استفاده از مدل‌های یادگیری ماشین برای پیش‌بینی و بهینه‌سازی مصرف انرژی در خطوط تولید صنایع غذایی

سماء جعفری افشار s.afshar.ac@gmail.com

چکیده

در سال‌های اخیر، مدیریت بهینه مصرف انرژی در صنایع غذایی به دلیل افزایش قیمت انرژی و الزام به کاهش ردپای کربن، به یکی از چالش‌های کلیدی این صنعت تبدیل شده است .[1]این مطالعه با هدف بررسی کاربرد مدل‌های یادگیری ماشین در پیش‌بینی و بهینه‌سازی مصرف انرژی در خطوط تولید صنایع غذایی انجام شد. داده‌های مورد استفاده شامل مجموعه‌ای از داده‌های عملیاتی استخراج‌شده از حسگرهای متصل به سامانه نظارت صنعتی (SCADA) بوده است که مصرف برق، مصرف بخار، دما، فشار و سایر پارامترهای فرآیندی را ثبت می‌کنند .[2] چهار خانواده مدل—شبکه عصبی مصنوعی (ANN)، جنگل تصادفی(Random Forest) ، رگرسیون بردار پشتیبان (SVR) و گرادیان بوستینگ—(XGBoost) آموزش داده شدند و عملکرد آن‌ها با استفاده از معیارهایMAE ، RMSEو R^2 مقایسه گردید [3]، .[4]نتایج تحقیق نشان داد که مدل‌های مبتنی بر بوستینگ) خصوصاً (XGBoost و ANN در اکثر سناریوهای آزمایش‌شده، دقت بالاتری در پیش‌بینی مصرف انرژی ارائه می‌کنند .[5] بر اساس پیشنهادهای استخراج‌شده از خروجی مدل‌ها—از جمله تنظیم دما و زمان‌بندی فرآیندها، نگهداری پیش‌بینانه تجهیزات، و بهینه‌سازی عملکرد کمپرسورها—امکان کاهش ۱۰ تا ۲۰ درصدی مصرف انرژی در خطوط تولید فراهم می‌شود .[6] این پژوهش یک چارچوب کاربردی برای توسعه سیستم‌های مدیریت انرژی مبتنی بر داده ارائه می‌دهد و نشان می‌دهد که ترکیب مدل‌های یادگیری ماشین با فناوری‌های اینترنت اشیا (IoT) و دوقلوی دیجیتال (Digital Twin) می‌تواند زمینه‌ساز بهبود هم‌زمان کارایی اقتصادی و پایداری زیست‌محیطی در صنایع غذایی باشد .[7]

کلمات کلیدی

یادگیری ماشین، بهینه‌سازی انرژی، صنایع غذایی، شبکه عصبی، جنگل تصادفی، XGBoost, پیش‌بینی مصرف انرژی , IoT, Digital Twin, نگهداری پیش‌بینانه

۱–مقدمه

صنایع غذایی یکی از بزرگ‌ترین مصرف‌کنندگان انرژی در میان صنایع تولیدی هستند و به دلیل ماهیت فرآیندهای حرارتی، سرمایشی، خشک‌کردن، پخت و بسته‌بندی، سهم قابل‌توجهی از انرژی الکتریکی و گرمایی را در زنجیره تأمین مواد غذایی به خود اختصاص می‌دهند .[8]افزایش مداوم هزینه‌های انرژی، فشارهای زیست‌محیطی ناشی از انتشار گازهای گلخانه‌ای و الزام صنایع به رعایت استانداردهای مدیریت انرژی، اهمیت بهینه‌سازی مصرف انرژی را بیش از پیش آشکار کرده است .[9]در چنین شرایطی، استفاده از روش‌های نوین مبتنی بر داده و هوش مصنوعی می‌تواند تحولی جدی در مدیریت انرژی ایجاد نماید .[10]

یکی ازpromising ترین ابزارها در این حوزه، مدل‌های یادگیری ماشین (Machine Learning) است. یادگیری ماشین با تحلیل داده‌های حجیم و پیچیده ٔ به‌دست‌آمده از حسگرها، دستگاه‌های صنعتی و سامانه‌هایSCADA ، قادر است الگوهای مصرف انرژی را شناسایی کرده، رفتار آینده را پیش‌بینی نموده و حتی پیشنهادهایی برای کاهش مصرف ارائه دهد .[11]ماهیت غیرخطی و پیچیده فرآیندهای صنایع غذایی، مانند تبخیر، پخت، تخمیر، پاستوریزاسیون، انجماد و خشک‌کردن، موجب می‌شود روش‌های کلاسیک آماری توان کافی برای تحلیل دقیق مصرف انرژی نداشته باشند .[12]در مقابل، مدل‌های یادگیری ماشین مانند شبکه‌های عصبی مصنوعی(ANN) ، جنگل تصادفی(RF) ، رگرسیون بردار پشتیبان (SVR)و مدل‌های گرادیان بوستینگ (XGBoost, LightGBM) توانایی چشمگیری در مدل‌سازی الگوهای غیرخطی، سیستم‌های وابسته به زمان و داده‌های دارای نویز از خود نشان داده‌اند .[13]

از سوی دیگر، با گسترش فناوری‌های اینترنت اشیا(IoT) ، امکان ثبت لحظه‌ای پارامترهای فرآیندی مانند دما، فشار، بار موتور، مصرف بخار، مصرف برق، رطوبت، و وضعیت تجهیزات فراهم شده است. ترکیب داده‌های IoT با الگوریتم‌های یادگیری ماشین، چارچوبی نوین برای مدیریت هوشمند انرژی ایجاد می‌کند که می‌تواند ضمن کاهش مصرف انرژی، کاهش هزینه تولید، افزایش طول عمر تجهیزات و ارتقای بهره‌وری را به‌دنبال داشته باشد .[14]

تحقیقات بین‌المللی نشان می‌دهد که استفاده از الگوریتم‌های ML در خطوط تولید مواد غذایی قادر است بین ۱۰ تا ۲۵ درصد مصرف انرژی را کاهش دهد، در حالی‌که دقت پیش‌بینی مصرف انرژی در بسیاری از مدل‌ها فراتر از ۹۰ درصد گزارش شده است .[15]این امر نشان‌دهنده ظرفیت بالای این فناوری برای افزایش بازدهی انرژی، کاهش ردپای کربن و کمک به دستیابی صنایع به استانداردهای مدیریت انرژی مانند ISO 50001 است .[16]

با توجه به اهمیت موضوع و خلأ موجود در پژوهش‌های داخلی، این مقاله با هدف بررسی کاربرد مدل‌های یادگیری ماشین در پیش‌بینی و بهینه‌سازی مصرف انرژی در خطوط تولید صنایع غذایی تدوین شده است. در این پژوهش، انواع مدل‌های ML معرفی شده، داده‌های موردنیاز تشریح گردیده و عملکرد مدل‌ها با استفاده از شاخص‌های آماری معتبر مورد مقایسه قرار گرفته است. همچنین کاربردهای عملی این روش‌ها در صنایع مختلف غذایی مانند لبنیات، نانوایی صنعتی، نوشیدنی‌ها و خشک‌کردن محصولات کشاورزی تشریح شده و پیشنهادهایی برای استقرار سیستم مدیریت انرژی هوشمند ارائه شده است .[17]

۲–پیشینه پژوهش

بهینه‌سازی مصرف انرژی در صنایع غذایی طی دو دهه اخیر مورد توجه بسیاری از پژوهشگران قرار گرفته است؛ با این حال توسعه روش‌های نوین مبتنی بر داده و استفاده از مدل‌های یادگیری ماشین (Machine Learning – ML) در این حوزه به‌صورت جدی از سال ۲۰۱۵ به بعد رشد چشمگیری داشته است .[18]پیچیدگی فرآیندهای صنایع غذایی، رفتارهای غیرخطی، وابستگی شدید به متغیرهای فرآیندی و تأثیرپذیری از شرایط محیطی، ضرورت استفاده از مدل‌های ML را افزایش داده است .[19]در ادامه، مهم‌ترین پژوهش‌های بین‌المللی بین سال‌های ۲۰۱۸ تا ۲۰۲۵ مرور می‌شود.

مطالعات مرتبط با پیش‌بینی مصرف انرژی در صنایع غذایی

»کومار و همکاران» (۲۰۱۹) از مدل شبکه عصبی مصنوعی (Artificial Neural Network – ANN) برای پیش‌بینی مصرف انرژی در فرآیند پاستوریزاسیون شیر استفاده کردند. نتایج نشان داد که مدل ANN توانست با دقت ۹۳ درصد رفتار مصرف انرژی را پیش‌بینی کند و جایگزینی مناسبی برای مدل‌های تجربی خطی باشد .[20]

در مطالعه‌ای مشابه، «چن و همکاران» (۲۰۲۰) مدل رگرسیون بردار پشتیبان (Support Vector Regression – SVR)را برای پیش‌بینی انرژی الکتریکی مصرفی در سیستم‌های سرمایشی کارخانه‌های فرآوری گوشت توسعه دادند. دقت بالای SVR در محیط‌های دارای نویز و داده‌های محدود از مهم‌ترین مزیت این مدل گزارش شد.[21] »نیکولائو و همکاران» (۲۰۲۱) با استفاده از جنگل تصادفی (Random Forest – RF) مصرف انرژی در خطوط تولید نوشیدنی‌های گازدار را تحلیل کردند. این پژوهش نشان داد که RF قادر است اهمیت متغیرهایی مانند دمای نقاط بحرانی، سرعت پمپ‌ها و فشار خطوط را به‌صورت دقیق مشخص کند. این موضوع به تشخیص عوامل اصلی انرژی‌بر کمک زیادی نمود .[22].

در سال ۲۰۲۳، «سینگ و همکاران» با استفاده از مدل گرادیان بوستینگ تقویت‌شده (Extreme Gradient Boosting – XGBoost)موفق شدند مصرف انرژی بخش خشک‌کردن میوه را با خطای کمتر از ۵ درصد پیش‌بینی کنند. این مطالعه یکی از دقیق‌ترین مدل‌های مبتنی بر داده در صنایع غذایی محسوب می‌شود .[23]

پژوهش‌های مرتبط با بهینه‌سازی انرژی مبتنی بر داده

پژوهش‌های اخیر نشان داده‌اند که استفاده از ML فقط در پیش‌بینی مصرف انرژی کاربرد ندارد، بلکه می‌تواند ابزار مهمی برای بهینه‌سازی نیز باشد .[24] در مطالعه «ژانگ و همکاران» (۲۰۲۰)، ترکیب یادگیری ماشین با اینترنت اشیا (Internet of Things – IoT)در یک کارخانه فرآوری چای منجر به کاهش ۱۶ درصدی مصرف انرژی شد. الگوریتم‌ها با تحلیل داده‌های مداوم، نقاط اتلاف انرژی را شناسایی کرده و سیستم به‌صورت خودکار تنظیمات دما و رطوبت را اصلاح می‌کرد .[25] مارتینز و همکاران» (۲۰۲۱) مدل دوقلوی دیجیتال (Digital Twin – DT) مبتنی بر ML را برای خط تولید ماکارونی توسعه دادند. این مدل امکان شبیه‌سازی کل فرآیند را فراهم کرد و نشان داد که تنظیم زمان اقامت محصول در خشک‌کن می‌تواند تا ۱۲ درصد مصرف انرژی را کاهش دهد .[26] در پژوهش «ال‌یزدی و همکاران» (۲۰۲۲)، الگوریتم تحلیل مؤلفه‌های اصلی (Principal Component Analysis – PCA) برای کاهش ابعاد داده و مدل‌سازی رفتار مصرف انرژی در بخش نانوایی صنعتی استفاده شد. نتایج نشان داد که حذف متغیرهای با اهمیت پایین اثر منفی بر دقت مدل ندارد و می‌تواند زمان پردازش را به میزان قابل توجهی کاهش دهد .[27].

مطالعات مرتبط با نگهداری پیش‌بینانه و مدیریت تجهیزات انرژی‌بر

»»سوباش و همکاران» (۲۰۲۰) نشان دادند که استفاده از یادگیری ماشین برای نگهداری پیش‌بینانه (Predictive Maintenance)کمپرسورهای سرمایشی می‌تواند تا ۳۰ درصد مصرف انرژی را کاهش دهد. در این مطالعه، الگوریتم‌ها با تحلیل ارتعاش، بار موتور و دمای خروجی، زمان خرابی را پیش‌بینی می‌کردند و از افزایش مصرف انرژی در حالت‌های نیمه‌خراب جلوگیری می‌شد .[28]در مطالعه‌ای جدید (۲۰۲۴)، ترکیب اینترنت اشیای صنعتی (Industrial Internet of Things – IIoT)با مدل‌های گرادیان بوستینگ (Light Gradient Boosting Machine – LightGBM) در کارخانه تولید شیر خشک بررسی شد. این مدل توانست الگوهای غیرعادی مصرف انرژی را تا ۴۸ ساعت پیش از وقوع تشخیص دهد و هشدارهای دقیق ارائه کند .[29].

خلاهای پژوهشی و ضرورت انجام مطالعه حاضر

بررسی مطالعات انجام‌شده، چند خلأ مهم را آشکار می‌کند:

- بیشتر پژوهش‌ها روی صنایع خاص تمرکز داشته‌اند و مدل‌های ارائه‌شده به‌صورت عمومی قابل تعمیم نیستند [30].
- داده‌های مربوط به مصرف انرژی در صنایع غذایی ایران بسیار محدود و پراکنده است .[31]
- مقایسه جامع مدل‌های مختلف(ANN) ML ، SVR، RF، (XGBoostدر یک چارچوب واحد کمتر انجام شده است .[32]
- ترکیب ML با دیجیتال‌توین (Digital Twin – DT) و اینترنت اشیا (IoT) در مطالعات داخلی کمتر مورد توجه قرار گرفته است. اغلب پژوهش‌ها تنها به «پیش‌بینی» پرداخته‌اند و به «بهینه‌سازی عملیاتی (Operational Optimization)کمتر توجه شده است .[33]

به همین دلیل، پژوهش حاضر با هدف ارائه یک چارچوب جامع برای پیش‌بینی و بهینه‌سازی مصرف انرژی در خطوط تولید صنایع غذایی با استفاده از مدل‌های یادگیری ماشین انجام شده است .[34]

۳–اهداف پژوهش

صنایع غذایی برای تولید محصولاتی مانند شیر، ماست، نوشیدنی، نان صنعتی و میوه خشک، از مقدار زیادی انرژی استفاده می‌کنند. بخش قابل‌توجهی از این انرژی در سیستم‌های گرمایشی، سرمایشی، خشک‌کن‌ها، پمپ‌ها و موتورهای الکتریکی مصرف می‌شود. با این حال، معمولاً مدیران کارخانه نمی‌دانند در هر ساعت یا هر روز دقیقاً چه مقدار انرژی مصرف می‌شود و چه عواملی باعث افزایش مصرف می‌گردد .[35]

بر اساس این چالش‌ها، پژوهش حاضر با سه هدف اصلی انجام شده است:

هدف ۱: پیش‌بینی مقدار انرژی مصرفی در کارخانه

یعنی قبل از اینکه دستگاه‌ها روشن شوند، بتوان پیش‌بینی کرد که امروز یا این ساعت چه مقدار انرژی مصرف خواهد شد [36].

هدف ۲: شناخت دقیق عواملی که بیشترین انرژی را مصرف می‌کنند

مثال‌هایی از این عوامل عبارتند از:

- کدام دستگاه انرژی‌برتر است؟
- کدام مرحله تولید باعث افزایش مصرف انرژی می‌شود؟
- آیا تنظیم نبودن دما باعث افزایش مصرف انرژی می‌شود؟

تحلیل اهمیت متغیرها یکی از نقاط قوت مدل‌های ML است .[37]

هدف ۳: ارائه راهکارهای عملی برای کاهش مصرف انرژی

برای مثال:

- تنظیم صحیح دمای پاستوریزاتور
- تغییر زمان‌بندی روشن بودن برخی دستگاه‌ها
- پیشنهاد تعمیر پیشگیرانه تجهیزات قبل از خرابی

این راهکارها بر اساس نتایج مدل‌های یادگیری ماشین قابل استخراج هستند .[38]

۴–سؤالات پژوهش

این پژوهش به دنبال پاسخ به پرسش‌های زیر است:

سؤال ۱:

آیا می‌توان با استفاده از روش‌های قابل‌اجرا و کم‌هزینه، مقدار انرژی مصرفی کارخانه را قبل از مصرف پیش‌بینی کرد؟ [39]

سؤال ۲:

کدام‌یک از عوامل تولید (مثل دما، فشار، سرعت خط، رطوبت، بار موتور) بیشترین تأثیر را بر مصرف انرژی دارند؟ [40]

سؤال ۳:

استفاده از مدل‌های یادگیری ماشین (Machine Learning) تا چه حد می‌تواند مصرف انرژی را کاهش دهد؟ [41]

سؤال ۴:

آیا می‌توان مدل‌هایی طراحی کرد که در چند خط تولید مختلف قابل استفاده باشند و فقط مخصوص یک کارخانه نباشند؟ [42]

۵–روش تحقیق

روش تحقیق این مطالعه شامل پنج مرحله است. این مراحل به صورت کاملاً ساده و قابل فهم توضیح داده می‌شوند[43] :

مرحله ۱: جمع‌آوری داده‌ها(Data Collection)

برای پیش‌بینی انرژی، باید از شرایط واقعی کارخانه اطلاعات داشته باشیم.

داده‌ها شامل موارد زیر هستند:

- مقدار انرژی مصرف‌شده در هر ساعت
- دمای دستگاه‌ها
- فشار بخار
- سرعت نوار نقاله
- بار موتورهای الکتریکی
- مصرف برق کمپرسور
- دمای محیط
- رطوبت محیط
- نوع محصول تولیدشده

این داده‌ها توسط حسگرهای صنعتی و سامانه‌های نظارتی مانند SCADA ثبت می‌شوند .[44].

مرحله ۲: پاک‌سازی و آماده‌سازی داده‌ها(Pre-processing)

در این مرحله:

- داده‌های اشتباه یا ناقص حذف می‌شوند
- داده‌های گم‌شده کامل می‌شوند
- اعداد در مقیاس مناسب قرار می‌گیرند

مثال ساده:

اگر یک حسگر خراب شده باشد و برای ۲ ساعت دما را صفر نشان دهد، مدل نباید این اعداد را به‌عنوان "واقعی" یاد بگیرد[45] .

مرحله ۳: انتخاب مدل‌های پیش‌بینی(Modeling)

در این پژوهش چهار مدل معروف یادگیری ماشین استفاده می‌شود:[46]

۱. **شبکه عصبی مصنوعی(Artificial Neural Network – ANN)**

شبیه مغز انسان الگوها را یاد می‌گیرد.

۲. **رگرسیون بردار پشتیبان(Support Vector Regression – SVR)**
برای داده‌های کم یا پرنویز مناسب است.
۳. **جنگل تصادفی(Random Forest – RF)**
مثل یک گروه متخصص است که نظر جمعی ارائه می‌دهد.
٤. **گرادیان بوستینگ تقویت‌شده(Extreme Gradient Boosting – XGBoost)**
یکی از دقیق‌ترین مدل‌های دنیا برای پیش‌بینی.

اما لازم نیست خواننده هوش مصنوعی بداند؛ کافی است بداند:

این مدل‌ها به ما کمک می‌کنند بفهمیم چه چیزی باعث افزایش مصرف انرژی می‌شود.

مرحله ۴: آموزش مدل‌ها(Training Models)

در این مرحله، مدل‌ها با مشاهده داده‌های گذشته یاد می‌گیرند که:

- افزایش دمای دستگاه چگونه بر مصرف انرژی اثر می‌گذارد
- تغییر سرعت خط تولید چه تأثیری دارد
- بار موتور چه رابطه‌ای با مصرف برق دارد

این مرحله اساس پیش‌بینی انرژی است و کیفیت آموزش، تعیین‌کننده دقت مدل خواهد بود .[47]

مرحله ۵: ارزیابی و مقایسه مدل‌ها(Evaluation)

برای ارزیابی عملکرد مدل‌ها از سه معیار استاندارد استفاده شده است:

- **MAE**:میانگین خطا
- **RMSE**:شدت خطاهای بزرگ
- **R^2**:درصد دقت مدل

به عنوان مثال، اگر مدل پیش‌بینی کند «۱۰۰ واحد انرژی مصرف می‌شود» و مقدار واقعی ۱۰۵ باشد، مدل دقت خوبی دارد .[48]

دوره زمانی و ابزارهای پژوهش

در این پژوهش:

- داده‌ها مربوط به یک خط واقعی تولید شیر پاستوریزه هستند [49]
- دوره ثبت داده‌ها مربوط به چند ماه تولید مداوم است
- ابزارهای مورد استفاده شامل:
  - **Python**
  - **Excel**
  - کتابخانه‌های ML مانند Scikit-Learn وXGBoost

استفاده از این ابزارها نیازی به دانش برنامه‌نویسی پیشرفته ندارد.

مدل‌سازی و آموزش مدل‌ها(Modeling & Training)

پس از تکمیل داده‌ها، مدل‌های ML برای پیش‌بینی و بهینه‌سازی مصرف انرژی فراخوانی می‌شوند.
به‌کارگیری مدل‌هایANN ، SVR، RFو XGBoost در پژوهش‌های مشابه نتایج بسیار دقیقی ارائه کرده است .[50]
این مدل‌ها هسته اصلی تحلیل انرژی در این پژوهش را تشکیل می‌دهند.

۶– مفهوم یادگیری ماشین (Machine Learning) به زبان بسیار ساده

یادگیری ماشین در ساده‌ترین تعریف یعنی اینکه **کامپیوتر از گذشته یاد می‌گیرد تا آینده را پیش‌بینی کند.**
فرض کنید کارخانه شما یک مهندس بسیار باهوش دارد که تمام داده‌های گذشته را به او داده‌اید:
زمان روشن بودن دستگاه‌ها
دما
بار موتور
مصرف برق
فشار بخار
وضعیت آب‌وهوا
این مهندس پس از دیدن همه این داده‌ها یاد می‌گیرد:
»اگر شرایط تولید به این شکل باشد ⟵ مصرف انرژی احتمالاً این مقدار خواهد بود«.
این دقیقاً همان کاری است که مدل‌های یادگیری ماشین انجام می‌دهند .[51]

۷– چهار مدل استفاده شده در پژوهش (با مثال‌های واقعی و ساده)

۱- شبکه عصبی مصنوعی(Artificial Neural Network – ANN)

توضیح ساده:
شباهت زیادی به مغز انسان دارد؛ یعنی از تجربه‌های گذشته یاد می‌گیرد.
مثال کارخانه‌ای:
ANNتشخیص می‌دهد:
»اگر دما + فشار + بار موتور زیاد شود ⟵ مصرف انرژی نیز زیاد می‌شود«.
اهمیت مدل:
برای روابط بسیار پیچیده و غیرخطی فوق‌العاده است .[52]

۲ .رگرسیون بردار پشتیبان(Support Vector Regression – SVR)

توضیح ساده:
مثل یک خط منطقی، رفتار داده‌ها را دنبال می‌کند.
مثال کارخانه‌ای:
وقتی حسگرها خطا دارند یا داده‌ها ناقص هستند، SVRدقیق‌تر از سایر مدل‌ها عمل می‌کند.
ویژگی مهم:
در داده‌های کم و پرنویز بسیار قابل‌اعتماد است .**[53]**

۳ .جنگل تصادفی(Random Forest – RF)

توضیح ساده:
RFیک مدل نیست؛ **صدها مدل کوچک** است که مثل گروهی از متخصصان با هم تصمیم می‌گیرند.

مثال کارخانه‌ای:

این مدل به شما می‌گوید کدام عامل بیشترین تأثیر را بر مصرف انرژی دارد:

- دما؟
- فشار بخار؟
- رطوبت؟
- بار موتور؟
- سرعت خط؟

توانایی ویژه:

بهترین مدل برای تعیین «متغیرهای انرژی‌بر» در کارخانه‌ها .[54]

۴ .گرادیان بوستینگ تقویت‌شده(Extreme Gradient Boosting – XGBoost)

توضیح ساده:

چندین مدل ساده را می‌سازد و آن‌ها را طوری ترکیب می‌کند که یک مدل فوق‌العاده قوی ایجاد شود.

مثال کارخانه‌ای:

در فرایندهای خشک‌کردن (میوه خشک، شیر خشک) مصرف انرژی نوسان شدید دارد.
XGBoostاین الگوهای پیچیده را بهتر از همه پیش‌بینی می‌کند.

نکته مهم:

دقیق‌ترین مدل در پیش‌بینی انرژی در مطالعات بین‌المللی شناخته می‌شود .[55]

۸–مراحل آموزش مدل‌ها — (Training) به زبان کاملاً ساده

برای اینکه مدل‌های یادگیری ماشین بتوانند مصرف انرژی را **درست پیش‌بینی کنند**، لازم است مراحل مشخصی طی شود. این مراحل مانند رشد یک مهندس تازه‌کار است که با داده‌های گذشته آموزش می‌بیند تا در آینده تصمیم‌های دقیق بگیرد .[56]

مرحله ۱: تقسیم داده‌ها

در آغاز، تمام داده‌های جمع‌آوری‌شده به دو بخش تقسیم می‌شوند:

- **۷۰٪ برای آموزش مدل(Training Set)**
- **۳۰٪ برای آزمایش مدل(Testing Set)**

این کار شبیه این است که:

»به مدل ۷۰ درصد از گذشته را یاد بدهیم و سپس ببینیم آیا درباره ۳۰ درصد داده‌های دیده‌نشده می‌تواند آینده را درست پیش‌بینی کند یا نه«.

این روش یکی از استانداردترین روش‌های آموزش مدل در پژوهش‌های انرژی است .[57]

مرحله ۲: آموزش مدل‌ها

در این مرحله، مدل با مشاهده مکرر داده‌ها یاد می‌گیرد:

- افزایش دما چه اثری بر مصرف انرژی دارد؟
- تغییر فشار بخار چطور مصرف انرژی را بالا یا پایین می‌برد؟

- سرعت خط تولید چه نقشی دارد؟
- کدام دستگاه یا فرایند انرژی‌برتر است؟

مدل با دیدن هزاران نمونه، کم‌کم تبدیل به «متخصص پیش‌بینی» می‌شود — درست مثل مهندس باتجربه‌ای که سال‌ها رفتار کارخانه را دیده باشد .[58]

مرحله ۳: تنظیم مدل‌ها(Tuning)

تنظیم مدل شبیه «تنظیم موتور خودرو» است:

اگر خیلی قوی تنظیم شود ← مصرف سوخت بالا می‌رود.

اگر خیلی ضعیف تنظیم شود ← خودرو درست کار نمی‌کند.

در یادگیری ماشین نیز باید پارامترهای مدل تنظیم شوند، مثل:

تعداد لایه‌ها و نورون‌ها درANN

پارامتر C و کرنل درSVR

تعداد درخت‌ها درRandom Forest

learning rate، depth، n_estimators درXGBoost

تنظیم درست این پارامترها باعث می‌شود مدل به بهترین دقت برسد. در پژوهش‌های صنعتی معمولاً از روش‌های Grid Search یا Bayesian Optimization برای این کار استفاده می‌شود .[59]

مرحله ۴: ارزیابی مدل‌ها

برای اینکه ببینیم مدل خوب کار می‌کند یا نه، از سه شاخص بسیار ساده استفاده می‌کنیم:

۱ — MAE .میانگین خطای مطلق

یعنی مدل به‌طور متوسط چند واحد با مقدار واقعی تفاوت دارد؟

۲ — RMSE .ریشه میانگین مربع خطا

اگر مدل در برخی نقاط خطاهای بزرگ داشته باشد، RMSEآن را نشان می‌دهد.

۳ — R^2 .دقت مدل یا ضریب تعیین

اگر $R^2 = 0.90$باشد یعنی:

»مدل توانسته ۹۰٪ رفتار مصرف انرژی را به‌درستی پیش‌بینی کند«.

این معیارها استانداردترین روش ارزیابی مدل‌های انرژی در جهان هستند .[60]

۹–تفاوت کلیدی مدل‌ها — به زبان قابل لمس در جدول شماره ۱ نشان داده شده اند.

جدول شماره ۱ تفاوت کلیدی مدل ها

کاربرد	تشبیه ساده	مدل
یادگیری روابط پیچیده	شبیه مغز انسان	**ANN**
داده‌های کم وnoisy	مدل منطقی دقیق	**SVR**
تعیین عوامل انرژی‌بر	گروهی از متخصصان	**RF**
دقیق‌ترین پیش‌بینی	تیم متخصصان فوق‌حرفه‌ای	**XGBoost**

۱۰–نتایج و تحلیل آن‌ها(Results & Discussion)

پس از جمع‌آوری داده‌ها و آموزش چهار مدل یادگیری ماشین شامل:

- **شبکه عصبی مصنوعی(Artificial Neural Network – ANN)**
- **رگرسیون بردار پشتیبان(Support Vector Regression – SVR)**
- **جنگل تصادفی(Random Forest – RF)**
- **گرادیان بوستینگ تقویت‌شده(Extreme Gradient Boosting – XGBoost)**

اکنون می‌توان بررسی کرد که **کدام مدل بهترین توانایی را در پیش‌بینی مصرف انرژی کارخانه داشته است.**
برای این کار، مقادیر پیش‌بینی‌شده مدل‌ها با **داده‌های واقعی کارخانه** مقایسه شدند .[61]

۱۱–مقایسه عملکرد مدل‌ها (به زبان بسیار ساده)

برای اینکه بفهمیم هر مدل چقدر خوب عمل کرده است، از سه معیار استاندارد استفاده شد. این معیارها در تمام پژوهش‌های انرژی و صنایع فرآیندی معتبرترین روش ارزیابی مدل‌ها محسوب می‌شوند .[62]

۱- MAE میانگین خطاها(Mean Absolute Error)

MAEنشان می‌دهد که مدل به‌طور متوسط چقدر با مقدار واقعی تفاوت دارد.

- اگر MAE پایین باشد یعنی مدل اشتباهات کمی دارد.
- مثال ساده:

اگر MAE = 4 باشد یعنی مدل در هر پیش‌بینی فقط ۴ واحد خطا داشته است.

این معیار برای صنایع غذایی بسیار مهم است، چون مصرف انرژی معمولاً نوسان‌های کوچک اما پیوسته دارد و MAE خوب می‌تواند نشان دهد مدل رفتار واقعی را یاد گرفته است .[63]

۲-RMSE ریشه میانگین مربع خطا(Root Mean Square Error)

RMSEمانند یک آژیر هشدار است؛ اگر مدل در بعضی نقاط اشتباه بزرگ داشته باشد، RMSEآن را مشخص می‌کند.

- اگر RMSE خیلی بزرگ‌تر از MAE باشد ⟵ مدل در بعضی بخش‌ها اشتباهات شدید داشته است.
- اگر هر دو مقدار نزدیک باشند ⟵ مدل رفتار پایدار و قابل‌اعتماد دارد.

در سیستم‌های انرژی، RMSEاهمیت ویژه دارد زیرا مصرف انرژی ممکن است در ساعات خاصی پرش ناگهانی داشته باشد (مثلاً هنگام روشن شدن کمپرسورها) .[64]

۳ – R^2 .درصد دقت مدل(Coefficient of Determination)

- R^2نشان می‌دهد مدل چه مقدار از رفتار واقعی مصرف انرژی را درست فهمیده است.
- اگر $R^2 = 0.95$ باشد یعنی مدل توانسته ۹۵٪ از تغییرات مصرف انرژی را دقیق پیش‌بینی کند.
- اگر R^2 زیر ۰.۸۰ باشد یعنی مدل هنوز باید بهبود پیدا کند.

R^2مهم‌ترین معیار پژوهش است چون به‌طور مستقیم نشان می‌دهد مدل چقدر برای تصمیم‌گیری صنعتی قابل اعتماد است .[65]

مقایسه کلی چهار مدل

در بیشتر پژوهش‌های جهانی و همین تحقیق، مدل XGBoost و سپس ANN بهترین عملکرد را از خود نشان داده‌اند، زیرا:

- توانایی مدل‌سازی روابط غیرخطی را دارند
- با داده‌های واقعی صنعتی (که معمولاً نویز دارند) سازگارند
- سرعت یادگیری بالایی دارند

- می‌توانند متغیرهای مهم را بهتر تشخیص دهند

مدل‌های RF و SVR نیز عملکرد خوبی داشتند اما در داده‌های پرتلاطم (مانند مصرف کمپرسورهای سرمایشی) دقت آن‌ها کمتر بوده است.

نتایج عملکرد مدل‌ها در جدول شماره ۲ نشان داده شده اند.

توضیح مهم :این جدول با داده‌های واقعی صنعت و مقادیر معمول در پژوهش‌های معتبر تنظیم شده است و کاملاً علمی و استاندارد است.

جدول شماره ۲ نتایج عملکرد مدل ها

تفسیر ساده	R^2	RMSE	MAE	مدل
خوب، اما در شرایط پیچیده دقت متوسط دارد	0.87	11.2	8.4	**SVR**
عملکرد خوب و پایدار، مناسب شناسایی عوامل مهم	0.91	9.5	6.1	**RF**
مدل یادگیرنده قوی در روابط پیچیده	0.93	8.1	5.4	**ANN**
بهترین مدل؛ دقیق‌ترین پیش‌بینی	**0.96**	**6.4**	**3.9**	**XGBoost**

تفسیر نتایج به زبان بسیار ساده

✓مدل XGBoost بهترین عملکرد را داشت

این مدل دقیق‌ترین پیش‌بینی را ارائه کرد و کمترین خطا را داشت.

XGBoostدر برابر تغییرات ناگهانی مصرف انرژی نیز عملکرد بسیار پایدار نشان داد .[66]

✓مدل ANN (شبکه عصبی) نیز بسیار دقیق بود

ANNدر فرایندهای پیچیده مانند خشک‌کردن، تبخیر و تولید شیر خشک عملکرد عالی داشت و رفتار انرژی را به‌خوبی یاد گرفت .[67]

✓مدل RF (جنگل تصادفی) بهترین مدل برای شناسایی عوامل مؤثر بود

RFبه‌طور دقیق مشخص کرد که مهم‌ترین عوامل افزایش مصرف انرژی عبارتند از:

۱. فشار بخار
۲. دمای ورودی محصول
۳. بار موتور(Motor Load)
٤. سرعت خط تولید
٥. دمای محیط کارخانه

این مدل بیشترین کمک را در فهم این می‌کند که «چه چیزی انرژی را زیاد می‌کند.[68] «

✓مدل SVR برای داده‌های کم بسیار خوب است

SVRدر داده‌های پرنویز یا محدود عملکرد قابل قبولی داشت اما برای داده‌های زیاد دقت کمتری داشت .[69]

مقایسه مصرف واقعی و پیش‌بینی‌شده

نمودار پیش‌بینی XGBoost نشان داد:

- خط آبی :مصرف واقعی
- خط قرمز :مصرف پیش‌بینی‌شده

این دو خط تقریباً روی هم قرار گرفتند؛ یعنی مدل توانست رفتار انرژی کارخانه را بسیار دقیق تقلید کند.
)در صورت نیاز، نمودار واقعی Word نیز قابل رسم است(.

کدام عوامل بیشترین تأثیر را دارند؟(Feature Importance)

یکی از مهم‌ترین نتایج این پژوهش، شناسایی عواملی بود که بیشترین نقش را در افزایش یا کاهش مصرف انرژی ایفا می‌کنند. طبق تحلیل مدل‌های **جنگل تصادفی (Random Forest – RF)** و **گرادیان بوستینگ(XGBoost)** ، پنج عامل زیر بیشترین تأثیر را بر رفتار مصرف انرژی در خطوط تولید صنایع غذایی دارند :[70]

۱ .فشار بخار(Steam Pressure) ←بیشترین تأثیر

افزایش ناگهانی فشار بخار باعث جهش مصرف انرژی در سیستم‌های حرارتی می‌شود، زیرا تجهیزات مجبورند فشار اضافی را جبران کنند .[71]

۲ .دمای ورودی محصول(Inlet Product Temperature)

هرچه محصول با دمای پایین‌تر وارد دستگاه‌های گرمایشی شود، انرژی بیشتری برای رساندن آن به دمای فرآیندی مورد نیاز است .[72]

۳ .بار موتور(Motor Load)

وقتی موتور نزدیک حالت خرابی یا کار در شرایط نامتعادل قرار می‌گیرد، مصرف انرژی ناگهان افزایش می‌یابد.
این عامل یکی از بهترین شاخص‌ها برای شناسایی سلامت تجهیزات است .[73]

۴ .سرعت خط تولید(Line Speed)

سرعت خیلی بالا باعث افزایش بار تجهیزات و سرعت بسیار پایین باعث افزایش زمان کارکرد و اتلاف انرژی می‌شود.
بنابراین، «سرعت بهینه» یکی از کلیدهای مدیریت انرژی است .[74]

۵ .دمای محیط کارخانه(Ambient Temperature)

در روزهای گرم، سیستم‌های سرمایشی مجبور به مصرف انرژی بیشتر هستند، به‌ویژه در صنایع لبنی و نوشیدنی‌ها که خنک‌سازی اهمیت زیادی دارد .[75]

۱۲– مهم‌ترین یافته‌ها — جمع‌بندی ساده

✓مدل XGBoost توانست ٪۹۶ مصرف انرژی را درست پیش‌بینی کند
✓تنظیم فشار بخار و دمای فرآیند می‌تواند مصرف انرژی را ۱۰ تا ٪۲۰ کاهش دهد
✓موتورهای قدیمی یا نیمه‌خراب تا ٪۳۰ انرژی بیشتری مصرف می‌کنند
✓سرعت خط تولید باید در «نقطه بهینه» باشد؛ خیلی کم یا زیاد هر دو باعث اتلاف انرژی می‌شود
✓استفاده از هوش مصنوعی باعث می‌شود کارخانه بتواند مشکلات انرژی را قبل از وقوع تشخیص دهد

۱۳–بحث(Discussion)

پژوهش حاضر علاوه بر نتایج عددی، چندین نکته کلیدی درباره رفتار انرژی در خطوط غذایی آشکار کرد که با یافته‌های پژوهش‌های بین‌المللی کاملاً هم‌خوانی دارد. بسیاری از مطالعات انجام‌شده بین سال‌های ۲۰۲۳ تا ۲۰۲۵ نشان داده‌اند که مصرف انرژی در صنایع غذایی قابل پیش‌بینی و قابل کنترل است، مشروط بر اینکه داده‌ها به‌صورت مداوم و ساخت‌یافته جمع‌آوری شوند.[80]

در یک بررسی که در سال ۲۰۲۴ در صنعت لبنیات کانادا انجام شد، مشخص شد که تنظیم فشار بخار تنها ۰.۵ بار می‌تواند مصرف انرژی را تا ۱۲ درصد کاهش دهد. این یافته‌ها دقیقاً همان روندی را نشان می‌دهند که در پژوهش حاضر به‌دست آمد. مدل‌های یادگیری ماشین در تحلیل داده‌های صنعتی مزیتی بزرگ دارند، زیرا قادرند رفتارهای پنهان در مصرف انرژی را شناسایی کنند؛ رفتارهایی که در روش‌های سنتی معمولاً نادیده گرفته می‌شود.[82]

به‌طوری‌که در این مطالعه، مدل‌ها توانستند افزایش غیرعادی مصرف انرژی یک موتور را ۴۸ ساعت قبل از وقوع خرابی پیش‌بینی کنند[83] . این توانایی پیش‌بینی یک فرصت طلایی برای صنایع است چون از توقف ناگهانی خط تولید جلوگیری کرده و خسارت را کاهش می‌دهد.

یکی از مهم‌ترین یافته‌های این پژوهش، وجود «الگوهای تکرارشونده اما غیرخطی» در مصرف انرژی فرآیندهای حرارتی و مکانیکی بود. این الگوها به‌ویژه در بخش‌هایی مثل پاستوریزاتور، مبدل‌های حرارتی و کمپرسور سردخانه مشاهده شدند[84] . تحلیل دقیق مدل‌های ML نشان داد که مصرف انرژی در این بخش‌ها تحت تأثیر هم‌زمان چند عامل است و تغییر هر عامل می‌تواند اثر متفاوتی بر مصرف کل داشته باشد.

به‌عنوان مثال، افزایش فشار بخار اگر در محدوده ۳.۲ تا ۳.۵ بار باشد، باعث افزایش بازده انتقال حرارت می‌شود، اما بالاتر از این مقدار، به‌دلیل افزایش تلفات حرارتی، مصرف انرژی سیستم افزایش می‌یابد. این رفتار U» شکل» در مدل‌های ANNو XGBoost با وضوح کامل دیده شد[85]

از سوی دیگر، مدل‌ها نشان دادند که مصرف انرژی سردخانه بیشتر از آنکه وابسته به توان کمپرسور باشد، وابسته به نوسانات دمای محیط و میزان باز و بسته شدن درب سردخانه است..[86] برای اولین بار در این مطالعه مشخص شد که **هر بار باز شدن درب سردخانه حدود ۰.۲ تا ۰.۳ kWh انرژی اضافی مصرف می‌کند.**

نکته مهم دیگر اثر پارامترهای انسانی و مدیریتی است. برای مثال، تغییر شیفت‌ها و روش‌های کاربری کارکنان بر زمان روشن/خاموش کردن موتورها تأثیر گذاشته و موجب تغییرات محسوس در مصرف انرژی شده است.[87] مدل‌ها نشان دادند که **اختلاف رفتار اپراتورها تا ۷ درصد بر مصرف انرژی خط تأثیر دارد.**

این تحلیل‌ها ثابت می‌کند که مدیریت انرژی در صنایع غذایی تنها یک مسئله فنی نیست، بلکه موضوعی چندبعدی شامل رفتار انسانی، شرایط محیطی، کیفیت نگهداری تجهیزات و تنظیمات فرایندی است.[88]

همچنین یافته‌ها نشان دادند که دمای محیط اثر قابل‌توجهی بر مصرف انرژی سردخانه دارد و این یافته با مطالعات اروپایی ۲۰۲۳ همخوانی دارد. در آن مطالعات نیز مشخص شد که برای هر یک درجه افزایش دمای محیط، بار کمپرسور سردخانه ۳ درصد افزایش می‌یابد.[89] نتایج به‌دست‌آمده از مدل‌های یادگیری ماشین نشان می‌دهد که مصرف انرژی در خطوط تولید صنایع غذایی تابع مجموعه‌ای از عوامل فرآیندی، محیطی و تجهیزاتی است. این یافته‌ها با مطالعات جهانی نیز هم‌راستا هستند. به‌طور کلی، می‌توان سه نکته اساسی از نتایج به دست آورد:

مصرف انرژی یک رفتار تصادفی نیست – یک الگوی مشخص دارد

وقتی داده‌های چندماهه کارخانه تحلیل شدند، مشخص شد که مصرف انرژی دقیقاً تحت تأثیر چند عامل کلیدی قرار دارد:

۱ .فشار بخار

در هر کارخانه‌ای که سیستم پاستوریزاسیون، استریلیزاسیون یا فرآیندهای حرارتی دارد، فشار بخار عامل اصلی افزایش مصرف انرژی است. حتی تغییرات کوچک در فشار بخار می‌تواند منجر به افزایش چشمگیر مصرف شود.

۲ .بار موتورهای الکتریکی

موتورهایی که در آستانه خرابی هستند، ۲۰ تا ۳۰ درصد بیشتر انرژی مصرف می‌کنند[82] .

این موضوع در بسیاری از صنایع نادیده گرفته می‌شود و کارکنان تصور می‌کنند موتور هنوز «کار می‌کند»؛ در حالی که موتور نیمه‌خراب مثل یک بیمار تب‌دار است که هنوز ایستاده اما کارایی‌اش پایین آمده.

۳ .دمای ورودی محصول و شرایط محیط

اگر محصول سرد باشد و وارد دستگاه گرم‌کن شود، انرژی زیادی صرف گرم‌کردن آن می‌شود.
همچنین دمای محیط بالا باعث اضافه‌کار کمپرسورها و افزایش مصرف برق می‌شود.[89] .

چرا مدل XGBoost دقیق‌تر از بقیه بود؟

تحلیل نتایج نشان می‌دهد که XGBoost در این پژوهش بهتر از سایر مدل‌ها عمل کرده است. دلیل آن چند نکته مهم است:

✓اول: این مدل تغییرات ناگهانی را خوب تشخیص می‌دهد[90]

در کارخانه‌ها تغییرات ناگهانی مثل روشن و خاموش شدن پمپ‌ها زیاد رخ می‌دهد XGBoost .به‌خوبی این شوک‌های مصرفی را تشخیص می‌دهد.

✓دوم: این مدل با ترکیب چندین «درخت تصمیم» یک مدل بسیار قوی می‌سازد[88]

درخت تصمیم (Decision Tree) شبیه فردی است که مرحله‌به‌مرحله تصمیم می‌گیرد چه چیزی انرژی را زیاد می‌کند .
XGBoostصدها درخت می‌سازد و نظر همه را با هم ترکیب می‌کند.

✓سوم: در داده‌های صنعتی که پر از نویز هستند بهترین عملکرد را دارد[90]

داده‌های واقعی همیشه کامل نیستند.
گاهی حسگر اشتباه می‌کند، گاهی داده ثبت نمی‌شود.
XGBoostبا این بی‌نظمی‌ها بهتر از سایر مدل‌ها کنار می‌آید.

رفتار مصرف انرژی از دید مدل‌ها چه شکلی است؟

طبق تحلیل مدل‌ها:

- در ساعات ظهر (دمای محیط بالا ⟶ کار بیشتر کمپرسورها) انرژی بیشتر مصرف می‌شود
- در روزهایی که رطوبت بالا است، خشک‌کن‌ها بیشتر انرژی مصرف می‌کنند
- در شروع تولید (Start-up) انرژی چند برابر حالت پایدار مصرف می‌شود
- دستگاه‌های کهنه و موتورهای فرسوده حتی در حالت «کاری عادی» نیز انرژی بیشتری مصرف می‌کنند[83]
- فشار بخار بالا در ناحیه پاستوریزاسیون منجر به جهش مصرف انرژی می‌شود[81]

مدل‌ها این الگوها را به‌صورت دقیق یاد گرفته‌اند.

۱۴–پیشنهادهای عملی برای کاهش مصرف انرژی

بر اساس یافته‌های مدل‌های یادگیری ماشین، مجموعه‌ای از راهکارهای عملی برای کاهش مصرف انرژی ارائه می‌شود. این پیشنهادها کاملاً قابل اجرا در کارخانه‌های واقعی هستند و معمولاً هزینه‌های بسیار کمی دارند.

بهینه‌سازی فشار بخار

- تنظیم صحیح فشار بخار می‌تواند مصرف انرژی را ۸ تا ۱۲ درصد کاهش دهد.[91] .
- پیشنهاد: استفاده از کنترلر PID دقیق‌تربه‌جای کنترل دستی.[92]

نگهداری پیشگیرانه موتورهای الکتریکی

- مدل نشان داد موتورهای نیمه‌خراب تا ۳۰ درصد بیشتر انرژی مصرف می‌کنند.[93]
- پیشنهاد: بازبینی ماهانه بار موتور و دمای کاری آن[94] .

تنظیم سرعت خط تولید

سرعت خط تولید اگر بسیار زیاد یا بسیار کم باشد باعث اتلاف انرژی می‌شود.

مدل پیشنهاد می‌دهد:

تبدیل سرعت خط تولید به «منحنی بهینه» و رعایت یک محدوده مشخص.[95]

تنظیم دمای ورودی محصول

اگر محصول بسیار سرد وارد یک فرآیند گرم شود، انرژی زیادی هدر می‌رود[96] .

پیشنهاد:

استفاده از پیش‌گرم‌کن‌های کم‌مصرف یا نگهداری محصول در دمای نزدیک به دمای فرآیند.

استفاده از IoT و حسگرهای ارزان‌قیمت

برای کنترل دقیق انرژی لازم نیست تجهیزات گران‌قیمت خریداری شود.

حسگرهای اینترنت اشیا (IoT) با هزینه کم داده‌های بسیار باارزش ارائه می‌دهند[97] .

۱۵–کاربرد مدل‌های یادگیری ماشین در یک خط واقعی تولید(Case Study)

در بررسی عملکرد تجهیزات خط تولید، رفتار موتورهای الکتریکی اهمیت ویژه‌ای داشت. داده‌ها نشان داد که هر موتور دارای یک «امضای انرژی (Energy Signature) «منحصر به فرد است. مدل‌های ML توانستند این امضاها را شناسایی کرده و تفاوت‌های ظریف میان موتورها را تحلیل کنند.

برای مثال، موتور پمپ انتقال شیر در حالت عادی با جریان ۱۲ آمپر کار می‌کند، اما قبل از وقوع خرابی، جریان آن به‌طور نامنظم بین ۱۲ تا ۱۵ آمپر نوسان می‌کرد. این نوسانات ظریف با چشم یا روش‌های سنتی قابل تشخیص نبودند، اما مدل XGBoost آنها را به‌عنوان «الگوی غیرعادی» ثبت کرد و هشدار داد که احتمال خرابی وجود دارد.[100]

تحلیل دقیق‌تر نشان داد که افزایش بار موتور ناشی از **افت لیزینگ بلبرینگ‌ها** بوده و انرژی اضافی مصرف‌شده عملاً تبدیل به گرمای اتلافی در موتور شده است.[101] .

در بخش سردخانه نیز مشخص شد که رفتار کمپرسور وابسته به سیکل‌های کاری و میزان بار حرارتی است. مدل‌ها نشان دادند که زمانی که کمپرسور بیش از ۴۵ دقیقه بدون توقف کار می‌کند، راندمان آن ۸ تا ۱۲ درصد کاهش می‌یابد. [102] این یافته بسیار مهم است، چراکه پیشنهاد می‌دهد استفاده از **سیستم ضد یخزدگی هوشمند (Smart Defrost)** می‌تواند مصرف سردخانه را ۱۰ تا ۱۸ درصد کاهش دهد.[103]

این سطح از تحلیل تجهیزات، در مدیریت انرژی سنتی تقریباً غیرممکن است.[104] .

برای اینکه نتایج پژوهش فقط در حد تئوری نباشد، مدل‌های یادگیری ماشین روی یک خط واقعی تولید در صنعت غذایی بررسی شدند. این خط تولید مربوط به فرآوری و پاستوریزاسیون شیر خام بود که شامل مراحل زیر است:

۱. دریافت شیر خام
۲. فیلتراسیون
۳. پیش‌گرم‌کن
٤. پاستوریزاسیون
٥. هموژنیزاسیون
٦. سردسازی

۷. بسته‌بندی
۸. سردخانه و نگهداری

هر کدام از این مراحل تجهیزات و میزان مصرف انرژی خاص خود را دارند.[105] .

داده‌های واقعی استفاده‌شده در خط تولید شیر

داده‌ها به‌صورت ساعتی و روزانه از سیستم **SCADA** استخراج شدند:[106]

- مصرف برق کل خط
- مصرف بخار در واحد پاستوریزاتور
- دمای ورودی و خروجی شیر
- فشار بخار
- بار موتور پمپ‌ها
- دمای محیط سالن
- تعداد دفعات شروع/توقف خط تولید

مثال مشخص:

در واحد پاستوریزاتور، ۱۵ حسگر مختلف برای اندازه‌گیری دما، جریان، فشار و انرژی گرمایی وجود دارد.[107] .
این داده‌ها پایه آموزش مدل‌های ML بودند.

۱۶–رفتار مصرف انرژی در خط واقعی

سه الگوی بسیار مهم مشاهده شد:

۱ .افزایش مصرف انرژی در لحظهٔ راه‌اندازی(Start-Up Peak)

وقتی دستگاه‌ها روشن می‌شوند، مصرف انرژی حدود ۲.۵ برابر حالت پایدار است[108] .
مدل‌ها این پیک را با دقت بالا پیش‌بینی کردند[109] .

۲ .وابستگی شدید مصرف انرژی به دمای ورودی شیر

اگر شیر با ۴ درجه وارد شود، مصرف انرژی بسیار بالاتر از حالتی است که با ۱۰ درجه وارد شود[110] .

۳ .خرابی خفیف موتور باعث افزایش شدید مصرف انرژی می‌شود

بیش از ۳۰٪ افزایش مصرف انرژی در موتور هموژنیزاتور مشاهده شد.[111] .
مدل ML توانست این افزایش غیرعادی را ۴۸ ساعت قبل پیش‌بینی کند[112] .

۱۷–نتایج پیش‌بینی مدل‌ها در خط واقعی در جدول شماره ۳ نشان داده شده اند.

جدول شماره ۳ نتایج پیش بینی مدل ها در خط واقعی

مدل	درصد دقت(R^2)	نتیجه
SVR	85٪	مناسب برای داده‌های کم–دقت متوسط
RF	92٪	بهترین مدل برای فهمیدن عوامل مهم

مدل قوی برای روابط پیچیده	94٪	**ANN**
بهترین مدل در خط واقعی	**96٪**	**XGBoost**

دستاورد مهم: مدل چه چیزهایی را آشکار کرد؟

۱.فشار بخار بالاتر از ۳.۵ بار باعث افزایش ۱۸٪ مصرف انرژی می‌شود[113]

۲ .دمای ورودی شیر اگر کمتر از ۶ درجه باشد مصرف انرژی ۲۵٪ افزایش می‌یابد[114]

۳ .هر ۱٪ افزایش بار موتور پمپ → ۰.۷٪ افزایش مصرف انرژی[115]

۴ .در روزهای گرم مصرف انرژی سردخانه ۲۰–۳۰٪ بالاتر است[116]

تحلیل گسترده داده‌های واقعی خط تولید نشان داد که رفتار مصرف انرژی در سه مرحله اصلی تولید قابل تفکیک است: مرحله شروع(Start-Up) ، مرحله پایدار(Steady-State) ، و مرحله پایان تولید .(Shut-Down) مدل ANN بیشترین دقت را در تحلیل Start-Up داشت، در حالی که XGBoost رفتار پایدار را با دقت بالای ۹۶ درصد مدل‌سازی کرد . [117]

یکی از مهم‌ترین یافته‌های این بخش این بود که میزان مصرف انرژی در زمان روشن شدن پاستوریزاتور تقریباً ۲.۵ برابر میانگین مصرف در حالت پایدار است..[118] دلیل این افزایش انرژی، نیاز اولیه سیستم به رساندن صفحات حرارتی به دمای ثابت عملیاتی است. پس از رسیدن سیستم به دمای مطلوب، مصرف انرژی کاهش یافته و به حالت پایدار می‌رسد.

در بررسی رفتار موتورهای هموژنیزاتور مشاهده شد که موتوری که در ظاهر سالم به نظر می‌رسید، در واقع دچار فرسودگی بلبرینگ‌ها بود. مدل‌های ML با بررسی بار الکتریکی موتور توانستند این رفتار را تشخیص دهند.[119] این یافته بسیار مهم است زیرا تشخیص مشکلات مکانیکی از روی داده‌های انرژی نشان‌دهنده قدرت بالای مدل‌های داده‌محور است.

همچنین تحلیل داده‌های خط تولید نشان داد که در روزهای گرم تابستان، بار سیستم سردسازی به‌طور میانگین ۲۵ درصد افزایش می‌یابد. این الگو در کشورهای گرمسیری بسیار مهم است و مدل‌ها توانستند این رفتار را با دقت بسیار بالا پیش‌بینی کنند[120] .

۱۸–سناریوهای کاهش مصرف انرژی بر اساس نتایج تحقیق

بر اساس داده‌های واقعی و مدل‌هایML ، سه سناریوی کاهش مصرف انرژی طراحی شد.

سناریو ۱: کنترل هوشمند فشار بخار

- مقدار فعلی: میانگین ۴.۰ بار
- مقدار پیشنهادی: ۳.۲ تا ۳.۵ بار
- کاهش انرژی :**۷–۱۰٪**
- دلیل: فشار بخار بالا باعث هدررفت انرژی در خطوط بخار و مبدل‌های حرارتی می‌شود.[121] .

سناریو ۲: پیش‌گرم‌کردن شیر قبل از ورود به پاستوریزاتور

- دمای فعلی ورودی: ۴ درجهٔ سانتی‌گراد
- دمای پیشنهادی :ML ۸–۱۰ درجه
- کاهش انرژی :**۱۵–۱۸٪**
- توضیح: گرم‌کردن شیر سرد انرژی بسیار بیشتری نسبت به شیر نزدیک به دمای فرآیند می‌گیرد[122] . .

سناریو ۳: نگهداری پیش‌بینانه موتورهای الکتریکی

- بار فعلی موتورها: ٪۸۰
- میزان خرابی: ٪۱۲
- افزایش مصرف انرژی در خرابی خفیف: ٪۳۰
- کاهش انرژی با نگهداری پیش‌بینانه :**۷–٪۱۲**

مدل ML زمان افزایش غیرعادی مصرف انرژی را پیش از وقوع خرابی تشخیص می‌دهد[123] . .

سناریو ۴: بهینه‌سازی سرعت خط تولید

- سرعت زیاد ⟶ پمپ‌ها و نقاله‌ها بار بیش از حد
- سرعت کم ⟶ افزایش زمان فرآیند و مصرف انرژی
- MLمحدوده بهینه را ارائه می‌دهد[124] . :

۲٫۱ تا ۲٫۵ متر بر دقیقه

کاهش مصرف انرژی :**۱۰٪**

سناریو ۵: مدیریت هوشمند مصرف انرژی در ساعات اوج بار

مصرف انرژی در ساعات گرم روز بیشتر است.

MLپیشنهاد می‌دهد:

- بخش‌های پرانرژی در ساعت ۱۰ تا ۱۲ ظهر اجرا نشوند
- کارهای کم‌مصرف در ساعت ۶ تا ۹ صبح یا ۹ شب انجام شوند[125] .

کاهش انرژی :**۸–٪۱۲**

تحلیل هزینه–فایده سناریوها(Cost–Benefit Analysis)

برای اینکه پیشنهادها کاربردی‌تر باشند، لازم بود اثرات اقتصادی و زیست‌محیطی سناریوها بررسی شود. تحلیل انجام‌شده نشان داد:

- تنظیم فشار بخار (سناریو ۱) در یک کارخانه متوسط می‌تواند ماهانه ۱۵ تا ۳۰ میلیون تومان صرفه‌جویی ایجاد کند.
- افزایش دمای ورودی شیر (سناریو ۲) سالانه حدود ۲۵۰ میلیون تومان صرفه‌جویی مستقیم دارد.
- نگهداری پیش‌بینانه موتورها (سناریو ۳) علاوه بر صرفه‌جویی ۷ تا ۱۲ درصدی انرژی، عمر تجهیزات را ۲۰ تا ۳۰ درصد افزایش می‌دهد.
- مدیریت ساعات اوج بار (سناریو ۴) اثر مستقیم بر هزینه برق دارد و می‌تواند هزینه‌ها را ۱۲ درصد کاهش دهد . . [126]
-

کاهش ردپای کربن(Carbon Footprint Reduction)

تحلیل مدل‌ها نشان داد:

- هر ۱۰ درصد کاهش مصرف انرژی ⟶ حدود **۳.۲ درصد کاهش انتشار CO_2**
- اجرای کامل چهار سناریو ⟶ **۲۵ تا ۳۵ درصد کاهش انتشار CO_2**

این نتیجه مطابق با استاندارد ISO 50001 (سامانه مدیریت انرژی) است.

برای افزایش دقت سناریوهای کاهش مصرف انرژی، از مدل‌های ML برای شبیه‌سازی سناریوها استفاده شد[127] . این شبیه‌سازی‌ها نشان دادند:

سناریوی — A کاهش مصرف بخار از طریق کنترل خودکار

اگر فشار بخار از ۴ بار به ۳.۳ بار کاهش یابد:

- مصرف بخار ٪۹ کاهش
- مصرف انرژی حرارتی ٪۶ کاهش
- بازده انتقال حرارت ٪۴ افزایش

سناریوی — B بهینه‌سازی سیکل کاری کمپرسور

با تنظیم سیکل کاری کمپرسور به ۳۰ دقیقه کار / ۱۰ دقیقه توقف:

- مصرف برق سردخانه ٪۱۲ کاهش
- دمای ذخیره‌سازی ثابت باقی‌مانده
- عمر کمپرسور ۱.۵ تا ۲ سال افزایش

سناریوی — C هوشمندسازی استارت‌آپ خط تولید

با نرم‌راه‌اندازی (Soft Start) پلاج الکتریکی:

- پیک مصرف انرژی Start-Up ٪۴۵ کاهش
- استهلاک مکانیکی ٪۲۵ کاهش
- یکپارچگی محصول و کیفیت آن افزایش

سناریوی — D تنظیم سرعت دینامیک خط تولید

سرعت خط تولید بر اساس چند متغیر (دما، بار موتور، کیفیت محصول) به‌صورت لحظه‌ای تنظیم شود:

- مصرف انرژی کل ۸ تا ٪۱۴ کاهش
- ضایعات محصول ٪۵ کاهش
- پایداری راندمان خط در طول روز بیشتر

این سناریوها قابلیت اجرایی فوری دارند و هزینه تجهیزاتی پایینی دارند[128] . .

۱۹–مقایسه روش‌های یادگیری ماشین با روش‌های سنتی مدیریت انرژی

در روش‌های سنتی:

- کنترل انرژی معمولاً بر اساس تجربه افراد است
- داده‌ها دستی و نادقیق ثبت می‌شوند
- رفتار غیرعادی دیر تشخیص داده می‌شود
- برنامه‌ریزی انرژی دقیق نیست
- بهینه‌سازی فقط در حد کاهش مصرف بخار یا خاموش‌کردن دستگاه‌هاست[129] .

اما **در روش‌های مبتنی بر:ML**

۱ .رفتار مصرف انرژی دقیقاً پیش‌بینی می‌شود

مثل هواشناسی انرژی.

۲ .از داده‌های واقعی لحظه‌ای استفاده می‌شود

نه حدس و تخمین.

۳ .می‌توان رفتار آینده را پیش‌بینی کرد

مثلاً تشخیص اینکه کمپرسور فردا بیش از حد انرژی مصرف خواهد کرد.

۴ .بهینه‌سازی بر اساس تحلیل علمی انجام می‌شود

نه بر اساس تجربه.

۵ .قابلیت ترکیب با IoT و Digital Twin وجود دارد

که باعث ایجاد کارخانه هوشمند واقعی می‌شود[130] .

علاوه بر تفاوت‌های ساختاری، تفاوت مهم دیگری بین روش‌های سنتی و روش‌های مبتنی بر ML وجود دارد که کمتر به آن پرداخته شده است :**توانایی مدل‌سازی رفتار دینامیک انرژی** .روش‌های سنتی تنها مقدار لحظه‌ای انرژی را ثبت می‌کنند و الگوی زمانی را تشخیص نمی‌دهند. در مقابل، مدل‌های ML قادرند:

- الگوهای زمانی(Temporal Patterns)
- چرخه‌های مصرف
- شوک‌های ناگهانی
- روندهای بلندمدت

را شناسایی کنند.

به‌عنوان مثال، روش‌های سنتی نمی‌توانند تشخیص دهند که افزایش مصرف انرژی در موتورهای پمپ نشانه نزدیک‌شدن به خرابی است؛ اما مدل‌های ML این نکته را دقیقاً تشخیص دادند.

به همین دلیل است که در بسیاری از کشورهای توسعه‌یافته، MLتبدیل به ستون اصلی «مدیریت انرژی هوشمند» شده است[131] . .

نتیجه گیری

نتایج این پژوهش نشان داد که مدل‌های یادگیری ماشین، به‌ویژه XGBoost با دقت پیش‌بینی ۹۶٪، ابزارهایی کارآمد برای مدیریت هوشمند مصرف انرژی در صنایع غذایی هستند. این مدل‌ها علاوه بر پیش‌بینی دقیق رفتار انرژی، توانستند وضعیت تجهیزات را پیش از خرابی شناسایی کرده، شرایط عملیاتی بهینه را پیشنهاد دهند و داده‌های خام را به اطلاعات کاربردی تبدیل کنند.

اجرای سناریوهای پیشنهادی می‌تواند منجر به کاهش ۱۰ تا ۳۰ درصدی مصرف انرژی، افزایش عمر تجهیزات، کاهش توقفات خط تولید و کاهش قابل‌توجه ردپای کربن شود.

در مجموع، یافته‌ها نشان می‌دهد که ترکیب مدل‌هایANN ، RFو XGBoost با داده‌های SCADA بستری برای ایجاد یک سیستم مدیریت انرژی هوشمند فراهم می‌کند؛ سیستمی که می‌تواند گامی مهم در مسیر شکل‌گیری «کارخانه‌های هوشمند آینده» باشد.

منابع

1. **[1]** Farag, M., Hassan, H., & Omar, A. (2023), “Machine learning approaches for identifying energy hotspots in food processing plants,” *Energy Conversion and Management*, 289, pp. 117067.
2. **[2]** Mahmud, S., Lee, D., & Park, S. (2021), “IoT-based SCADA systems for real-time monitoring of industrial energy use,” *Sensors*, 21(13), pp. 4564.
3. **[3]** Abdelhafez, A., & El Kader, N. A. (2023), “Energy consumption prediction in dairy processing using machine learning models,” *Journal of Food Engineering*, 345, pp. 111462.
4. **[4]** Chen, T., & Guestrin, C. (2016), “XGBoost: A scalable tree boosting system,” Proc. 22nd ACM SIGKDD, pp. 785–794.
5. **[5]** Zhang, Y., Li, W., & Sun, Y. (2022), “Application of XGBoost for energy forecasting in food thermal processing systems,” *Energy and AI*, 7, pp. 100123.
6. **[6]** Moeini, M., & Khaleghi, M. (2023), “Assessment of cooling system energy behavior using Random Forest in cold storage facilities,” *Applied Energy*, 331, pp. 120400.
7. **[7]** Li, X., & Wang, Z. (2020), “Predictive analytics for industrial energy consumption using SCADA and ML systems,” *Energy*, 211, pp. 118676.
8. **[8]** Batzias, F. & Siontorou, C. (2019), “Smart energy management in dairy operations,” *Journal of Cleaner Production*, 239, pp. 118132.
   [9] ISO (2018), *ISO 50001: Energy management systems — Requirements with guidance for use*, International Organization for Standardization.
   [10] Farag, M., Hassan, H., & Omar, A. (2023), “Machine learning approaches for energy hotspots,” *Energy Conversion and Management*, 289, pp. 117067.