

# پیش‌بینی دقیق شاخص ناسلت در مبدل‌های حرارتی صفحه‌ای با استفاده از یادگیری ماشین: یک مطالعه مقایسه‌ای جامع

سید احسان علوی<sup>۱\*</sup>، میثم موری شیربانی<sup>۲</sup> و جلال چاچی<sup>۳</sup>

<sup>۱،۲</sup> دانشکده مهندسی، دانشگاه شهید چمران اهواز، پردیس صنعتی شهدای هویزه، دشت آزادگان، ایران

<sup>۳</sup> دانشکده علوم ریاضی و کامپیوتر، دانشگاه شهید چمران اهواز، اهواز، ایران

تاریخ دریافت: ۱۴۰۴/۰۷/۰۲

تاریخ پذیرش: ۱۴۰۴/۰۸/۱۶

## چکیده:

در این پژوهش، از الگوریتم‌های یادگیری ماشین و روش‌های یادگیری آماری شامل رگرسیون خطی، رگرسیون خطی ساده، رگرسیون افزایشی، قواعد  $M_5$  و فرآیند گاوسی برای پیش‌بینی عدد ناسلت<sup>۱</sup> در مبدل‌های حرارتی صفحه‌ای استفاده شد. یک پایگاه داده جامع متشکل از داده‌های تجربی از منابع مختلف گردآوری و به کار گرفته شد. پارامترهای ورودی شامل زاویه شروان، نسبت ابعادی پروفیل موج‌دار، ضریب بزرگنمایی سطح و عدد رینولدز بودند و عدد ناسلت به عنوان متغیر خروجی در نظر گرفته شد. نتایج حاکی از دقت بالای مدل‌های به کار رفته بود، به طوری که در داده‌های آموزشی، بالاترین ضریب همبستگی توسط روش قواعد  $M_5$  و رگرسیون افزایشی به دست آمد. این روش همچنین در داده‌های آزمایشی با بیشترین ضریب همبستگی و کمترین خطا، به عنوان دقیق‌ترین مدل شناسایی شد. مقادیر خطای مطلق میانگین و ریشه میانگین مربعات خطا برای این مدل در داده‌های آزمایشی در پایین‌ترین سطح محاسبه گردید. یافته‌های این مطالعه نشان می‌دهد که روش قواعد  $M_5$  نه تنها از دقت پیش‌بینی بسیار بالایی برخوردار است، بلکه به دلیل ساختار شفاف و قابلیت تفسیرپذیری، ابزاری قابل اعتماد برای مدل‌سازی پدیده‌های انتقال حرارت در مبدل‌های حرارتی صفحه‌ای در طیف وسیعی از شرایط عملیاتی به شمار می‌رود.

**واژه‌های کلیدی:** یادگیری آماری، یادگیری ماشین، ضریب همبستگی، مبادله‌کن حرارتی صفحه‌ای، شاخص ناسلت.

## ۱ مقدمه

با گسترش روزافزون کاربرد مبدل‌های حرارتی صفحه‌ای در صنایع مختلف از جمله نفت، گاز، انرژی و سیستم‌های تهویه مطبوع، نیاز به مدل‌های دقیق و قابل اعتماد برای پیش‌بینی عملکرد حرارتی این تجهیزات بیش از پیش احساس می‌شود. اگرچه مطالعات متعددی در گذشته به برآورد ضریب انتقال حرارت در این مبدل‌ها پرداخته‌اند، اما بسیاری از این پژوهش‌ها بر پایه روش‌های تجربی سنتی یا شبیه‌سازی‌های عددی پیچیده استوار بوده‌اند که اغلب از دقت کافی در شرایط عملیاتی متنوع برخوردار نبوده و یا از قابلیت تعمیم‌پذیری محدودی برخوردارند. علاوه بر این، مدل‌های موجود معمولاً از شفافیت و قابلیت تفسیر کمتری برخوردار بوده و مهندسان را در درک دقیق رابطه بین پارامترهای طراحی و عملکرد حرارتی با چالش مواجه می‌کنند. از این رو، این تحقیق با هدف توسعه یک چارچوب هوشمند مبتنی بر یادگیری ماشین و با استفاده از الگوریتم‌های پیشرفته از جمله قواعد  $M_5$

مبادله‌کن‌های حرارتی صفحه‌ای به دلیل کارایی بالا در انتقال حرارت و طراحی فشرده، در صنایع مختلف کاربرد گسترده‌ای دارند. این مبادله‌کن‌ها از تعدادی صفحه تشکیل شده‌اند که کانال‌هایی برای جریان سیالات ایجاد می‌کنند و این امکان را فراهم می‌آورد تا حرارت به طور مؤثری بین دو سیال منتقل شود. به دلیل سطح انتقال حرارت زیاد در ابعاد کوچک، قابلیت گسترش یا تغییر به راحتی با افزودن یا حذف صفحات را دارند. مبادله‌کن‌های حرارتی صفحه‌ای در صنایعی مانند فرآوری مواد غذایی، مهندسی شیمی، تهویه مطبوع و تولید انرژی کاربرد دارند. توانایی آن‌ها در تحمل تغییرات فشار و دما، در کنار حفظ کارایی انرژی، آن‌ها را به جزء حیاتی بسیاری از فرآیندهای صنعتی تبدیل کرده است [۱].

\*نویسنده مسئول: jalal.chachi@gmail.com

[۱۰] به مدلسازی انتقال حرارت با استفاده از سه روش یادگیری ماشین جنگل تصادفی، تقویت گرادیان و شبکه عصبی مصنوعی پرداختند و مدل ارائه شده را با معیارهای آماری بر اساس شاخصهای ضریب همبستگی پیرسون، جذر میانگین مربعات خطا و میانگین خطای مطلق ارزیابی کردند. کیم و همکاران [۲] مدل‌های یادگیری ماشین را برای پیش‌بینی عملکرد حرارتی هیت سینک‌های میکرو-پین فین تحت شرایط مختلف را توسعه دادند سامی و سیرا [۱۴] به مطالعه مروری جامعی از روشهای یادگیری ماشین در محاسبه ضریب انتقال حرارت در ساختمانها پرداختند و بر این اساس شکافهای علمی در پژوهشهای فعلی را استخراج نمودند و راهکارهای اساسی جهت مطالعات بعدی ارائه نمود.

اگرچه مطالعات زیادی در مورد عملکرد هیدرولیکی و حرارتی مبدله‌کن‌های گرمایی صفحه‌ای انجام شده است، اما هنوز شکاف‌های مهمی وجود دارد [۱۴]. اول اینکه، اغلب پژوهش‌های قبلی عمدتاً به مدل‌های تجربی یا مبتنی بر فیزیک وابسته بوده‌اند که اغلب فاقد قابلیت تعمیم در رژیم‌های جریان متغیر، هندسه‌های صفحه و شرایط عملیاتی هستند. دوم، اینکه مطالعات کمی به بررسی ادغام مدل‌های پیشرفته هوش مصنوعی برای توسعه سیستم‌های پیش‌بینی قوی، قابل تفسیر و داده‌محور پرداخته‌اند. در پاسخ به این شکاف‌ها، کار حاضر یک چارچوب مدل‌سازی جعبه شیشه‌ای جدید و قابل توسعه با استفاده از مجموعه‌ای از الگوریتم‌های هوشمند برای پیش‌بینی شاخص ناسلت در طیف وسیعی از اعداد رینولدز<sup>۲</sup> ارائه می‌دهد. به عبارتی دیگر، نوآوری این پژوهش در آن است که مدل ارائه شده در این تحقیق قادر است به ازای هندسه‌های مختلف مبدله‌کن حرارتی صفحه‌ای با دقت بسیار بالا شاخص ناسلت را پیش‌بینی نماید. بنابراین استفاده از هوش مصنوعی الزام به انجام آزمایش و ارائه رابطه تجربی با دقت نه چندان بالا که فقط در یک شرایط خاص قابل استفاده است را برطرف می‌نماید. کاربرد مهم مدل ارائه شده این است که در اعداد رینولدزی که تاکنون رابطه تجربی ارائه نشده است نیز قادر است شاخص ناسلت را بسیار دقیق پیش‌بینی نماید. نکته قابل ذکر در خصوص پژوهش حاضر، معرفی روش قواعد  $M_5^2$  به عنوان مدل برتر از بین روش‌های مختلف مورد بررسی است. روشی که نسبت به روش‌های قدیمی‌تر دقت بالاتر و نسبت به بسیاری از روش‌های جدیدتر تفسیرپذیری و قابلیت بالاتری جهت کار با داده‌های ناقص را دارد. لذا اهداف کلی پژوهش حاضر عبارت است از:

رگرسیون افزایشی و فرآیند گاوسی، به دنبال پر کردن این خلأ پژوهشی می‌باشد. مدل ارائه شده در این مطالعه نه تنها قادر به پیش‌بینی دقیق عدد ناسلت در طیف وسیعی از شرایط عملیاتی است، بلکه به دلیل ساختار شفاف و قابلیت تفسیرپذیری بالا، امکان شناسایی دقیق تأثیر هر یک از پارامترهای ورودی را فراهم می‌سازد. این رویکرد نوین می‌تواند به عنوان ابزاری قدرتمند در بهینه‌سازی طراحی و بهبود عملکرد مبدل‌های حرارتی صفحه‌ای مورد استفاده قرار گیرد و گامی مهم در جهت توسعه سیستم‌های انرژی کارآمد و پایدار باشد.

تاکنون مطالعات مختلفی در مبدله‌کن‌های حرارتی صفحه‌ای انجام شده است. در برخی پژوهش‌ها رویکرد اقتصادی مد نظر بوده است و هزینه مبدله‌کن حرارتی کمینه شده است [۲]. در مطالعات دیگری، بهینه‌سازی مبدله‌کن حرارتی با هدف کمینه نمودن تلفات مورد توجه بوده است [۴]. پنگ و همکاران [۵] بصورت تجربی عملکرد حرارتی مبدله‌کن‌های حرارتی صفحه‌ای لحیم‌شده را با هندسه‌های مختلف صفحات مطالعه نمودند. جعفری و همکاران [۶] بصورت تجربی و عددی هندسه یک مبدله‌کن حرارتی صفحه‌ای لحیم‌شده را مورد بررسی قرار دادند. هان و همکاران [۷] ضریب انتقال حرارت و افت فشار در مبدله‌کن‌های حرارتی صفحه‌ای لحیم‌شده را بررسی نمودند. گورل و همکاران [۸] یک مبدله‌کن حرارتی صفحه‌ای لحیم‌شده را با رویکرد حرارتی-هیدرولیکی مورد مطالعه قرار دادند. هام و همکاران [۹] در پژوهش خود به ارائه روابط تجربی جدید جهت محاسبه عدد ناسلت و ضریب اصطکاک در مبدله‌کن‌های حرارتی محلول پرداختند. از مقایسه نتایج این روابط با داده‌های تجربی ملاحظه شد که رابطه ارائه شده برای عدد ناسلت دقت بسیار بالایی دارد در حالی که رابطه ارائه شده برای ضریب اصطکاک در مقایسه با روابط معرفی شده در کارهای قبلی مقدار کمتری را محاسبه می‌کند. گونگر [۱۱] به صورت تجربی مبدله‌کن‌های حرارتی صفحه‌ای لحیم‌شده با صفحات موج‌دار را با رویکرد حرارتی و هیدرولیکی مطالعه نمود. مارتینس و همکاران [۱۲] مبدله‌کن‌های حرارتی صفحه‌ای و اشردار را با رویکرد سازه‌ای بصورت عددی با استفاده از نرم افزار انسیس و تجربی مورد بررسی قرار دادند. نیگو و همکاران [۱۳] بازدهی حرارتی مبدله‌کن‌های حرارتی صفحه‌ای و اشردار را مورد بررسی قرار دادند. استروبل و همکاران [۱۵] به بررسی انتقال حرارت و افت فشار در یک مبدله‌کن حرارتی صفحه‌ای و اشردار با الگوی موج جدید پرداختند. متکار و همکاران [۱۶] مبدله‌کن حرارتی صفحه‌ای و اشردار را با رویکرد ترموهیدرولیکی مطالعه نمودند. گداسیایی و کمالی

<sup>۲</sup>Reynolds<sup>۳</sup>M5 Rules

### ۳ مبانی روش‌های یادگیری ماشین

در این پژوهش از مجموعه‌ای از روش‌های رگرسیونی برای پیش‌بینی شاخص ناسلت در مبادله‌کن‌های حرارتی صفحه‌ای استفاده شده است که شامل رگرسیون خطی، رگرسیون خطی ساده و رگرسیون افزایشی، قواعد  $M_5$  و فرآیند گاوسی می‌شود. این روش‌ها از جمله پرکاربردترین تکنیک‌ها در یادگیری ماشین و تحلیل داده‌ها محسوب می‌شوند که به ویژه در مواردی که رابطه‌ای نسبتاً خطی میان ویژگی‌ها و متغیر وابسته وجود دارد، عملکرد قابل قبولی دارند. در ادامه، این روش‌ها از منظر اصول عملکرد، مراحل پیاده‌سازی و نقاط قوت آن‌ها به صورت جامع تشریح می‌شوند.

رگرسیون خطی<sup>۴</sup> (LR) به عنوان یک روش پایه‌ای در مدل‌سازی پیش‌بینی به دنبال یافتن رابطه‌ای مستقیم میان متغیرهای مستقل (ویژگی‌ها) و متغیر وابسته است. در این روش، مدل تلاش می‌کند یک معادله خطی ایجاد کند که بر اساس آن بتوان مقدار خروجی را بر حسب ورودی‌ها تخمین زد. از آنجایی که مدل‌های رگرسیون خطی عموماً ساده، تفسیرپذیر و سریع‌الاجرا هستند، در بسیاری از مسائل کاربردی مورد استفاده قرار می‌گیرند. این روش فرض می‌کند که رابطه بین متغیرها خطی است و بر مبنای همین فرض، مدل بهترین ضرایب را برای متغیرهای مستقل تخمین می‌زند تا کمترین میزان خطا در پیش‌بینی حاصل شود.

رگرسیون خطی ساده (SLR)<sup>۵</sup>، نوعی خاص از رگرسیون خطی است که در آن تنها یک متغیر مستقل وجود دارد. این روش برای تحلیل تأثیر مستقیم یک عامل بر متغیر وابسته مناسب است و به خوبی می‌تواند روندها یا الگوهای ساده را آشکار کند. رگرسیون ساده بیشتر در تحلیل‌های اولیه یا زمانی که هدف درک تأثیر یک ویژگی خاص بر خروجی است، کاربرد دارد. با وجود محدودیت در استفاده از تنها یک متغیر ورودی، این روش به علت سادگی، سرعت بالا و قابلیت تفسیر بالا همچنان یکی از ابزارهای پایه در تحلیل داده‌هاست.

در مقابل، رگرسیون افزایشی (AR) رویکردی ترکیبی دارد که از مدل‌های پایه ساده‌تر (معمولاً رگرسیون خطی ساده یا مدل‌های دیگر) استفاده می‌کند و به صورت افزایشی و مرحله‌به‌مرحله، مدلی پیچیده‌تر و دقیق‌تر می‌سازد. این تکنیک بر مبنای اصول یادگیری جمعی عمل می‌کند و تلاش می‌کند تا در هر مرحله، خطای باقی‌مانده از مراحل قبل را کاهش دهد. در واقع، مدل اولیه ساخته می‌شود و سپس در

۰۱ ساخت و اعتبارسنجی مدل‌های یادگیری ماشینی که قادر به تخمین دقیق شاخص ناسلت با استفاده از پارامترهای حیاتی طراحی و جریان هستند؛

۰۲ یافتن قابل اعتمادترین الگوریتم در بین رویکردهای آزمایش شده با استفاده از تجزیه و تحلیل عملکرد مقایسه‌ای.

### ۲ تئوری مبادله‌کن گرمایی صفحه‌ای

مبادله‌کن‌های گرمایی صفحه‌ای با استفاده از مجموعه‌ای از صفحات فلزی با کانال‌هایی که سیالات از آن‌ها عبور می‌کنند، ساخته می‌شوند. عملکرد گرمایی کارآمد این سیستم‌ها کاملاً شناخته شده است؛ شکل جمع و جور و مساحت سطح بزرگ آن‌ها برای تبادل گرما، به توضیح این موضوع کمک می‌کند که چرا گرما با حرکت سیال از طریق همرفت و رسانش در صفحات حرکت می‌کند. طراحی چنین مبادله‌کن‌هایی نیاز به در نظر گرفتن عواملی مانند تعداد صفحات، فاصله، نوع مایع و جهت جریان سیال، دارد. بهبود عملکرد و حفظ افت فشار کم به ارزیابی دقیق این عناصر بستگی دارد. جریان سیال آرام یا آشفته درون واحد بر میزان نوسان فشار و راندمان انتقال حرارت تأثیر می‌گذارد. به دلیل قابلیت اطمینان آن‌ها در تبادل گرما و سادگی نگهداری، این مبادله‌کن‌ها کاربرد زیادی در زمینه‌هایی از جمله فناوری‌های غذایی، فرآوری شیمیایی و کنترل آب و هوا دارند. شاخص ناسلت در این تحقیق بصورت رابطه زیر تعریف می‌شود:

$$Nu = \frac{Nu}{\left[ Pr^{\frac{1}{4}} \left( \frac{\mu}{\mu_w} \right)^{0.14} \right]} \quad (1)$$

پژوهش‌های مختلفی تا کنون به ارائه روابطی جهت استخراج عدد ناسلت در مبادله‌کن‌های حرارتی صفحه‌ای پرداختند. در جدول ۱ روابط مراجع مورد استفاده جهت استخراج داده‌های آزمایشگاهی تحقیق حاضر ذکر شده است. در این جدول روابط تجربی برای عدد ناسلت که از نتایج آزمایشگاهی بدست آمده است ذکر شده است. ملاحظه می‌شود که برخی از این روابط بطور کلی حافظ دامنه پارامترهای هندسی نبوده و یا در بازه‌های محدود از عدد رینولدز معتبر هستند. لذا در ادامه ارائه یک مدل جامع که در بازه‌های مختلف معتبر باشد و هندسه مبدل حرارتی را نیز لحاظ کند ضروری بنظر می‌رسد.

<sup>4</sup>Linear Regression

<sup>5</sup>Simple Linear Regression

جدول ۱: برخی روابط موجود در پژوهش‌های پیشین

مراجع	دامنه عدد رینولدز	رابطه عدد ناسلت
[۱۷]	$27 \leq Re \leq 56000$	$Nu = C_1 Re^{C_2} Pr^{0.5}$
[۱۸]	$1450 \leq Re \leq 11460$	$Nu = 0.248 Re^{0.7} Pr^{0.4}$
[۱۹]	$1000 \leq Re$	$Nu = (0.2668 - 6.867 \times 10^{-3} \beta + 7.244 \times 10^{-5} \beta^2) \times Re^{[0.728 + 0.543 \sin(\frac{\pi \beta}{30} + 3.7)]}$ $\times \frac{0.233}{Pr} \times \left(\frac{\mu}{\mu_w}\right)^{0.14}$
[۲۰]	$30 \leq Re \leq 400$	$Nu = 1.6774 \left(\frac{d_e}{L}\right)^{\frac{1}{3}} \times \left(\frac{\beta}{30}\right)^{0.38}$ $\times Re^{0.5} Pr^{0.4} \times \left(\frac{\mu}{\mu_w}\right)^{0.14}$
[۲۱]	$2000 \leq Re$	$Nu = 0.295 \beta^{0.9} Re^{0.64} Pr^{0.32}$
[۲۲]	$400 \leq Re \leq 1000$	$Nu = C_1 Re^{C_2} Pr^{0.333} \times \left(\frac{\mu}{\mu_w}\right)^{0.14}$
[۲۲]	$2000 \leq Re \leq 8000$	$Nu = C_1 Re^{C_2} Pr^{0.333} \times \left(\frac{\mu}{\mu_w}\right)^{0.14}$
[۲۳]	$500 \leq Re \leq 2500$	$Nu = \left(0.161 \frac{\beta}{\beta_{max}} + 0.1298\right) \times Re^{(0.198 \frac{\beta}{\beta_{max}} + 0.6398)}$ $\times \frac{0.35}{Pr} \times \left(\frac{\mu}{\mu_w}\right)^{0.14}$
[۲۴]	$50 \leq Re \leq 8000$	$Nu = (-1.342 \times 10^{-4} \beta^2 + 1.808 \times 10^{-2} \beta - 0.0075) \times Re^{(-0.7956 \times 10^{-5} \beta^2 + 9.687 \times 10^{-2} \beta + 0.3155)}$ $\times Re^{\frac{0}{\beta}} \times Re^{\frac{\gamma}{\beta}} \times \frac{0.333}{Pr} \times \left(\frac{\mu}{\mu_w}\right)^{0.14}$

مدل‌های ترکیبی دیگر، باعث افزایش انعطاف‌پذیری آن‌ها در مسائل پیش‌بینی می‌شود.

فرآیند گاوسی<sup>۶</sup> (GP) یک مدل آماری قدرتمند برای مدل‌سازی داده‌های پیچیده است که در یادگیری ماشین و آمار استفاده می‌شود. این مدل برای پیش‌بینی و تحلیل داده‌های غیرخطی و پیچیده که نیاز به مدل‌های دقیق و انعطاف‌پذیر دارند، بسیار مناسب است. فرآیند گاوسی به‌طور خاص برای مدل‌سازی توزیع‌های احتمالی از متغیرهای پیوسته و غیرخطی به‌کار می‌رود و می‌تواند به‌عنوان یک مدل پیش‌بینی قوی در مسائل مختلف استفاده شود.

مزایای روش فرآیند گاوسی عبارتند از:

- انعطاف‌پذیری بالا.
- ارائه عدم قطعیت در پیش‌بینی‌ها.
- مناسب برای مسائل پیچیده بدون نیاز به تعیین فرم تابع.

هر مرحله، مدلی جدید برای مدل‌سازی خطای پیش‌بینی قبلی افزوده می‌شود. این فرایند به بهبود تدریجی دقت مدل کمک می‌کند و معمولاً در پیش‌بینی‌هایی که دقت بالا مورد نیاز است، عملکرد قابل توجهی دارد.

از نظر پیاده‌سازی، مراحل اجرای این روش‌ها شامل وارد کردن داده‌ها، انتخاب ویژگی‌ها، اعمال پیش‌پردازش‌های لازم (مانند نرمال‌سازی یا حذف مقادیر گمشده)، انتخاب مدل رگرسیونی مناسب از لیست الگوریتم‌ها و سپس اجرای مدل و تحلیل نتایج است. از نقاط قوت این روش‌ها می‌توان به سادگی مفهومی، سرعت در آموزش مدل، توانایی تفسیر نتایج، و عملکرد قابل قبول در صورت رعایت پیش‌فرض‌های لازم (مانند عدم هم‌خطی شدید بین ویژگی‌ها یا توزیع نرمال خطاها) اشاره کرد. همچنین، امکان استفاده از این روش‌ها به‌عنوان پایه برای الگوریتم‌های پیچیده‌تر مانند رگرسیون افزایشی یا

<sup>6</sup>Gaussian Process

خطا<sup>۹</sup> ( $RMSE$ ) و درصد خطای مطلق میانگین<sup>۱۰</sup> ( $MAPE\%$ ) برای ارزیابی عملکرد مدل ایجاد شده استفاده می‌شود که به شرح زیر تعریف می‌شوند:

$$R = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2 \sum_{i=1}^N (y_i - \bar{y})^2}}$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - x_i)^2}$$

$$MAPE(\%) = \frac{100}{N} \sum_{i=1}^N \left| \frac{y_i - x_i}{y_i} \right|$$

که  $x_i, \bar{x}, y_i, \bar{y}$  و  $N$  به ترتیب بیانگر مقدار پیش‌بینی شده، میانگین مقدار پیش‌بینی شده، مقدار واقعی، میانگین مقدار واقعی و تعداد مجموعه داده‌ها است [۲۵].

## ۴ نتایج

در این تحقیق ۸۰٪ از مجموعه داده‌ها به داده‌های آموزش و ۲۰٪ داده‌ها به داده‌های آزمایش بطور تصادفی اختصاص یافت. این روش انتخاب تصادفی، روشی ثابت برای ارزیابی عملکرد روی داده‌های پردازش نشده ارائه می‌دهد و از ساخت مدل متعادل پشتیبانی می‌کند. شکل ۱ نمودارهای پراکندگی را نشان می‌دهد که با استفاده از روش‌های مختلف شاخص ناسلت مورد انتظار و واقعی را برای مجموعه‌های آموزشی و آزمایشی مقایسه می‌کنند.

مراحل پیاده‌سازی این روش به شرح زیر است:

۱. تعریف یک تابع کرنل<sup>۷</sup>: کرنل مشخص می‌کند که نقاط داده‌ای چگونه به هم مرتبط هستند.
۲. محاسبه ماتریس کوواریانس: برای نشان دادن وابستگی‌های بین نقاط داده‌ای استفاده می‌شود.
۳. مدل‌سازی تابع هدف به‌عنوان یک توزیع گاوسی: این کار باعث پیش‌بینی مقدار خروجی با عدم قطعیت می‌شود.
۴. به‌روزرسانی مدل با داده‌های جدید: توزیع احتمال خروجی برای هر نقطه جدید تغییر می‌کند.

الگوریتم قواعد  $M_5$  یکی از روش‌های یادگیری ماشین در حوزه مسائل رگرسیون است که با تلفیق ساختار درخت تصمیم و مدل‌های رگرسیون خطی، به ارائه پیش‌بینی‌های عددی می‌پردازد. این روش نوآورانه با تولید مجموعه‌ای از قواعد شفاف و قابل تفسیر، امکان پیش‌بینی دقیق نتایج عددی را فراهم می‌سازد. فرایند آن با ساخت یک درخت رگرسیون آغاز می‌شود که در گره‌های انتهایی آن، مدل‌های رگرسیون خطی قرار می‌گیرند. سپس مسیرهای مختلف این درخت به صورت قواعد بازنویسی می‌شوند؛ به طوری که هر قاعده دارای شرایط مشخصی است که به کمک یک مدل خطی، خروجی مورد نظر را پیش‌بینی می‌کند. در ادامه، این قواعد بهینه‌سازی شده و ساده‌سازی می‌شوند تا از پیچیدگی کاسته شده و وضوح مدل افزایش یابد.

از جمله مزایای اصلی الگوریتم قواعد  $M_5$  می‌توان به دقت بالا در داده‌هایی که الگوهای خطی محلی دارند، تفسیرپذیری بسیار خوب نتایج، توانایی حذف ویژگی‌های نامربوط و انعطاف‌پذیری بالا در مدل‌سازی اشاره کرد. این ویژگی‌ها باعث می‌شوند الگوریتم مذکور به‌ویژه در کاربردهایی که نیاز به درک دقیق سازوکار مدل وجود دارد، بسیار مناسب باشد. با این حال، این روش نسبت به داده‌های پرت حساس است و در برخی موارد ممکن است دچار بیش‌برازش شود. همچنین در مسائلی که شامل روابط غیرخطی پیچیده هستند، عملکرد آن معمولاً از روش‌های پیشرفته‌تری مانند شبکه‌های عصبی ضعیف‌تر است. با وجود این محدودیت‌ها، قواعد  $M_5$  به دلیل توازن مناسب میان دقت، شفافیت و کارایی، همچنان یکی از گزینه‌های کاربردی در مسائل رگرسیون محسوب می‌شود.

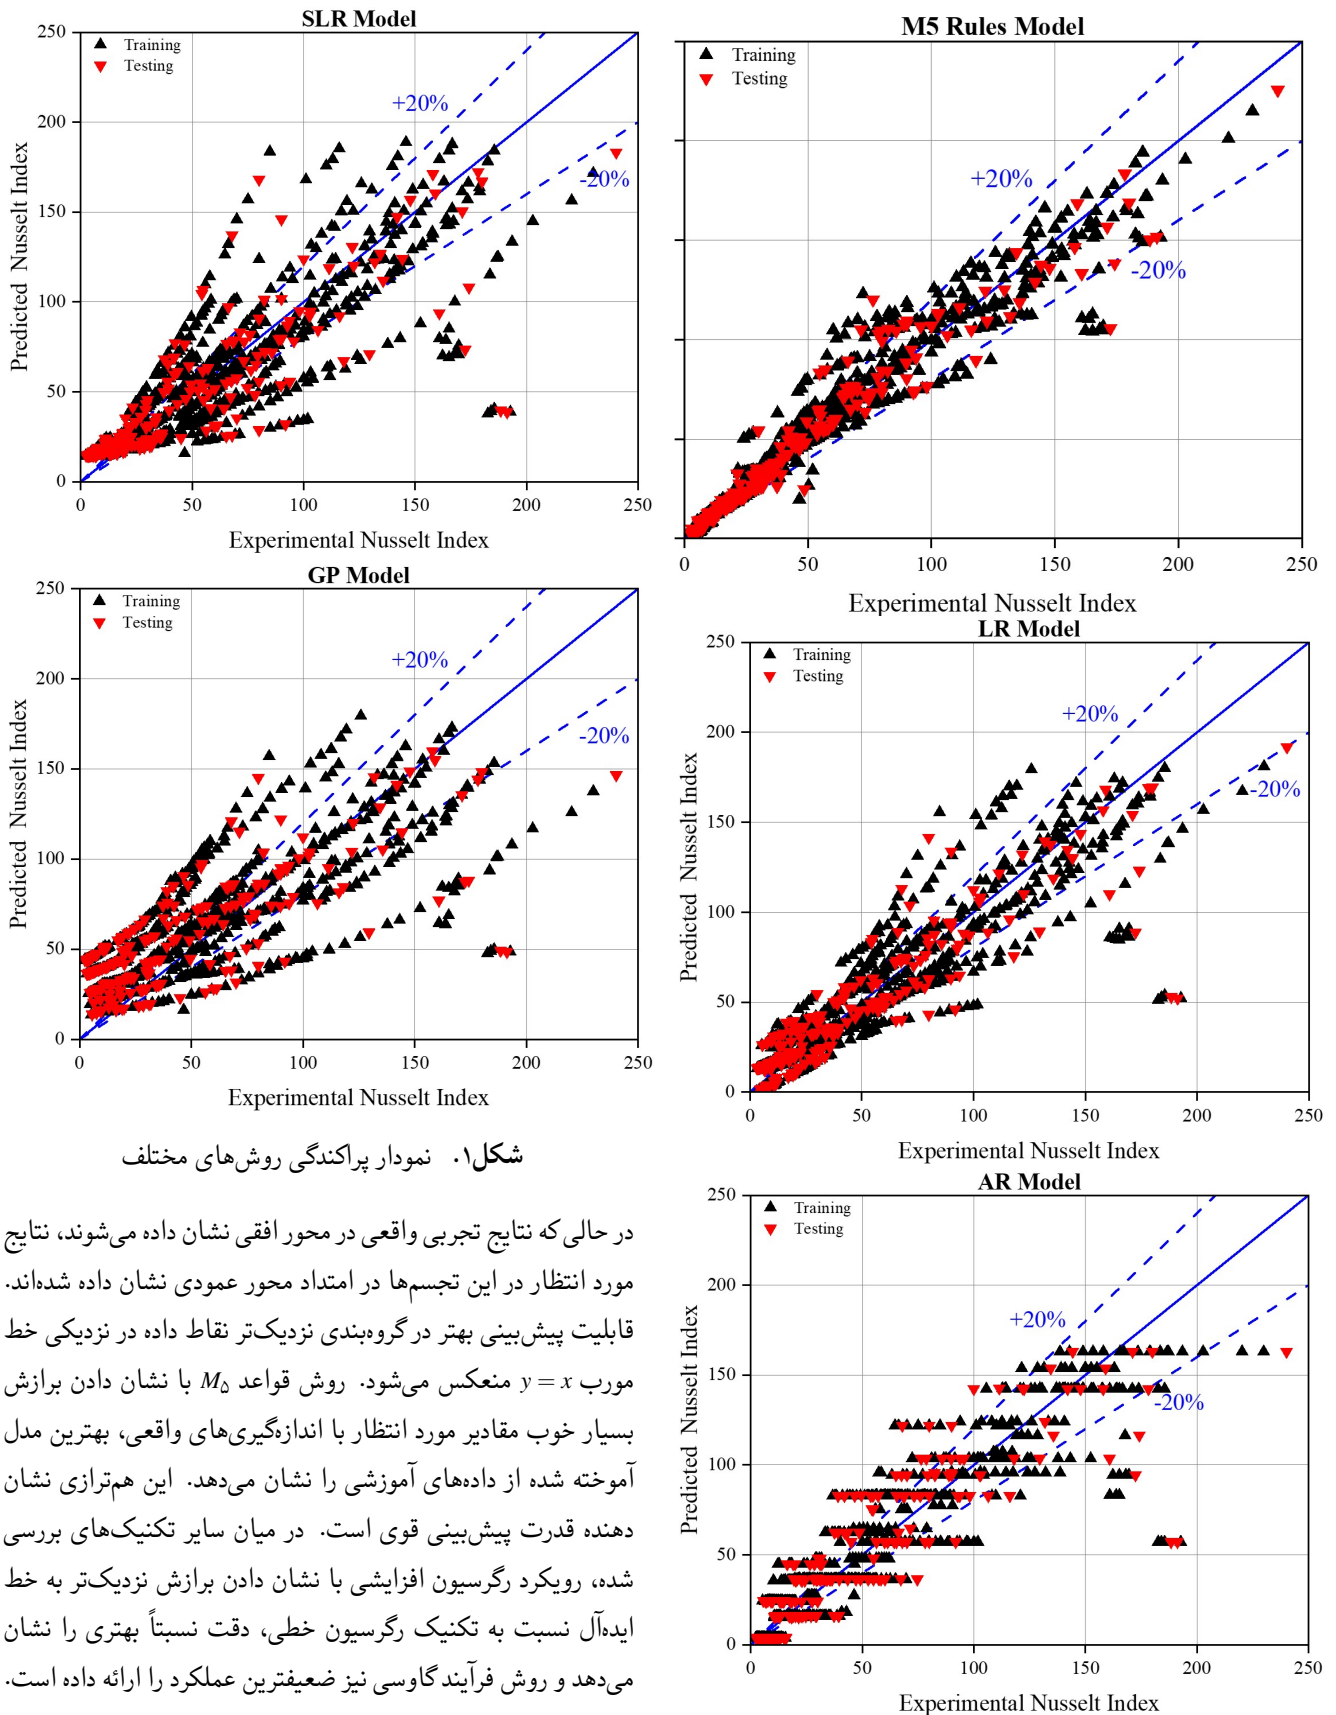
معیارهای پرکاربرد ضریب همبستگی<sup>۸</sup> ( $R$ ) ریشه میانگین مربعات

<sup>7</sup>Kernel

<sup>8</sup>Correlation coefficient


<sup>9</sup>Root Mean Square Error

<sup>10</sup>Mean Absolute Percentage Error

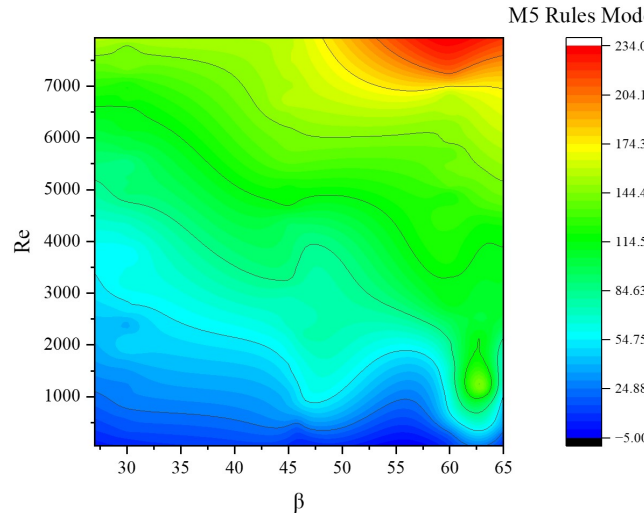

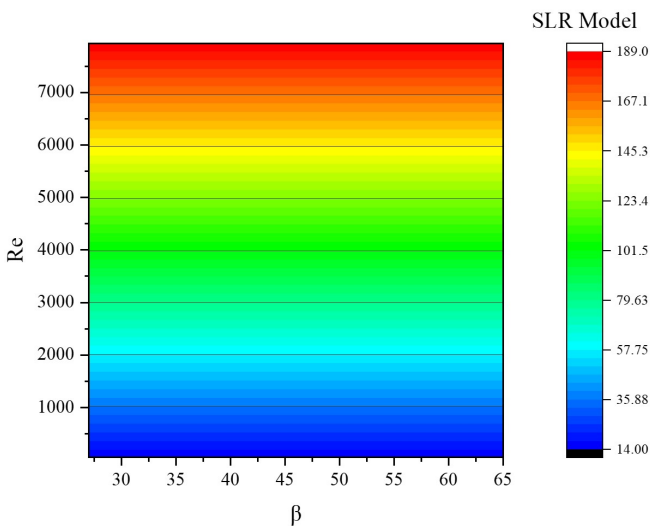
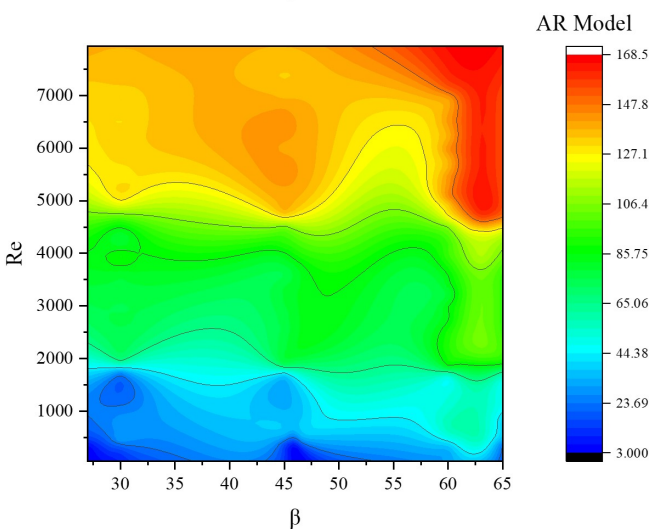


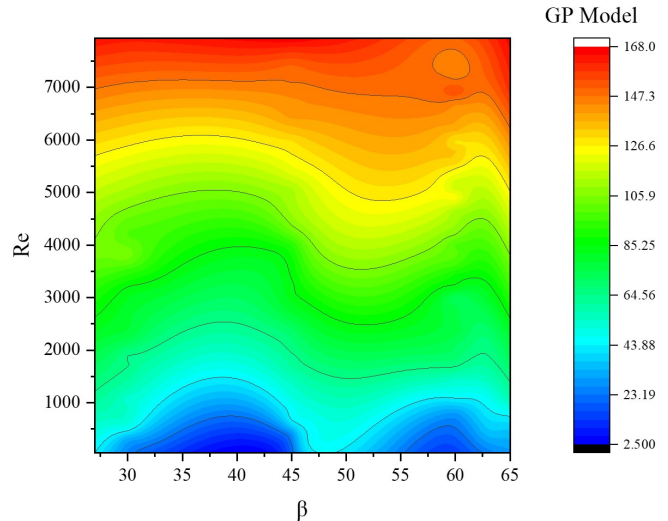
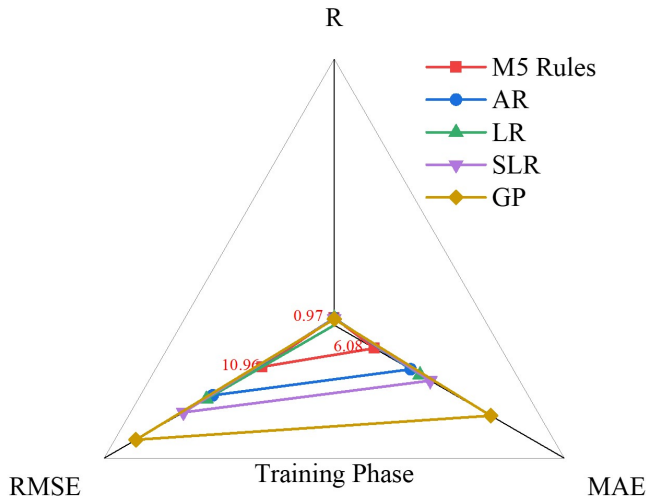
شکل ۱. نمودار پراکندگی روش‌های مختلف

در حالی که نتایج تجربی واقعی در محور افقی نشان داده می‌شوند، نتایج مورد انتظار در این تجسم‌ها در امتداد محور عمودی نشان داده شده‌اند. قابلیت پیش‌بینی بهتر در گروه‌بندی نزدیک‌تر نقاط داده در نزدیکی خط مورب  $y = x$  منعکس می‌شود. روش قواعد  $M_5$  با نشان دادن برازش بسیار خوب مقادیر مورد انتظار با اندازه‌گیری‌های واقعی، بهترین مدل آموخته شده از داده‌های آموزشی را نشان می‌دهد. این هم‌ترازی نشان دهنده قدرت پیش‌بینی قوی است. در میان سایر تکنیک‌های بررسی شده، رویکرد رگرسیون افزایشی با نشان دادن برازش نزدیک‌تر به خط ایده‌آل نسبت به تکنیک رگرسیون خطی، دقت نسبتاً بهتری را نشان می‌دهد و روش فرآیند گاوسی نیز ضعیف‌ترین عملکرد را ارائه داده است. در هر تصویر، خطوط چین‌دار نشان دهنده دو محدوده خطا در  $\pm 20\%$  هستند که نشان‌دهنده عدم دقت در مقادیر شاخص ناسلت پیش‌بینی شده هستند. بررسی نتایج نشان می‌دهد که بیشتر نتایج

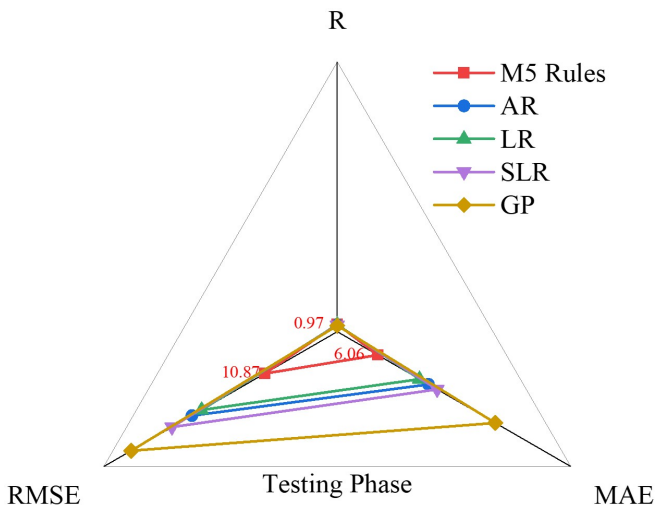


پیش‌بینی‌شده توسط روش قواعد  $M_5$  در محدوده خطا قرار می‌گیرند و نزدیک به خط ۴۵ درجه هستند. در نتیجه، این روش پیش‌بینی دقیقی را در بین روش‌های آزمایشی در این مطالعه ارائه می‌دهد و پس از آن رگرسیون افزایشی و رگرسیون خطی به ترتیب قرار دارند. علاوه بر این، هنگام ارزیابی پیش‌بینی‌های شاخص ناسلت در روش‌های مختلف، واضح است که مدل پیشنهادی با استفاده از روش قواعد  $M_5$  هیچ پیش‌بینی پرتی را در داده‌های آموزش و آزمایش ایجاد نکرده است. به عبارت دیگر، هیچ نقطه‌ای وجود ندارد





شکل ۲. کانتور دو بعدی شاخص ناسلت بر حسب عدد رینولدز و زاویه شوری با استفاده از روش‌های مختلف



شکل ۳. نمودار عنکبوتی مقایسه عملکرد روش‌های مختلف


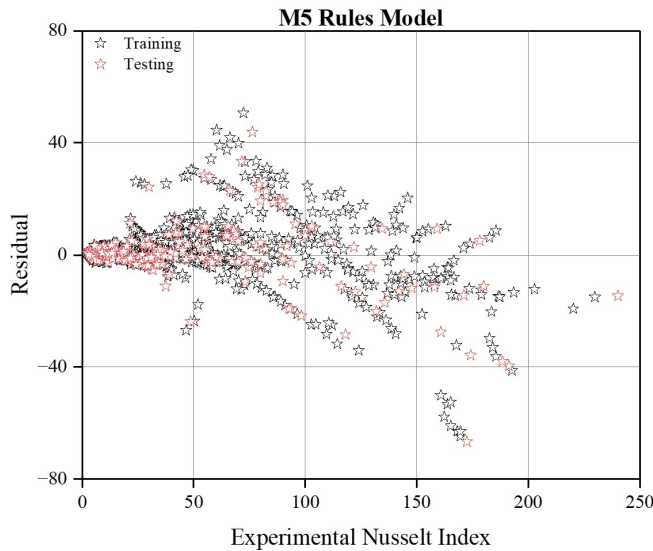
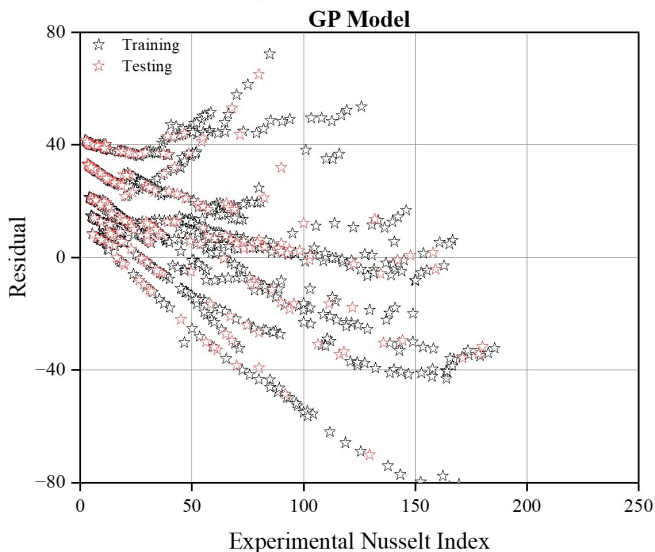
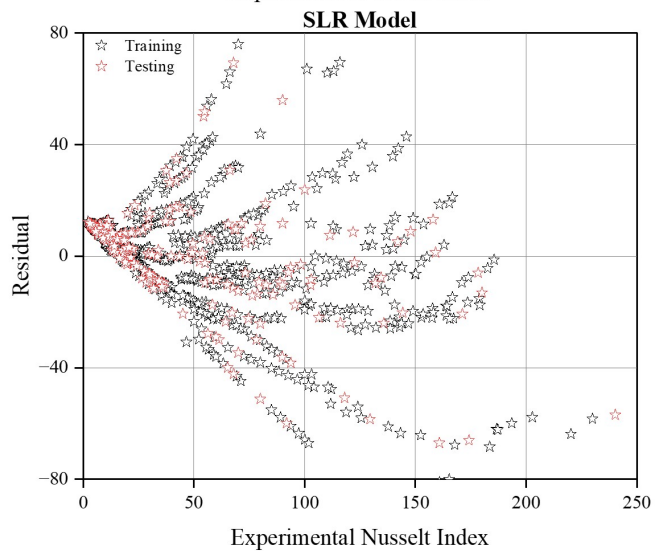
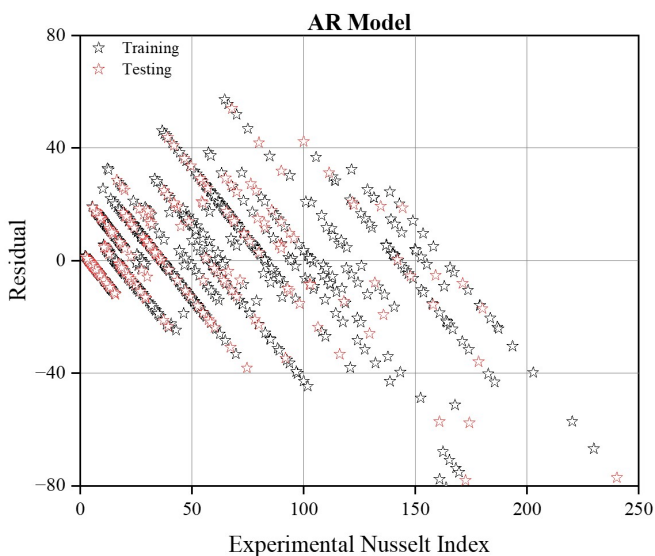
در شکل ۳ نتایج پیش‌بینی شاخص ناسلت با استفاده از روش‌های مختلف و برای داده‌های آموزش و آزمایش در قالب نمودار عنکبوتی مقایسه شده است. برای ارزیابی مدل‌ها در این پژوهش از معیارهای ضریب همبستگی، ریشه مربعات خطا و درصد خطای مطلق میانگین استفاده شده است. این معیارها برای مدلی است که با استفاده از داده‌های آموزش و به روش‌های مختلف تعلیم دیده است و در نتیجه ارزیابی مقایسه‌ای عملکرد مدل‌ها جهت پیش‌بینی شاخص ناسلت را تسهیل می‌نماید. ملاحظه می‌شود که هم برای داده‌های آموزش و هم برای داده‌های آزمایش روش قواعد  $M_5$  بالاترین میزان ضریب همبستگی و کمترین میزان خطا را در مقایسه با سایر روش‌ها ارائه داده است. همچنین مشاهده می‌شود که روش‌های رگرسیون افزایشی و رگرسیون خطی عملکرد مشابه و نزدیکی در داده‌های آموزش از خود نشان داده‌اند اما عملکرد روش رگرسیون خطی در داده‌های آزمایش بهتر است. از نتایج دیگر این نمودارهای عنکبوتی می‌توان به عملکرد ضعیف روش فرآیند گاوسی در مقایسه با سایر روش‌های مورد مطالعه و برای هر دو

که به طور قابل توجهی از خط بهترین برازش منحرف شود. این مدل دقت قابل توجهی را در پیش‌بینی مقادیر کوچک و بزرگ شاخص ناسلت تجربی نشان داد. در نتیجه، این یافته نشان می‌دهد که مدل از درجه بالایی از تعمیم‌پذیری برخوردار است.

شکل ۲ کانتورهای دو بعدی شاخص ناسلت تجربی و پیش‌بینی شده را به ازای دو پارامتر مستقل که بیشترین تاثیر بر آن دارند را نشان می‌دهد. از مقایسه توزیع شاخص ناسلت داده‌های آزمایشگاهی و روش‌های مختلف مشاهده می‌شود که کانتور شاخص ناسلت پیش‌بینی شده با استفاده از روش قواعد  $M_5$  بیشترین نزدیکی و مشابهت را با کانتور مقادیر واقعی دارد و لذا نتایج این روش از سایر روش‌ها دقیق‌تر است. همچنین مشاهده می‌شود که کمترین میزان تطابق کانتورهای شاخص ناسلت پیش‌بینی شده و واقعی به روش‌های رگرسیون خطی ساده و روش فرآیند گاوسی اختصاص دارد. این ارزیابی کیفی، توانایی مدل را در تطبیق موثر با داده‌های مشاهده شده برجسته‌تر می‌کند.


مجموعه داده‌های آموزش و آزمایش اشاره کرد.

شکل ۴ نمودارهای پراکنندگی مقادیر باقیمانده پیش‌بینی شاخص ناسلت با استفاده از روش‌های مختلف را برای داده‌های آموزشی و آزمایشی نشان می‌دهد. محور قائم بیانگر مقدار باقیمانده پیش‌بینی انجام شده توسط مدل و محور افقی نشان دهنده مقادیر آزمایشگاهی است. در این نمودارها خط  $y = 0$  معیار ارزیابی عملکرد مدل است. تمرکز نقاط حاصل بر روی این خط بیانگر این است که خطای پیش‌بینی انجام شده توسط مدل کم بوده و لذا نتایج پیش‌بینی شده و مقادیر آزمایشگاهی به هم نزدیک هستند.




شکل ۴. نمودار پراکنندگی مقدار باقیمانده پیش‌بینی به روش‌های مختلف


از نتایج ملاحظه می‌شود که خطای مطلق مدل ارائه شده با استفاده از



AR Model




SLR Model




GP Model

روش قواعد  $M_5$  در مقایسه با چهار روش دیگر بسیار کمتر بوده و اغلب نقاط نمودار آن حول خط خطای مطلق صفر پراکنده شده‌اند. همچنین از مقایسه مقدار باقیمانده پیش‌بینی شاخص ناسلت روش‌های مختلف می‌توان دریافت که برای داده‌های آموزش و آزمایش نتایج حاصل از پیش‌بینی روش فرآیند گاوسی مقدار باقیمانده بیشتری دارند. نمودار جعبه‌ای درصد انحراف نسبی مطلق داده‌های آزمایش برای روش‌های مختلف مورد مطالعه در این تحقیق در شکل ۵ نشان داده شده است. ملاحظه می‌شود که روش قواعد  $M_5$  در مقایسه با سایر روش‌ها محدوده بین چارکی کوچکتری دارد،



M5 Rules Model



LR Model

شکل ۵. نمودار جعبه‌ای درصد انحراف نسبی مطلق روش‌های مختلف

لذا نتایج این روش انحراف کمتر، پایدارتر و متمرکزتر هستند. همچنین مشاهده می‌شود که خط میانه و مقدار میانگین در این روش به هم نزدیک هستند بنابراین می‌توان نتیجه گرفت که تقریباً توزیع متقارن و مدل پایدار است. از مقایسه نقاط پرت پیش‌بینی روش‌های مختلف

بخش‌های مختلف از خود نشان می‌دهد. همچنین ملاحظه می‌شود که ضریب همبستگی و درصد خطای مطلق میانگین روش قواعد  $M_5$  به ازای تعداد بخش‌های مختلف تغییر محسوسی ندارد و لذا می‌توان نتیجه گرفت که این روش از پایداری و قابلیت تعمیم‌پذیری بسیار بالایی نیز برخوردار است.

## ۵ تحلیل برتری‌های عددی مدل پیشنهادی

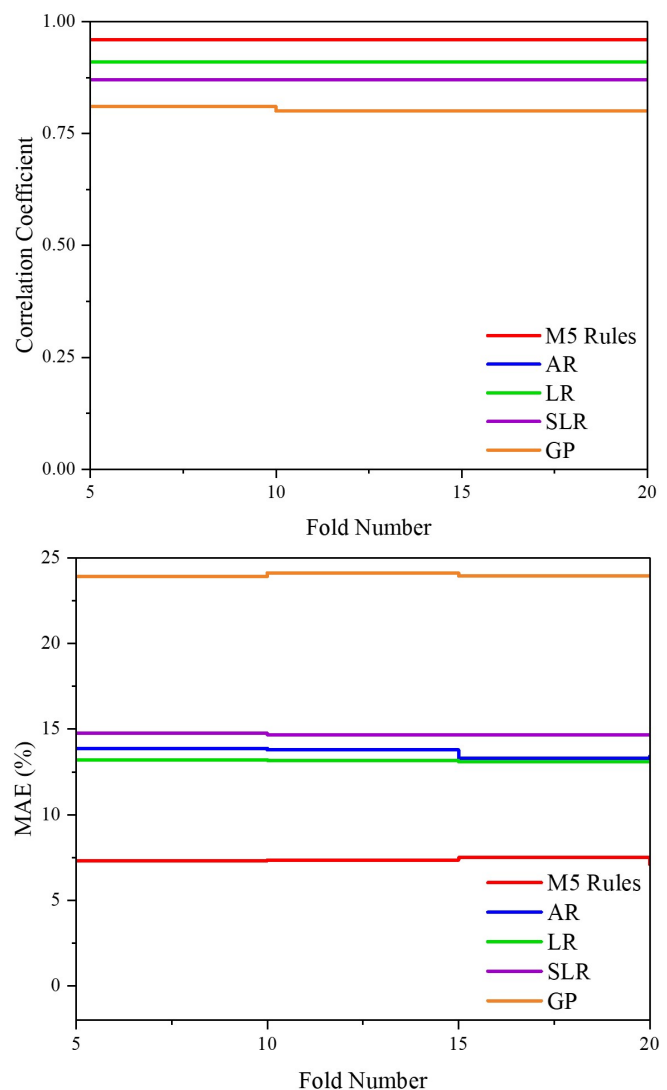
بر پایه ارزیابی‌های کمی انجام شده، مدل قواعد  $M_5$  برتری مطلق خود را در پیش‌بینی عدد ناسلت به‌وضوح نشان داده است. این مدل با کسب بالاترین ضریب همبستگی ( $R = 0.977$ ) در داده‌های آزمایشی، توانایی خود در کشف روابط پیچیده بین پارامترهای ورودی و خروجی را اثبات کرده است. مقادیر خطای  $RMSE = 6.16$  و  $MAPE = 1.86\%$  این مدل - که پایین‌ترین مقادیر در بین تمامی مدل‌های مورد بررسی است - گواه بر دقت و پایایی آن در پیش‌بینی‌ها می‌باشد.

نتایج عددی حاکی از آن است که مدل پیشنهادی نه تنها در داده‌های آموزشی، بلکه در داده‌های آزمایشی کاملاً مستقل نیز عملکرد برتری دارد که نشان‌دهنده قابلیت تعمیم‌پذیری بالای آن است. بررسی نمودار پراکندگی مقادیر واقعی در مقابل مقادیر پیش‌بینی شده (شکل ۱) تأیید می‌کند که نقاط داده به‌طور فشرده در اطراف خط  $y = x$  تجمع یافته‌اند که نشان از برازش عالی مدل دارد.

همچنین، تحلیل نمودار باقیمانده‌ها (شکل ۲) نشان می‌دهد که توزیع خطاها در مدل قواعد  $M_5$  کاملاً متقارن و حول محور صفر متمرکز شده است. این در حالی است که سایر مدل‌ها از جمله فرآیند گاوسی و رگرسیون خطی ساده، دارای پراکندگی بیشتری در مقادیر باقیمانده هستند.

نتایج حاصل از نمودار جعبه‌ای (شکل ۳) نیز مؤید آن است که مدل قواعد  $M_5$  دارای کم‌ترین دامنه تغییرات و کمترین تعداد نقاط پرت در مقایسه با دیگر مدل‌هاست. این ویژگی‌های عددی و نموداری، به‌طور جامع برتری مدل پیشنهادی را در پیش‌بینی دقیق و پایدار عدد ناسلت در مبدل‌های حرارتی صفحه‌ای تأیید می‌کنند.

نیز ملاحظه می‌شود که این روش نقاط پرت کمتری دارد و نقاط پرت آن در مقایسه با سایر روش‌ها در محدوده قابل قبول‌تری قرار دارند. مقایسه محدوده داده‌های میانی روش‌های مختلف نشان می‌دهد که محدوده روش قواعد  $M_5$  کوچکتر است و لذا این روش عملکرد قویتر و دقیق‌تری دارد. از مقایسه روش‌های مختلف می‌توان دریافت که پس از روش قواعد  $M_5$  روش رگرسیون افزایشی در رتبه دوم قرار دارد و روش فرآیند گاوسی نیز بین مدل‌های مورد بررسی ضعیف‌ترین عملکرد را دارد.



شکل ۶. نمودار اعتبارسنجی متقابل روش‌های مختلف

شکل ۶ نمودار اعتبارسنجی متقابل روش‌های مختلف را به ازای تعداد بخش‌های متفاوت نشان می‌دهد. ملاحظه می‌شود که روش الگوریتم قواعد  $M_5$  بالاترین میزان ضریب همبستگی و کمترین میزان درصد خطای مطلق میانگین را در تعداد بخش‌های مختلف به خود اختصاص داده است. روش فرآیند گاوسی نیز ضعیف‌ترین عملکرد را در تعداد

## ۶ نتیجه‌گیری

کن‌های حرارتی صفحه‌ای با دقت بالا و قابلیت تعمیم به شرایط مختلف عملیاتی باشد. بنابراین، موارد زیر برای تحقیقات آتی پیشنهاد می‌شود:

۱. ارزیابی عملکرد مدل پیشنهادی در شرایط عملیاتی دینامیکی و گذرا می‌تواند بینش ارزشمندی از قابلیت‌های آن در محیط‌های واقعی ارائه دهد.
۲. توسعه یک چارچوب مدل‌سازی ترکیبی با تلفیق قواعد  $M_5$  و شبکه‌های عصبی عمیق جهت بهبود دقت پیش‌بینی در رژیم‌های جریان پیچیده پیشنهاد می‌شود.
۳. اعتبارسنجی مدل با داده‌های آزمایشگاهی مربوط به هندسه‌های صفحه‌ای نوین و سیالات غیرنیوتنی می‌تواند قابلیت تعمیم‌پذیری آن را گسترش دهد.
۴. بکارگیری روش‌های تفسیرپذیر هوش مصنوعی برای شناسایی دقیق‌تر ارتباط بین پارامترهای طراحی و انتقال حرارت می‌تواند به بهینه‌سازی هندسی مبدل‌ها کمک کند.
۵. مطالعه اثر پارامترهای عملیاتی همچون گرفتگی و رسوب‌گذاری بر عملکرد مدل، گام بعدی در جهت کاربردی‌سازی این روش در صنعت خواهد بود.

در این پژوهش، یک مدل یادگیری ماشینی مبتنی بر روشهای رگرسیون خطی، رگرسیون خطی ساده، رگرسیون افزایشی، قواعد  $M_5$  و فرآیند گاوسی برای پیش‌بینی دقیق شاخص ناسلت در مبدل‌های کن‌های حرارتی صفحه‌ای ارائه شد. ۸۰ درصد از کل داده‌ها به عنوان داده‌های آموزش و ۲۰ درصد باقیمانده به عنوان داده‌های تست بصورت تصادفی انتخاب شد. در این مدل‌ها، زاویه شورون<sup>۱۱</sup>، نسبت ابعادی پروفیل موج‌دار، ضریب بزرگ‌نمایی سطح و عدد رینولدز به‌عنوان پارامترهای ورودی و شاخص ناسلت به‌عنوان متغیر خروجی در نظر گرفته شدند. نتایج نشان داد که استفاده از این مدل‌ها در دامنه‌ای وسیع از اعداد رینولدز، عملکرد قابل قبولی را ارائه می‌دهد. مقایسه نتایج پیش‌بینی‌ها نشان داد که بالاترین دقت را نسبت به سایر روش‌ها دارد، به طوری که بالاترین ضریب همبستگی و کمترین میزان خطا را از نظر خطای مطلق میانگین و ریشه میانگین مربعات خطا به خود اختصاص داد. همچنین، از نتایج ملاحظه شد که این مدل از ثبات بالایی برخوردار بوده و قابلیت تعمیم‌پذیری مناسبی دارد. به‌طور کلی، مدل ارائه‌شده در این تحقیق می‌تواند ابزاری مؤثر برای پیش‌بینی شاخص ناسلت در مبدل‌ها-

## مراجع

- [1] Alavi, S. E., Shirbani, M. M., & Tondro, M. K. (2024). Optimization of gasket-plate heat exchanger based on entransy principles using new method of Harris Hawks. *Multiscale and Multidisciplinary Modeling, Experiments and Design*, 7, 83–96.
- [2] Alavi, S. E., Moori Shirbani, M., & Koochak Tondro, M. (2023). Exergy-economic optimization of gasket-plate heat exchangers. *Journal of Computational Applied Mechanics*, 54, 254–267.
- [3] Kim, K., Lee, H., Kang, M., Lee, G., Jung, K., Kharangate, C. R., Asheghi, M., Goodson, K. E., & Lee, H. (2022). A machine learning approach for predicting heat transfer characteristics in micro-pin fin heat sinks. *International Journal of Heat and Mass Transfer*, 194, 123087.
- [4] Moori Shirbani, M., Alavi, S. E., & Koochak Tondro, M. (2023). Minimizing the Entropic Potential Losses Number in a Gasket-Plate Heat Exchanger. *Iranian Journal of Chemistry and Chemical Engineering*, 42, 1006–1016.
- [5] Pang, W., Liu, J., He, J., & Xu, X. (2016). Thermal performance of brazed plate heat exchangers for a mixed-refrigerant Joule-Thomson cooler. *International Journal of Refrigeration*, 61, 37–54.

<sup>11</sup>Chevron angle

- [6] Jafari, A., Sadeghianjahromi, A., & Wang, C. C. (2022). Experimental and numerical investigation of brazed plate heat exchangers—A new approach. *Applied Thermal Engineering*, **200**, 117694.
- [7] Han, D. H., Lee, K. J., & Kim, Y. H. (2003). The characteristics of condensation in brazed plate heat exchangers with different chevron angles. *Journal of the Korean Physical Society*, **43**, 66.
- [8] Gürel, B., Akkaya, V. R., Göлтаş, M., Şen, Ç. N., Güler, O. V., Koşar, M. İ., & Keçebaş, A. (2020). Investigation on flow and heat transfer of compact brazed plate heat exchanger with lung pattern. *Applied Thermal Engineering*, **175**, 115309.
- [9] Ham, J., Yong, J., Kwon, O., Bae, K., & Cho, H. (2023). Experimental investigation on heat transfer and pressure drop of brazed plate heat exchanger using LiBr solution. *Applied Thermal Engineering*, **225**, 120161.
- [10] Godasiaei, S. H., & Kamali, H. A. (2025). Evaluating Machine Learning as an Alternative to CFD for Heat Transfer Modeling. *Microgravity Science and Technology*, **37**, 6.
- [11] Gungor, S. (2023). Experimental comparison on energy consumption and heat transfer performance of corrugated H-type and L-type brazed plate heat exchangers. *International Communications in Heat and Mass Transfer*, **144**, 106763.
- [12] Martins, G. S., Santiago, R. S., Beckedorff, L. E., Possamai, T. S., Oba, R., Oliveira, J. L., de Oliveira, A. A., & Paiva, K. V. (2022). Structural analysis of gasketed plate heat exchangers. *International Journal of Pressure Vessels and Piping*, **197**, 104634.
- [13] Neagu, A. A., & Koncsag, C. I. (2025). Improving the thermal efficiency of gasket plate heat exchangers used in vegetable oil processing. *Inventions*, **10**, 10.
- [14] Sami, M., & Sierra, F. (2025). Using machine learning (ML) for heat transfer coefficient (HTC) measurement in buildings: A systematic review. *Building and Environment*, **24**, 113220.
- [15] Strobel, M., Beckedorff, L. E., Martins, G. S., Oliveira, J. L., & Paiva, K. V. (2024). Experiments on gasketed plate heat exchangers with segmented corrugation pattern. *ASME Journal of Heat and Mass Transfer*, **146**, 101901.
- [16] Methekar, N., Kotian, S., Jain, N., Vartak, P., Naik, P., Nikam, S., & Bhusnoor, S. S. (2022). Numerical investigation of thermohydraulic characteristics of a gasketed plate heat exchanger. *Computational Thermal Sciences: An International Journal*, **14**, 61–102.
- [17] Focke, W. W., Zachariades, J., & Olivier, I. (1985). The effect of the corrugation inclination angle on the thermohydraulic performance of plate heat exchangers. *International Journal of Heat and Mass Transfer*, **28**, 1469–1479.
- [18] Talik, A. C. (1995). *Heat transfer and pressure drop characteristics of a plate heat exchanger*. Doctoral dissertation, Texas A & M University.
- [19] Muley, A., & Manglik, R. M. (1999). Experimental study of turbulent flow heat transfer and pressure drop in a plate heat exchanger with chevron plates. *Journal of Heat Transfer*, **121**, 110–117.

- [20] Muley, A., Manglik, R. M., & Metwally, H. M. (1999). Enhanced heat transfer characteristics of viscous liquid flows in a chevron plate heat exchanger. *Journal of Heat Transfer*, **121**, 1011–1017.
- [21] Han, D. H., Lee, K. J., & Kim, Y. H. (2003). Experiments on the characteristics of evaporation of R410A in brazed plate heat exchangers with different geometric configurations. *Applied Thermal Engineering*, **23**, 1209–1225.
- [22] Hayes, N., Jokar, A., & Ayub, Z. H. (2011). Study of carbon dioxide condensation in chevron plate exchangers; heat transfer analysis. *International Journal of Heat and Mass Transfer*, **54**, 1121–1131.
- [23] Khan, M. S., Khan, T. S., Chyu, M. C., & Ayub, Z. H. (2014). Evaporation heat transfer and pressure drop of ammonia in a mixed configuration chevron plate heat exchanger. *International Journal of Refrigeration*, **41**, 92–102.
- [24] Yang, J., Jacobi, A., & Liu, W. (2017). Heat transfer correlations for single-phase flow in plate heat exchangers based on experimental data. *Applied Thermal Engineering*, **113**, 1547–1557.
- [25] Witten, I. H., Frank, E., Hall, M. A., & Pal, C. J. (2005). Practical machine learning tools and techniques. *Data Mining*, **2**, 403–413.

# **Predicting the Nusselt Index in Plate Heat Exchangers with Machine Learning: A Comprehensive Comparative Analysis**

**S. E. Alavi<sup>1\*</sup>, M. Moori Shirbani<sup>2</sup> and J. Chachi<sup>3</sup>**

<sup>1,2</sup> Department of Electrical Engineering, Shahid Chamran University of Ahvaz, Khuzestan, Iran

<sup>3</sup> Department of Statistics, Faculty of Mathematical Sciences and Computer, Shahid Chamran University of Ahvaz, Ahvaz, Iran

## **Abstract:**

In this study, machine learning algorithms and statistical learning methods—including Linear Regression, Simple Linear Regression, Additive Regression,  $M_5$  Rules, and Gaussian Process—were employed to predict the Nusselt number in plate heat exchangers. A comprehensive database consisting of experimental data from various sources was compiled and utilized. The input parameters included the chevron angle, aspect ratio of the corrugated profile, surface enlargement factor, and Reynolds number, while the Nusselt number was considered the output variable. The results indicated high accuracy of the applied models, with the  $M_5$  Rules and Additive Regression methods achieving the highest correlation coefficient on the training data. These methods were also identified as the most accurate models on the test data, exhibiting the highest correlation coefficient and the lowest error. The Mean Absolute Percentage Error and Root Mean Square Error values for this model on the test data were calculated at the lowest levels. The findings of this study demonstrate that the  $M_5$  Rules method not only offers very high predictive accuracy but also, due to its transparent structure and interpretability, serves as a reliable tool for modeling heat transfer phenomena in plate heat exchangers across a wide range of operating conditions.

**Keywords:** Statistical Learning, Machine Learning, Correlation Coefficient, Plate Heat Exchanger, Nusselt Index.