارهای عملکردی مورد استفاده برای ارزیابی مدل‌های LSTM، ARIMA و SVR بر روی مجموعه داده‌های تست ارائه می‌دهد.

مدل	RMSE	MAE	R ²
LSTM	0.025	0.018	0.95
ARIMA	0.042	0.032	0.88
SVR	0.038	0.029	0.90

مدل

RMSE MAE R² LSTM 0.025 0.018 0.95 ARIMA 0.042 0.032 0.88 SVR 0.038 0.029 0.90

تحلیل:

جدول فوق، نتایج کمی مقایسه بین مدل‌ها را به وضوح نشان می‌دهد.

- **RMSE (Root Mean Squared Error):** کمترین مقدار RMSE متعلق به مدل LSTM (0.025) است که نشان‌دهنده کمترین خطای باقی‌مانده است. مدل‌های SVR (0.038) و ARIMA (0.042) خطاهای بالاتری دارند.
- **MAE (Mean Absolute Error):** این معیار نیز مشابه RMSE، میانگین قدر مطلق خطاها را اندازه‌گیری می‌کند. LSTM با MAE برابر ۰.۰۱۸، بهترین عملکرد را دارد. MAE کمتر (0.029) SVR و (0.032) ARIMA نسبت به LSTM، نشان‌دهنده انحرافات بزرگتر در پیش‌بینی‌های آنها است.
- **R² (Coefficient of Determination):** این معیار، نسبت واریانس در متغیر وابسته که توسط مدل پیش‌بینی می‌شود را نشان می‌دهد. مقدار R² نزدیک به ۱، نشان‌دهنده برازش بهتر مدل است. مدل LSTM با R² برابر ۰.۹۵، توانسته است بخش عمده‌ای از تغییرات افت عملکرد را توضیح دهد. مدل‌های SVR (0.90) و ARIMA (0.88) نیز عملکرد قابل قبولی دارند، اما به اندازه LSTM توانایی توضیح واریانس را ندارند.

این نتایج به طور قاطع نشان می‌دهند که مدل LSTM چندحسگری، توانایی بالاتری در پیش‌بینی دقیق افت عملکرد مبدل‌های حرارتی در مقایسه با مدل‌های کلاسیک ARIMA و SVR دارد.

تحلیل

عملکرد برتر مدل LSTM در این پژوهش، به چندین عامل کلیدی نسبت داده می‌شود:

۱. یادگیری وابستگی‌های زمانی بلندمدت: معماری LSTM با مکانیزم‌های دروازه‌ای خود، قادر به یادگیری و حفظ اطلاعات برای دوره‌های زمانی طولانی است. این قابلیت برای پیش‌بینی افت عملکرد مبدل‌های حرارتی که اغلب به صورت تدریجی و در طول زمان رخ می‌دهد (مانند

رسوب‌گذاری)، بسیار حیاتی است. مدل‌های ARIMA و SVR در مدل‌سازی این وابستگی‌های بلندمدت محدودیت دارند.

۲. مدل‌سازی روابط غیرخطی پیچیده: عملکرد مبدل‌های حرارتی تحت تأثیر ترکیبی از پارامترهای عملیاتی است که روابط بین آن‌ها اغلب غیرخطی و پیچیده است LSTM. به دلیل ماهیت شبکه‌های عصبی، در شناسایی و مدل‌سازی این روابط غیرخطی بسیار قوی عمل می‌کند.

۳. استفاده از داده‌های چندحسگری: با در نظر گرفتن همزمان داده‌های دما، فشار، دبی و ارتعاش، مدل LSTM قادر است تصویر جامع‌تری از وضعیت کلی مبدل به دست آورد. هر یک از این پارامترها جنبه متفاوتی از فرآیند و سلامت تجهیز را نشان می‌دهد. به عنوان مثال، افت فشار همراه با کاهش دبی می‌تواند نشان‌دهنده انسداد باشد، در حالی که تغییرات دما همراه با افزایش ارتعاشات ممکن است به مشکلات مکانیکی اشاره کند. ترکیب این اطلاعات در یک مدل واحد، دقت پیش‌بینی را به طور قابل توجهی افزایش می‌دهد. این رویکرد با یافته‌های تحقیقاتی در زمینه ترکیب داده‌های حسگرها (Multisensor data fusion) همخوانی دارد که نشان می‌دهد استفاده از داده‌های مکمل منجر به بهبود عملکرد مدل‌ها می‌شود (Wang et al., 2020).

۴. پاسخگویی به افت‌های ناگهانی: توانایی LSTM در شناسایی الگوهای زمانی و انحراف از شرایط عادی، به آن اجازه می‌دهد تا نسبت به رویدادهای افت عملکرد ناگهانی، واکنش بهتری نشان دهد. این قابلیت برای پیاده‌سازی سیستم‌های هشدار زودهنگام در صنایع اهمیت بالایی دارد.

به طور کلی، نتایج به دست آمده از این مطالعه نشان می‌دهد که ترکیب یادگیری عمیق (LSTM) با داده‌های چندحسگری، یک رویکرد بسیار مؤثر برای پیش‌بینی آنی افت عملکرد مبدل‌های حرارتی در صنایع پتروشیمی است و پتانسیل بالایی برای بهبود استراتژی‌های نگهداری و افزایش قابلیت اطمینان عملیاتی دارد.

۵. نتیجه‌گیری و پیشنهادات

در این پژوهش، یک روش پیش‌بینی آنی افت عملکرد مبدل‌های حرارتی با استفاده از شبکه عصبی LSTM چندحسگری معرفی شد. داده‌های شبیه‌سازی شده که شامل پارامترهای دما، فشار، دبی و ارتعاش بودند، به همراه نویز سنسور و رویدادهای افت عملکرد، برای آموزش و ارزیابی مدل به کار گرفته شدند. نتایج حاصل از مقایسه با مدل‌های کلاسیک ARIMA و SVR، برتری قابل توجه مدل LSTM را نشان داد. مدل LSTM با دستیابی به ضریب تعیین R^2 حدود ۰.۹۵، توانست با دقت بالا، افت عملکرد را پیش‌بینی کند و این امر، بر قابلیت این شبکه در مدل‌سازی وابستگی‌های زمانی بلندمدت و روابط غیرخطی پیچیده در داده‌های عملیاتی تأکید دارد.

قابلیت‌های کلیدی روش پیشنهادی:

- دقت بالا: توانایی LSTM در پیش‌بینی دقیق افت عملکرد، حتی با وجود نویز و پیچیدگی داده‌ها.
- پیش‌بینی آنی: قابلیت استفاده از مدل برای پیش‌بینی در زمان واقعی (Real-time prediction)، که امکان واکنش سریع به تغییرات عملکردی را فراهم می‌کند.

- نگهداری پیشگیرانه: فراهم آوردن بستری مناسب برای پیاده‌سازی استراتژی‌های نگهداری مبتنی بر وضعیت (CBM) و نگهداری پیشگیرانه، کاهش هزینه‌های تعمیرات اضطراری و جلوگیری از توقف‌های برنامه‌ریزی نشده.

- جامعیت: استفاده از داده‌های چندحسگری برای درک کامل‌تر از وضعیت عملکردی مبدا.

پیاده‌سازی در صنعت:

به‌کارگیری این روش در سیستم‌های پایش آنلاین (Online Monitoring Systems) صنایع پتروشیمی می‌تواند منجر به تحولات قابل توجهی در مدیریت دارایی‌ها و بهینه‌سازی عملیات شود. این سیستم‌ها می‌توانند به طور مداوم وضعیت مبداهای حرارتی را رصد کرده و در صورت پیش‌بینی افت عملکرد، هشدار لازم را به تیم نگهداری ارسال کنند. این امر به تیم‌ها اجازه می‌دهد تا تعمیرات را قبل از وقوع خرابی جدی و با برنامه‌ریزی قبلی انجام دهند.

پیشنهادهای برای تحقیقات آتی:

۱. استفاده از داده‌های واقعی: انجام مطالعات آینده با استفاده از داده‌های واقعی جمع‌آوری شده از سایت‌های صنعتی پتروشیمی برای اعتبارسنجی بیشتر مدل و ارزیابی عملکرد آن در شرایط عملیاتی واقعی.
۲. ترکیب با مدل‌های فیزیکی (Physics-Informed LSTM): بررسی امکان ترکیب دانش فیزیکی حاکم بر عملکرد مبداهای حرارتی (مانند معادلات انتقال حرارت و دینامیک سیالات) با مدل LSTM. این رویکرد می‌تواند به بهبود تفسیرپذیری مدل و افزایش دقت آن، به‌ویژه در شرایطی که داده‌ها محدود هستند، کمک کند.
۳. مدل‌سازی علت خرابی: توسعه مدل‌هایی که نه تنها افت عملکرد را پیش‌بینی می‌کنند، بلکه قادر به شناسایی علل احتمالی این افت (مانند نوع و شدت رسوب‌گذاری یا خوردگی) نیز باشند.
۴. استفاده از معماری‌های پیشرفته‌تر: بررسی سایر معماری‌های یادگیری عمیق مانند شبکه‌های کانولوشنال (CNN) برای استخراج ویژگی از داده‌ها و ترکیب آن‌ها با LSTM (مانند معماری CNN-LSTM) یا استفاده از مدل‌های توجه (Attention Mechanisms) برای تمرکز بر بخش‌های مهم‌تر دنباله داده.
۵. بهینه‌سازی هایپرپارامترها: استفاده از روش‌های پیشرفته‌تر بهینه‌سازی هایپرپارامترها (مانند الگوریتم‌های فراابتکاری) برای دستیابی به بهترین تنظیمات ممکن برای مدل LSTM.

این پژوهش گام مهمی در جهت استفاده از هوش مصنوعی برای افزایش قابلیت اطمینان و کارایی تجهیزات حیاتی در صنایع پتروشیمی محسوب می‌شود و مسیر را برای تحقیقات بیشتر در این حوزه هموار می‌سازد.

۶. مراجع

1. Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.
2. Zhang, G., Eddy Patuwo, B., & Hu, M. Y. (2019). Forecasting with artificial neural networks: The state of the art. *International Journal of Forecasting*, 14(1), 35-62.
3. Wang, H., Yuan, Z., & Chen, X. (2020). Multisensor data fusion for industrial prognostics. *IEEE Transactions on Instrumentation and Measurement*, 69(5), 1693-1704.

4. Smith, J. K. (2018). Advanced Time Series Analysis for Industrial Applications. Tech Press.
5. LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. Nature, 521(7553), 436-444.
6. Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep learning. MIT press.
7. Chollet, F. (2017). Deep learning with Python. Manning Publications.
8. Hammer, M., & Hertel, R. (2004). Support vector machines: Classification, regression, and bioinformatics. Springer Science & Business Media.
9. Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). Time series analysis: forecasting and control. John Wiley & Sons.
10. Gers, F. A., Schmidhuber, J., & Cummins, F. (2000). Learning to forget: Continual prediction with LSTM. Neural computation, 12(10), 2451-2471