



## نشریه علوم و مهندسی سطح

### مروری بر انفورماتیک تریبولوژی و دستاوردهای حاصله از به کارگیری

### یادگیری ماشین در پژوهش‌های تریبولوژی

نگار باقریه<sup>۱</sup>، میثم نوری<sup>۱\*</sup>، مسلم نوری<sup>۲</sup>

۱. گروه مهندسی مواد، دانشکده مهندسی، دانشگاه بوعلی سینا، همدان، ایران

۲. وان کیو بیت، ونکوور، کانادا

#### چکیده

داده‌های متنوع و مختلفی مربوط به خواص و ویژگی‌های تریبولوژیکی وجود دارند که در قالب‌های متنوعی از جمله مقالات علمی، اسناد فنی و پایگاه‌های داده پراکنده هستند. این داده‌ها می‌توانند برای حل مسائل پیچیده مرتبط با تریبولوژی، مانند بررسی رابطه بین ساختار و خواص مواد در سطوح تحت اصطکاک و سایش مورد استفاده قرار گیرند. انفورماتیک تریبولوژی با ترکیب تریبولوژی و انفورماتیک به چگونگی به کارگیری دانش و ابزارهای تحلیل این داده‌های مختلف به منظور استفاده از آنها در بررسی مسایل تریبولوژی می‌پردازد. یادگیری ماشین که یکی از زیرمجموعه‌های هوش مصنوعی است، ابزارهای توانمندی در تحلیل داده‌های پیچیده و کشف روابط چند بعدی بین داده‌ها داشته و می‌تواند درک بهتری از ویژگی‌ها و فرآیندهای تریبولوژیکی ارائه دهد. در این مقاله پس از تشریح مفهوم انفورماتیک تریبولوژی، الگوریتم‌های اصلی یادگیری ماشین که توسط پژوهشگران در مطالعه‌های مختلف به منظور تحلیل داده‌های تریبولوژیکی استفاده شده است، به طور خلاصه مرور شده‌اند. در ادامه، پژوهش‌هایی که تا کنون در زمینه انفورماتیک تریبولوژی انجام شده‌اند، بررسی شده است. در این پژوهش‌ها از ابزارهای یادگیری ماشین جهت ارتباطی بین عواملی مانند ترکیب شیمیایی ماده، فرایند ساخت یا خواص مکانیکی با خواص تریبولوژیک به ویژه نرخ سایش و ضریب اصطکاک استفاده شده است. نتایج گزارش شده در این مطالعات، قابلیت یادگیری ماشین در پیش‌بینی خواص تریبولوژیک با دقت‌هایی تا حدود ۹۰ درصد را نشان می‌دهد. چنین دقت‌هایی می‌تواند کارگشا بودن یادگیری ماشین در توسعه دانش تریبولوژی و حل برخی مسایل پیچیده در این زمینه را نشان دهد.

#### واژگان کلیدی:

انفورماتیک تریبولوژی، تریبولوژی، یادگیری ماشین، سایش.

تاریخ دریافت: ۱۴۰۳/۹/۲۵

تاریخ پذیرش: ۱۴۰۳/۱۱/۱۲

DOI: 10.22034/ISSST.2025.2048240.1633

## A Comprehensive Review of Triboinformatics and the Advancements Achieved Through Machine Learning in Tribology Research

#### Abstract

There is a diverse range of data related to tribological properties and features, scattered across various formats such as scientific articles, technical documents, and databases. This data can be utilized to address complex tribological issues, including examining the relationship between the structure and properties of materials on surfaces under friction and wear. Triboinformatics, by merging tribology and informatics, focuses on leveraging knowledge and analytical tools to investigate tribological problems. Machine learning, a subset of artificial intelligence, offers powerful tools for analyzing complex data and uncovering multidimensional relationships between data. This can enhance our understanding of tribological properties and processes. In this article, we first explain the concept of triboinformatics, and then briefly review the primary machine learning algorithms used by researchers to analyze tribological data. Following this, we examine research conducted in the field of triboinformatics. These studies have employed machine learning tools to link factors such as the chemical composition of materials, manufacturing processes, or mechanical properties with tribological properties, particularly wear rate and friction coefficient. The results reported in these studies demonstrate machine learning's capability to predict tribological properties with accuracies of up to approximately 90%. Such accuracies underscore the potential of machine learning in advancing tribology knowledge and addressing complex issues in this field.

**Keywords:** Triboinformatics, Tribology, Machine learning, Wear, Friction coefficient

\* Corresponding author E-mail: m.nouri@basu.ac.ir.

## ۱. مقدمه

تریبولوژی علمی است که به بررسی رفتار سطوح جامد در هنگام حرکت نسبی آن‌ها می‌پردازد و موضوعاتی نظیر اصطکاک، سایش و روانکاری را شامل می‌شود [۱]. تریبولوژی به‌عنوان یکی از علوم کلیدی مطرح بوده و همچنان از اهمیت زیادی برخوردار است زیرا تقریباً در تمامی ابعاد زندگی روزمره تأثیرگذار است. نقش حیاتی پدیده‌هایی نظیر اصطکاک، روانکاری و سایش در صنایع مختلف، به‌خوبی اهمیت این علم را نشان می‌دهد و به‌عنوان مثال اجزای متحرک تجهیزات و قطعات مهندسی در معرض سایش و اصطکاک هستند. وقوع سایش و اصطکاک خسارت‌های اقتصادی قابل توجهی در صنایع مختلف به دنبال دارد [۲]–[۵]. تسلط بر مهندسی تریبولوژی می‌تواند در مواجهه با چالش‌های فنی پیش رو، راه‌حل‌های موثری ارائه کند. با وجود تلاش‌های فراوان برای تدوین قوانین حاکم بر پدیده‌های تریبولوژیک، به‌دلیل پیچیدگی ذاتی اصطکاک و سایش، درک تریبولوژی عمدتاً ماهیتی آزمایشگاهی داشته است [۶].

تحقیقات در زمینه تریبولوژی با بهره‌گیری از روش‌های مختلفی صورت می‌پذیرد. روش‌های آزمون و خطای آزمایشگاهی، به‌کارگیری قوانین فیزیک و شیمی، شبیه‌سازی و روش‌های داده‌محور به‌عنوان روش‌های مطالعاتی در این زمینه مطرح می‌شوند [۷]. مطالعات آزمایشگاهی و نظری اغلب زمان‌بر هستند زیرا پیشرفت قابل توجه در این دو نیازمند ترکیبی از شهود عملی و وقوع نتایج مثبت است [۸]. در ابتدا محققان یک مساله تحقیقاتی را مطرح می‌کنند. سپس داده‌های مرتبط را جمع‌آوری می‌کنند و بر اساس این داده‌ها یک فرضیه تدوین می‌شود که به‌عنوان مبنای مراحل آزمایشگاهی و آزمون‌ها مورد توجه قرار می‌گیرد. با تکرار مراحل مذکور دانش جدید تولید می‌شود و فرضیات بیشتری مطرح می‌شود. برخلاف ظاهر ساده این چارچوب، مشکلات

متعددی از جمله ماهیت دشوار شرایط آزمایشگاهی و مبانی نظری وجود دارد که مانع اجرای هموار آن می‌شود [۹].

به‌طور کلی انسان از زمان تکامل خود ابزارهای مختلفی مانند ماشین‌ها و رایانه‌ها را برای تسهیل کارها و وظایف خود به‌کار گرفته است [۱۰]. با ظهور رایانه‌ها، روش‌های محاسباتی بر اساس رابطه‌های نظری مطرح شد. این امر امکان شبیه‌سازی پدیده‌های پیچیده دنیای واقعی را بر اساس الگوهای نظری فراهم کرده که می‌توان به نظریه تابعی چگالی و شبیه‌سازی دینامیک مولکولی اشاره کرد [۹]. روش‌های مذکور به نوبه خود به پیشبرد روش‌های قبلی کمک کرده‌اند و امروزه آن‌ها به‌عنوان شاخه‌های نظری آزمایشی و محاسبه تقریباً در تمام زمینه‌های علمی مورد توجه قرار گرفته‌اند. با وجود این، روش‌های ذکر شده برای کشف مواد معمولاً به تحقیقات گسترده و چرخه توسعه طولانی نیازمند هستند [۱۱].

روش‌های مبتنی بر داده می‌توانند سه روش دیگر را در زمینه‌های نظری، آزمایشگاهی و شبیه‌سازی رایانه‌ای تکامل ببخشند. یادگیری ماشین یکی از کارآمدترین راه‌ها برای جایگزینی تجربیات آزمایشگاهی است. در مقایسه با شبیه‌سازی آزمایشگاهی، یادگیری ماشین راه‌حل‌های مناسبی برای شناسایی الگوها در مجموعه داده‌های چند بعدی و مسائل شامل محاسبات فرضیه‌های پیچیده را فراهم می‌کند [۷]. یادگیری ماشین یکی از زیرمجموعه‌های هوش مصنوعی و تکامل یافته تشخیص الگو است که در دهه ۱۹۴۰ مطرح شد و اواخر قرن بیستم توسعه یافت [۱۲]–[۱۴].

از آغاز عصر رایانه، محققان تلاش کرده‌اند تا قابلیت یادگیری را در رایانه‌ها قرار دهند. یادگیری به‌عنوان یک مفهوم کلی به صورت فرآیند بهبود توانایی برای انجام یک کار تعریف می‌شود [۱۵]. یادگیری یک پدیده چندوجهی شامل کسب دانش جدید، توسعه مهارت‌های حرکتی و

شناختی از طریق آموزش یا تمرین و کشف مفاهیم و نظریه‌های جدید از طریق مشاهده و آزمایش است [۱۶]. حل این مسئله، چالش برانگیزترین و جذاب‌ترین هدف در هوش مصنوعی بوده است. جلوه‌های متعدد مطالعه و مدل‌سازی رایانه‌ای فرآیندهای یادگیری، موضوع یادگیری ماشین را تشکیل می‌دهد [۱۵]. قادر ساختن رایانه‌ها برای شبیه‌سازی رفتار و توانایی یادگیری انسان و برقراری روابط منطقی بر اساس تجربیات به عنوان هدف یادگیری ماشین مطرح می‌شود. این هدف به تصمیم‌گیری خودکار رایانه منجر می‌شود. به‌طور کلی اگر عملکرد یک برنامه‌ی رایانه‌ای در یک وظیفه به‌صورت خودکار و بر اساس تجربه بهبود یابد، به این معنی است که برنامه از تجربه یاد گرفته است [۱۷]–[۱۹]

حصول داده‌های گسترده در زمینه‌های مرتبط با سایش، اصطکاک و ویژگی‌های سطحی مواد، امکان بهره‌گیری از رویکردهای داده‌محور و یادگیری ماشین را در این زمینه‌ها فراهم کرده است. پیشرفت فناوری رایانه‌ای و افزایش قدرت پردازش، رشد سریع تحلیل‌های مبتنی بر داده را ممکن ساخته است. استفاده از الگوریتم‌های یادگیری ماشین و هوش مصنوعی به‌عنوان جایگزینی برای رویکردهای سنتی، به شناسایی روابط پیچیده در داده‌ها کمک شایانی کرده است. این پیشرفت‌ها، مسیر ظهور زمینه‌ای نوین به نام تریبولوژی انفورماتیک یا انفورماتیک تریبولوژی را هموار ساخته‌اند [۲۰].

در این مقاله، انفورماتیک تریبولوژی به‌عنوان زمینه‌ای میان‌رشته‌ای و نوظهور در تریبولوژی مورد بررسی قرار می‌گیرد. این زمینه با بهره‌گیری از الگوریتم‌های یادگیری ماشین و تحلیل‌های داده‌محور، چشم‌انداز جدیدی را برای حل مسائل پیچیده در زمینه تریبولوژی و مهندسی سطح فراهم کرده است. ابتدا، مروری بر مبانی یادگیری ماشین

انجام خواهد شد و برخی الگوریتم‌های کلیدی آن معرفی می‌شوند. در ادامه، به کاربردهای این الگوریتم‌ها در تحلیل و مدل‌سازی فرایندهای تریبولوژیکی نظیر پیش‌بینی و بهینه‌سازی سایش و کاهش اصطکاک پرداخته خواهد شد. همچنین، روش‌های داده‌محور و نقش آن‌ها در تحول مطالعه رفتار سطوح، با تاکید بر داده‌کاوی و تجزیه و تحلیل آماری، بررسی می‌شوند. هدف این مقاله، ارائه درکی جامع از فرصت‌های بالقوه یادگیری ماشین و روش‌های نوین مبتنی بر آن در ارتقای بهره‌وری صنعتی، کاهش هزینه‌ها و بهبود پایداری سامانه‌های مهندسی مرتبط با تریبولوژی است [۲۰]. داده‌ی تریبولوژیکی به صورت ساختاریافته<sup>۱</sup> از جمله ضریب اصطکاک، سایش و سایر پارامترهای تریبولوژیکی و به صورت ساختاریافته مانند تصاویر میکروسکوپی در مطالعات انفورماتیک تریبولوژی مورد بررسی قرار می‌گیرند [۲۱]، [۲۲].

## ۲. هوش مصنوعی

هوش مصنوعی یکی از زمینه‌های پیشرفته علوم رایانه است که هدف آن طراحی سامانه‌ها، نرم‌افزارها یا ربات‌هایی است که می‌توانند وظایفی را انجام دهند که معمولاً به هوش انسانی نیاز دارند. این زمینه ماهیتی میان‌رشته‌ای دارد و از علومی مانند علوم رایانه، ریاضیات و مهندسی بهره می‌گیرد. در میان روش‌های مختلفی که برای توسعه هوش مصنوعی وجود دارد، یادگیری ماشین رایج‌ترین روش است و یادگیری عمیق به‌عنوان زیرمجموعه‌ای از یادگیری ماشین شناخته می‌شود. پیشرفت‌های اخیر در یادگیری ماشین و یادگیری عمیق، تحولی بنیادین در صنایع مرتبط با فناوری، مهندسی و تولید ایجاد کرده‌اند [۲۰].

<sup>1</sup> Structural

### ۳. یادگیری ماشین

یادگیری ماشین به فرایند طراحی و توسعه برنامه‌های رایانه‌ای اشاره دارد که از داده‌ها برای حل مسائل و بهبود عملکرد استفاده می‌کنند و قادرند رفتارهای مشابه هوش انسانی را تقلید کنند [۱۲]، [۱۶]، [۲۳]. این روش محاسباتی و برنامه‌نویسی با بهره‌گیری از داده‌های آموزشی و تجربیات گذشته، عملکرد مدل را بهینه‌سازی کرده و توانایی پیش‌بینی داده‌های جدید را فراهم می‌آورد [۱۴]، [۲۴]. یادگیری ماشین شامل پردازش حجم زیادی از داده‌ها و طراحی الگوریتم‌های دقیق و کارآمد به منظور مدل‌سازی است. مراحل یک پروژه یادگیری ماشین شامل جمع‌آوری داده، آماده‌سازی داده‌ها، مدل‌سازی، ارزیابی با شاخص‌های ارزیابی از جمله میانگین مطلق خطا<sup>۱</sup> و پیاده‌سازی یا توسعه مدل است [۱۹]. یادگیری ماشین به یادگیری تحت نظارت<sup>۲</sup>، یادگیری بدون ناظر<sup>۳</sup>، یادگیری نیمه‌نظارت‌شده<sup>۴</sup> و یادگیری تقویتی<sup>۵</sup> تقسیم می‌شود [۱۲]. در الگوریتم یادگیری تحت نظارت، داده‌های ورودی همراه با خروجی‌های مربوطه به مدل ارائه می‌شود تا فرایند یادگیری انجام شود. این الگوریتم با استفاده از داده‌ها، مدلی برای رگرسیون یا طبقه‌بندی ایجاد کرده و آن را آموزش می‌دهد تا بتواند داده‌های جدید یا مجموعه داده‌های آزمون را پیش‌بینی کند. یادگیری تحت نظارت با استفاده از الگوریتم‌های طبقه‌بندی و روش‌های رگرسیون، مدل‌های پیش‌بینی را توسعه می‌دهد. در این روش یادگیری، طبقه‌بندی به پیش‌بینی داده‌های گسسته می‌پردازد و در کاربردهایی نظیر دسته‌بندی، برچسب‌گذاری و تفکیک داده‌ها به گروه‌های مشخص استفاده می‌شود. یادگیری بدون نظارت بر شناسایی الگوها و ساختارهای موجود در داده‌های ورودی تمرکز دارد. در این روش، مدل به

شناسایی و استخراج الگوهای می‌پردازد که بیشتر از سایر الگوها در داده‌ها تکرار شده‌اند. یادگیری نیمه نظارت‌شده ترکیبی از یادگیری تحت نظارت و بدون نظارت است و زمانی به کار می‌رود که تنها تعداد محدودی از داده‌ها دارای مقادیر خروجی مشخص برای یک کاربرد خاص باشند. یادگیری تقویتی بر تعامل ماشین با محیط تمرکز دارد و به بررسی نحوه انتخاب و اجرای اقدامات بهینه برای دستیابی به اهداف مورد نظر می‌پردازد [۱۷].

الگوریتم‌ها را می‌توان مجموعه‌ای از دستورالعمل‌های برنامه‌ریزی شده دانست که برای انجام محاسبات یا حل مسائل طراحی شده‌اند. در یادگیری ماشین، الگوریتم‌ها با استفاده از داده‌های موجود، مدل‌سازی را تسهیل کرده و فرآیند تصمیم‌گیری خودکار را بر اساس داده‌های ورودی و تجربیات انجام می‌دهند. این الگوریتم‌ها مسوولیت شناسایی، کشف و ایجاد روابط و الگوها در داده‌ها را بر عهده دارند [۲۵].

یکی از الگوریتم‌های یادگیری ماشین، رگرسیون خطی است. این روش به مدل‌سازی رابطه بین یک متغیر وابسته و یک یا چند متغیر مستقل یا توصیف‌کننده می‌پردازد. رگرسیون خطی به‌عنوان یک روش تحلیل داده، در مدل‌سازی‌هایی با ماهیت خطی مورد استفاده قرار می‌گیرد. هدف اصلی این الگوریتم پیدا کردن خطی است که بهترین تناسب را با نقاط داده داشته باشد و بتواند روابط موجود را بهینه‌سازی کند.

الگوریتم درخت تصمیم<sup>۶</sup> دارای ساختاری شبیه به درخت است که در آن هر گره نمایانگر یک ویژگی خاص، هر شاخه نمایانگر یک تقسیم‌بندی و برگ‌های درخت نمایانگر خروجی‌ها یا توزیع خروجی‌ها هستند. گره اول که به

<sup>۴</sup> Semi-supervised learning

<sup>۵</sup> Reinforcement learning

<sup>۶</sup> Decision tree

<sup>۱</sup> Mean absolute error

<sup>۲</sup> Supervised learning

<sup>۳</sup> Unsupervised learning

عنوان گره ریشه شناخته می‌شود، بر اساس تعداد پاسخ‌ها تقسیم‌بندی می‌شود. پارامتر ورودی با بیشترین همبستگی نسبت به مقدار هدف در گره ریشه قرار می‌گیرد. در الگوریتم‌های مبتنی بر درخت تصمیم، انتخاب ورودی که بیشترین تأثیر را بر هدف دارد، از اهمیت ویژه‌ای برخوردار است. به عبارتی دیگر، ورودی باید کمترین میزان بی‌نظمی را در توزیع خروجی داشته باشد. برای اندازه‌گیری همگنی نمونه‌ها و تعیین خلوص مجموعه داده، از شاخص‌های بی‌نظمی مانند بهره اطلاعات و شاخص جینی استفاده می‌شود. برگ درخت آخرین گره‌ای است که بعد از آن دیگر تقسیم‌بندی صورت نمی‌گیرد. هدف از ساخت درخت تصمیم، پیش‌بینی مقادیر خروجی بر اساس متغیرهای ورودی با استفاده از قوانین تصمیم‌گیری است [۷].

الگوریتم جنگل تصادفی<sup>۱</sup> یکی از روش‌های یادگیری ماشین تحت نظارت است که از مجموعه‌ای از درختان تصمیم برای آموزش و توسعه مدل استفاده می‌کند. این الگوریتم در دسته الگوریتم‌های یادگیری تجمیعی<sup>۲</sup> قرار دارد و مبتنی بر روش بگینگ<sup>۳</sup> عمل می‌کند. یادگیری تجمیعی شامل روش‌هایی است که یا از الگوریتم‌های مختلف بر روی یک مجموعه داده استفاده می‌کنند یا همان الگوریتم را بر روی نمونه‌های مختلف از مجموعه داده (بگینگ) به کار می‌گیرند. همچنین در رویکرد تقویتی، نتایج حاصل از یادگیرنده‌های مختلف ترکیب می‌شوند تا به دقت بالاتری برسد [۱۹]. بگینگ، فرآیندی است که با استفاده از نمونه‌گیری مجدد، مجموعه داده‌های مختلفی ایجاد می‌کند و واریانس مدل را کاهش می‌دهد. در بوت‌استرپ، نمونه‌گیری به صورت مکرر و با احتمال مساوی از مجموعه داده اولیه انجام می‌شود و امکان درک

بهرتر از توزیع داده‌ها را فراهم می‌سازد [۱۲]. الگوریتم جنگل تصادفی به دلیل ساختار ترکیبی خود، برای مدیریت مؤثر داده‌های حجیم و متغیرهای ورودی متعدد بسیار مناسب است. این الگوریتم با استفاده از چندین درخت تصمیم و ترکیب نتایج آنها از طریق میانگین‌گیری (برای رگرسیون) یا رأی‌گیری (برای طبقه‌بندی)، دقت پیش‌بینی را بهبود می‌بخشد. همچنین، جنگل تصادفی مشکل بیش‌برازش<sup>۴</sup> داده‌ها که در درختان تصمیم ساده مشاهده می‌شود، را کاهش می‌دهد و عملکرد بهتری در مواجهه با داده‌های متنوع و پرنوسان ارائه می‌دهد [۲۶].

گرادین بوسستینگ<sup>۵</sup> یکی از الگوریتم‌های مبتنی بر یادگیری تجمیعی است که با استفاده از یک نوع طبقه‌بندی‌کننده یا رگرسور به صورت مرحله‌ای مدل‌سازی می‌کند. در این الگوریتم، مدل‌های مجزا به صورت متوالی بر مجموعه آموزش منطبق می‌شوند و توزیع داده‌ها بر اساس نتایج یادگیرنده قبلی به‌روزرسانی می‌شود. این فرآیند امکان بهبود یادگیرنده‌های ضعیفی مانند درخت تصمیم و توانایی آنها در یادگیری از داده‌های پیچیده را فراهم می‌کند. هر درخت تصمیم به صورت جداگانه بر روی بخشی از داده‌ها عمل کرده و نتایج آنها برای پیش‌بینی دقیق‌تر ترکیب می‌شود. در الگوریتم‌های مبتنی بر بوسستینگ، مدل‌سازی به صورت مرحله‌ای انجام می‌شود. پیش‌بینی‌کننده جدید از خطاهای پیش‌بینی‌کننده‌های قبلی یاد می‌گیرد که به کاهش بایاس کمک می‌کند. در این روش، انتخاب داده‌ها متناسب با وزن اختصاص داده‌شده به آنها انجام می‌شود. به عبارت دیگر، داده‌هایی که توسط یادگیرنده قبلی به درستی پیش‌بینی نشده‌اند، احتمال انتخاب بیشتری برای مرحله بعدی دارند [۶]، [۲۷].

<sup>4</sup> Overfitting

<sup>5</sup> Gradient boosting

<sup>1</sup> Random forest

<sup>2</sup> Ensemble learning

<sup>3</sup> Bagging

ماشین بردار پشتیبان<sup>۱</sup> یک الگوریتم موثر برای حل مسائل طبقه‌بندی و رگرسیون است، به‌ویژه در مواردی که تعداد متغیرهای ورودی زیاد و داده‌ها محدود هستند [۶]، [۱۰]، [۲۸]. در مسائل رگرسیون، ابرصفحه‌ها<sup>۲</sup> برای نگاشت نقاط داده به ابعاد بالاتر تعریف می‌شوند به‌گونه‌ای که ابرصفحه بهینه بیشترین تعداد نقاط داده را در بر بگیرد. در شرایطی که داده‌ها غیرخطی باشند، از توابع هسته‌ای مانند هسته شعاعی، هسته خطی، هسته چندجمله‌ای و هسته سیگموئید برای افزایش ابعاد داده‌ها استفاده می‌شود [۲۹]، [۳۰].

شبکه‌های عصبی مصنوعی<sup>۳</sup> به تقلید از فرآیند یادگیری مغز انسان طراحی شده‌اند و توانایی تحلیل روابط پیچیده و معنادار بین داده‌ها را دارند. این شبکه‌ها ابزار کارآمدی برای پیش‌بینی، بهینه‌سازی، طبقه‌بندی داده‌ها و انجام نگاشت‌های غیرخطی ارائه می‌کنند. به دلیل پیچیدگی ساختار، این الگوریتم‌ها در حل مسائل پیچیده عملکرد بهتری نسبت به روش‌های آماری دارند و گزینه‌ای مناسب برای کاربردهای پیشرفته محسوب می‌شوند. ساختار شبکه‌های عصبی مصنوعی از تعداد زیادی واحد پردازش متصل به یکدیگر تشکیل شده است که در کنار هم شبکه‌ای مشابه مغز انسان را شبیه‌سازی می‌کنند. این مدل‌ها با استفاده از داده‌های آموزشی و یادگیری تجربی، قابلیت تولید خروجی‌های مرتبط و دقیق برای داده‌های جدید را پیدا می‌کنند. به‌طور معمول، این شبکه شامل سه بخش اصلی است: لایه ورودی برای دریافت داده‌ها، لایه‌های پنهان که عملیات پردازش را انجام می‌دهند و لایه خروجی که نتیجه نهایی را ارائه می‌دهد. نورون‌ها در این ساختار از توابع فعال‌سازی برای پردازش داده‌های دریافتی و انتقال اطلاعات به لایه‌های بعدی استفاده می‌کنند [۳۱].

شبکه‌های عصبی مصنوعی از طریق فرآیند یادگیری که بر اساس نمونه‌های آموزشی و تغییرات وزنی انجام می‌شود، آموزش می‌بینند. الگوریتم اصلی مورد استفاده برای تنظیم وزن‌ها به‌منظور کاهش خطا، الگوریتم پس‌انتشار خطا<sup>۴</sup> نام دارد. این روش بر پایه قاعده زنجیره‌ای در حساب دیفرانسیل عمل کرده و گرادیان خطا را از خروجی شبکه به سمت لایه‌های قبلی محاسبه می‌کند. این فرآیند به شبکه اجازه می‌دهد وزن‌ها را به‌گونه‌ای تنظیم کند که خطای کلی کاهش یابد و دقت پیش‌بینی بهبود پیدا کند. الگوریتم شبکه عصبی پیش‌خور<sup>۵</sup> یکی از الگوریتم‌های پرکاربرد در زمینه یادگیری ماشین و یادگیری عمیق است. این الگوریتم شامل چندین لایه از نورون‌های متصل به یکدیگر است که به ترتیب و به صورت متوالی سازمان‌دهی شده‌اند. داده‌ها در این شبکه‌ها به صورت یک‌طرفه از لایه ورودی به لایه خروجی جریان می‌یابند و هیچ حلقه یا بازخوردی در مسیر وجود ندارد. نورون‌های هر لایه، خروجی‌های لایه بعدی را بر اساس ورودی‌های دریافتی از لایه قبلی محاسبه می‌کنند. به‌منظور کاهش مقدار تابع ضرر، وزن‌ها یا پارامترهای قابل آموزش مرتبط با هر نورون بهینه‌سازی می‌شوند. این فرآیند به شبکه اجازه می‌دهد تا الگوها و روابط پیچیده میان داده‌ها را یاد بگیرد [۳۲].

در الگوریتم نزدیک‌ترین همسایگی<sup>۶</sup>، برای پیش‌بینی یک نقطه داده جدید در مسائل رگرسیونی، میانگین مقادیر نزدیک‌ترین نقاط داده در مجموعه آموزش محاسبه می‌شود. تعداد این نقاط نزدیک با پارامتر  $k$  یا  $n$  نشان داده می‌شود که نقش تعیین‌کننده‌ای در پیچیدگی مدل ایفا می‌کند. مقدار مناسب  $k$  باید با دقت و بر اساس ویژگی‌های داده‌ها و پیچیدگی مساله انتخاب شود تا عملکرد مدل بهینه شود [۳۳].

<sup>4</sup> Backpropagation

<sup>5</sup> Feedforward

<sup>6</sup> k-nearest neighbors

<sup>1</sup> Support vector machine

<sup>2</sup> Hyperplane

<sup>3</sup> Artificial neural network

#### ۴. انفورماتیک تریبولوژی

تریبولوژی به عنوان علمی که به سطوح متحرک و در حال تماس می‌پردازد، تعریف می‌شود [۱]. این زمینه شامل مطالعه مواردی چون اصطکاک، سایش و روانکاری است. به عبارتی دیگر، تریبولوژی به تحلیل تعاملات بین سطوحی که نسبت به یکدیگر حرکت می‌کنند، مربوط می‌شود [۳۴]. سایش و اصطکاک به عنوان نتیجه فرآیندهای تریبولوژیکی که در اثر تماس بین دو سطح متحرک بوجود می‌آیند، شناخته می‌شوند [۳۵].

انفورماتیک تریبولوژی رویکردی میان‌رشته‌ای است که فناوری اطلاعات را با پژوهش‌های تریبولوژیکی ادغام می‌کند و کارایی و اثربخشی مطالعات تریبولوژیکی را بهبود می‌بخشد. هدف، سازمان‌دهی و تحلیل نظام‌مند حجم وسیعی از داده‌ها و اطلاعات تولیدشده در زمینه تریبولوژی است که اغلب در میان رشته‌ها و قالب‌های مختلف پراکنده بوده و باعث افزایش پراکندگی اطلاعات می‌شود. با ایجاد استانداردها، توسعه پایگاه‌های داده جامع و بهره‌گیری از فناوری‌های پیشرفته اطلاعاتی، انفورماتیک تریبولوژی فرآیندهای جمع‌آوری، طبقه‌بندی، ذخیره‌سازی، بازیابی، تحلیل و انتشار اطلاعات تریبولوژیکی را تسهیل می‌کند. این روش ساختاریافته نه تنها به پژوهشگران در دسترسی به داده‌های مرتبط کمک می‌کند، بلکه توسعه نظریه‌ها و مدل‌های یکپارچه را ترویج داده و در نهایت، فرآیند پژوهش را بهینه کرده و به پیشرفت‌های قابل‌توجه در تریبولوژی کمک می‌کند [۲۰].

بهره‌گیری از انفورماتیک تریبولوژی برای مقابله با چالش‌های ناشی از ماهیت پیچیده و میان‌رشته‌ای تریبولوژی که زمینه‌های مختلفی را در بر می‌گیرد، ضروری است. با توجه به حجم بالای داده‌های تولیدشده در پژوهش‌های تریبولوژیکی، مدیریت و تحلیل مؤثر داده‌ها برای جلوگیری از ایجاد جزایر اطلاعاتی که مانع نوآوری

می‌شوند، اهمیت زیادی دارد. تریبولوژی هوشمند با استفاده از روش‌های پیشرفته محاسباتی مانند الگوریتم‌های یادگیری ماشین و یادگیری عمیق، امکان پیش‌بینی پارامترهای تریبولوژیکی نظیر اصطکاک و سایش را فراهم می‌کند و بدین ترتیب درک سیستم‌های تریبولوژیکی را بهبود می‌بخشد. این زمینه به پیشرفت‌های چشمگیری در زمینه‌هایی مانند روانکاری، مهندسی سطوح و بیوتریبولوژی منجر می‌شود که برای توسعه فناوری‌ها و کاربردهای نوین در جامعه مدرن ضروری هستند [۳۰].

#### ۱.۴ کاربرد روش‌های داده‌محور در زمینه تریبولوژی

روش‌های نوین یادگیری ماشین و هوش مصنوعی فرصت‌هایی را برای کشف فرآیندهای پیچیده در سیستم‌های تریبولوژیکی و طبقه‌بندی یا کمی کردن رفتار آنها فراهم می‌کنند. بنابراین روش‌های مذکور علاوه بر کاربردهای تحقیقاتی در زمینه‌های مختلف صنعتی نیز مورد توجه قرار گرفته‌اند. روش‌های داده‌محور امکان مدیریت مسائل پیچیده و مجموعه داده‌های با ابعاد بالا را فراهم می‌کنند. همچنین قابلیت تطبیق در شرایط متغیر را با هزینه منطقی امکان‌پذیر می‌کنند [۳۶].

#### ۲.۴ کاربرد روش‌های داده‌محور در پیش‌بینی خواص

##### تریبولوژیکی پوشش‌ها

اجزای متحرک ماشین‌آلات و قطعات مهندسی همواره در معرض پدیده‌هایی نظیر سایش و اصطکاک قرار دارند [۳۸]، [۳۷]. این پدیده‌ها می‌توانند زیان‌های اقتصادی قابل‌توجهی را در صنایع مختلف به همراه داشته باشند [۳۹]–[۴۱]. به همین دلیل، تقاضای فزاینده‌ای برای استفاده از مواد با خواص تریبولوژیکی بهبودیافته و افزایش عمر مفید قطعات و ماشین‌آلات مهندسی وجود دارد. در این راستا، فرآیندهای پوشش‌دهی به‌عنوان یکی از مؤثرترین

جدول ۱. مقایسه عملکرد الگوریتم‌های مورد استفاده برای پیش‌بینی نرخ سایش با بهره‌گیری از شاخص‌های ارزیابی مجذور R، جذر میانگین مربعات خطا و درصد خطای نسبی


الگوریتم	مجذور R	جذر میانگین مربعات خطا	درصد خطای نسبی
رگرسیون مخلوط گاوسی	۰/۹۵۱۱	۰/۰۱۴۶	۹/۳۱۴۱
شبکه عصبی پس انتشار	۰/۹۴۹۴	۰/۰۱۵۲	۹/۵۴۹۴
شبکه عصبی تابع شعاعی	۰/۸۸۳۰	۰/۰۰۶۹	۱۳/۳۰۰۶
رگرسیون خطی چندگانه	۰/۸۸۳۸	۰/۰۰۲۱۱	۱۳/۲۲۸۱

افزودن عناصر کاربیدزا نظیر نیوبوم، وانادیوم، تنگستن و تیتانیوم سبب افزایش سختی و تشکیل کاربیدهای ریزدانه می‌شود. با وجود اهمیت آزمون‌های سایش برای ارزیابی مقاومت این پوشش‌ها، هزینه و زمان‌بر بودن این آزمایش‌ها چالش‌برانگیز است. در این راستا، الگوریتم‌های یادگیری ماشین برای پیش‌بینی رفتار سایش با استفاده از داده‌های آزمایشگاهی مورد استفاده قرار گرفته‌اند و عملکرد مناسبی نشان داده‌اند. [۴۵]. به همین منظور در یک مطالعه آلتای و همکاران [۴۵] به بررسی رفتار سایش مواد با بهره‌گیری از الگوریتم‌های یادگیری ماشین و داده‌های آزمایشگاهی پرداختند که کاهش هزینه و زمان مورد نیاز مطالعات آزمایشگاهی را به دنبال داشته است. در این پژوهش به بررسی نمونه‌های فولادی AISI1020 پوشش‌دهی شده با فرآیند<sup>۱</sup>PTAW و مخلوطی از پودرهایی با ترکیب 70FeCrC-30FeB و 50FeCrC-20FeW-30FeB پرداخته شده است. مخلوط پودرها، سختی پوشش‌ها، مسافت لغزش و بار عمودی در آزمون سایش به‌منظور

روش‌ها برای بهبود مقاومت سطوح در برابر سایش مورد استفاده قرار می‌گیرند.

تعیین خواص تریبولوژیکی پوشش‌های اعمال شده در کاربردهای مختلف تریبولوژیکی امری ضروری است. به‌منظور کاهش تعداد آزمایش‌ها و کاهش هزینه‌های مطالعات تجربی تعیین خواص تریبولوژیکی پوشش‌ها، الگوریتم‌های یادگیری ماشین مورد توجه قرار گرفته‌اند. از این رو باتیستا و همکاران [۴۲] به‌منظور پیش‌بینی نرخ سایش پوشش‌های تک‌لایه و چندلایه نیتربیدی و جلوگیری از انجام آزمون‌های متعدد از الگوریتم رگرسیون خطی برای ساخت مدل پیش‌بینی استفاده کردند. در مطالعه‌ای دیگر وانگ و همکاران [۴۳] نرخ سایش ابزار را با استفاده از مدل رگرسیون مخلوط گاوسی مورد بررسی قرار دادند. نتایج این مطالعه حاکی از موفقیت مدل در شرایطی است که داده‌ها نوسان دارند و یا داده‌ی پرت وجود دارد. مدل پیشنهادی می‌تواند در شرایطی که مقادیر ویژگی‌های ورودی برای وضعیت‌های مختلف سایش در یک محدوده مشخص نوسان دارند و یا حتی داده‌های پرت در مجموعه آموزشی وجود دارد، نتایج دقیق‌تری نسبت به الگوریتم‌های شبکه عصبی پس انتشار، شبکه عصبی مبتنی بر تابع شعاعی و رگرسیون خطی چندگانه ارائه دهد. نتایج ارزیابی الگوریتم‌های مذکور در پیش‌بینی نرخ سایش در جدول ۱ گزارش شده است. شبکه مصنوعی عصبی یکی از روش‌های معمول در پیش‌بینی آزمایش‌های سایش هستند [۴۴]. لایه‌نشانی پوشش‌های سخت مانند کاربیدها، نیتربیدها و بورایدها بر روی سطوح قطعات فلزی، مقاومت به سایش را افزایش می‌دهد. آلیاژهای FeCrC به‌دلیل تشکیل کاربیدهای سخت مانند M7C3 و M23C6 و مقرون‌به‌صرفه بودن از جمله پوشش‌های مقاوم به سایش محسوب می‌شوند.

<sup>۱</sup> Plasma transfer arc welding




شکل ۱. نمودار مقایسه مقادیر واقعی و مقادیر پیش‌بینی شده توسط رگرسیون پردازش گوسین [۴۵].

مدل‌سازی با استفاده از الگوریتم‌های شبکه عصبی، ماشین یادگیری افراطی، ماشین یادگیری افراطی وزن‌دار شده و ماشین یادگیری افراطی کرنل صورت پذیرفت. به همین منظور فولاد AISI1020 به‌عنوان زیر لایه و پوششی با ترکیب پودرهای FeW، FeCrC، و FeB لحاظ شدند. نتایج پیش‌بینی حاصل از شبکه عصبی مصنوعی و ماشین یادگیری افراطی وزن‌دار شده به یک دیگر نزدیک بودند. مقادیر آزمایشگاهی و پیش‌بینی شده‌ی مربوط به مدل‌های طراحی شده در نمودارهای شکل ۲ با توجه به مقادیر شاخص‌های ارزیابی نشان داده شده است. به‌طور کلی بهترین و بدترین عملکرد مدل‌ها به ترتیب در ماشین یادگیری افراطی وزن‌دار شده و ماشین یادگیری افراطی کرنل مشاهده شده است. خطای میانگین مطلق الگوریتم‌های شبکه عصبی مصنوعی، ماشین یادگیری افراطی، ماشین یادگیری افراطی وزن‌دار شده و ماشین یادگیری افراطی کرنل به ترتیب ۰/۴۴۲۸، ۰/۴۷۹۷، ۰/۴۳۶۹ و ۰/۵۲۹۸ گزارش شده است [۴۶].


پیش‌بینی نرخ سایش با استفاده از الگوریتم‌های رگرسیون خطی، بردار پشتیبان و رگرسیون پردازش گوسین مورد بررسی قرار گرفتند. نتایج بررسی شاخص‌های ارزیابی خطای جذر میانگین مربعات، خطای میانگین قدر مطلق و ضریب همبستگی و دقت مدل‌های سه الگوریتم حاکی از عملکرد بالای رگرسیون پردازش گوسین در این مطالعه است. مقادیر شاخص‌های ارزیابی خطای جذر میانگین مربعات، خطای میانگین مطلق و ضریب همبستگی برای الگوریتم رگرسیون پردازش گوسین به ترتیب ۰/۶۹، ۰/۵۲ و ۰/۹۶ است. در شکل ۱ مقایسه مقادیر واقعی و پیش‌بینی شده توسط الگوریتم رگرسیون پردازش گوسین که بهترین عملکرد را داشته، ارائه شده است. در اینگونه نمودارها هر چه داده‌ها بر خط  $y=x$  منطبق‌تر باشند، بیانگر دقت بالاتر مدل در پیش‌بینی است. مدل پیشنهادی با کاهش زمان و هزینه، تولید قطعات پوشش‌دهی شده مقاوم به سایش را بهبود می‌بخشد. این مدل به‌ویژه در ساخت قطعات با سایش بالا در صنایع نورد، ماشین‌آلات کشاورزی و صنایع معدنی مانند فرز و آسیاب کاربرد دارد [۴۵].

اولاس و همکاران [۴۶] زیرلایه فولادی از جنس AISI 1020 را با فرآیند جوشکاری قوسی پلاسما و مخلوط پودرهایی با ترکیب FeW، FeCrC، و FeB پوشش‌دهی کردند. سپس برای کاهش هزینه و زمان مورد نیاز آزمون‌های تریبولوژی، ویژگی‌هایی از قبیل ترکیبات پوشش، بار عمودی و مسافت لغزش با استفاده از الگوریتم‌های یادگیری ماشین مورد مطالعه قرار گرفتند. ترکیب پوشش، میانگین سختی، بار عمودی و مسافت لغزش به عنوان ورودی و نرخ سایش به عنوان خروجی لحاظ شدند

۳ کمترین خطا در پیش‌بینی سایش و ضریب اصطکاک به ترتیب در ایپاک ۹۸۸ و ۷۲۴ بدست آمده است.



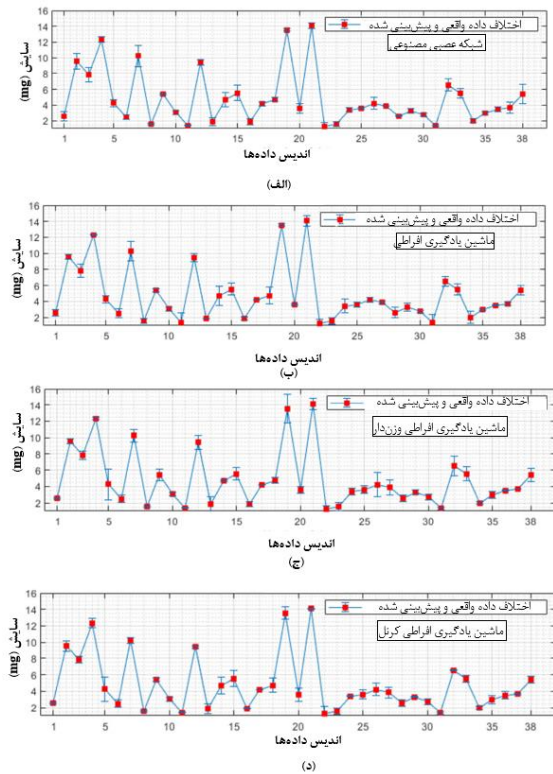
تعداد ایپاک در پیش‌بینی سایش



تعداد ایپاک در پیش‌بینی ضریب اصطکاک

شکل ۳. روند تغییرات میانگین مربعات خطا در طول آموزش، ارزیابی و آزمون مدل شبکه عصبی مصنوعی برای پیش‌بینی (الف) سایش و (ب) اصطکاک [۴۷].

در یک پژوهش نرخ سایش آلیاژ AZ91D پوشش‌دهی شده با  $ZrO_2$ -wt. % 22 MgO مورد مطالعه قرار گرفته است. پوشش توسط دو نوع روش پوشش‌دهی شامل پلاسما اسپری و پاشش شعله‌ای بر آلیاژ مورد بررسی، اعمال شده است. پارامترهای مختلف از جمله نرخ جریان اکسیژن، پروپان، حامل نیتروژن و فاصله اسپری در پاشش شعله‌ای و نرخ تغذیه پودر، نرخ جریان گاز آرگون، جریان، ولتاژ و فاصله اسپری در پلاسما اسپری به عنوان پارامترهای ورودی در مدل‌سازی به کار گرفته شده‌اند. در این مطالعه



شکل ۲. مقایسه نتایج آزمایشگاهی و مقادیر پیش‌بینی شده توسط (الف) شبکه عصبی مصنوعی، (ب) ماشین یادگیری افراطی، (ج) ماشین یادگیری افراطی کرنل و (د) ماشین یادگیری افراطی وزن‌دار [۴۶].

در مطالعه‌ای دیگر خواص تریبولوژیکی پوشش  $W/W_2N$  بر زیر لایه فولادی با الگوریتم شبکه عصبی مصنوعی به منظور کاهش زمان و بهینه‌سازی پارامترهای پوشش‌دهی مورد بررسی قرار گرفت. هدف اصلی این مطالعه، توسعه مدلی برای پیش‌بینی دقیق رفتار اصطکاک و سایش در فولادهای ابزار بوده است. این روش با حل چالش‌های مربوط به انجام آزمایش‌های مکرر که زمان‌بر و پرهزینه هستند، شرایط را تسهیل کرده است. از طرفی با توجه به دقت بالای شبکه عصبی مصنوعی در یافتن روابط غیرخطی بین پارامترهای پوشش‌دهی و خواص تریبولوژیکی این الگوریتم در مطالعه مذکور مورد استفاده قرار گرفته است [۴۷]. در شکل ۳-الف روند کاهش خطا در طول آموزش، ارزیابی و آزمون الگوریتم شبکه عصبی مصنوعی به منظور پیش‌بینی سایش و شکل ۳-ب به منظور پیش‌بینی ضریب اصطکاک نشان داده شده است. باتوجه به نمودارهای شکل

کلیدی در فرآیند اعمال پوشش به شمار می‌روند. پارامترهای ورودی، خروجی و معماری شبکه عصبی مصنوعی در شکل ۴ نشان داده شده است.

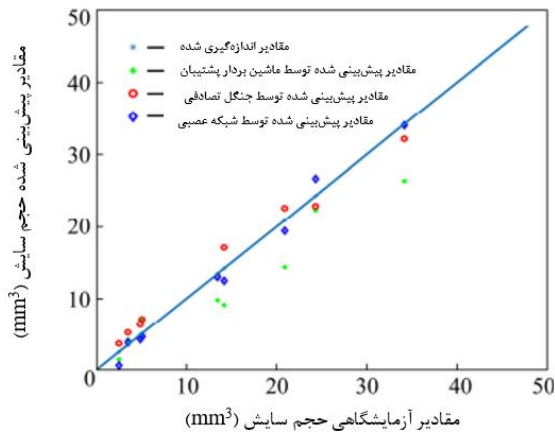
جدول ۲. مقادیر بهینه هایپرپارامترهای الگوریتم‌های رگرسیون بردار پشتیبان و یادگیری ماشین افراطی در پیش‌بینی نرخ سایش آلیاژ AZ91 پوشش‌دهی شده [۴۸].

مقادیر	هایپر پارامتر	الگوریتم
درجه دوم	تابع کرنل	رگرسیون بردار
۰/۷۷	تابع ضرر	پشتیبان
۱/۶۳	مقیاس کرنل	
۶	نورون‌های ورودی	یادگیری ماشین افراطی
۱	نورون‌های خروجی	
۱۰۰	نورون‌های پنهان	
سیگموئید	تابع فعال‌سازی	

با استفاده از الگوریتم لوبنبرگ-مارکواریت آموزش داده شد که در مدل‌سازی روابط غیرخطی پیچیده بین پارامترهای ورودی و خروجی بسیار مؤثر است. نتایج، نشان‌دهنده همبستگی بالایی بین مقادیر پیش‌بینی شده و آزمایشگاهی بود به طوری که مقدار مجذور R برای اصطکاک برابر با ۰/۹۹۹۷۶ و برای سایش برابر با ۰/۹۹۹۹۸ گزارش شد که نشان‌دهنده قابل اطمینان بودن پیش‌بینی‌های الگوریتم شبکه عصبی مصنوعی است. این مطالعه به طور موفقیت‌آمیزی نشان داد که شبکه عصبی مصنوعی می‌تواند فرآیندهای صنعتی پیچیده را ساده کند در حالی که صرفه‌جویی در زمان و هزینه را به همراه داشته و پیش‌بینی‌های دقیقی از اصطکاک و سایش در پوشش‌های چندلایه ارائه دهد [۴۹].

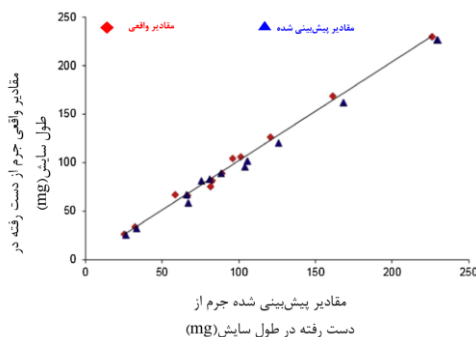
الگوریتم‌های رگرسیون بردار پشتیبان و یادگیری ماشین افراطی اعمال شدند. مقادیر مجذور R برای روش‌های یادگیری ماشین افراطی و رگرسیون بردار پشتیبان به ترتیب ۰/۹۹۰۱ و ۰/۹۶۰۱ است. با توجه به اینکه دقت مدل علاوه بر مرحله آماده‌سازی داده‌های جمع‌آوری شده، به مقدار هایپرپارامترهای هر الگوریتم نیز بستگی دارد، مقادیر مربوطه در جدول ۲ گزارش شده است. مدل‌های طراحی-شده با استفاده از دو روش مختلف یادگیری ماشین مورد استفاده، نشان دادند که می‌توانند به صورت قابل قبولی در صنایع تولید پوشش سطحی با استفاده از روش‌های پوشش اسپری حرارتی مورد استفاده قرار گیرند. استفاده از روش یادگیری ماشین افراطی در صنعت می‌تواند پیش‌بینی سایش را بر اساس عامل‌های شناخته‌شده مانند عوامل مربوط به شرایط تولید نمونه، سختی، زبری سطح، مسافت لغزش و بار اعمال‌شده انجام دهد. به این صورت، بدون نیاز به آزمون‌های سایش طولانی مدت و پرهزینه، پیش‌بینی سایش صورت می‌پذیرد و مهندسان طراح می‌توانند از این روش به عنوان ابزارهای پشتیبانی تصمیم‌گیری استفاده کنند [۴۸].

در یک مطالعه به بررسی خواص تریبولوژیکی پوشش‌های کامپوزیتی آلیاژ پایه نیکل تقویت‌شده با TiC با استفاده از دو الگوریتم شبکه عصبی پس‌انتشار و ماشین بردار پشتیبان پرداخته شده است. شرایط مختلف آزمایش، نظیر بار عمودی، سرعت و دما به عنوان ورودی برای پیش‌بینی ضریب اصطکاک و نرخ سایش مورد استفاده قرار گرفتند. در این مطالعه الگوریتم ماشین بردار پشتیبان عملکرد قابل قبولی در پیش‌بینی ارائه کرده است [۴۴]. در بررسی دیگری به پیش‌بینی خواص تریبولوژیکی پوشش‌های نیتریدی چندلایه با استفاده از شبکه عصبی مصنوعی پرداخته شده است. پارامترهای ورودی شامل ولتاژ بایاس، نرخ جریان کل گاز، فاصله، زمان، سرعت و بار بودند که از عوامل




شکل ۵. مقایسه مقادیر پیش‌بینی شده و اندازه‌گیری شده در مجموعه آزمون [۵۱].

پالاوار و همکاران [۵۲] مدل شبکه عصبی مصنوعی را برای پیش‌بینی رفتار سایش سوپرآلیاژ PM Inconel 706 بر اساس پارامترهای پیرسختی توسعه دادند. در این مطالعه دما و زمان پیرسختی به عنوان پارامترهای ورودی و حجم از دست‌رفته در آزمون سایش به عنوان خروجی در الگوریتم شبکه عصبی پیش‌خور و پس‌انتشار به کار گرفته شدند. نتایج عملکرد پیش‌بینی مدل توسعه یافته برای داده‌هایی که مدل در طول آموزش خود ندیده‌است، در شکل ۶ گزارش شده است. با توجه به شکل ۶ و دقت بالای مدل توسعه یافته، پژوهشگران در این مطالعه این مدل را برای پیش‌بینی دقیق جرم از دست‌رفته در طول سایش پیشنهاد کردند [۵۲].



شکل ۶. مقایسه اختلاف مقادیر واقعی و پیش‌بینی شده توسط شبکه عصبی مصنوعی [۵۲].



شکل ۴. معماری شبکه عصبی، عامل‌های ورودی و خروجی [۴۹].

مطالعه‌ای توسط شاهرویی به بررسی اصطکاک پوشش‌های HVOF<sup>۱</sup> با استفاده از شبکه عصبی مصنوعی پرداخته است. در این مطالعه، شبکه عصبی به صورت یک پرسپترون چندلایه طراحی شده و با داده‌های آزمایشگاهی شامل بار عمودی، سرعت لغزش و مسافت لغزش آموزش داده شد. نتایج نشان‌دهنده عملکرد قابل قبول این الگوریتم با خطای ۰/۰۱۸۶ در پیش‌بینی ضریب اصطکاک پوشش است [۵۰].

### ۳.۴. کاربرد روش‌های داده‌محور در پیش‌بینی خواص تریبولوژیکی آلیاژها و کامپوزیت‌های زمینه فلزی

در یک مطالعه نرخ سایش آلیاژ AZ91 با استفاده از الگوریتم‌های یادگیری ماشین مورد بررسی قرار گرفتند. با استفاده از آنالیز واریانس تاثیر پارامترهای سایش (سرعت لغزش، مسافت لغزش و بار عمودی) بر میزان سایش آلیاژ AZ91 مورد بررسی قرار گرفته است. مشارکت بار عمودی، مسافت لغزش و سرعت لغزش به ترتیب ۱۲/۹۹ درصد، ۸۳/۰۴ درصد و ۳/۹۷ درصد گزارش شده است که نشان می‌دهد موثرترین پارامتر بر میزان سایش آلیاژ AZ91 مسافت لغزش است. شکل ۵ مقایسه نتایج مدل‌ها با نتایج آزمایشگاهی را نشان می‌دهد. شبکه عصبی مصنوعی با دقت ۰/۹۸۴۵ به عنوان بهترین الگوریتم برای برآورد میزان سایش آلیاژ AZ91 گزارش شده است [۵۱].



<sup>1</sup> High velocity oxy fuel

پارامترهای آزمون سایش بیشترین مشارکت را در پیش‌بینی حجم سایش آلیاژهای منیزیم با استفاده از پارامترهای آزمون سایش، ترکیب شیمیایی، عملیات حرارتی و روش تولید داشته‌اند. نتایج بررسی دقت عملکرد الگوریتم بوستینگ تطبیقی در شکل ۷ گزارش شده است [۵۳].

ترکیب آلیاژی مواد، میانگین اندازه دانه، سختی، استحکام تسلیم، شکل‌پذیری، مراحل فرآیند و عملیات حرارتی برخی از متغیرهای مواد هستند که بر رفتار تریبولوژی آلیاژهای آلومینیوم تاثیر می‌گذارند. از این رو در یک مطالعه پنج الگوریتم نزدیک‌ترین همسایگی، رگرسیون بردار پشتیبان، شبکه عصبی مصنوعی، جنگل تصادفی و گرادیان بوستینگ به منظور برقراری روابط بین پارامترهای ورودی و خروجی و پیش‌بینی رفتار تریبولوژیکی آلیاژهای آلومینیوم مورد استفاده قرار گرفتند. بیشترین مقدار مجذور R، ۰/۸۳ گزارش شده که مربوط به مدل نزدیک‌ترین همسایگی است. این مدل می‌تواند ضریب اصطکاک آلیاژهای آلومینیوم را با استفاده از متغیرهای مواد و پارامترهای تریبولوژی با دقت ۸۳ درصد پیش‌بینی کند. مقادیر میانگین مربعات خطا، جذر میانگین مربعات خطا و میانگین مطلق خطا این مدل به ترتیب ۰/۰۰۲، ۰/۰۵۲۹ و ۰/۰۳۴۵ ارائه شده است. این مقادیر به طور قابل توجهی پایین بوده و دقت بالا در پیش‌بینی را نشان می‌دهند. نمودار مربوط به مقادیر ضریب اصطکاک پیش‌بینی شده و واقعی برای مدل نزدیک‌ترین همسایگی در شکل ۸ ارایه شده است [۳۰].

در این مطالعه یافتن پارامترهای ورودی که بیشتر تاثیر را بر خروجی داشتند، با استفاده از الگوریتم جنگل تصادفی صورت پذیرفت که نتیجه در شکل ۹ نشان داده شده است.

اسلاوکویچ و همکاران [۲۹] نرخ سایش گلوله‌های شناور از جنس چدن سفید در فرآیند آسیاب سنگ معدن و مقدار بهینه کروم را گزارش کردند. در این مطالعه ویژگی‌هایی مانند سختی و ترکیب شیمیایی گلوله‌ها (درصد عناصر کربن، منیزیم، سیلیسیم و کروم) به منظور مدل‌سازی با الگوریتم‌های ماشین بردار پشتیبان و ماشین بردار پشتیبان بهبود یافته مورد استفاده قرار گرفتند. توسعه الگوریتم ماشین بردار پشتیبان توسط توابع هسته از قبیل RBF، ERBF و چندجمله‌ای انجام شد. عملکرد توابع مذکور توسط خطای میانگین مربعات، خطای میانگین قدرمطلق و انحراف استاندارد معیار ارزیابی شدند. با توجه نتایج ارزیابی الگوریتم‌ها، بهترین عملکرد و کمترین خطا با تابع ERBF حاصل شد [۲۹].

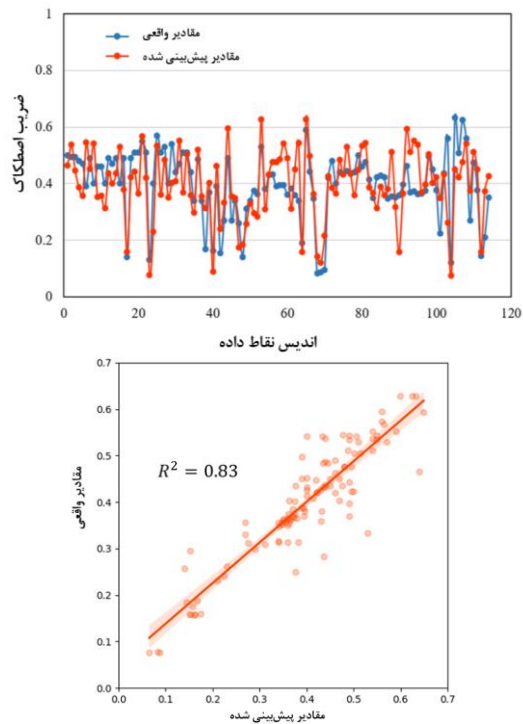


شکل ۷. الف) نمودار انطباق و ب) نمودار نقطه‌ای نتایج پیش‌بینی شده توسط الگوریتم بوستینگ تطبیقی و داده‌های آزمایشگاهی.



در یک مطالعه با استفاده از الگوریتم‌های یادگیری ماشین حجم سایش آلیاژهای منیزیم مورد بررسی قرار گرفت. الگوریتم بوستینگ تطبیقی با ۹۴ درصد بیشترین دقت و

رشد قابل توجهی در استفاده از مواد ساخته شده از دو یا چند ماده تشکیل دهنده با خواص فیزیکی یا شیمیایی متفاوت وجود داشته است [۳۶]، [۵۴]–[۵۷].



در مطالعه‌ای توسط باقریه و همکاران پیش‌بینی ضریب اصطکاک آلیاژهای منیزیم با استفاده از خواص مکانیکی و پارامترهای آزمون سایش انجام شد. در این مطالعه، الگوریتم‌های شبکه عصبی مصنوعی، نزدیک‌ترین همسایگی، جنگل تصادفی، گرادیان بوستینگ و ماشین بردار پشتیبان به منظور پیش‌بینی ضریب اصطکاک آلیاژهای منیزیم به کار گرفته شدند که الگوریتم گرادیان بوستینگ با دقت ۸۶ درصد (شکل ۱۰) بهترین عملکرد را ثبت کرد. مقایسه عملکرد الگوریتم‌های مورد استفاده در این مطالعه در شکل ۱۱ ارائه شده است [۵۸].



شکل ۸. نمودار ضریب اصطکاک پیش‌بینی شده و واقعی مربوط به مدل نزدیک‌ترین همسایگی [۳۰].



شکل ۱۰. نمودار انطباق (ب) نمودار نقطه‌ای نتایج پیش‌بینی شده توسط الگوریتم گرادیان بوستینگ و داده‌های آزمایشگاهی [۵۸].





شکل ۹. رتبه‌بندی اهمیت ویژگی‌ها برای پیش‌بینی الف) نرخ سایش و ب) ضریب اصطکاک [۳۰].

در حال حاضر الگوریتم‌های یادگیری ماشین به طور گسترده در زمینه مواد کامپوزیتی برای کاربردهای تربیولوژیکی مورد استفاده قرار می‌گیرند. به طور کلی، در سالهای اخیر،

تولید و پارامترهای آزمون سایش است. این نشان‌دهنده تعداد زیاد متغیرهای تأثیرگذار بر خواص مکانیکی و تریبولوژیکی کامپوزیت‌های آلومینیوم و گرافیت است. در مطالعه بررسی اثر تغییرات چند پارامتری به رویکردهای داده‌محور مانند الگوریتم‌های یادگیری ماشین نیاز است. در یک مطالعه بیشترین تأثیر بر پیش‌بینی نرخ سایش در اثر مقدار گرافیت، سرعت لغزش و سختی و برای پیش‌بینی ضریب اصطکاک سختی، مقدار گرافیت و استحکام تسلیم گزارش شده است. این مطالعه نشان داد که سختی و میزان گرافیت تأثیر چشمگیری بر رفتار سایشی و ضریب اصطکاک کامپوزیت‌های آلومینیوم-گرافیت دارند. افزایش سختی ماده منجر به کاهش تغییرشکل پلاستیک و کاهش جزء چسبندگی و جزء تغییرشکل در تماس‌های لغزشی شده و به‌طور کلی، ضریب اصطکاک را کاهش می‌دهد. شایان ذکر است که رابطه میان سختی و ضریب اصطکاک پیچیده بوده و نمی‌توان تنها بر اساس سختی پیش‌بینی دقیقی از ضریب اصطکاک ارائه کرد. افزایش سختی معمولاً کاهش نرخ سایش را به دنبال دارد. زیرا تغییرشکل پلاستیک و جرم از دست رفته در تماس‌های لغزشی کمتر می‌شود. همچنین، گرافیت نقش مهمی در کاهش اصطکاک ایفا می‌کند. با تشکیل یک لایه روان‌کننده توسط گرافیت، اصطکاک به‌طور قابل‌توجهی کاهش یافته و عملکرد تریبولوژیکی کامپوزیت‌ها بهبود می‌یابد. این نتایج اطلاعات ارزشمندی برای بهینه‌سازی طراحی و تولید کامپوزیت‌های آلومینیوم-گرافیت در کاربردهای صنعتی ارائه می‌دهند [۶].

در پژوهش دیگری نرخ سایش کامپوزیت زمینه مس تقویت‌شده با نیتريد بور و نیتريد آلومینیوم با در نظر گرفتن کسر حجمی، بارعمودی، سرعت لغزش و مسافت لغزش به عنوان پارامتر ورودی مورد بررسی قرار گرفت. در این مطالعه از شبکه عصبی برای پیش‌بینی استفاده شد. در این مطالعه به بررسی بهینه‌سازی رفتار تریبولوژیکی




شکل ۱۱. نمودار میله‌ای مقایسه‌ای (الف) مجذور R و (ب) خطای میانگین مطلق الگوریتم‌های شبکه عصبی مصنوعی، نزدیک‌ترین همسایگی، گرادبان بوستینگ و جنگل تصادفی [۵۸].

این پژوهشگران به‌منظور بررسی تأثیر خواص مکانیکی به‌عنوان ویژگی‌های قابل اندازه‌گیری مهندسی و تحلیل نقش روش تولید و تاریخچه عملیات حرارتی به‌عنوان مراحل اساسی و اولیه در فرآیند ساخت و تولید در خواص تریبولوژیکی آلیاژهای منیزیم، یادگیری ماشین را به کار گرفتند و پیش‌بینی حجم سایش و ضریب اصطکاک را با استفاده از چهار گروه داده انجام دادند. نتایج این مطالعه حاکی از تأثیر بالای پارامترهای آزمون تریبولوژی، سختی و ازدیاد طول بر حجم سایش و تأثیر بالای بارعمودی، مسافت لغزش، ازدیاد طول، مدول الاستیک و درصد وزنی روی بر ضریب اصطکاک آلیاژهای منیزیم بود [۵۹].

سایش و اصطکاک کامپوزیت‌های آلومینیوم و ذرات گرافیت تحت تأثیر متغیرهای مواد مانند خواص زمینه، مقدار گرافیت، شکل و اندازه ذرات گرافیت و مراحل روش

مورد بررسی قرار گرفت. درصد و اندازه ذرات تقویت-کننده، سرعت لغزش و بار نرمال به عنوان ورودی در نظر گرفته شدند. این محققان گزارش کرده‌اند که با استفاده از الگوریتم شبکه عصبی مصنوعی تا دقت ۹۵ درصد می‌توانند نرخ سایش و ضریب اصطکاک را پیش‌بینی نمایند.



شکل ۱۲. معماری شبکه عصبی مصنوعی با دو لایه پنهان به منظور پیش‌بینی ضریب اصطکاک و نرخ سایش با استفاده از درصد وزنی گرافیت، بار عمودی و سرعت لغزش [۶۱].

## ۵. نتیجه گیری

با پیشرفت‌های اخیر در فناوری اطلاعات و ابزارهای یادگیری ماشین و هوش مصنوعی، تریبولوژی به یک زمینه تحقیقاتی نوآورانه‌تر و کارآمدتر تبدیل شده است. استفاده از انفورماتیک تریبولوژی، که شامل جمع‌آوری، ذخیره‌سازی، تحلیل، مدل‌سازی و بهینه‌سازی داده‌ها در تریبولوژی است، به‌طور چشمگیری چرخه‌های پژوهشی را کوتاه‌تر کرده و بهره‌وری را افزایش داده است. این رویکرد با کاهش پراکندگی اطلاعات و بهبود نظم داده‌ها، بهینه‌سازی فرآیندهای تحقیقاتی و تسریع در دستیابی به نتایج علمی را تسهیل می‌کند. بررسی مقالات منتشر شده در زمینه انفورماتیک تریبولوژی چنین می‌نمایاند که تا کنون تمرکز اصلی بر استفاده از الگوریتم‌های یادگیری ماشین جهت پیش‌بینی ضریب اصطکاک و نرخ سایش در آلیاژها و پوشش‌ها بوده است و پژوهشگران تلاش کرده‌اند با استفاده از داده‌های مربوط به ترکیب شیمیایی، خواص

کامپوزیت‌های مس هیبریدی با استفاده از تکنیک‌های آماری و یادگیری ماشین پرداخته شده است. اثرات متغیرهایی همچون کسر حجمی تقویت‌کننده‌ها، بار عمودی، سرعت لغزش و مسافت لغزش بر نرخ سایش با استفاده از تحلیل واریانس ارزیابی شده است. نتایج نشان می‌دهد که بار عمودی با مشارکت ۵۹/۹۲ درصد بیشترین تأثیر را بر نرخ سایش داشته و پس از آن کسر حجمی تقویت‌کننده‌ها با ۱۳/۳۲ درصد قرار می‌گیرد. تحلیل رگرسیون رابطه‌ای مؤثر بین پارامترهای ورودی و نرخ سایش ایجاد کرده و توانایی مدل در پیش‌بینی نتایج را نشان داده است. بررسی‌های ریزساختاری با استفاده از میکروسکوپ الکترونی روبشی پراکندگی یکنواخت ذرات تقویت‌کننده و انتقال از سایش شدید به سایش ملایم با افزایش مقدار تقویت‌کننده‌ها را تأیید کرده است. این پژوهش نشان داد که مدل شبکه عصبی پیش‌خور می‌تواند نرخ سایش را با دقت بالایی پیش‌بینی کند و پتانسیل بالای کامپوزیت‌های هیبریدی مس را در کاربردهای مکانیکی مختلف نشان داد [۶۰].

در مطالعه‌ای دیگر نرخ سایش و ضریب اصطکاک کامپوزیت زمینه Al-Si تقویت‌شده با گرافیت مورد مطالعه قرار گرفت. مقدار گرافن، بار عمودی و سرعت لغزش به عنوان ورودی و الگوریتم شبکه عصبی پیش‌خور برای مدل‌سازی به کار گرفته شد. مقدار مجذور R به عنوان شاخص ارزیابی عملکرد الگوریتم شبکه عصبی پیش‌خور ۹۸ درصد گزارش شده است. معماری شبکه عصبی مورد استفاده در شکل ۱۲ گزارش شده است [۶۱].

ساروانان و همکاران [۶۲] کامپوزیت زمینه آلومینیومی تقویت‌شده با خاکستر پوسته برنج جهت بهبود مقاومت به سایش سنتز کردند. پیش‌بینی نرخ سایش و ضریب اصطکاک این کامپوزیت با اعمال الگوریتم شبکه عصبی

“Triboinformatics approach for friction and wear prediction of Al-graphite composites using machine learning methods,” *Journal of Tribology*, vol. 144, no. 1, pp. 1–13, 2022.

[7] J. Wei, *et al.*, “Machine learning in materials science,” *InfoMat*, vol. 1, no. 3, pp. 338–358, 2019.

[8] S. Badini, S. Regondi, and R. Pugliese, “Unleashing the Power of Artificial Intelligence in Materials Design,” *Materials*, vol. 16, no. 17, 2023.

[9] C. Li and K. Zheng, “Methods, progresses, and opportunities of materials informatics,” *InfoMat*, vol. 5, no. 8, pp. 1–30, 2023.

[10] B. Mahesh, “A Review: Machine Learning Algorithms,” *Data Science: Practical Approach with Python & R*, vol. 9, no. 1, pp. 381–386, 2018.

[11] A. Agrawal and A. Choudhary, “Perspective: Materials informatics and big data: Realization of the ‘fourth paradigm’ of science in materials science,” *APL Materials*, vol. 4, no. 5, 2016.

[12] G. Shobha and S. Rangaswamy, “*Machine Learning*,” 1st ed., vol. 38. Elsevier B.V., 2018.

[13] X.-D. Zhang, “*Chapter 6 Machine Learning*,” vol. 45, no. 13. 2017.

[14] K. J. Kim and I. Tagkopoulos, “Application of machine learning in rheumatic disease research,” *Korean Journal of Internal Medicine*, vol. 34, no. 4, pp. 708–722, 2019.

[15] D. M. Dutton and G. V. Conroy, “A review of machine learning,” *Knowledge Engineering Review*, vol. 12, no. 4, pp. 341–367, 1997.

[16] J. G. Carbonell, R. S. Michalski, and T. M. Mitchell, “*An Overview of Machine Learning*,” Morgan Kaufmann., 1983.

[17] E. Alpaydin, “*Introduction to machine learning*,” Third. The MIT Press Cambridge, Massachusetts London, England.

[18] M. Mohri, A. Rostamizadeh, and A. Talwalkar, “*Foundations of machine learning*,” Second. The MIT Press Cambridge, Massachusetts London, England, 1384.

فیزیکی و مکانیکی، شرایط ساخت و فرایند و نیز شرایط آزمون‌های سایش به‌عنوان ورودی برای آموزش ماشین، به پیش‌بینی ضریب اصطکاک و نرخ سایش پردازند و در این راستا دقت‌های پیش‌بینی قابل قبولی حتی تا مقادیر بیش از ۹۰٪ گزارش کرده‌اند. دیگر استفاده‌ای که پژوهشگران از آن سود برده‌اند، رتبه‌بندی میزان تاثیرگذاری عوامل مختلف دخیل بر ضریب سایش و نرخ اصطکاک بوده است. این رتبه‌بندی‌ها در بحث‌هایی نظیر طراحی آلیاژها یا پوشش‌های مقاوم به سایش یا در غربال عوامل اصلی موثر بر تخریب‌های ناشی از سایش می‌توانند بسیار مفید باشند.

#### مراجع

[1] I. M. Hutchings, “*Tribology: friction and wear of engineering materials*,” vol. 13, no. 3. 1992.

[2] C. Özel and T. Gürgeç, “Effect of heat input on microstructure, wear and friction behavior of (wt.-%) 50FeCrC-20FeW-30FeB coating on AISI 1020 produced by using PTA welding,” *PLoS ONE*, vol. 13, no. 1, pp. 1–12, 2018.

[3] J. Prost, U. Cihak-Bayr, I. Adina Neacșu, R. Grundtner, F. Pirker, and G. Vorlaufer, “Semi-supervised classification of the state of operation in self-lubricating journal bearings using a random forest classifier,” *Lubricants*, vol. 9, no. 5, 2021.

[4] B. S. Ünlü, H. Durmuş, and C. Meriç, “Determination of tribological properties at CuSn10 alloy journal bearings by experimental and means of artificial neural networks method,” *Industrial Lubrication and Tribology*, vol. 64, no. 5, pp. 258–264, 2012.

[5] P. Sathiya, S. Aravindan, A. N. Haq, and K. Paneerselvam, “Optimization of friction welding parameters using evolutionary computational techniques,” *Journal of Materials Processing Technology*, vol. 209, no. 5, pp. 2576–2584, 2009.

[6] M. S. Hasan, A. Kordijazi, P. K. Rohatgi, and M. Nosonovsky,

- parts,” *Computers and Industrial Engineering*, vol. 64, no. 3, pp. 850–857, 2013.
- [30] M. S. Hasan, A. Kordijazi, P. K. Rohatgi, and M. Nosonovsky, “Triboinformatic modeling of dry friction and wear of aluminum base alloys using machine learning algorithms,” *Tribology International*, vol. 161, no. MARCH, p. 107065, 2021.
- [31] X. W. Yang, *et al.*, “Prediction of mechanical properties of A357 alloy using artificial neural network,” *Transactions of Nonferrous Metals Society of China (English Edition)*, vol. 23, no. 3, pp. 788–795, 2013.
- [32] W. Li, *et al.*, “Deep learning modeling strategy for material science: From natural materials to metamaterials,” *JPhys Materials*, vol. 5, no. 1, 2022.
- [33] M. A. Devi, C. P. S. Prakash, R. P. Chinnannavar, V. P. Joshi, R. S. Palada, and R. Dixit, “Properties of Aluminum Alloys using Machine Learning Techniques,” no. ICOSEC, pp. 536–541, 2020..
- [34] B. Bhushan, "*Principles and Applications of tribology*," Second. John Wiley & Sons, 1999.
- [35] A. Matthews and K. Holmberg, "*Friction, Lubrication, and Wear Technology*," vol. 18. 1992.
- [36] M. Marian and S. Tremmel, “Current trends and applications of machine learning in tribology—a review,” *Lubricants*, vol. 9, no. 9, pp. 1–30, 2021.
- [37] W. Grzegorzec and S. F. Scieszka, “Prediction on friction characteristics of industrial brakes using artificial neural networks,” *Proceedings of the Institution of Mechanical Engineers, Part J: Journal of Engineering Tribology*, vol. 228, no. 10, pp. 1025–1035, 2014.
- [38] A. Senatore, V. D’Agostino, R. Di Giuda, and V. Petrone, “Experimental investigation and neural network prediction of brakes and clutch material frictional behaviour considering the sliding acceleration influence,” *Tribology International*, vol. 44, no. 10, pp. 1199–1207, 2011.
- [39] A. Baraka, G. Panoutsos, and S. Cater, “A real-time quality monitoring framework for
- [19] P. Dangeti, "*Statistics for Mashine Learning*," vol. 15, no. 2. 2016.
- [20] Z. Zhang, N. Yin, S. Chen, and C. Liu, “Tribo-informatics: Concept, architecture, and case study,” 2020..
- [21] H. Chang, P. Borghesani, and Z. Peng, “Automated assessment of gear wear mechanism and severity using mould images and convolutional neural networks,” *Tribology International*, vol. 147, no. FEBRUARY, p. 106280, 2020.
- [22] E. Šabanovič, V. Žuraulis, O. Prentkovskis, and V. Skrickij, “Identification of road-surface type using deep neural networks for friction coefficient estimation,” *Sensors (Switzerland)*, vol. 20, no. 3, 2020.
- [23] A. Chen, X. Zhang, and Z. Zhou, “Machine learning: Accelerating materials development for energy storage and conversion,” *InfoMat*, vol. 2, no. 3, pp. 553–576, 2020.
- [24] I. El Naqa and M. J. Murphy, “Machine Learning in Radiation Oncology,” *Machine Learning in Radiation Oncology*, pp. 3–11, 2015.
- [25] G. Bonaccorso, "*Mastering Machine Learning Algorithms*," no. OCTOBER 2013. 2018.
- [26] J. Schmidt, M. R. G. Marques, S. Botti, and M. A. L. Marques, “Recent advances and applications of machine learning in solid-state materials science,” *Npj Computational Materials*, vol. 5, no. 1, 2019.
- [27] Y. Liu, *et al.*, “Accelerated Development of High-Strength Magnesium Alloys by Machine Learning,” *Metallurgical and Materials Transactions A: Physical Metallurgy and Materials Science*, vol. 52, no. 3, pp. 943–954, 2021.
- [28] S. Ray, “A Quick Review of Machine Learning Algorithms,” *2019 International Conference on Machine Learning, Big Data, Cloud and Parallel Computing (COMITCon)*, pp. 35–39, 2019..
- [29] R. Slavkovic, Z. Jugovic, S. Dragicevic, A. Jovicic, and V. Slavkovic, “An application of learning machine methods in prediction of wear rate of wear resistant casting

PVD magnetron sputtering,” *Tribology - Materials, Surfaces & Interfaces*, vol. 5831, no. FEBRUARY, pp. 1–10, 2017.

[48] T. Gurgenc, O. Altay, M. Ulas, and C. Ozel, “Extreme learning machine and support vector regression wear loss predictions for magnesium alloys coated using various spray coating methods,” *Journal of Applied Physics*, vol. 127, no. 18, 2020.

[49] R. K. Upadhyay and L. A. Kumaraswamidhas, “Friction and wear response of nitride coating deposited through PVD magnetron sputtering,” *Tribology - Materials, Surfaces and Interfaces*, vol. 10, no. 4, pp. 196–205, 2016.

[50] T. Sahraoui, S. Guessasma, N. E. Fenineche, G. Montavon, and C. Coddet, “Friction and wear behaviour prediction of HVOF coatings and electroplated hard chromium using neural computation,” *Materials Letters*, vol. 58, no. 5, pp. 654–660, 2004.

[51] F. AYDIN and R. DURGUT, “Estimation of wear performance of AZ91 alloy under dry sliding conditions using machine learning methods,” *Transactions of Nonferrous Metals Society of China (English Edition)*, vol. 31, no. 1, pp. 125–137, 2021.

[52] O. Palavar, D. Özyürek, and A. Kalyon, “Artificial neural network prediction of aging effects on the wear behavior of IN706 superalloy,” *Materials and Design*, vol. 82, pp. 164–172, 2015.

[53] باقریه نگار، نوری میثم، نوری مسلم، مدل پیش-بینی سایش آلیاژهای پایه منیزیم با استفاده از الگوریتم-های یادگیری ماشین، بیست و سومین همایش ملی مهندسی سطح و دومین همایش ملی آنالیز تخریب و تخمین عمر، ۱۴۰۲.

[54] T. Nasir, B. F. Yousif, S. McWilliam, N. D. Salih, and L. T. Hui, “An artificial neural network for prediction of the friction coefficient of multi-layer polymeric composites in three different orientations,” *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*, vol. 224, no. 2, pp. 419–429, 2010.

[55] P. K. Padhi and A. Satapathy, “Analysis of Sliding Wear Characteristics of

steel friction stir welding using computational intelligence,” *Journal of Manufacturing Processes*, vol. 20, pp. 137–148, 2015.

[40] B. Das, S. Pal, and S. Bag, “Torque based defect detection and weld quality modelling in friction stir welding process,” *Journal of Manufacturing Processes*, vol. 27, pp. 8–17, 2017.

[41] K. Anand, R. Shrivastava, K. Tamilmannan, and P. Sathya, “A comparative study of artificial neural network and response surface methodology for optimization of friction welding of incoloy 800 H,” *Acta Metallurgica Sinica (English Letters)*, vol. 28, no. 7, pp. 892–902, 2015.

[42] J. C. A. Batista, C. Godoy, and A. Matthews, “Micro-scale abrasive wear testing of duplex and non-duplex (single-layered) PVD (Ti,Al)N, TiN and Cr-N coatings,” *Tribology International*, vol. 35, no. 6, pp. 363–372, 2002.

[43] G. Wang, L. Qian, and Z. Guo, “Continuous tool wear prediction based on Gaussian mixture regression model,” *International Journal of Advanced Manufacturing Technology*, vol. 66, no. 9–12, pp. 1921–1929, 2013.

[44] Y. F. Tan, L. He, X. L. Wang, X. Hong, and W. G. Wang, “Tribological properties and wear prediction model of TiC particles reinforced Ni-base alloy composite coatings,” *Oral Oncology*, vol. 50, no. 10, pp. 2566–2573, 2014.

[45] O. Altay, T. Gurgenc, M. Ulas, and C. Özel, “Prediction of wear loss quantities of ferro-alloy coating using different machine learning algorithms,” *Friction*, vol. 8, no. 1, pp. 107–114, 2020.

[46] M. Ulas, O. Altay, T. Gurgenc, and C. Özel, “A new approach for prediction of the wear loss of PTA surface coatings using artificial neural network and basic, kernel-based, and weighted extreme learning machine,” *Friction*, vol. 8, no. 6, pp. 1102–1116, 2020.

[47] R. K. Upadhyay, L. A. Kumaraswamidhas, R. K. Upadhyay, and L. A. Kumaraswamidhas, “Friction and wear response of nitride coating deposited through PVD magnetron sputtering Friction and wear response of nitride coating deposited through

BFS Filled Composites Using an Experimental Design Approach Integrated with ANN,” *Tribology Transactions*, vol. 56, no. 5, pp. 789–796, 2013.

[56] J. Zhu, Y. Shi, X. Feng, H. Wang, and X. Lu, “Prediction on tribological properties of carbon fiber and TiO<sub>2</sub> synergistic reinforced polytetrafluoroethylene composites with artificial neural networks,” *Materials and Design*, vol. 30, no. 4, pp. 1042–1049, 2009.

[57] V. Kavimani, K. Soorya Prakash, and T. Thankachan, “Surface characterization and specific wear rate prediction of r-GO/AZ31 composite under dry sliding wear condition,” *Surfaces and Interfaces*, vol. 6, pp. 143–153, 2017.

[58] باقریه نگار، نوری میثم، نوری مسلم، مدل پیش-بینی اصطکاک آلیاژهای پایه منیزیم با استفاده از الگوریتم-های یادگیری ماشین، یازدهمین کنفرانس بین المللی مهندسی مواد و متالورژی،

[59] باقریه نگار، مدل پیش-بینی سایش و اصطکاک آلیاژهای پایه منیزیم با استفاده از الگوریتم-های یادگیری ماشین، دانشگاه بوعلی سینا، ۱۴۰۱.

[60] T. Thankachan, K. Soorya Prakash, and M. Kamarthin, “Optimizing the Tribological Behavior of Hybrid Copper Surface Composites Using Statistical and Machine Learning Techniques,” *Journal of Tribology*, vol. 140, no. 3, 2018.

[61] B. Stojanović, A. Vencl, I. Bobić, S. Miladinović, and J. Skerlić, “Experimental optimisation of the tribological behaviour of Al/SiC/Gr hybrid composites based on Taguchi’s method and artificial neural network,” *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, vol. 40, no. 6, 2018.

[62] S. D. Saravanan and M. Senthilkumar, “Prediction of tribological behaviour of rice husk ash reinforced aluminum alloy matrix composites using artificial neural network,” *Russian Journal of Non-Ferrous Metals*, vol. 56, no. 1, pp. 97–106, 2015.