

## پیشرانی ارزش تجاری در صنعت 4.0:

### داده‌های بزرگ و تحلیلی

### برای بهبود فرآیند تولید فولاد<sup>1</sup>

ترجمه: محمدحسین نشاطی

تولیدکنندگان فولاد جهان هر روز به دلیل نیاز به رقابتی بودن در بازارهای خود و همچنین تولید محصولات با کیفیت بالا برای تامین انتظارات مطالبه‌گرترین مشتریان خود، با چالش‌های جدیدی روبرو هستند.

این وضعیت مستلزم دو چیز است:

1. فرآیندها باید به خوبی تنظیم شوند تا خواص محصول در دقیقترین تلرانس‌ها حفظ شوند و دامنه پراکندگی را کاهش دهند.
2. به حداقل رساندن ریسک‌های عملیاتی که می‌توانند باعث زمان توقف خرابی دستگاه شوند، بر اثربخشی کلی تجهیزات (OEE) فرآیندها تأثیر بگذارند بسیار مهم است.

برای هر دو چالش، ترکیبی از تکنولوژی‌ها و رشته‌هایی همانند داده‌های بزرگ و یادگیری ماشین امکان داشتن بسترهای (پلتفرم‌های) قدرتمندی برای پیش‌بینی، تحلیل اکتشافی و تحلیل توصیفی به منظور تامین موارد زیر را فراهم می‌سازند:

- حسگرهای مجازی: پیش‌بینی‌کننده‌های نقاطی که اندازه‌گیری به صورت فیزیکی دشوار یا غیرممکن است.
- بهینه‌سازی فرآیند از نظر بهره‌وری، کارآئی تجهیز و هزینه‌های تولید.
- تشخیص ریسک‌های عملیاتی که می‌توانند به زمان توقف خرابی برنامه‌ریزی نشده دستگاه‌ها منجر شوند.
- پیش‌بینی تنزل عملکرد تجهیزات.
- تشخیص ریسک‌هایی که کیفیت محصول را به مخاطره می‌اندازند.
- گرفتن دانش تخصصی حاصل از تجربه کارشناسانی که نزدیک به بازنشستگی هستند.

می‌توان به حل مشکلات کیفیت و فرآیند از دیدگاه ارائه شده توسط علم داده‌ها، توسعه مدل‌های تحلیلی برای پیش‌بینی‌های زمان واقعی که می‌توانند به سیستم‌های کنترل وارد شوند یا به عنوان سیستم‌های پشتیبانی تصمیم برای عملیات مورد استفاده قرار گیرند، پرداخت.

### قسمت I – انگیزه

**هدف** - هدف از این متن ارائه مقدمه و معرفی موارد واقعی یکی از رشته‌های صنعت 4.0 - داده‌های بزرگ و تحلیلی - نشان دادن آن است که چگونه علم داده‌ها می‌تواند در ایجاد ارزش و منافع تجاری برای شرکت‌های تولید فولاد از طریق توسعه مدل‌های تحلیلی برای توضیح و پیش‌بینی رفتارهای فرآیند کمک کند. مزایای مورد انتظار از توسعه این رشته‌ها عبارتند از:

عملیاتی:

- کاهش زمانی که در آن خطوط فرآیند زیر حداکثر سرعت خود کار می‌کنند.
- بهبود کارآئی با کاهش زمان توقف خرابی دستگاه.

ارتقای کیفیت:

<sup>1</sup> -Driving Business Value in Industry 4.0: Big Data and Analytics for Steel Process Improvement, IRON & STEEL TECHNOLOGY, JUN 2020.

- کاهش نرخ شکایت.
- کاهش تن محصول انباشته.
- کاهش زمان فرآوری مجدد.
- کاهش محصول فراضه شده.
- کاهش زمانی که در آن خطوط فرآیند زیر حداکثر سرعت خود کار می‌کنند.
- کاهش زمان انبار کردن محصول.
- بهبود زمان تحویل.

### مدل‌های ریاضی در صنعت

**مدل‌های جعبه سفید [باز]** - استفاده از مدل‌های ریاضی در محیط‌های صنعتی چیز جدیدی نیست و برای مقاصد مختلفی به طور گسترده مورد استفاده قرار گرفته‌اند؛ برای مثال، مدل‌هایی برای راه‌اندازی ماشین‌های پیچیده و چندمتغیره مانند دستگاه‌های نورد سرد. مدل‌سازی کلاسیک بر پایه مدل‌های فیزیکی فرآیند است که می‌تواند پارامتری شوند و در برخی موارد از تکنیک‌های بهینه سازی برای یافتن نقاط بهینه عملیاتی استفاده می‌شود. این مدل‌ها عموماً به داده‌های تاریخی کمی نیاز دارند، نگهداری آنها دشوار است و به راحتی قابل سازگار با تغییرات فرآیند نیستند.

**مدل‌های مبتنی بر قواعد** - نوع دیگری از مدل‌ها که غالباً استفاده می‌شود مبتنی بر قواعد تولید است که دارای موتورهای استنتاج می‌باشد که امکان گرفتن دانش تخصصی در هر یک از قواعد و کارکردها را می‌دهد. این مدل امکان پی بردن به موقعیت‌های خاص فرآیندی را فراهم می‌کند، که می‌تواند اقدامات را به سمت تعامل با سایر سیستم‌ها فعال کند یا اینکه هشدارها یا اخطارها را برای اپراتورها فعال کند. به طور کلی، آنها سیستم‌های آسانتری برای تحلیلگران و پردازشگرهای هستند که به منظور پیکربندی قوانین و اقدامات سناریوهای که باید اتخاذ شوند بر روی آنها کار می‌کنند، اما آنها توانایی یادگیری یا تغییر خودکار قواعد را ندارند، وابستگی شدید به متخصصین فرآیند ایجاد می‌کنند.

**مدل‌های یادگیری ماشین (به اصطلاح مدل‌های جعبه سیاه [بسته])** - یادگیری ماشین رشته جدیدی نیست بلکه همراه با قدرت محاسباتی سیستم‌های جاری و توانایی کار با حجم زیادی از داده‌های پشتیبانی شده توسط تکنولوژی‌های داده‌های بزرگ، در سال‌های اخیر به عنوان ابزاری فوق‌العاده قدرتمند ظهور پیدا کرده است. این روش به طور گسترده‌ای در کاربردهای پیچیده، حل مشکلاتی که قبلاً غیرقابل تصور بود استفاده می‌شود. این هم افزایی در را برای نوع جدیدی از مدل ریاضی-آماري باز می‌کند: به اصطلاح "مدل داده-محور". این نوع جدید مدل با استفاده از الگوریتم‌های یادگیری ماشین که با داده‌های تاریخی "پرورده" می‌گردد ساخته می‌شود. در نتیجه، دانستن روابط ریاضی مربوط به فیزیک اساسی با جزئیات، که در بسیاری از موارد مدل‌سازی آنها به دلیل دخالت متغیرهای بی‌شمار و پیچیدگی‌های در برگیرنده آنها عملاً غیرممکن می‌باشد لازم نیست (اگرچه در عمل بسیار با ارزش است). الگوریتم‌های یادگیری ماشین می‌توانند ساختار روابط داده‌ها را گرفته و تا اندازه‌ای یاد بگیرند که در بخش زیر تعریف خواهد شد.

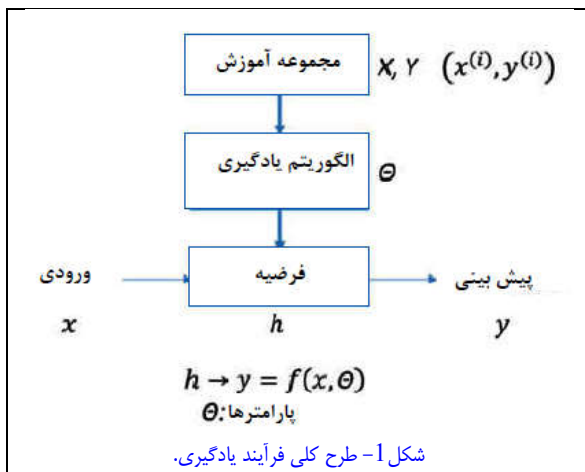
### مدل‌های یادگیری ماشین

به بیانی دقیق [1]، یک برنامه کامپیوتری توانایی یادگیری از تجربه E را دارد، در رابطه با مجموعه‌ای از کارهای عینی T، با اندازه گیری عملکرد P، اگر عملکردی که در آن کارهای T انجام می‌شوند با تجربه E بهبود یابند.

مثال: یک پیش‌بینی‌کننده خواص مکانیکی می‌تواند از داده‌های تاریخی (تجربه E) برای انجام کار T برای پیش‌بینی متغیرهای استحکام تسلیم، ازدیاد طول نسبی و استحکام کششی توسط اندازه‌گیری عملکرد پیش‌بینی P به صورت درصد جمعیت مجموعه آزمون که برای آن خطای پیش‌بینی کمتر یا مساوی با یک حد مشخص است یاد بگیرد. تجربه E "مجموعه آموزش" نامیده می‌شود.

شود. داده‌های مجموعه آموزش در یک مجموعه داده ساماندهی می‌شوند، که یک نظم جدولی از داده‌ها است که در آن هر ستون متغیری است که جزئی از مدل و هر سطر یک مشاهده است. متغیرها فقط باید در ارتباط با متغیرهای مورد پیش‌بینی باشند. این بدان معناست که طراحی یک سیستم بر پایه یادگیری ماشین نیاز به مجموعه‌ای از تصمیمات طراحی شامل موارد زیر دارد:

- انتخاب مجموعه آموزش، که شامل انتخاب متغیرهای مجموعه داده‌ها است. تصمیم‌گیری در مورد اینکه کدام متغیرها بخشی از مدل هستند و کدامیک صرفنظر می‌شوند یکسوگرایی را به مدل وارد می‌کند.



- تابع "هدف" که باید یادگیری شود.

- نمایش این تابع هدف.

- الگوریتمی برای یادگیری تابع هدف از مجموعه آموزش.

- سنجشی از عملکرد برای ارزیابی خوبی پیش‌بینی.

فرآیند یادگیری را می‌توان به عنوان جستجو در فضاهای فرضیه، به منظور یافتن فرضیه‌ای که به بهترین وجه در مثال‌های آموزشی موجود و سایر محدودیت‌ها یا دانش قبلی متناسب شود، مشاهده کرد. فضاهای فرضیه شامل توابع عددی،  $y=f(x, \theta)$  می‌باشد، با  $x$  که یک بردار ورودی،  $x \in X$  است. چالش، دانستن شرایطی است که تحت آن این روش‌های جستجو به سمت یک فرضیه بهینه همگرا می‌شوند؛ برای مثال، با توجه به تابع تقریب که در شکل 1 توضیح داده شده است.

مقصود پیدا کردن یک تابع تقریب  $f(x)$  می‌باشد، که با استفاده از نمونه‌های تجربی تاریخی متناسب شود، نشان داده شده توسط:

$$i = 1, \dots, n \text{ برای } \{(x, y)_i\}$$

متناسب سازی  $f(x)$  به معنای به حداقل رساندن یک تابع ضرر خاص است، که تعداد خطای مورد انتظار انجام شده توسط  $f(x)$  در رابطه با  $y$  را نشان می‌دهد:

$$L(f()) = \frac{1}{n} \sum_i f(x_i) \neq y_i \quad (\text{معادله 1})$$

به طور معمول، توان دوم زیان (مربع زیان) می‌تواند معیار خوبی برای عملکرد متناسب سازی  $f(x)$  باشد:

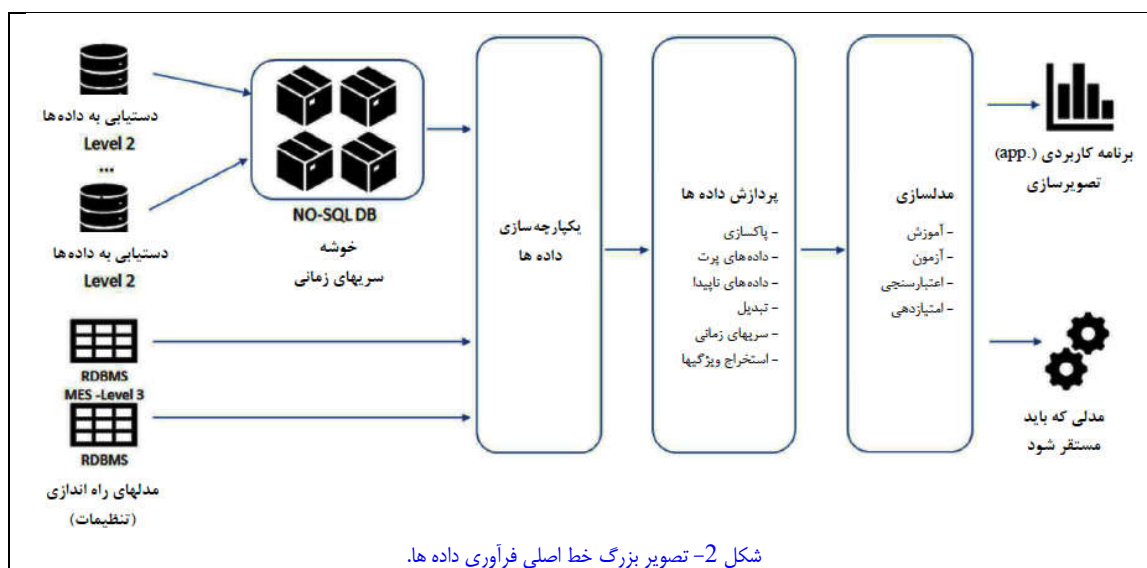
$$\text{مربع زیان} = L(f(x), y) = (f(x) - y)^2$$

**فرآیند KDD<sup>2</sup> (کشف دانش از داده‌ها)** - به طور خلاصه، KDD چارچوبی روشمند برای پیگیری توسعه مدل‌های پیش‌بینی‌کننده یا توضیحی و شامل مراحل زیر است:

- ادغام داده‌ها: ادغام منابع مختلف داده‌ها که بخشی از مجموعه‌های آموزش، آزمون و اعتبارسنجی خواهد بود.
- انتخاب داده‌ها: انتخاب کاندیداهای متغیرها (ستون‌ها) به عنوان بخشی از مدل و انتخاب مشاهدات (سطرها) که کاندیداهای بخشی از مجموعه داده‌ها هستند.
- پاکسازی داده‌ها: فرآیند حذف نویز در داده‌ها، تشخیص ناسازگاری‌ها و راه‌حل برای مقادیر ناپیدا.
- تبدیل داده‌ها: آماده‌سازی داده‌ها به روشی که الگوریتم‌های یادگیری ماشین به آن نیاز دارند.

<sup>2</sup> - Knowledge Discovery From Data

- مهندسی ویژگی‌ها: ایجاد متغیرهای جدید محاسبه شده از متغیرهای موجود، یا موارد منتج از فرآیندهای تجمیع همانند میانگین، شمارش، حداکثر، حداقل و غیره. موضوع خاص در این مرحله عملیات سری‌های زمانی است که بعداً مورد بحث قرار خواهند گرفت.
  - تحلیل اکتشافی: این مرحله در مورد یادگیری از روابط اساسی داده‌ها می‌باشد؛ همبستگی‌ها، علیت و محدودیت‌ها کشف می‌شوند، و دانش استخراج شده برای استفاده از آن در مرحله بعدی سرمایه‌گذاری می‌شود.
  - توسعه مدل: ساخت چند مدل با الگوریتم‌های مختلف یادگیری ماشین و انتخاب بهترین‌ها، پس از فرآیند پالایش یک مدل.
  - اعتبارسنجی و پالایش در تولید: پس از پیاده‌سازی، بهبود مدل می‌تواند ادامه یابد.
- کل فرآیند را می‌توان در **شکل 2** مشاهده کرد.



## پردازش سری‌های زمانی در زمینه صنعتی

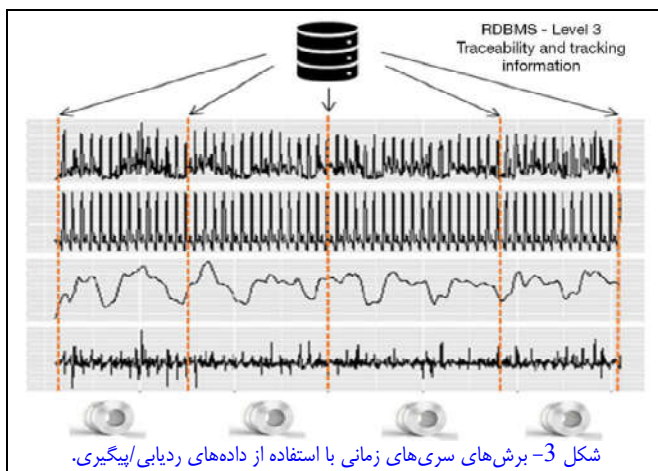
سری‌های زمانی فراوانترین نوع داده‌های یافت شده در فرآیندها و خطوط تولید می‌باشند، زیرا آنها علائمی از حسگرها و سیستم‌های ابزار دقیق هستند.

برای اینکه سری‌های زمانی به درستی پردازش شوند، باید با توجه به واحدهایی که تولید می‌شوند و مواردی که گمان می‌رود هویت مطمئن و ثبت شده و قابلیت ردیابی دارند در زمینه قرار بگیرند. برای مثال، در صنعت محصولات فولادی تخت، واحد تولید شده توپ (رول) یا کلاف ورق فولاد است. هنگامی که کلاف یک فرآیند، برای مثال خط نورد گرم را طی می‌کند، سری‌های زمانی با توجه به لحظات زمانی که کلاف فرآیند را طی می‌کند دارای یک آغاز و یک انتها هستند.

در پایان، متغیرهایی همانند دما، سرعت، نیروهای نورد و غیره، بخشه‌ای از سری‌های زمانی برای هر کلاف؛ به بیان ریاضی، بردارهای "n" نمونه، با فرض نمونه‌گیری زمانی یکنواخت هستند.

برای به دست آوردن بخش‌های سری زمانی مربوط به هر محصول تولیدی (در این حالت، کلاف‌ها)، لازم است اطلاعات قابلیت ردیابی و پیگیری که در سیستم‌های سطح 3 قرار می‌گیرند، یکپارچه شوند، همانطور که در **شکل 3** نشان داده شده است. اگر متغیرها که از خطوط تولید مختلف می‌آیند می‌بایستی در مجموعه داده‌ها یکپارچه شوند، اطلاعات قابلیت ردیابی برای فیلتر

کردن مشاهداتی (کلاف‌هایی) که یک مسیر فرآیند خاص را طی می‌کنند، اساسی است. طرح کلی این وضعیت در شکل 4 نشان داده شده است.



سؤال این است که چگونه متغیرهایی را که سری‌های زمانی نشان می‌دهند در مدل گنجانده شوند. یعنی، اگر برای مورد قبلی، هر مشاهده (سطر) مجموعه داده‌ها با یک کلاف مطابقت داشته باشد، هر متغیر از مجموعه داده‌ها که نمایانگر یک سری زمانی است، متغیری است که دارای چند مقدار است، به این معنی که این موردی تک مقدار نیست بلکه یک بردار از نمونه‌ها است. از آنجا که از این طریق نمی‌توان داده‌ها را پردازش کرد، لازم است که سری‌های زمانی را با استفاده از عملگرهای (اپراتورهای) ریاضی که شناسه (آرگومان) ورودی آن یک بردار است و به یک عامل عددی

مقیاس منتج می‌شود، به یک پیش-پردازش به نام استخراج ویژگی ارسال کرد.

تنوع زیادی از اپراتورها برای استخراج ویژگی، از ساده‌ترین آنها (همانند میانگین، واریانس، حداکثر، حداقل) تا عملگرهای پیچیده (همانند تبدیل سریع فوریه، موجک (wavelets) و غیره) وجود دارد [2].

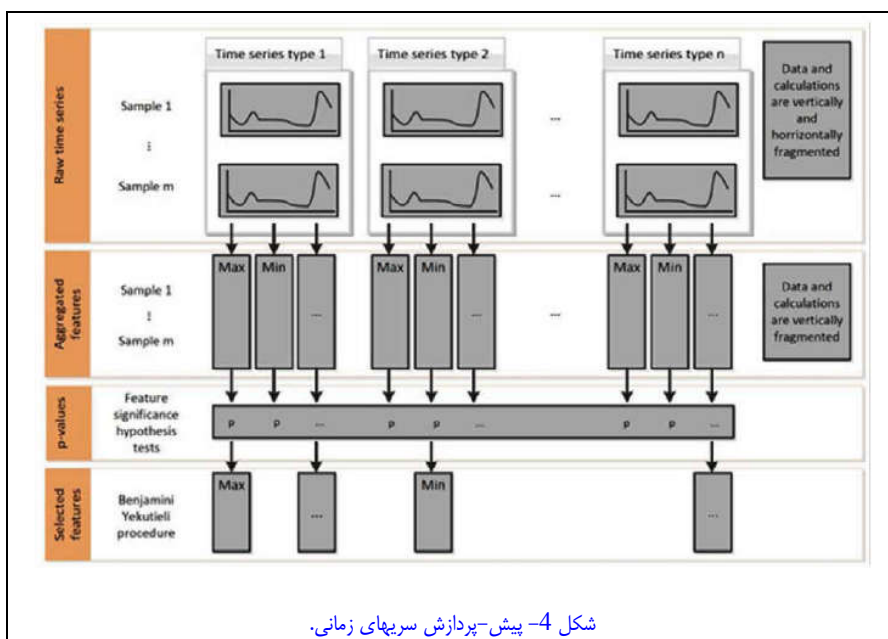
این ویژگی‌های استخراج شده، به همراه سایر متغیرهای فرآیند که ذاتاً تک مقدار هستند به متغیرهای مجموعه داده‌ها تبدیل می‌شوند. اما، از آنجا که سری‌های زمانی معمولاً نویزی و حاوی زوائد هستند، لازم است که آنها را به فرآیند فیلتر کردن ارسال کرد تا در مورد درج آنها در مجموعه داده‌ها تصمیم‌گیری شود.

بنابراین، باید توازن بین استخراج ویژگی‌های قابل توجه اما احتمالاً شکننده و ویژگی‌های قوی اما احتمالاً غیرمهم حفظ شود. برخی از ویژگی‌ها همانند میانه (median) تحت تأثیر قوی داده‌های پرت (غیرعادی) قرار نمی‌گیرند، در حالی که برخی دیگر همانند حداکثر مقدار سری‌های زمانی

ذاتاً شکننده خواهند بود.

**اهمیت ویژگی‌ها برای تشخیص ناهنجاری آماری** - ناهنجاری الگویی است که از رفتار مورد انتظار یا عادی انحراف دارد. بنابراین، تشخیص ناهنجاری سرخ‌ها را بررسی می‌نماید و صفات را برای کشف الگوهای غیرعادی مقایسه می‌کند. در بسیاری از مواقع، ناهنجاری‌های متعددی در گروه‌ها، نه فقط تک اتفاقات وجود دارد.

ناهنجاری‌ها نوعی از اختلال یا عملکرد غیرعادی یک ماشین یا



شکل 4- پیش-پردازش سری‌های زمانی.

فرآیند را نشان می‌دهند. از طرفی، تجزیه و تحلیل علامت‌ها از طریق توسعه مدل‌هایی برای تشخیص ناهنجاری‌ها و ایجاد اختلالات و هشدارها به اپراتور، به حل این مسئله کمک می‌کند.

تشخیص ناهنجاری به دو قسمت تقسیم می‌شود: (1) توسعه ویژگی‌های مناسب، و (2) تغذیه این ویژگی‌ها در یک مدل آماری و یادگیری ماشین که ناهنجاری‌های موجود در ویژگی‌ها را تشخیص می‌دهد. در صورت انجام صحیح، ناهنجاری‌های تشخیص داده شده همبستگی بسیار خوبی با اختلالات در محل خواهد داشت و می‌توان از آنها برای ایجاد هشدارهایی با میزان کم مثبت کاذب استفاده کرد. ممکن است چنین به نظر برسد که پیچیدگی چنین سیستم‌هایی بر بخش آماری متمرکز است. اما، به خوبی شناخته شده است که انتخاب ویژگی در کاربردهای واقعی مهم است.

## قسمت II- موارد استفاده واقعی

**پیش‌بینی خواص مکانیکی در کارخانه نورد گرم-** در صنعت فولاد، خواص مکانیکی فولاد متمایزکننده‌ترین ویژگی‌های اصلی در بین انواع مختلف محصولات است. خواصی از قبیل استحکام کششی، استحکام تسلیم و ازدیاد طول نسبی فولاد پارامترهای اساسی هستند در هنگام تصمیم‌گیری در مورد اینکه با کدام مواد در صنعت ساخت‌وساز یا در صنعت خودرو کار شود. بعلاوه، این خواص برای تعیین پارامترهایی که در فرآیند تولید فولاد مورد استفاده قرار می‌گیرند نیز بکار می‌روند.

خواص مکانیکی معمولاً در بخش آزمایش‌های فیزیکی با نمونه‌های برداشته از مواد در پایان فرآیند سرد اندازه‌گیری می‌شوند. این شیوه، گرچه قابل اعتماد است، اما معایب مختلفی دارد. اول، نمونه معمولاً از یک انتهای کلاف بدست می‌آید، یعنی جایی که بیشترین تغییرپذیری در شاخص‌های آن، به دلیل مسائل ذاتی فرآیند پیدا می‌شود. دوم، خواص مکانیکی می‌توانند در طول کلاف متفاوت باشند، که در حال حاضر تشخیص آن غیرممکن است. سوم، تحویل نتایج آزمایشگاهی فوری نیست، بنابراین بسیاری از محصولات انباشته می‌شوند؛ این باعث افزایش زمان و هزینه‌های تولید می‌گردد.

از این رو یک مدل پیش‌بینی‌کننده برای تخمین خواص مکانیکی کلاف در هنگام خروج از خط نورد سودمند و مطلوب است، زیرا امکان کار بر روی محصول در فرآیند پایین‌دستی و اصلاح انحرافات را فراهم می‌کند، بنابراین از افت کلاس محصول جلوگیری می‌شود.

از آنجا که خواص مکانیکی به میزان زیادی به نوع فولاد بستگی دارند، مدل‌های مختلفی برای سه کلاس که بر اساس ترکیب

شیمیایی تقسیم می‌شوند تهیه شدند:

- فولاد نیوبیوم دار (Nb)
- فولاد کربنی (C)
- فولاد وانادیوم دار (V)

برای هر نوع فولاد، استحکام کششی، استحکام تسلیم و ازدیاد طول نسبی پیش‌بینی شد، بنابراین در کل 9 مدل وجود داشت. معیارهای ارزیابی تناسب مدل همانطور که در **جدول 1** نشان داده شده است، یک محدوده تolerانس انحراف پیش‌بینی از مقدار واقعی و یک حداقل درصد که پیش‌بینی‌های واقع شده در آن محدوده برای مدل مناسب در نظر گرفته می‌شوند تعیین گردید.

مجموعه داده‌های مورد استفاده برای این مورد شامل داده‌های فرآیندی خط نورد گرم (HRM) می‌باشد که دوره تقریباً 7 ماهه تولید را در بر می‌گیرد و شامل متغیرهای مربوط به فرآیند (دماها، سرعت‌های نوار ورق، کاهش‌های سطح مقطع و غیره) و متغیرهای مربوط به ترکیب شیمیایی فولاد فرآوری شده است. هر مشاهده (سطر) کلافی را نشان می‌دهد که توسط HRM فرآوری شده و خواص مکانیکی آن در آزمایشگاه مشخص شده است. مشاهدات به سه دسته توضیح داده شده قبلی مطابق ترکیب شیمیایی فولاد تقسیم شدند.

تمام مجموعه داده‌ها در معرض یک فرآیند پاکسازی قرار گرفتند: متغیرهای غیرمرتبط با خواص مکانیکی شناسایی و صرف نظر شدند، همچنین متغیرهایی با نسبت بالایی از مقادیر ناپیدا؛ پس از آن، مشاهدات با مقادیر ناپیدا یا حذف شده یا با یک مقدار دلخواه (برای مثال، ستون میانگین) بسته به ماهیت متغیرها پر می‌شوند. توزیع متغیرها در مجموعه داده‌های حاصل برای شناسایی مقادیر پرت افتاده مورد بررسی قرار گرفت و مشخص شد که آیا آنها خطاهای اندازه‌گیری، خطاهای ثبت یا مقادیر واقعی را نشان می‌دهند و مطابق آن با آنها رفتار شد.

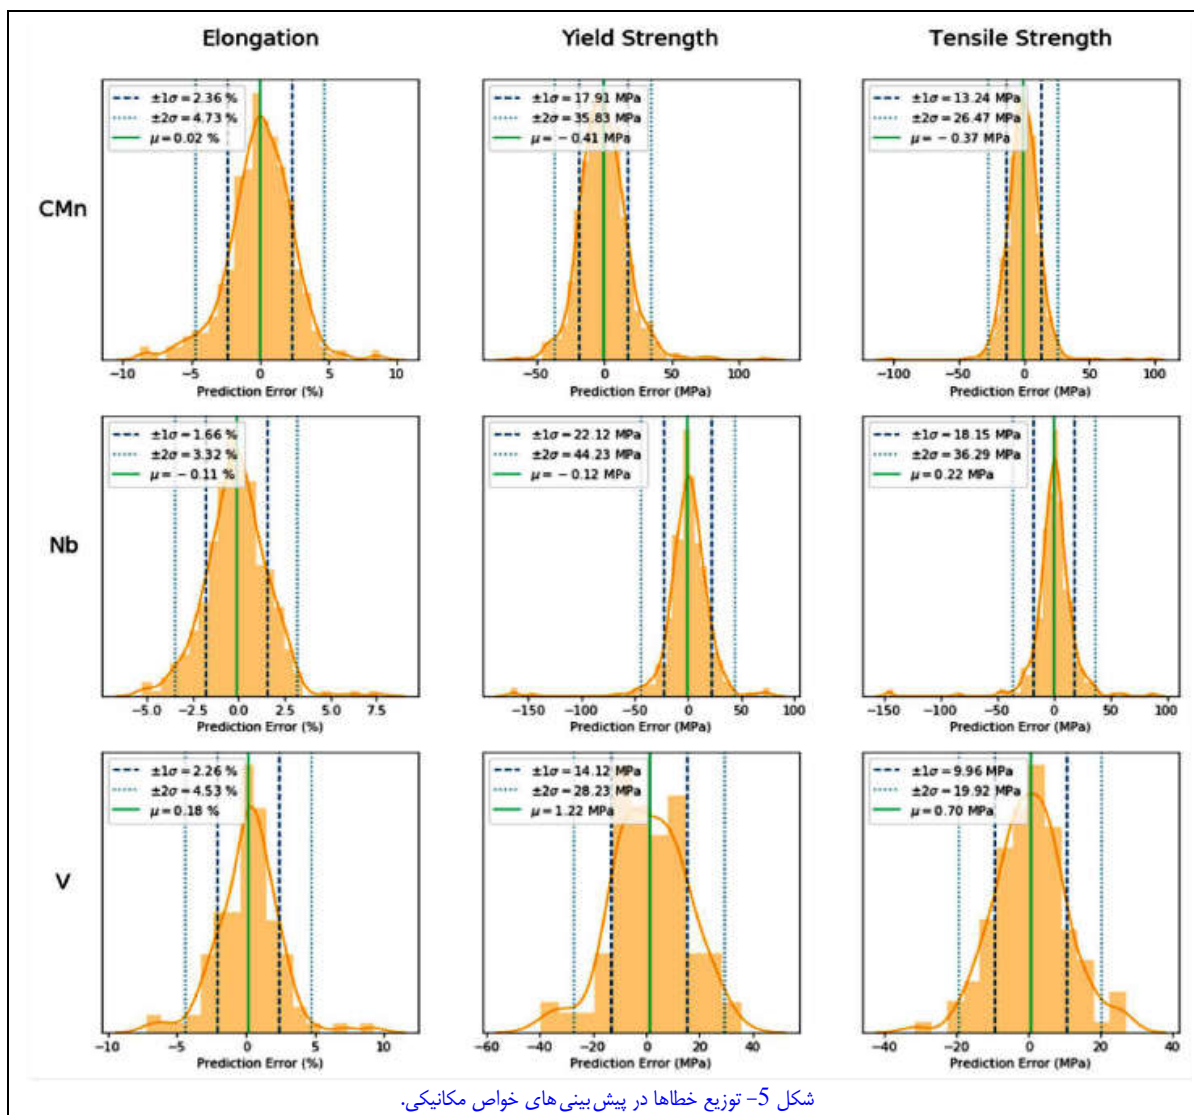
جدول 2- امتیاز مدلها برای هر نوع فولاد.

خاصیت مکانیکی	امتیاز* به ازای هر نوع فولاد		
	CMn	Nb	V
ازدیاد طول نسبی	%83.66	%93.44	%87.50
استحکام تسلیم	%82.01	%81.36	%85.16
استحکام کششی	%92.41	%87.66	%94.53

\* درصد پیش‌بینی‌های قرار گرفته در داخل محدوده تolerانسهای نشان داده شده در جدول 1.

مجموعه داده‌ها به زیرمجموعه آموزش و زیرمجموعه آزمون تقسیم شد. برای هر نوع فولاد، یک الگوریتم یادگیری ماشین با نام Gradient Boosting Regressor [4] برای پیش‌بینی هر خاصیت مکانیکی

استفاده شد. این الگوریتم با زیرمجموعه پرورده شد و اعتبارسنجی گردید و سپس با استفاده از زیرمجموعه آزمون ارزیابی شد. پس از تنظیم پارامترهای الگوریتم، امتیازات حاصل از همه مدل‌ها از آستانه‌های تعیین شده پیشی گرفتند (جدول 2 را ببینید). توزیع خطاهای پیش‌بینی برای هر مدل را می‌توان در شکل 5 مشاهده کرد.

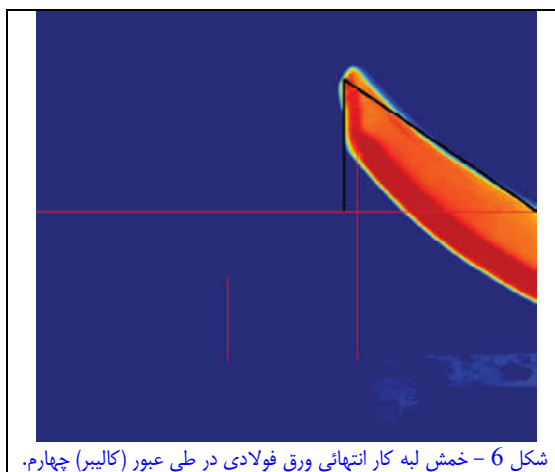


شکل 5- توزیع خطاها در پیش‌بینی‌های خواص مکانیکی.

**پیش بینی خمش لبه کار انتهائی در دستگاه نورد گرم دو طرفه-** در طی فرآیند نورد گرم، ضخامت اسلب تا 99 درصد کاهش می‌یابد. در خط خاصی که این پروژه انجام شده است، بیشتر این کاهش در یک دستگاه نورد اولیه دو طرفه 4 غلتکی انجام می‌شود. در دستگاه نورد اولیه، اسلب فولادی که از کوره می‌آید، از مجموعه‌ای از غلتک‌های افقی و عمودی به صورت رفت و برگشتی، یعنی چند بار عبور از یک مجموعه غلتک، عبور می‌کند. در حین عبور اسلب در دستگاه نورد دو طرفه، گاهی عیب خمیدگی در نوک ورق در حال فرآوری وجود دارد، همانطور که در **شکل 6** مشاهده می‌شود. این عیب، به دلیل شکلی که ارائه می‌دهد، اصطلاحاً به SKI یا ski معروف است. بسته به جهت و بزرگی (ارتفاع) آن، می‌تواند باعث شود اسلب با قاب مرحله بعدی برخورد کند یا در غلتک‌های نقاله وارد شود، در نتیجه به تجهیزات صدمه زده و باعث توقف تولید گردد.

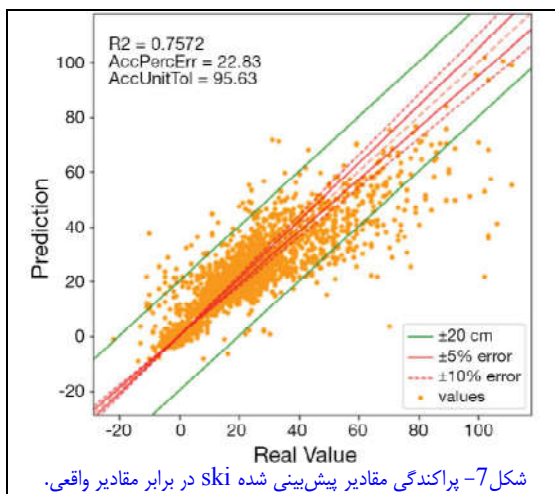
راهکارهایی در مطالب منتشره وجود دارد که مشکل SKI را از طریق مدل‌سازی المان محدود و شبیه‌سازی، از قبیل منابع 6 و 7 حل کرده‌اند. مطابق گزارش‌های آنها، ارتفاع SKI عمدتاً به تفاوت دمای بین وجه فوقانی و تحتانی ماده، اختلاف سرعت بین غلتک‌ها، ضرایب اصطکاک بین غلتک‌ها و ورق و همچنین اختلاف قطر بین غلتک‌ها بستگی دارد.

برای این پروژه خاص، هدف تعیین متغیرهای فرآیندی بود که بر وجود عیب تأثیر می‌گذارند و می‌توانند با پیش‌بینی ارتفاع SKI یا بزرگی خمش لبه کار انتهائی، مشخص کنند کدام اسلب‌ها مستعدتر به بروز SKI هستند. مجموعه داده‌های ویژگی‌های اولیه فرآیند شامل متغیرهایی از مراحل مختلف فرآیند و مشخصات محصول، عمدتاً کوره گرمایش و داده‌های تنظیمات دستگاه نورد دو طرفه بود. یک سیستم ترموگرافی مادون قرمز (IRT)، بزرگی، جهت و زاویه SKI را که به عنوان هدف مورد استفاده قرار



می‌گرفت، فراهم کرد. گروه‌های متغیر مورد استفاده برای مدل‌سازی عبارتند از: روند تغییرات (پروفیل) حرارتی اسلب، غلتک‌ها، تنظیمات دستگاه نورد دو طرفه، سرعت چرخش غلتک و مشخصات اسلب.

گردآوری جامع داده‌ها برای به حداقل رساندن احتمال داشتن داده‌های ناکافی یا عدم توصیف کامل پدیده انجام شد. پس از مرحله پاکسازی داده‌ها و مهندسی متغیرها، مشخص شد که این پدیده تنها با تعداد کمی از متغیرها قابل توضیح نیست. تجزیه و تحلیل مؤلفه اصلی بر روی داده‌ها انجام شد، که نشان داد 95 درصد از واریانس توسط 21 مؤلفه اصلی از یک مجموعه داده‌ها با 223 متغیر توضیح داده شده، که 85 متغیر آنها محاسبه می‌شوند.



مشاهدات نادرست (برای مثال، تاریخ‌های اشتباه ناشی از عملیات دستی خط) در مجموعه داده‌ها قبل از مدل‌سازی حذف شدند. سپس مجموعه داده‌ها به صورت تصادفی به زیرمجموعه‌های آموزش و آزمون در نسبت 80:20، به ترتیب با 12782 و 3364 مشاهده تقسیم شد. سپس مشاهدات آموزش برای داده‌های پرت، که از داده‌ها حذف شدند بررسی شدند. همراستائی نیز مورد بررسی قرار گرفت و متغیرهای بالاترین همراستائی برای افزایش اختلافات و بهبود قدرت پیش‌بینی آنها به نسبت‌های مختلف تبدیل شدند.

یک متا-مدل (مدل فراگیر) از چهار مدل جداگانه بهترین عملکرد را در آزمون‌های مختلف ارائه داد. چنین مدل‌های منفردی عبارت بودند از:



یک شبکه عصبی عمیق، یک مدل XGB [4]، مدل جنگل تصادفی و یک مدل درخت اضافی. سپس برای بدست آوردن پیش‌بینی نهایی، متوسط پیش‌بینی مدل‌های منفرد محاسبه شد. مدل‌سازی با Python libraries sklearn [3] و keras [5] انجام شد، در حالی که کلیه پیش‌پردازش داده‌ها در R انجام شد.

بهترین مدل دارای  $R^2=0.75$  در مجموعه آزمون بود، 95 درصد پیش‌بینی‌ها دارای خطای مطلق زیر 20 cm و 61 درصد خطای زیر 4 cm بودند. تابع توزیع تجمعی خطاهای مطلق در شکل 7 نشان داده شده است. این مدل در حال حاضر اجرا می‌شود، با هدف پیش‌بینی ترکیب تنظیمات احتمالاً خطرناکی که ممکن است به بزرگی نایمن خمش لبه کار انتهایی منجر شوند. سیستم پیش‌بینی با داده‌های تنظیم تغذیه می‌شود و در صورت تشخیص چنین وضعیت نایمی، زنگ هشدار ایجاد خواهد شد. توزیع خطا در شکل 8 و تابع توزیع تجمعی خطاهای مطلق در شکل 9 نشان داده شده است.

### نتیجه‌گیری

همانطور که در مثال‌ها مشاهده می‌شود، استفاده از تحلیل‌های صنعتی برای پیش‌بینی رفتارهای فرآیند نه فقط یک فرمول‌بندی نظری که یک واقعیت است. اگر شرایط لازم برای توسعه مدل‌های تحلیلی برآورده شود، یعنی در دسترس بودن داده‌های تاریخی، کیفیت داده‌ها، بخش مرتبط متغیرهای فرآیندی ابزار دقیق فرآیند و در دسترس بودن متخصصان با تجربه در حوزه برای کار در یک تیم چند رشته‌ای با دانشمندان علم داده‌ها، امکان ایجاد ارزش از طریق نوآوری‌های بر پایه تحلیلی وجود دارد.

این مسیر آسانی نیست، اما ارزش تجاری بالقوه‌ای که تولید می‌شود دلیلی بر بازده سرمایه‌گذاری قابل توجه است و می‌تواند سازمان‌ها را قادر سازد تا استراتژی‌های جدید تمایز در بازار فولاد را توسعه دهند.

### منابع:

1. T. Mitchell, Machine Learning, McGraw-Hill Inc., New York, N.Y., USA, 1997.
2. M. Christa, A. Kempa-Liehrb and M. Feindta, "Distributed and Parallel Time Series Feature Extraction for Industrial Big Data Applications," October 2016.
3. F. Pedregosa et al., "Scikit-learn: Machine Learning in Python," JMLR 12, 2011, pp. 2825–2830.
4. T. Chen and C. Guestrin, "Xgboost: A Scalable Tree Boosting System," Proceedings of the 22nd ACM International Conference on Knowledge Discovery and Data Mining, ACM, 2016, pp. 785–794.
5. F. Chollet et al., Keras, GitHub repository, 2015, available on <https://github.com/fchollet/keras>.
6. D. Anders et al., "A Dimensional Analysis of Front-End Bending in Plate Rolling Applications," Journal of Materials Processing Technology, Vol. 212.6, 2012, pp. 1387–1398.
7. T. Kiefer and A. Kugi, "Modeling and Control of Front-End Bending in Heavy Plate Mills," IFAC Proceedings, Vol. 40.11, 2007, pp. 231–236.