



پژوهش‌های نوین در تصمیم‌گیری

دوره ۱۱، شماره ۱، بهار ۱۴۰۵، صص ۸۲-۱۱۸

نوع مقاله: پژوهشی

ارائه یک سیستم استنتاج فازی پویا مبتنی بر بهینه‌سازی سراسری (GODFIS) برای پیش‌بینی در صنعت خرده‌فروشی

محمد حسین علوی دوست^۱، حسین صفری^{۲*}، فرزاد بهرامی^۳

۱. دکتری تخصصی مدیریت صنعتی، دانشکده مدیریت دانشگاه تهران، تهران، ایران

۲. استاد گروه مدیریت صنعتی، دانشکده مدیریت دانشگاه تهران، تهران، ایران

۳. استادیار گروه مدیریت صنعتی، دانشکده علوم اداری و اقتصاد، اراک، ایران

تاریخ دریافت: ۱۴۰۴/۱۰/۰۵

تاریخ بازنگری: ۱۴۰۴/۱۲/۰۱

تاریخ پذیرش: ۱۴۰۴/۱۲/۰۷

چکیده

با گسترش داده‌های عملیاتی و افزایش پیچیدگی محیط تجاری، به‌ویژه در صنعت خرده‌فروشی، پیش‌بینی دقیق تقاضای کالا به یک الزامات کلیدی برای تصمیم‌گیری مؤثر و مدیریت کارآمد زنجیره تأمین تبدیل شده است. ماهیت غیرخطی، پویایی شدید، و وجود نویز در داده‌های فروش موجب عملکرد ضعیف و غیر قابل‌اعتماد روش‌های سنتی پیش‌بینی می‌شود. این چالش در ایران به دلیل سطح بالای عدم قطعیت ناشی از نوسانات اقتصادی، تغییرات سیاست‌های تجاری، محدودیت‌های لجستیکی و پیامدهای تحریم‌ها شدت بیشتری پیدا می‌کند. در پاسخ به این نیاز، پژوهش حاضر الگوریتم GODFIS را معرفی می‌کند؛ یک سیستم استنتاج فازی پویا مبتنی بر بهینه‌سازی سراسری که با هدف ارائه پیش‌بینی‌های دقیق، مقاوم و سازگار با محیط‌های پرنوسان طراحی شده است. معماری GODFIS با ترکیب یادگیری برخط، خوشه‌بندی پویا، به‌روزرسانی بازگشتی پارامترهای تالی، و مکانیزم حذف نویز، امکان مدل‌سازی روابط پیچیده را با دقت بالا و بدون نیاز به بازآموزی کامل فراهم می‌سازد. برای ارزیابی عملکرد، الگوریتم پیشنهادی بر روی دو دسته داده مورد آزمون قرار گرفته است: (۱) داده‌های معیار با رفتارهای غیرایستا، و (۲) داده‌های واقعی یک خرده‌فروشی ایرانی. نتایج نشان می‌دهد که GODFIS نسبت به روش‌های کلاسیک، مدل‌های یادگیری ماشینی، و مدل‌های در حال تکامل، بهبود قابل‌توجهی در دقت، پایداری و سرعت انطباق ارائه می‌دهد. به طور کلی، یافته‌ها مؤید آن است که GODFIS با فراهم‌کردن تفسیرپذیری، مقیاس‌پذیری و کارایی محاسباتی، می‌تواند به‌عنوان یک چارچوب پیش‌بینی پویا برای محیط‌های عملیاتی خرده‌فروشی—به‌ویژه در شرایط ناپایدار ایران—به کار گرفته شود و نقش مؤثری در بهینه‌سازی تصمیمات موجودی و مدیریت عدم قطعیت ایفا کند.

کلیدواژه‌ها: پیش‌بینی تقاضا، صنعت خرده‌فروشی، سیستم‌های فازی در حال تکامل، بهینه‌سازی سراسری، GODFIS



۱- مقدمه و بیان مسئله

پیش‌بینی تقاضای یکی از ارکان اساسی مدیریت زنجیره تأمین و برنامه‌ریزی عملیاتی در خرده‌فروشی است [۱، ۲] و نقش مستقیمی در تصمیمات مرتبط با موجودی، تولید، تخصیص منابع و عملکرد مالی دارد [۳، ۴] به طوری که حتی خطاهای کوچک در پیش‌بینی می‌تواند به کمبود یا مازاد موجودی، افزایش ضایعات و کاهش رضایت مشتری منجر شود [۵]. از این رو، توسعه روش‌هایی که بتوانند پیش‌بینی‌هایی دقیق، سازگار و مقاوم در برابر نوسانات تولید کنند، از اهمیت ویژه برخوردار است. با وجود پیشرفت مدل‌های آماری، علی و یادگیری ماشین، داده‌های خرده‌فروشی - به‌ویژه در بازارهای پرنوسانی مانند ایران - به دلیل ماهیت غیرخطی، غیرایستا و نویزی، همچنان چالش‌برانگیز هستند [۸-۶]. عواملی نظیر نوسانات اقتصادی، شوک‌های ارزی، تغییر رفتار مصرف‌کننده و ورود و خروج کالاها، الگوهای تقاضای وقفه‌دار، نامنظم، و فله‌ای^۱ ایجاد می‌کند که مدل‌های سنتی سری زمانی و علی را با محدودیت جدی مواجه می‌سازد [۹-۱۲]. مدل‌های ML/DL اگرچه در استخراج روابط پیچیده توانمندند، اما به داده‌های حجیم و پایدار نیاز دارند، از تفسیرپذیری محدودی برخوردارند و برای کاربرد هم‌زمان در مقیاس وسیع پرهزینه‌اند [۱۳، ۱۴]. مدل‌های هیبریدی نیز به دلیل پیچیدگی بالا و دشواری تنظیم، با چالش اجرایی روبه‌رو هستند [۱۵، ۱۶]. در مقابل، سیستم‌های فازی تکاملی (EFS)^۲ با قابلیت یادگیری برخط و تفسیرپذیری بالا معرفی شده‌اند [۱۷]. اما اغلب فاقد بهینه‌سازی سراسری بوده و در داده‌های پر نویز دقت کافی ندارند؛ از سوی دیگر، مدل‌های دارای بهینه‌سازی سراسری معمولاً آفلاین‌اند. این محدودیت‌ها نشان‌دهنده شکافی مهم در کاربرد EFS‌ها برای پیش‌بینی تقاضای خرده‌فروشی است [۸، ۱۲].

مروار ادبیات بیانگر آن است که هنوز مدلی ارائه نشده که به طور هم‌زمان دقت بالا در محیط‌های غیرایستا، تفسیرپذیری مبتنی بر قواعد، مقاومت نسبت به نویز، مقیاس‌پذیری برای هزاران SKU، یادگیری برخط و کارایی محاسباتی در محیط‌های عملیاتی را تأمین کند. بر این اساس، پژوهش حاضر مدل GODFIS^۳ را به‌عنوان یک سیستم استنتاج فازی پویا مبتنی بر

^۱ Intermittent, Erratic, & Lumpy

^۲ Evolving Fuzzy Systems

^۳ Global Optimization-based Dynamic Fuzzy Inference System



بهینه‌سازی سراسری معرفی می‌کند که با بهره‌گیری از خوشه‌بندی پویا، یادگیری برخط، به‌روزرسانی بازگشتی و سازوکار حذف نویز، چارچوبی مقاوم، تفسیرپذیر و مقیاس‌پذیر برای پیش‌بینی تقاضای خرده‌فروشی - به‌ویژه در بازار ایران - ارائه می‌دهد.

۲- مبانی نظری و پیشینه پژوهش

پیش‌بینی تقاضا در صنعت خرده‌فروشی طی چهار دهه گذشته یکی از پرستندادترین حوزه‌های پژوهشی در مدیریت عملیات، تحقیق در عملیات، یادگیری ماشین و سیستم‌های هوشمند بوده است. اهمیت این حوزه از آن جهت برجسته است که تصمیماتی نظیر مدیریت موجودی، سفارش‌دهی، طراحی ترویجات، کنترل ضایعات و برنامه‌ریزی تولید به طور مستقیم به کیفیت پیش‌بینی وابسته‌اند [۴، ۱۸]. این پدیده در بازارهای پرنوسانی مانند ایران، به دلیل شوک‌های ارزی، محدودیت‌های وارداتی، تغییرات ناگهانی قیمت و رفتارهای نامنظم مصرف‌کننده به شدت تشدید شده و ماهیتی کاملاً غیرخطی و غیرایستا به تقاضا می‌بخشد. ادبیات پیش‌بینی تقاضا را می‌توان در پنج رویکرد کلی طبقه‌بندی کرد که همگی با چالش مشترک «دستیابی به دقت پایدار در شرایط واقعی خرده‌فروشی» مواجه‌اند:

- ۱- مدل‌های سری زمانی کلاسیک (نظیر ARIMA و هموارسازی نمایی): اگرچه این مدل‌ها ساده و تفسیرپذیرند [۱۸]، اما در محیط‌های پرنوسان و در برابر تغییرات ساختاری ناگهانی، کارایی خود را از دست داده و با خطای بالایی همراه می‌شوند [۱۹، ۲۰].
- ۲- مدل‌های علی و چندمتغیره: این روش‌ها تلاش می‌کنند اثر متغیرهای خارجی را نیز لحاظ کنند [۲۱-۲۳]. با این حال، در بازارهایی با داده‌های نویزدار و تغییرات سریع (مانند ایران)، این مدل‌ها به سرعت دچار بیش‌برازش یا سوگیری می‌گردند [۸، ۱۲].
- ۳- مدل‌های یادگیری ماشین (ML)^۱ و عمیق^۲: با رشد فناوری‌های داده‌محور، روش‌هایی نظیر ماشین‌های بردار پشتیبان (SVM)^۲ [۲۴]، Random Forest [۲۵]، Gradient Boosting [۱۳، ۱۴]، LSTM [۷]، CNN-BiLSTM [۱۶] به طور گسترده برای پیش‌بینی تقاضا به کار گرفته شده‌اند [۲۶، ۲۷]. با این حال، فاقد تفسیرپذیری («جعبه سیاه» بودن) بوده، و نیاز به داده‌های بزرگ و پاک‌سازی‌شده و حساسیت بالا به تغییرات ساختاری، دقت آن‌ها

^۱ Machine Learning

^۲ Support Vector Machine



را در داده‌های غیرایستا و پر نویز محدود می‌کند [۲۸].

۴- مدل‌های هیبریدی^۱: این مدل‌ها با ترکیب الگوریتم‌های مختلف (مانند ARIMA+ANN یا مدل‌های تجزیه + ML) تلاش دارند دقت و تفسیرپذیری را هم‌زمان ارتقا دهند [۱۶، ۲۹-۳۱]. اما پیچیدگی زیاد و بار محاسباتی بالا، استقرار عملی آن‌ها را در محیط واقعی خرده‌فروشی بسیار دشوار می‌سازد.

۵- سیستم‌های فازی در حال تکامل (EFS): این مدل‌ها نسل جدیدی از مدل‌های هوشمند هستند که قابلیت یادگیری برخط، تطبیق پویا با داده‌های جریانی، ایجاد یا حذف قواعد در لحظه، تفسیرپذیری مبتنی بر قواعد، و پیچیدگی محاسباتی کنترل‌پذیر را فراهم می‌کنند [۳۲، ۳۳]. با وجود این، به دلیل ساختار یادگیری تک‌گذری^۲ و عدم وجود یک سازوکار بهینه‌سازی سراسری دقت پیش‌بینی و قابلیت تعمیم نسبتاً پایینی دارند.

سیستم‌های فازی در حال تکامل (EFS) طی دو دهه گذشته پیشرفت‌های ساختاری قابل‌توجهی را تجربه کرده‌اند؛ از مدل‌های اولیه مبتنی بر یادگیری محلی، تا معرفی خانواده eTS برای یادگیری تک‌گذری، و نهایتاً توسعه مدل‌های مقاوم در برابر نویز و رانش مفهوم^۳. این تحولات در چهار نسل متمایز در جدول ۱ خلاصه شده است.

جدول ۱. تحولات حوزه EFS ها طی دو دهه‌ی اخیر و مقالات شاخص این حوزه

نسل	دوره	هدف اصلی	ویژگی‌های کلیدی	محدودیت‌ها	مدل‌های شاخص
نسل ۱: الگوریتم‌های مبتنی بر یادگیری محلی و خوشه‌بندی بازگشتی	اوایل دهه ۲۰۰۰	ایجاد اولین ساختارهای یادگیری آنلاین برای داده‌های جریانی	- یادگیری محلی و تولید تدریجی قواعد - خوشه‌بندی بازگشتی مبتنی بر فاصله - عدم نیاز به آموزش چندمرحله‌ای	- حساسیت به نویز - مشکلات در داده‌های نامتوازن/پیچیده - معیارهای ساده فاصله	- EFuNN [۳۴] - Non-iterative EFS [۳۵] - DENFIS [۳۶]
نسل ۲: مدل‌های خانواده eTS و توسعه‌های ساختاری	۲۰۰۴-۲۰۱۰	یکپارچه‌سازی یادگیری ساختار و پارامترها به صورت تک‌گذری	- یادگیری بدون ناظر برای ساختار و نظارت‌شده برای پارامترها - تولید قواعد بر اساس تراکم/فاصله - به‌روزرسانی سریع بدون ذخیره داده - ساختار تکاملی	- وابستگی به معیارهای تراکم/فاصله - گاهی افزایش بیش از حد تعداد قواعد	- eTS [۳۷] - Simpl_eTS [۳۸] - xTS [۳۹] - eTS+ [۴۰] - DeTS [۴۱]
نسل ۳: مدل‌های مقاوم‌تر و	۲۰۰۶-۲۰۱۷	ارتقای دقت، پایداری و مقاومت در برابر نویز	- مکانیزم‌های ادغام/حذف قوی‌تر قواعد - مدیریت بهتر نویز	- پیچیدگی بالاتر مدل‌ها - نبود بهینه‌سازی سراسری	- FLEXFIS [۴۲] - SOFMLS [۴۳] - eMG [۴۴]

^۱ Hybrid Models

^۲ One-pass Learning

^۳ Concept Drift




نسل	دوره	هدف اصلی	ویژگی‌های کلیدی	محدودیت‌ها	مدل‌های شاخص
انعطاف‌پذیرتر			- مدل‌های بازگشتی پایدارت - افزایش انعطاف‌پذیری ساختار	- احتمال بیش برآزش در داده‌های پیچیده	- PANFIS [۴۵] - ePL+ [۴۶] - ePFM [۴۷]
نسل ۴: مدل‌های مقاوم در برابر نویز، داده‌های نامطمئن و ساختارهای پیچید	۲۰۱۷ تاکنون	مدیریت عدم قطعیت بالا، داده‌های فازی نوع ۲، ساختارهای مکانی-زمانی و Concept Drift	- پشتیبانی از داده‌های نامطمئن و نوع - ساختارهای مکانی-زمانی - شاخص‌های پیشرفته شباهت و همسان‌تروپی - آستانه‌های پویا برای تولید/ادغام قواعد - تحلیل‌های پایداری پیشرفته	- افزایش پیچیدگی محاسباتی - همگرایی دیر هنگام در برخی ساختارها - نبود بهینه‌سازی دقیق مشترک بین ساختار و پارامتر	- eT ² RFNN [۴۸] - CEFNS [۴۹] - SPATFIS [۵۰] - EFS-SLAT [۵۱] [۵۲, ۵۳]

چالش بنیادین یادگیری جریانی: نبود بهینه‌سازی سراسری و اثر «بی‌آموزشی» ناشی از فرایند اکتشافی

با وجود این پیشرفت‌ها، ضعف بنیادین در اکثر مدل‌های EFS این است که به صورت سراسری بهینه نمی‌شوند و یادگیری صرفاً به صورت تک‌گذری و اکتشافی صورت می‌پذیرد. در یادگیری جریانی^۱، داده‌ها به صورت ترتیبی وارد سیستم می‌شوند؛ کل مجموعه داده در دسترس نیست، داده‌های گذشته ذخیره نمی‌شوند و مدل تنها بر اساس اطلاعات لحظه‌ای به روز می‌گردد. در نتیجه، تعیین مرکز واقعی خوشه‌ها به معنای آماری امکان‌پذیر نبوده و به روزرسانی لحظه‌ای مراکز خوشه منجر به یک «انحراف تجمعی»^۲ از مرکز ثقل واقعی داده‌ها می‌شود (مفهومی که در شکل ۱ به تصویر کشیده شده است). این امر به کاهش دقت، رشد بی‌رویه قوانین و افت تعمیم‌پذیری می‌انجامد [۵۴, ۵۵].

^۱ Stream Learning

^۲ drift bias



شکل ۱. مقایسه میان مراکز خوشه‌ها در روش آنلاین و آفلاین

مطالعات اخیر نشان می‌دهند که اعمال مکانیزم‌های بهینه‌سازی می‌تواند کارایی EFSها را ارتقا دهد [۵۴، ۵۵]. با این حال، پژوهش‌های موجود نظیر بهینه‌سازی مبتنی بر خطای محلی [۵۶]، رویکردهای سیستماتیک [۵۷] و محاسبات تکاملی مانند PSO-ALMMo [۵۴] و MIIPSO- EFS [۵۵] اغلب یا زمان‌بر بوده و صرفاً در محیط‌های آفلاین کاربرد دارند، و یا بهبودهای محدودی در دقت ایجاد کرده‌اند. در چارچوب این مقاله، «بهینه‌سازی سراسری» به مفهوم کلاسیک دسترسی کامل به داده‌ها اشاره ندارد، بلکه به عنوان یک الزام ساختاری برای جبران انحراف تجمعی در یادگیری جریانی تعریف می‌شود. در مجموع، علی‌رغم توسعه گسترده EFSها، مطالعات اندکی به بهینه‌سازی سراسری آن‌ها پرداخته‌اند و اغلب روش‌های موجود، یا زمان‌بر بوده‌اند یا تنها به بهبودهای محدود در دقت منجر شده‌اند.

شکاف تحقیقاتی

مرور پژوهش‌های پیش‌بینی تقاضای خرده‌فروشی نشان می‌دهد که با وجود توسعه روش‌های مختلف، چند شکاف اساسی همچنان پابرجاست. نخست، سیستم‌های فازی تکاملی اگرچه پویا و قابل تفسیرند، عموماً فاقد بهینه‌سازی سراسری‌اند؛ در مقابل، بسیاری از مدل‌های کلاسیک و ML/DL از سازوکارهای بهینه‌سازی برخوردارند، اما به دلیل ایستایی، توان سازگاری محدودی با محیط پویای خرده‌فروشی دارند. دوم، داده‌های خرده‌فروشی، به‌ویژه در بازار ایران، به دلیل نوسانات اقتصادی، تغییر رفتار مشتری و ورود و خروج کالا، ماهیتی نویزی و غیرایستا دارند که عملکرد پایدار بسیاری از مدل‌های موجود را با مشکل مواجه می‌سازد.



سوم، بخش مهمی از مدل‌های موجود از نظر مقیاس‌پذیری برای تعداد زیاد SKUها مناسب نیستند و به بازآموزی یا ذخیره‌سازی گسترده داده نیاز دارند. چهارم، همچنان میان دقت و تفسیرپذیری مدل‌ها نوعی مبادله وجود دارد؛ به‌گونه‌ای که مدل‌های دقیق‌تر غالباً شفافیت کمتری دارند. پنجم، با وجود قابلیت بالقوه EFSها، به کارگیری موفق آن‌ها در پیش‌بینی تقاضای خرده‌فروشی به دلیل محدودیت‌های مربوط به بهینه‌سازی و دقت، هنوز محدود است. در پاسخ به این شکاف‌ها، پژوهش حاضر مدل GODFIS را به‌عنوان یک چارچوب فازی پویا، مقیاس‌پذیر و مبتنی بر بهینه‌سازی سراسری ارائه می‌کند که با هدف بهبود دقت، سازگاری و تفسیرپذیری در پیش‌بینی تقاضای خرده‌فروشی توسعه یافته است.

۳- روش‌شناسی پژوهش

پیش‌بینی دقیق تقاضا در محیط‌های پرنوسان، مانند بازار خرده‌فروشی ایران، مستلزم مدلی است که نه تنها تطبیق‌پذیر و تفسیرپذیر باشد، بلکه از دقت بالایی نیز برخوردار باشد. برای پاسخ به این نیاز، «استنتاج فازی پویا مبتنی بر بهینه‌سازی سراسری» GODFIS را ارائه می‌کنیم. این بخش به تشریح معماری و مکانیزم‌های یادگیری GODFIS می‌پردازد که بر پایه ساختار سیستم استنتاج فازی مدل فازی تاکاگی-سوگنو (T-S) بنا شده و تکنیک‌های نوآورانه بهینه‌سازی سراسری را برای بخش‌های مقدم و تالی یکپارچه می‌سازد.

نمادهای مدل ریاضی:

مجموعه‌ها:

$a, i = 1, 2, \dots, r$	اندیس قوانین فازی سیستم و خوشه‌های مرتبط با آن‌ها
$j = 1, \dots, n$	اندیس پارامترهای تالی
k, t	اندیس زمان

نمادها

x^k	بردار ورودی در زمان k
y^k	مقدار هدف در زمان k
C_i	خوشه مرتبط با قوانین فازی i ام
CC_{ij}^k	مؤلفه i ام از مرکز خوشه i ام در لحظه k
σ_{ij}^k	مؤلفه i ام از شعاع خوشه i ام در لحظه k



θ	بردار پارامتر تالی
$\hat{\theta}_k$	برآورد بردار پارامتر تالی در لحظه k
C_k	ماتریس کوواریانس در لحظه k
U_{ik}	سودمندی قانون i ام در لحظه k
ϵ	آستانه‌ی سودمندی
ε	آستانه‌ی شناسایی نویز
r	تعداد قوانین

مبانی نظری و معماری پایه:

یک سیستم فازی استاندارد که بر اساس قوانین فازی کار می‌کند، از چهار بخش فازی‌سازی^۱، موتور استنتاج^۲، پایگاه دانش^۳، و غیرفازی‌سازی^۴ تشکیل می‌شود [۵۸، ۵۹]. در این پژوهش از مدل فازی TS نوع یک استفاده شده است که ساختار قانون فازی i ام آن به صورت فرمول (۱) تعریف می‌شود:

$$\mathcal{R}_i: \text{IF } \mathbf{x} \text{ is } \tilde{\mathcal{A}}_i \text{ THEN } y_i = \theta_i(\mathbf{x}) = \mathbf{x}_e^T \theta_i = \theta_{i0} + \theta_{i1}x_1 + \dots + \theta_{in}x_n \quad (1)$$

که در این رابطه، $\mathcal{R}_i$ نامین قانون فازی برای $i = 1, 2, \dots, r$ تعداد قوانین فازی سیستم، $\tilde{\mathcal{A}}_i = [\tilde{\mathcal{A}}_{i1}, \tilde{\mathcal{A}}_{i2}, \dots, \tilde{\mathcal{A}}_{in}]$ متغیر ورودی سیستم، $\mathbf{x} = [x_1, x_2, \dots, x_n]^T \in \mathbb{R}^n$ مجموعه فازی بخش مقدم قانون فازی i ام با توابع عضویت $\mu_{ij}(x_j)$ ، $\gamma_i \in \mathbb{R}$ خروجی قانون i ام و θ_{i0} و θ_{ij} ، $j = 1, \dots, n$ پارامترهای تالی قانون i ام هستند.

فرمول قدرت فعال‌سازی (درجه فعال‌سازی نرمال‌شده) هر قانون فازی (γ_i) با فرمول (۲) محاسبه می‌شود و خروجی نهایی از ترکیب وزنی خروجی‌های تمام قوانین به دست می‌آید (فرمول (۳)).

$$\gamma_i(\mathbf{x}) = \prod_{j=1}^n \mu_{ij}(x_j) \quad (2)$$

^۱ fuzzifier

^۲ Inference Engine

^۳ Knowledge Base

^۴ Defuzzifier



$$y = \sum_{i=1}^r \lambda_i * y_i = \sum_{i=1}^r \lambda_i * \mathbf{x}_e^T \theta_i; \quad \lambda_i = \frac{\gamma_i(\mathbf{x})}{\sum_{j=1}^r \gamma_j(\mathbf{x})}; \quad \mathbf{x}_e^T = [\mathbf{1} \quad \mathbf{x}^T] \quad (3)$$

در حقیقت این مسئله‌ای، شناسایی تعداد قوانین فازی r ، پارامترهای مقدم شامل مرکز خوشه $\sigma_i = (Cc_i, \sigma_{i,1}, \sigma_{i,2}, \dots, \sigma_{i,r})$ و اندازه شعاع (میزان پراکندگی) $\theta_i = (\theta_{i0}, \theta_{i1}, \theta_{i2}, \dots, \theta_{in})$ همچنین پارامترهای تالی سیستم فازی TS، به منظور پیش‌بینی y می‌باشند.

برای استخراج ساختار اولیه سیستم فازی شامل تعداد قوانین، مراکز خوشه‌ها و پارامترهای پراکندگی، از یک روش خوشه‌بندی داده‌محور استفاده می‌شود. در میان الگوریتم‌های خوشه‌بندی تکاملی، الگوریتم ECM به دلیل سادگی، سرعت و تفسیرپذیری مورد توجه قرار گرفته است [۳۶، ۶۴-۶۰]. با این حال، این روش با محدودیت‌هایی نظیر عدم بهینگی سراسری، فرض کروی بودن خوشه‌ها به دلیل شعاع یکسان در تمام ابعاد و نبود مکانیزم حذف خوشه‌های منسوخ مواجه است. برای رفع این محدودیت‌ها، الگوریتم GOECA پیشنهاد می‌شود که با بهره‌گیری از بهینه‌سازی برخط، شعاع متغیر چندبعدی برای تشکیل خوشه‌های هابیر بیضوی و مکانیزم هرس، ساختار خوشه‌بندی کارآمدتری فراهم می‌کند.

خوشه‌بندی در حال تکامل الگوریتم GOECA^۱:

در چارچوب GODFIS، همانند بسیاری از مطالعات مشابه، از توابع عضویت گاوسی به دلیل قابلیت تعمیم مناسب و پوشش کامل فضای ورودی استفاده شده است [۵۹، ۶۵]. این تابع به صورت رابطه (۴) تعریف می‌شود:

$$\mu_{ij}(x_j) = \exp \frac{-(x_j - Cc_{ij})^2}{2\sigma_{ij}^2} \quad (4)$$

که در آن Cc_{ij} مرکز خوشه و σ_{ij} شعاع یا ناحیه نفوذ آن است. ساختار خوشه‌ها در GOECA بر اساس معیار فاصله شکل می‌گیرد، با این تفاوت که اثر تعدد ابعاد از معیار فاصله حذف و آستانه فاصله مستقل از بعد تعریف می‌شود (رابطه (۵)):

$$D_i^k = \frac{\|Cc_i^k - \mathbf{x}^k\|_d}{n}, \quad \forall i \quad (5)$$

^۱ Global Optimization-based Evolving Clustering Algorithm



در این چارچوب، سه حالت برای به‌روزرسانی خوشه‌ها وجود دارد: تخصیص نقطه جدید به خوشه موجود، تخصیص همراه با گسترش شعاع خوشه، و ایجاد خوشه جدید در صورت فاصله زیاد از خوشه‌های موجود.

اصلاح مرکز خوشه به‌صورت بازگشتی:

مرکز خوشه در حالت آفلاین به صورت میانگین نقاط خوشه محاسبه می‌شود (رابطه (۶))، اما برای محیط‌های آنلاین این رابطه به فرم بازگشتی تبدیل می‌شود (روابط (۷)–(۸)):

$$Cc_{ij}^k = \frac{\sum_{t=1, x^t \in C_i}^k x_j^t}{nPop_i^k}, \quad \forall i, j \quad (6)$$

$$\begin{aligned} Cc_{ij}^{k+1} &= \frac{\sum_{t=1, x^t \in C_i}^{k+1} x_j^t}{nPop_i^{k+1}} = \frac{\sum_{t=1, x^t \in C_i}^k x_j^t + x_j^{k+1}}{nPop_i^k + 1} \\ &= \frac{\sum_{t=1, x^t \in C_i}^k x_j^t}{nPop_i^k + 1} + \frac{x_j^{k+1}}{nPop_i^k + 1} \\ &= \frac{\sum_{t=1, x^t \in C_i}^k x_j^t}{nPop_i^k} \times \frac{nPop_i^k}{nPop_i^k + 1} + \frac{x_j^{k+1}}{nPop_i^k + 1} \\ &= Cc_{ij}^k \times \frac{nPop_i^k}{nPop_i^k + 1} + \frac{x_j^{k+1}}{nPop_i^k + 1} \end{aligned} \quad (7)$$

$$Cc_{ij}^{k+1} = Cc_{ij}^k \times \frac{nPop_i^k}{nPop_i^k + 1} + \frac{x_j^{k+1}}{nPop_i^k + 1} \quad (8)$$

به طوری که، $nPop_i^k$ تعداد اعضای خوشه نام در لحظه k و Cc_{ij}^k مؤلفه نام از مرکز خوشه نام در لحظه k است. این فرمول امکان به‌روزرسانی مرکز خوشه بدون ذخیره داده‌های قبلی را فراهم کرده و باعث همگرایی تدریجی مراکز به سمت مرکز ثقل واقعی داده‌ها می‌شود. در نتیجه، فرایند یادگیری ضمن جلوگیری از بایاس تک‌گذری، ساختار خوشه‌ها را به سمت توزیعی داده‌ها هدایت می‌کند.

اصلاح شعاع کلاستر به‌صورت بازگشتی:

برای به‌روزرسانی شعاع خوشه نیز در روش کلاسیک ECM شعاع برابر فاصله مرکز تا دورترین نقطه خوشه است (رابطه (۹)). با این حال، این روش شعاع یکسانی در تمام ابعاد ایجاد می‌کند. در روش پیشنهادی، شعاع هر بعد به‌صورت مستقل و بازگشتی محاسبه می‌شود



(رابطه (۱۰):

$$S_{ia} = \min_j (S_{ij} = d_{ij} + Ru_j), \quad Ru_a = S_{ia}/2 \quad (9)$$

$$\sigma_{aj}^{k+1} = \text{Max} \left(\sigma_{aj}^k, \|Cc_{aj}^{k+1} - x_j^{k+1}\|_d \right), \quad \forall j \quad (10)$$

این رویکرد امکان شکل‌گیری خوشه‌های غیرکروی و تطبیق تدریجی ساختار خوشه‌ها با داده‌های جدید را فراهم می‌کند.

برآورد قسمت تالی مدل در حالت تکاملی:

در بخش تالی سیستم فازی نیز دو رویکرد اصلی شامل بهینه‌سازی سراسری و محلی وجود دارد. اگرچه در شرایط آفلاین روش سراسری معمولاً دقت بیشتری دارد [۶۶]، در محیط‌های آنلاین به دلیل فرایند یادگیری تک‌گذری و به‌روزرسانی پایگاه دانش، این برتری همواره تضمین‌شده نیست [۴۰، ۴۲]. در بسیاری از مدل‌های آنلاین، خطاهای ناشی از تشخیص نادرست بخش مقدم می‌تواند به بخش تالی منتقل شود که به آن «اثر بی‌آموزشی» گفته می‌شود [۵۶]. نتایج آزمایش‌ها نشان می‌دهد که در مدل GODFIS، به دلیل دقت بالاتر در تشخیص خوشه‌ها، استفاده از بهینه‌سازی سراسری برای پارامترهای تالی عملکرد بهتری نسبت به روش محلی ارائه می‌دهد و این یافته با نتایج [۶۶] برای شرایط بهینه آفلاین همخوانی دارد. در این حالت، بردار پارامترهای مدل با کمینه‌سازی خطای سراسری مطابق رابطه (۱۱) محاسبه می‌شود:

$$E_G = \sum_{k=1}^t (y_k - \psi_k^T \theta)^2 = (Y - \Psi^T \theta)^T (Y - \Psi^T \theta) \quad (11)$$

$$\theta = (\Psi^T \Psi)^{-1} \Psi^T Y$$

برآورد بازگشتی این پارامترها نیز با استفاده از روش حداقل مربعات بازگشتی (فیلتر کالمن) انجام می‌شود [۳۷، ۴۰]:

$$\begin{aligned} \hat{\theta}_k &= \hat{\theta}_{k-1} + C_k \psi_k (y_k - \psi_k^T \hat{\theta}_{k-1}) \\ C_k &= C_{k-1} + \frac{C_{k-1} \psi_k \psi_k^T C_{k-1}}{1 + \psi_k^T C_{k-1} \psi_k}, \quad k = [1, t] \end{aligned} \quad (12)$$

برای حالت بهینه‌سازی محلی فرمول (۱۱) با فرض استقلال و یا سطوح تعامل ضعیف بین



زیرسیستم‌های خطی، تابع خطا را به مجموع توابع هزینه تبدیل می‌شود (فرمول (۱۳)).

$$E_L = \sum_{i=1}^r E_{Li}, \quad E_{Li} = (Y - X^T \theta_i)^T \Lambda_i (Y - X^T \theta_i) \quad (13)$$

$$\theta_i = (X^T \Lambda_i X)^{-1} X^T \Lambda_i Y, \quad i = [1, r]$$

به‌صورت جایگزین، در حالت بهینه‌سازی محلی هر تابع هزینه E_{Li} (بردارها θ_i) را می‌توان به‌صورت بازگشتی از طریق الگوریتم RLS وزنی (wRLS) محاسبه کرد (فرمول (۱۲)) به فرمول (۱۴) تبدیل می‌شود.

$$\begin{aligned} \hat{\theta}_{ik} &= \hat{\theta}_{ik-1} + c_{ik} x_{ek} \lambda_i(x_k) (y_k - x_{ek}^T \hat{\theta}_{ik-1}) \\ c_{ik} &= c_{ik-1} + \frac{\lambda_i(x_k) c_{ik-1} x_{ek}^T x_{ek} c_{ik-1}}{1 + \lambda_i(x_k) x_{ek}^T x_{ek} c_{ik-1}}, \quad k = [1, t] \end{aligned} \quad (14)$$

اندازه‌گیری کیفیت خوشه‌ها در GODFIS:

سیستم‌های فازی در حال تکامل دارای ساختاری پویا هستند؛ به‌گونه‌ای که پایگاه قوانین آن‌ها می‌تواند با افزودن قوانین جدید یا حذف قوانین کم‌کاربرد به طور مداوم تنظیم شود. برای جلوگیری از برآزش بیش از حد^۱، بسیاری از رویکردهای موجود از هرس قوانین^۲ استفاده می‌کنند. در الگوریتم GODFIS نیز سازوکاری با عنوان اصل حذف نویز به‌عنوان یک مکانیزم نظارت آنلاین معرفی شده که نسخه بهبودیافته‌ای از معیار سودمندی^۳ [۴۰] محسوب می‌شود و کیفیت خوشه‌بندی را پایش می‌کند. معیار سودمندی نشانگر درجه فعال‌سازی نسبی انباشته یک قانون است (فرمول (۱۵)):

$$U_{ik} = \frac{\sum_{k=1}^t \theta_k}{k - I_i^*}, \quad k = [1, t] \quad (15)$$

در اینجا I_i^* زمان ایجاد قانون فازی i ام را نشان می‌دهد. هدف این معیار، حذف خوشه‌های بلااستفاده است؛ به‌گونه‌ای که قوانین با فعال‌سازی پایین حذف می‌شوند (فرمول (۱۶)).

$$IF \quad U_{ik} < \epsilon \quad THEN \quad Prune \mathcal{R}_i, \quad r_k \leftarrow r_k - 1 \quad (16)$$

^۱ Overfitting

^۲ Rules Pruning

^۳ Utility Measure



با وجود کارایی این معیار در حفظ قوانین مفید، داده‌های نویزی می‌توانند منجر به تشکیل خوشه‌های نامعتبر شده و در نتیجه باعث افزایش پیچیدگی مدل و برآزش بیش از حد شوند. برای رفع این مشکل، در GODFIS معیار سودمندی با افزودن شرطی جدید اصلاح شده و اصل حذف نویز به صورت زیر تعریف می‌شود:

به طوری که $\epsilon \in [0.03, 0.1]$ آستانه‌ی سودمندی و r_k تعداد قوانین در پایگاه قانون در مرحله k ام است. با وجود کارایی این معیار در حفظ قوانین مفید، داده‌های نویزی می‌توانند منجر به تشکیل خوشه‌های نامعتبر شده و در نتیجه باعث افزایش پیچیدگی مدل و برآزش بیش از حد شوند. برای رفع این مشکل، در GODFIS معیار سودمندی با افزودن شرطی جدید اصلاح شده و اصل حذف نویز به صورت زیر تعریف می‌شود:

$$IF (U_{ik} < \epsilon) \quad AND \quad \left(nPop_{ik} < \epsilon \times \frac{k}{r}\right) \quad THEN \quad (17)$$

$$Prune \mathcal{R}_i, \quad r_k \leftarrow r_k - 1$$

در این چارچوب، حذف یک قانون تنها زمانی انجام می‌شود که دو شرط به طور هم‌زمان برقرار باشند:

(۱) کیفیت (مطلوبیت) خوشه پایین باشد

(۲) تعداد داده‌هایی که یک خوشه را تشکیل می‌دهند از یک حدی $(\epsilon \times \frac{k}{r})$ کمتر باشد

در این رابطه، $\frac{k}{r}$ نشان‌دهنده سهم هر خوشه از کل داده‌ها است. اگر جمعیت یک خوشه به طور محسوسی کمتر از $\frac{k}{r}$ باشد، احتمال تشکیل آن از نویز افزایش می‌یابد. مقدار پیشنهادی $\epsilon = 0.01$ بر مبنای مفهوم سه انحراف معیار (3σ) در توزیع نرمال انتخاب می‌شود. مقدار کوچک‌تر ϵ منجر به حذف نویز سخت‌گیرانه‌تر (حفظ قوانین بیشتر) و مقدار بزرگ‌تر ϵ موجب حذف آسان‌تر قوانین می‌شود.

الگوریتم GODFIS:

این بخش، مراحل اجرای الگوریتم GODFIS را شرح می‌دهد. این الگوریتم دارای ساختاری باز و منعطف است که با تغییر الگوی داده‌ها، مدل را به‌روز و با شرایط جدید تطبیق می‌دهد. ماهیت بازگشتی این الگوریتم نیز آن را از نظر محاسباتی کارآمد می‌سازد. قوانین این الگوریتم به صورت هم‌زمان با خوشه‌بندی فضای ورودی تولید و به‌روزرسانی می‌شوند.



آموزش مدل با برآورد اولیه مدل یعنی استخراج r قانون اولیه و برآورد مقادیر θ_k و C_k به صورت زیر شروع می‌شود.

مرحله اول: آماده‌سازی اولیه

- ورود داده‌های آموزشی: n جفت داده‌های ورودی-خروجی $(x_k^T, y_k), k = [1, n]$ وارد سیستم می‌شوند.
- پیش‌پردازش داده‌ها: نرمال‌سازی داده‌ها.

مرحله دوم: استخراج ساختار اولیه

- خوشه‌بندی آفلاین: استخراج r خوشه اولیه و تعیین پارامترهای مقدم شامل مراکز، شعاع‌ها، و جمعیت خوشه‌ها.
- آموزش اولیه مدل TSK: برآورد ضرایب توابع خطی (ماتریس θ) با روش به‌روزرسانی سراسری یا محلی.

مرحله سوم: یادگیری آنلاین

برای هر داده جدید x_k ساختار مقدم با استفاده از GOECA به‌روزرسانی می‌شود. سه حالت ممکن است رخ دهد:

۱. قرارگیری درون شعاع خوشه موجود: تنها مرکز خوشه طبق رابطه (۸) اصلاح می‌شود.
۲. نزدیک بودن به خوشه موجود $(Min(D_i^k) < D_{thr})$: مرکز و شعاع خوشه با روابط (۸) و (۱۰) بروز می‌شوند.
۳. ایجاد خوشه جدید $(Min(D_i^k) > D_{thr})$: خوشه‌ای جدید با مرکزیت $(C_{r+1} = x_k)$ و شعاع صفر ایجاد می‌شود.

پس از اصلاح مقدم، پارامترهای تالی با روش سراسری (رابطه (۱۲)) یا روش محلی (روابط (۱۴)) به‌روزرسانی می‌شوند.

مرحله چهارم: کاهش پیچیدگی و پایداری در برابر نویز

- با اعمال اصل حذف نویز (رابطه (۱۷))، خوشه‌هایی که شرایط کیفیت و جمعیت حداقلی را برآورده نکنند از پایگاه قوانین حذف می‌شوند. این فرایند از افزایش بی‌رویه قوانین و برازش بیش از حد جلوگیری می‌کند.
- شرط توقف زمانی برقرار است که داده جدیدی برای پردازش وجود نداشته باشد.



به طور کلی الگوریتم GODFIS شامل ویژگی‌های کلیدی ۱) انعطاف‌پذیری ساختاری: رشد/کاهش هوشمندانه پایگاه قوانین، ۲) کارایی محاسباتی: به‌روزرسانی بازگشتی بدون نیاز به بازآموزی کامل، ۳) مقاومت به نویز: مکانیزم تشخیص خوشه‌های نویزی، ۴) بهینه‌سازی مقدم و تالی: انطباق به‌روزرسانی مقدم و تالی با هدف بهینه‌سازی سراسری می‌باشد. این ویژگی‌ها به این الگوریتم کمک می‌کند تا این الگوریتم عملکرد قابل توجهی نسبت به الگوریتم‌های موجود داشته باشد. در نهایت، شبکه‌کد الگوریتم GODFIS ارائه می‌گردد.

شبکه‌کد الگوریتم GODFIS

ورودی: داده‌های جریانی (x_k, y_k) و آستانه‌ها (ε, U_{min})

خروجی: به‌روزرسانی پایگاه قوانین و پارامترهای مقدم و تالی

۱. استخراج خوشه‌های اولیه با GOECA آفلاین

۲. تخمین اولیه پارامترهای تالی با RLS

۳. برای هر داده جدید:

✓ محاسبه فاصله تا خوشه‌ها

○ اگر داخل شعاع $\leftarrow$ به‌روزرسانی مرکز (فرمول (۸))

○ اگر نزدیک $\leftarrow$ به‌روزرسانی مرکز و شعاع (روابط (۸) و (۱۰))

○ در غیر این صورت $\leftarrow$ ایجاد خوشه جدید

✓ به‌روزرسانی پارامترهای تالی (رابطه (۱۲) یا (۱۴))

✓ اعمال اصل حذف نویز (رابطه (۱۷))

۴. پایان

در بخش بعد نتایج محاسباتی این الگوریتم با سایر الگوریتم‌های موجود در ادبیات مورد ارزیابی قرار می‌گیرد.

۴- یافته‌های پژوهش

در این بخش، فرایند اعتبارسنجی الگوریتم GODFIS در چهار محور اصلی انجام می‌شود:

۱. ارزیابی عمومی عملکرد الگوریتم با استفاده از داده‌های Mackey–Glass (MG) [۶۷].

Delta Ailerons [۶۸] و S&P ۵۰۰ [۴۵].

۲. مقایسه به‌روزرسانی محلی و سراسری پارامترهای تالی و تأثیر آن‌ها بر عملکرد نهایی

GODFIS مشخص گردد.

۳. بررسی کارایی اصل حذف نویز در بهبود پایداری مدل.



۴. بررسی عملکرد در پیش‌بینی تقاضای خرده‌فروشی با استفاده از داده‌های واقعی یک زنجیره فروشگاهی ایرانی.

عملکرد GODFIS با معیارهای $RMSE$ ، $NDEI$ ، تعداد قوانین و زمان محاسباتی (t_{exe}) استفاده می‌شود.

ملاحظات بازتولیدپذیری و جزئیات پیاده‌سازی:

الگوریتم GODFIS در محیط MATLAB پیاده‌سازی شده و آزمایش‌ها روی سیستمی با پردازنده Intel Core i7 نسل ۹ و ۱۶GB RAM اجرا شده‌اند. تنظیمات اصلی مدل به صورت زیر است:

✓ مقدار اولیه ماتریس کوواریانس در RLS: $P_0 = \alpha I$ ($\alpha = 10000$)

✓ آستانه ایجاد خوشه جدید در GOECA: $thr = 0.05$

✓ حد آستانه مطلوبیت قانون برای حذف: $\epsilon = 0.03$

✓ حد آستانه جمعیت خوشه (تعداد داده‌هایی یک خوشه): $\frac{k}{r} \times \epsilon$ ($\epsilon = 0.01$)

تمام پارامترها پس از تحلیل حساسیت اولیه ثابت نگه داشته شده و برای تمامی مجموعه داده‌ها بدون تنظیم مجدد استفاده شده‌اند. داده‌ها به صورت برخط و ترتیبی وارد مدل شده‌اند؛ در هر گام ابتدا پیش‌بینی انجام شده و سپس پس از مشاهده مقدار واقعی، ساختار و پارامترهای مدل به‌روزرسانی شده‌اند.

بررسی عملکرد الگوریتم به صورت عمومی روی بنچمارک‌های سری زمانی:

اعتبار سنجی GODFIS روی سری زمانی مکی گلاس:

برای ارزیابی عملکرد در پیش‌بینی سری‌های زمانی آشفته، مجموعه داده MG با تأخیر $\tau = 17$ و ۳۵۰۰ نمونه تولید شد که ۳۰۰۰ نمونه برای آموزش و ۵۰۰ نمونه برای آزمون استفاده شد. مسئله پیش‌بینی به صورت زیر تعریف شد:

$$\hat{x}(t+15) = f(x(t), x(t-1), x(t-12), x(t-18)) \quad (18)$$

برای مقایسه GODFIS با روش‌های پیشین، سه شاخص $NDEI$ ، تعداد قوانین ($\#(Rule)$) و زمان آموزش (t_{exe}) به کار گرفته شد. به منظور مقایسه منصفانه، نتایج مدل‌های پیشین

^۱ Root Mean Square Error

^۲ Non-Dimensional Error Index



مستقیماً از ادبیات تخصصی استخراج و در جدول ۲ گزارش شده‌اند [۵۰, ۵۶, ۵۹, ۶۹, ۷۰].

جدول ۲. مقایسه‌ی عملکرد GODFIS با سایر روش‌ها روی داده MG

Model	Model Type	NDEI	\$(Rule)\$	t_{exe}
GODFIS	T-S	۰.۱۰۶	۴۲	۹.۳
LEOA [۵۶]	T-S	۰.۲۴۸	۴۲	۱۴۴.۸
ALMMo [۷۱]	T-S	۰.۴۰۲	۹	۰.۵
PSO-ALMMo [۵۴]	T-S	۰.۱۹۱	۸	۳۱۴.۳
CEFNS [۴۹]	T-S	۰.۲۶۴	۵	۰.۴
DENFIS [۳۶]	T-S	۰.۲۷۸	۵۸	— ^۱
EFuMo [۷۲]	T-S	۰.۱۳۹	۴۱	—
EFS-SLAT [۵۱]	T-S	۰.۱۱۴	۸	—
ESAFIS [۷۳]	T-S	۰.۲۹۶	۶	۵.۸
eTS [۳۷]	T-S	۰.۳۸۱	۹	۳.۱
eTS+ [۴۰]	T-S	۰.۳۹۲	۱۰	—
Simpl_eTS [۳۸]	T-S	۰.۳۹۴	۱۱	۴.۴
Simpl_eTS+ [۷۴]	T-S	۰.۳۷۵	۱۵	—
GENEFIS [۷۵]	T-S	۰.۲۸	۱۹	۴.۵
GSETSK [۷۶]	T-S	۰.۳۴۷	۱۹	—
McFIS [۷۷]	T-S	۰.۲۵	۱۰	۸.۲
PANFIS [۴۵]	T-S	۰.۳۰۱	۱۹	۴.۵
RMCEFS [۷۰]	T-S	۰.۱۱۷	۵	۰.۳
SAFIS [۷۸]	RBF	۰.۳۷۶	۶	—
SEFS [۶۹]	T-S	۰.۱۲۹	۴	۰.۴
eT ^۲ RFNN [۴۸]	T-S	۰.۳۲	۳	—
SPATFIS [۵۰]	T-S	۰.۲۷۹	۳۰	—
DeTS [۴۱]	T-S	۰.۴۴	۳	—

۱ مقادیری که با "—" گزارش شده در منبع ذکر نشده است.



نتایج نشان می‌دهد، GODFIS از نظر شاخص NDEI بهترین عملکرد را در میان بسیاری از مدل‌های EFS گزارش شده در ادبیات ارائه می‌دهد. اگرچه تعداد قوانین و زمان اجرا نسبت به برخی روش‌ها بیشتر است، این موضوع ناشی از طراحی الگوریتم برای حفظ اطلاعات تاریخی و دستیابی به بهینگی سراسری است. در مقایسه با مدل LEOA—تنها روش آنلاین مبتنی بر بهینه‌سازی سراسری—GODFIS با تعداد قوانین مشابه، دقت بالاتر و زمان اجرای کمتر دارد. همچنین در مقایسه با الگوریتم PSO-ALMMo (غیرآنلاین و مبتنی بر متاهیوریستیک)، GODFIS از نظر دقت پیش‌بینی و زمان محاسباتی عملکرد بهتری دارد، هرچند قوانین بیشتری تولید می‌کند.

اعتبار سنجی GODFIS روی مجموعه داده Delta Ailerons:

برای ارزیابی بیشتر، مجموعه داده Delta Ailerons از پایگاه KEEL^۱ (مرتبط با کنترل سطوح پروازی هواپیمای F^{۱۶}) مورد استفاده قرار گرفت. نتایج (جدول ۳) نشان می‌دهد که GODFIS با تنها دو قانون فازی مدلی بسیار فشرده ایجاد کرده و از نظر دقت پیش‌بینی در رتبه دوم قرار می‌گیرد. این موضوع نشان می‌دهد که الگوریتم توانسته میان سادگی مدل، سرعت اجرا و دقت پیش‌بینی تعادل برقرار کند.

جدول ۳. مقایسه‌ی GODFIS نسبت به روش‌های دیگر در ادبیات روی مجموعه داده Delta Ailerons

Model	Model Type	NDEI	\$(Rule)\$	t_{exe}
GODFIS	T-S	۰.۰۴۴۹	۲	۱.۷
ALMMo [۷۱]	T-S	۰.۰۵۱۳	۱۰	۴
CEFNS [۴۹]	T-S	۰.۰۵۰۲	۳	۳
DENFIS [۳۶]	T-S	۰.۰۴۹۷	۱۱	—
EFS-SLAT [۵۱]	T-S	۰.۰۴۱۲	۸	—
ESAFIS [۷۳]	T-S	۰.۰۵۰۶	۱۳	۱۲.۴
eTS [۳۷]	T-S	۰.۰۵۱۳	۴	۲.۱
McFIS [۷۷]	T-S	۰.۰۵۰۹	۱۵	—
RMCEFS [۷۰]	T-S	۰.۰۴۹۸	۲	۰.۲

^۱ Available at: <https://sci.s.ugr.es/keel/datasets.php>



Model	Model Type	NDEI	\$(Rule)\$	t_{exe}
SAFIS [۷۸]	RBF	۰.۰۵۴۹	۱۴	۶.۸
SEFS [۶۹]	T-S	۰.۰۴۷۶	۷	۰.۴
Simpl_eTS [۳۸]	T-S	۰.۰۵۱۲	۴	۲

همچنین مقایسه با روش PSO-ALMMo (جدول ۴) نشان می‌دهد که اگرچه این روش در برخی موارد اندکی دقت بالاتری دارد، GODFIS با تعداد قوانین کمتر و زمان محاسباتی بسیار کوتاه‌تر عملکرد کارآمدتری ارائه می‌دهد. علاوه بر این، GODFIS از قابلیت یادگیری آنالین و سازگاری لحظه‌ای برخوردار است که در روش‌های آفلاین وجود ندارد (نتایج از [۵۴] اخذ شده‌اند).

جدول ۴. مقایسه‌ی GODFIS، ALMMo و PSO-ALMMo روی مجموعه داده Delta Ailerons

Model	Model Type	NDEI	\$(Rule)\$	t_{exe}
GODFIS	T-S	۰.۵۴۳۷	۲	۱۱.۷
ALMMo [۷۱]	T-S	۰.۵۴۹۹	۱۰	۰.۵
PSO-ALMMo [۵۴]	T-S	۰.۵۳۵۱	۱۰	۳۶۲.۴

برای ارزیابی در یک مسئله واقعی و پیچیده، پیش‌بینی قیمت پایانی شاخص S&P ۵۰۰ مورد بررسی قرار گرفت. این مجموعه داده شامل ۱۴۸۹۳ نمونه (سال‌های ۱۹۵۰ تا ۲۰۰۹) است که با افزودن نسخه معکوس سری زمانی به ۲۹۷۸۶ نمونه افزایش یافته است. نیمی از داده‌ها برای آموزش و نیمی برای آزمون استفاده شدند و مدل پیش‌بینی به صورت زیر تعریف شد:

$$\hat{x}(t+1) = f(x(t), x(t-1), x(t-2), x(t-3), x(t-4)) \quad (19)$$

عملکرد GODFIS در مقایسه با نتایج سایر الگوریتم‌ها (اخذ شده از [۷۱، ۵۱، ۴۵]) در جدول ۵ ارائه شده است.

جدول ۵. مقایسه‌ی GODFIS نسبت به روش‌های دیگر در ادبیات روی مجموعه داده S&P ۵۰۰

Model	Model Type	NDEI	\$(Rule)\$	t_{exe}
GODFIS	T-S	۰.۰۱۵۳	۱۴	۱۶.۷
LEOA [۵۶]	T-S	۰.۱۲۳	۵۲	-
ALMMo [۷۱]	T-S	۰.۰۱۴۷	۶	۳.۶
PSO-ALMMo [۵۴]	T-S	۰.۰۱۴۶	۶	۲۷۸۳.۳



Model	Model Type	NDEI	\$(Rule)\$	t_{exe}
DENFIS [۳۶]	T-S	۰.۰۲	۶	-
EFuNN [۷۹]	T-S	۰.۱۵۴	۱۱۴	-
EFS-SLAT [۵۱]	T-S	۰.۰۱۶	۲۳	-
eTS [۳۷]	T-S	۰.۰۱۵	۱۴	-
GENEFIS [۷۵]	T-S	۰.۰۷	۲	-
PANFIS [۴۵]	T-S	۰.۰۹	۴	-
SEFS [۶۹]	T-S	۰.۰۱۸	۲	-
Simpl_eTS [۳۸]	T-S	۰.۰۴۵	۷	-

نتایج نشان می‌دهد که در میان الگوریتم‌های آنالین، GODFIS از نظر NDEI عملکردی رقابتی و نزدیک به بهترین روش‌ها دارد. همچنین در مقایسه با الگوریتم‌های مبتنی بر بهینه‌سازی سراسری مانند LEOA عملکرد بهتری ارائه می‌دهد و نسبت به روش متاهوریستیک PSO-ALMMo زمان محاسباتی بسیار کمتری دارد.

مقایسه به‌روزرسانی محلی و یا سراسری پارامترهای تالی:

یکی از پرسش‌های بنیادین در طراحی سیستم‌های فازی تکاملی آن است که آیا به‌روزرسانی سراسری پارامترهای تالی نسبت به به‌روزرسانی محلی واقعاً مزیتی ایجاد می‌کند و در صورت وجود این مزیت، در چه شرایطی این برتری آشکار می‌شود. نتایج ارائه‌شده در جدول ۶ امکان بررسی تجربی این موضوع را فراهم می‌سازد.

در الگوریتم GODFIS، به‌روزرسانی سراسری پارامترهای تالی به‌گونه‌ای طراحی شده است که تمامی تعاملات میان ضرایب مدل را به‌صورت یکپارچه و هم‌زمان در نظر می‌گیرد. این رویکرد موجب می‌شود تنظیم پارامترها با انسجام بیشتری انجام گیرد و ناهماهنگی احتمالی بین قوانین مختلف کاهش یابد. همان‌گونه که در جدول ۶ مشاهده می‌شود، تعداد قوانین تولیدشده در هر دو نسخه سراسری و محلی یکسان است، اما مقادیر RMSE و NDEI در نسخه سراسری بهبود یافته‌اند (در MG اختلاف به طور معنادار، و در Delta Ailerons و S&P ۵۰۰ جزئی و محدود). این موضوع نشان می‌دهد که حتی با ساختار یکسان، نحوه بهینه‌سازی پارامترهای تالی می‌تواند تأثیر تعیین‌کننده‌ای بر دقت پیش‌بینی داشته باشد. این یافته با نتایج گزارش‌شده در مطالعه [۶۶] (که برای شرایط بهینه و آفلاین است) همسو است و



مؤید اهمیت رویکردهای سراسری در تنظیم ضرایب مدل می‌باشد.

جدول ۶. مقایسه‌ی بروزسانی سراسری تالی در مقابل بروزسانی محلی تالی در الگوریتم GODFIS

Dataset	Model	RMSE	NDEI	\$(Rule)\$	t_{exe}
Mackey-Glass	GODFIS (Global)	۰.۰۲۷۰	۰.۱۰۶۲	۴۲	۹.۳
	GODFIS (Local)	۰.۰۸۴۳	۰.۳۳۲۱	۴۲	۸.۴
Delta Ailerons	GODFIS (Global)	۰.۰۴۴۹	۰.۵۴۳۷	۲	۱۱.۷
	GODFIS (Local)	۰.۰۴۵۶	۰.۵۴۹۲	۲	۱۱.۳
S&P ۵۰۰	GODFIS (Global)	۰.۰۰۴۴	۰.۰۱۵۳	۱۴	۱۶.۷
	GODFIS (Local)	۰.۰۰۴۵	۰.۰۱۵۷	۱۴	۱۵.۳

به طور کلی نتایج تجربی نشان می‌دهد که الگوریتم GODFIS با ترکیب خوشه‌بندی تکاملی مبتنی بر مرکز ثقل (GOECA) و به‌روزرسانی سراسری پارامترهای تالی قادر است میان دقت پیش‌بینی، پیچیدگی مدل و کارایی محاسباتی تعادل برقرار کند. این هم‌افزایی ساختاری موجب شده است GODFIS در بسیاری از موارد عملکردی رقابتی یا برتر نسبت به روش‌های موجود در ادبیات ارائه دهد.

جمع‌بندی تحلیل رفتاری GODFIS روی بنچمارک‌ها:

نتایج در جدول ۲ تا جدول ۵ نشان می‌دهد که عملکرد GODFIS به ماهیت دینامیکی داده‌ها وابسته است و میزان بهبود آن تابعی از پیچیدگی ساختاری، شدت آشوب و سطح نویز در سری زمانی است.

در مجموعه داده MG، GODFIS با دستیابی به کمترین مقدار NDEI (۰.۱۰۶) در میان مدل‌های مقایسه‌شده، عملکرد برتری نشان می‌دهد. ماهیت آشوبناک این سیستم باعث می‌شود خطاهای کوچک در تخمین پارامترها به سرعت تقویت شوند. در روش‌های مبتنی بر به‌روزرسانی محلی، اصلاح پارامترها تنها در قانون فعال انجام می‌شود که می‌تواند به نوسان پارامترها و پدیده فراموشی تدریجی منجر شود. در مقابل، GODFIS با به‌روزرسانی سراسری پارامترهای تالی، تمامی ضرایب مدل را به‌صورت هماهنگ تنظیم کرده و از انتشار خطا جلوگیری می‌کند. اختلاف قابل‌توجه میان نسخه سراسری و محلی در جدول ۶ (۰.۱۰۶۲ در برابر ۰.۳۳۲۱) نشان‌دهنده اهمیت این سازوکار در داده‌های آشوبناک است. در مجموعه داده Delta Ailerons، GODFIS عملکردی رقابتی (NDEI=۰.۰۴۴۹) ارائه



می‌دهد و با تنها دو قانون فازی ساده‌ترین ساختار را در میان مدل‌ها ایجاد می‌کند. از آنجا که دینامیک این داده‌ها هموارتر است، مزیت بهینه‌سازی سراسری نسبت به محلی کاهش می‌یابد و اختلاف عملکرد دو نسخه بسیار محدود باقی می‌ماند. با این حال، فشردگی مدل حاصل بیانگر کارایی ساختاری الگوریتم GOECA در جلوگیری از تولید قوانین غیرضروری است. در داده S&P ۵۰۰، GODFIS با NDEI برابر ۰.۰۱۵۳ در میان الگوریتم‌های آنلاین عملکردی رقابتی ارائه می‌دهد. ماهیت نیمه تصادفی و نویزی این سری زمانی موجب می‌شود بخشی از تغییرات ذاتاً غیرقابل پیش‌بینی باشد؛ از این رو بهینه‌سازی سراسری بیشتر به افزایش پایداری ساختاری مدل کمک می‌کند تا کاهش چشمگیر خطا. با این حال، GODFIS در مقایسه با بسیاری از EFS‌های کلاسیک تعادل مناسبی میان دقت پیش‌بینی و تعداد قوانین (۱۴ قانون) برقرار کرده است.

در مجموع، نتایج نشان می‌دهد که مزیت اصلی GODFIS در داده‌های دارای آشوب و تعاملات غیرخطی قوی آشکارتر است، در حالی که در داده‌های هموارتر یا با مؤلفه تصادفی غالب، بهینه‌سازی سراسری بیشتر نقش تثبیت‌کننده در ساختار مدل ایفا می‌کند.

اعتبارسنجی GODFIS روی داده‌های واقعی:

به منظور ارزیابی عملی الگوریتم GODFIS، عملکرد آن با چهار دسته از روش‌های پیش‌بینی مقایسه شد: روش‌های کلاسیک تک‌متغیره (ARIMA)، روش‌های کلاسیک علی چندمتغیره (Regression)، روش‌های هوش مصنوعی آفلاین مبتنی بر تاکاگی-سوگنو (ANFIS) و روش‌های هوش مصنوعی آنلاین (DENFIS و eTS). داده‌های مورد استفاده شامل فروش واقعی یک زنجیره خرده‌فروشی ایرانی با بیش از ۱۰۰۰ فروشگاه در سراسر کشور است.

تشریح داده‌ها و پروتکل ارزیابی مطالعه خرده‌فروشی:

برای ارزیابی عملکرد الگوریتم در مقیاس عملیاتی، داده‌های فروش روزانه ۲۸۴۷ قلم کالای طی حدود دو سال مورد استفاده قرار گرفت. به منظور تمرکز بر اقلام با اهمیت اقتصادی و جلوگیری از سوگیری ناشی از اقلام کندگردش، تحلیل بر اساس اصل پارتو انجام شد و تنها کالاهایی که حدود ۸۰٪ از فروش را تشکیل می‌دادند در مطالعه لحاظ شدند. همچنین کالاهایی وارد تحلیل شدند که حداقل در ۳۰٪ ماه‌های دوره مطالعه حضور فعال داشتند. هر مشاهده شامل تاریخ فروش، شناسه کالا، مقدار فروش، قیمت، درصد تخفیف و وضعیت



موجودی بود. به منظور افزایش اعتبار نتایج، چند مرحله پیش پردازش انجام شد: حذف اثر چرخه هفتگی با تجمیع داده‌ها به سطح هفتگی، حذف دوره‌های دارای عدم موجودی شدید، حفظ داده‌های پروموشن برای شبیه‌سازی شرایط واقعی بازار، و نرمال‌سازی داده‌ها پیش از ورود به مدل.

ارزیابی در چارچوب یادگیری برخط انجام شد؛ به گونه‌ای که مدل در هر گام زمانی با داده‌های گذشته پیش‌بینی انجام داده و سپس با مشاهده مقدار واقعی به‌روزرسانی می‌شود. این طراحی شرایط واقعی استفاده از سیستم‌های پیش‌بینی تقاضا در محیط‌های عملیاتی را شبیه‌سازی می‌کند.


طبقه‌بندی کالاها:

بر اساس طبقه‌بندی مطالعه‌ی [۸۰]، کالاها به چهار گروه یکنواخت (Smooth)، وقفه‌دار (Intermittent)، نامنظم (Erratic) و فله‌ای (Lumpy) تقسیم شدند. مقایسه با مطالعات خرده‌فروشی بریتانیا نشان داد سهم کالاهای یکنواخت در داده‌های ایران بسیار کمتر است و بیش از ۷۰٪ کالاها در دسته‌های نامنظم و فله‌ای قرار می‌گیرند. این موضوع بیانگر نوسانات شدید تقاضا در بازار خرده‌فروشی ایران است که ناشی از عواملی مانند بی‌ثباتی تأمین، رفتار متغیر مصرف‌کنندگان، سیاست‌های قیمتی و محدودیت‌های لجستیکی است. در چنین محیطی، مدل‌های تطبیقی و آنلاین مانند GODFIS برای مواجهه با تغییرات ناگهانی بازار مناسب‌تر هستند.


سناریوهای متفاوت سناریوهای متفاوت برای اعتبارسنجی:

مدل‌های پیش‌بینی بر اساس داده‌های ورودی استخراج شده، در دو سناریوی زیر مورد آزمایش قرار می‌گیرند:

- ✓ سناریوی ۱ (آموزش آنلاین و آفلاین): مدل‌ها با داده‌های دو سال اول آموزش داده شده و سپس به صورت روزانه به‌روزرسانی می‌شوند (شکل ۲).
- ✓ سناریوی ۲ (آموزش پنجره غلتان/دوره‌ای): مدل‌های آفلاین با داده‌های سال اول آموزش دیده و هر سال یکبار با داده‌های جدید بازآموزی می‌شوند. (شکل ۳).



شکل ۲. سناریو اول - آموزش برخط



شکل ۳. سناریو سوم - مدل پنجره غلتان برای مدل‌های آفلاین

نتایج آزمون سناریو اول: مقایسه آموزش برخط و آموزش غیر برخط

در شرایط واقعی، عموماً مدل‌های غیر برخط یکبار آموزش می‌بیند و مدل آموزش داده شده برای پیش‌بینی مابقی دوره بکار برده می‌شود. در این آزمون نیز، عملکرد GODFIS و سایر مدل‌ها (روش‌های سنتی، روش‌های هوش مصنوعی آفلاین، و روش‌های هوش مصنوعی آنلاین) تحت دو سناریو اول و سوم مورد بررسی قرار می‌گیرد. این آزمون، منسوخ و قدیمی شدن مدل و قواعد آن مورد بررسی قرار می‌گیرد. از اینرو، هر دو مدل با تعداد قواعد یکسان و همچنین دوره آموزشی و تعداد مشاهدات یکسان آموزش دیده‌اند. در این آزمون مدل‌ها با داده‌های دو سال اول (۱۴۰۰-۱۴۰۱)، آموزش داده شده است و مدل‌های آموزش دیده برای پیش‌بینی مابقی داده‌ها استفاده شده است. نتایج آزمایشات روی داده‌های آموزشی در جدول ۷ و روی داده‌های تست در جدول ۸ ارائه شده است.



جدول ۷. نتایج آزمایشات سناریو اول روی داده‌های آموزشی

Train Data		Smooth			Intermittent			Lumpy			Erratic		
Model	#(Rule)	RMSE	NDEI		#(Rule)	RMSE	NDEI	#(Rule)	RMSE	NDEI	#(Rule)	RMSE	NDEI
ARIMA	-	۴.۵۸	۰.۱۴۵		-	۸.۷۵	۰.۲۳	-	۱۰.۸۲	۰.۲۸	-	۱۴.۳۹	۰.۳۲
Regression	-	۴.۸۲	۰.۱۵		-	۹.۲۷	۰.۲۵	-	۱۱.۸۷	۰.۳۱	-	۱۵.۰۲	۰.۳۳
ANFIS	۴	<u>۴.۴۳</u>	<u>۰.۱۴۱</u>		۹	<u>۶.۳۴</u>	<u>۰.۱۶۹</u>	۱۱	<u>۷.۳۱</u>	<u>۰.۱۹</u>	۱۷	<u>۹.۲۴</u>	<u>۰.۲۰</u>
DENFIS	۴	۶.۰۲	۰.۱۹		۹	۷.۶۴	۰.۲۰	۱۱	۱۰.۴۶	۰.۲۷	۱۷	۱۳.۳۲	۰.۳۰
eTS	۴	۶.۱۲	۰.۱۹		۹	۷.۷۸	۰.۲۱	۱۱	۱۰.۹۰	۰.۲۸	۱۷	۱۳.۰۵	۰.۲۹
GODFIS	۴	۴.۵۵	۰.۱۴۴		۹	۶.۴۵	۰.۱۷۲	۱۱	۸.۷۶	۰.۲۳	۱۷	۹.۹۰	۰.۲۲

جدول ۸. نتایج آزمایشات سناریو اول روی داده‌های آموزشی

Test Data		Smooth			Intermittent			Lumpy			Erratic		
Model	#(Rule)	RMSE	NDEI		#(Rule)	RMSE	NDEI	#(Rule)	RMSE	NDEI	#(Rule)	RMSE	NDEI
ARIMA	-	۹.۱۵	۰.۲۸		-	۱۷.۰۵	۰.۴۳	-	۲۲.۴۸	۰.۵۳	-	۲۵.۶۳	۰.۵۲
Regression	-	۹.۰۷	۰.۲۷		-	۱۶.۳۶	۰.۴۲	-	۲۲.۸۹	۰.۵۳	-	۲۷.۹۰	۰.۵۶
ANFIS	-	۷.۲۲	۰.۲۲		-	۱۰.۳۴	۰.۲۶	-	۱۳.۲۸	۰.۳۱	-	۱۸.۳۸	۰.۳۷
DENFIS	$۴+۳=۷$	۸.۶۹	۰.۲۶		$۹+۵=۱۴$	۱۱.۰۳	۰.۲۸	$۱۱+۶=۱۷$	۱۳.۰۸	۰.۳۱	$۱۷+۹=۲۶$	۱۵.۴۲	۰.۳۱
eTS	$۴+۴=۸$	۸.۸۳	۰.۲۷		$۹+۴=۱۳$	۱۱.۲۳	۰.۲۹	$۱۱+۷=۱۸$	۱۳.۰۳	۰.۳۰	$۱۷+۱۲=۲۹$	۱۵.۱۱	۰.۳۰
GODFIS	$۴+۳-۱=۶$	<u>۶.۸۰</u>	<u>۰.۲۱</u>		$۹+۶-۲=۱۳$	<u>۸.۷۸</u>	<u>۰.۲۲</u>	$۱۱+۱۲-۳=۲۰$	<u>۹.۵۸</u>	<u>۰.۲۲</u>	$۱۷+۱۹-۵=۳۱$	<u>۱۱.۲۳</u>	<u>۰.۲۳</u>

همان‌طور که در داده‌های آموزشی مشاهده می‌شود، GODFIS عملکردی بسیار نزدیک به ANFIS دارد. این موضوع طبیعی است، زیرا GODFIS در فاز آموزش اولیه، مخصوصاً در یادگیری پارامترهای تالی مشابه ANFIS آموزش می‌بیند. هرچند در یادگیری بخش مقدماتی تفاوت‌هایی میان این دو الگوریتم وجود دارد، اما به دلیل مکانیزم بهینه‌سازی تعبیه‌شده در GODFIS که مبتنی بر الگوریتم‌های خوشه‌بندی کلاسیک است، خروجی نهایی آن به پاسخ بهینه بسیار نزدیک می‌شود. ضعف ناشی از رویکرد اکتشافی و نبود مکانیزم بهینه‌سازی، کاملاً در دو الگوریتم DENFIS و eTS مشهود است و حتی در گروه کالاهای Smooth نسبت به الگوریتم‌های کلاسیک نیز عملکرد ضعیف‌تری دارند. به طور کلی، الگوریتم‌های هوش مصنوعی به دلیل توانایی مدل‌سازی غیرخطی، دقت بالاتری نسبت به روش‌های کلاسیک از



خود نشان می‌دهند.

در مقابل، در داده‌های تست، بر اساس نتایج جدول و نمودارهای فوق، مشاهده می‌شود که الگوریتم GODFIS در تمامی الگوهای تقاضا عملکردی برتر نسبت به سایر روش‌ها دارد. در شاخص RMSE، این الگوریتم به طور میانگین حدود ۲۰ تا ۴۰ درصد کاهش خطا نسبت به روش‌های سنتی (ARIMA و Regression) و حدود ۱۰ تا ۲۰ درصد بهبود نسبت به روش‌های هوش مصنوعی پیشین (ANFIS، DENFIS و eTS) نشان داده است. همچنین در شاخص NDEI نیز GODFIS در تمامی دسته‌های تقاضا دارای کمترین مقدار بوده است که نشان‌دهنده پایداری و دقت بالاتر آن در پیش‌بینی مقادیر واقعی فروش می‌باشد.

در الگوهای دارای نوسانات زیاد نظیر Lumpy و Erratic، اختلاف عملکرد GODFIS با سایر روش‌ها چشمگیرتر است. این موضوع بیانگر آن است که ساختار در حال تکامل GODFIS قادر است با تغییرات ناگهانی تقاضا، قوانین فازی خود را به صورت برخط تنظیم کرده و مدل را با داده‌های جدید منطبق سازد. به همین دلیل، در بازارهای ناپایدار مانند بازار خرده‌فروشی ایران، GODFIS نسبت به مدل‌های ثابت و آفلاین از سازگاری و پایداری بیشتری برخوردار است. نتایج همچنین نشان می‌دهد که GODFIS در عین دستیابی به خطای کمتر، از نظر پیچیدگی مدل و تعداد قوانین فازی نیز کاراتر عمل می‌کند. در این الگوریتم، تعداد قوانین فازی به صورت پویا تنظیم شده و از رشد غیرضروری آن جلوگیری می‌شود، در حالی که در مدل‌های مشابه نظیر DENFIS و eTS، افزایش مستمر قوانین ممکن است منجر به افزایش پیچیدگی محاسباتی شود. بنابراین GODFIS توانسته است تعادلی بهینه میان دقت، سرعت و سادگی ساختار ایجاد نماید.

به طور کلی، یافته‌های این بخش تأیید می‌کند که الگوریتم GODFIS با بهره‌گیری از قابلیت یادگیری برخط، تنظیم پویا و حذف قوانین کم‌اثر (وجود اصل حذف نویز)، و همچنین وجود مکانیزم بهینه‌سازی توانسته است عملکرد پیش‌بینی تقاضا را در تمامی الگوهای رفتاری کالاهای بهبود دهد و در مقایسه با سایر روش‌های متداول، راهکاری دقیق‌تر و منعطف‌تری برای مدیریت موجودی و برنامه‌ریزی فروش در خرده‌فروشی‌ها ارائه نماید.



نتایج آزمون آزمون سناریو دوم: مقایسه عملکرد آموزش برخط و پنجره لغزان

در روش‌های آفلاین پیش‌بینی سری‌های زمانی، از «پنجره لغزان» به دلایل متعددی استفاده می‌شود که مهم‌ترین آن، تبدیل مسئله‌ای پویا و وابسته به زمان، به نمایشی ایستا در بازه‌های مختلف می‌باشد و به مدل این امکان را می‌دهد تا وابستگی‌های زمانی کوتاه‌مدت را فراگیرد، با تغییرات رفتاری سیستم سازگار شود و از پیچیدگی اضافی و بیش برآزش جلوگیری کند. به همین دلیل، پنجره لغزان یک روش پرکاربرد و مؤثر در حوزه پیش‌بینی سری‌های زمانی شناخته می‌شود.

هدف از تحلیل حاضر، ارزیابی دقت پیش‌بینی، پایداری عملکرد و کارایی الگوریتم GODFIS در مقایسه با دیگر روش‌های متداول است. در این راستا، عملکرد GODFIS و سایر روش‌ها در سناریوی دوم در جدول ۹ ارائه شده است.

جدول ۹. مقایسه عملکرد الگوریتم GODFIS با سایر روش‌ها روی داده واقعی خرده فروشی در سناریو دوم

Model	Smooth		Intermittent		Lumpy		Erratic	
	RMSE	NDEI	RMSE	NDEI	RMSE	NDEI	RMSE	NDEI
ARIMA	۷.۲۲	۰.۲۲	۱۳.۱۳	۰.۳۳	۱۴.۶۱	۰.۳۴	۱۸.۷۱	۰.۳۸
Regression	۷.۷۱	۰.۲۳	۱۳.۹۱	۰.۳۵	۱۶.۰۲	۰.۳۷	۱۹.۵۳	۰.۳۹
ANFIS	۶.۸۶	۰.۲۱	۹.۸۲	۰.۲۵	۱۱.۹۵	۰.۲۸	۱۶.۵۴	۰.۳۳
DENFIS	۷.۸۲	۰.۲۴	۹.۹۳	۰.۲۵	۱۱.۵۱	۰.۲۷	۱۴.۶۵	۰.۳۰
eTS	۷.۹۵	۰.۲۴	۱۰.۱۱	۰.۲۶	۱۱.۹۹	۰.۲۸	۱۴.۳۵	۰.۲۹
GODFIS	<u>۶.۶۰</u>	<u>۰.۲۰</u>	<u>۸.۵۲</u>	<u>۰.۲۲</u>	<u>۹.۲۹</u>	<u>۰.۲۲</u>	<u>۱۰.۸۹</u>	<u>۰.۲۲</u>

با توجه به جدول ارائه شده، نتایج زیر قابل استنتاج است:

✓ در الگوهای Smooth: اگرچه تمامی مدل‌ها از عملکرد مطلوبی برخوردارند، ولی روش‌های آنالین eTS و DENFIS در مقایسه با روش‌های آفلاین و حتی کلاسیک، به دلیل استفاده از مکانیزم اکتشافی و فقدان بهینه‌سازی سراسری، عملکرد ضعیف‌تری نشان می‌دهند. در مقابل، GODFIS با بهره‌گیری از مکانیزم بهینه‌سازی، عملکرد برتری را در این الگوها ارائه کرده است.

✓ در الگوهای Intermittent: روش‌های آنالین به لطف ساختار یادگیری تدریجی، توانایی بالاتری در تطبیق با دوره‌های فاقد فروش و جهش‌های ناگهانی تقاضا را دارند و نیاز



به بازآموزی کامل مدل را برطرف می‌کنند. با این حال، ضعف eTS و DENFIS در نبود مکانیزم بهینه‌سازی باعث شده ANFIS آفلاین عملکردی مشابه و اندکی بهتر داشته باشد. این چالش در GODFIS با استفاده از مکانیزم بهینه‌سازی مرتفع شده است.

✓ در الگوهای Lumpy: ماهیت پراکنده و غیرپیوسته داده‌ها در این الگو، منجر به بروز خطای قابل توجه در روش‌های سنتی و آفلاین شده است. در مقابل، الگوریتم‌های آنلاین به دلیل یادگیری تدریجی و تطبیق‌پذیری بالا، از پایداری و دقت بیشتری برخوردارند که در این میان GODFIS با به کارگیری بهینه‌سازی سراسری، برتری محسوسی از خود نشان داده است.

✓ در الگوهای Erratic: در شرایط نوسانات شدید، روش‌های سنتی و آفلاین با افت عملکرد چشمگیری مواجه می‌شوند. این در حالی است که GODFIS با ترکیب یادگیری تکاملی آنلاین، مکانیزم حذف نویز و بهینه‌سازی سراسری، قادر به مدل‌سازی رفتارهای نامنظم تقاضا بوده و عملکردی پایدار و دقیق ارائه می‌دهد.

در مجموع، الگوریتم GODFIS در تمامی الگوهای تقاضا عملکرد مطلوبی داشته است، اما مزیت رقابتی آن به‌ویژه در الگوهای ناپایدار (Lumpy و Erratic) به‌مراتب چشمگیرتر است. این نتایج گواه بر آن است که در بازارهای پرتلاطم و با داده‌های پراکنده، روش‌های پیش‌بینی تطبیقی و آنلاین مانند GODFIS از دقت و قابلیت اطمینان بالاتری برخوردارند. مزیت‌های کلیدی GODFIS که به این برتری منجر شده عبارتند از:

- یادگیری آنلاین و تکاملی قوانین فازی بدون نیاز به بازآموزی کلی؛
- به‌روزرسانی مستمر پارامترها متناسب با جریان داده‌های ورودی؛
- قابلیت مدل‌سازی روابط غیرخطی و نویزی در بازارهای پویا و غیرایستا؛
- بهره‌گیری از مکانیزم اصل حذف نویز برای افزایش پایداری در داده‌های دارای گپ زمانی و نوسان زیاد؛
- بهره‌گیری از مکانیزم بهینه‌سازی برای خنثی‌سازی تأثیر منفی یادگیری اکتشافی

بر این اساس، GODFIS به‌عنوان یک چارچوب پیش‌بینی پویا، گزینه‌ای کارآمد و برتر برای محیط‌های عملیاتی خرده‌فروشی ایران محسوب می‌شود که الگوهای فروش در آن به‌شدت



نوسانی و غیرقابل پیش‌بینی هستند.

مقایسه نتایج سناریو اول و سناریو دوم:

نتایج اجرای دو سناریوی ارزیابی نشان می‌دهد که الگوریتم GODFIS در تمامی الگوهای تقاضا عملکردی برتر نسبت به روش‌های مقایسه‌شده دارد، هرچند میزان این برتری در دو سناریو متفاوت است. در سناریوی یادگیری برخط، GODFIS توانست خطای پیش‌بینی را به طور چشمگیری کاهش دهد؛ به‌گونه‌ای که شاخص‌های RMSE و NDEI نسبت به سایر روش‌ها بین ۲۰ تا ۶۵ درصد بهبود یافت. این برتری به‌ویژه در الگوهای Erratic و Lumpy که دارای نوسانات شدید و رفتار غیرایستا هستند، بیشتر مشاهده شد. دلیل این عملکرد، یادگیری پیوسته مدل، به‌روزرسانی لحظه‌ای قوانین فازی و حذف قواعد کم‌اثر است که امکان انطباق سریع با تغییرات بازار را فراهم می‌کند.

در مقایسه با سناریوی پنجره لغزان نیز GODFIS عملکرد مطلوبی نشان داد، اما میزان بهبود آن نسبت به سناریوی برخط کمتر و در بازه ۳ تا ۴۸ درصد قرار داشت. علت این تفاوت آن است که در این رویکرد، مدل تنها در بازه‌های زمانی مشخص بازآموزی می‌شود و در فاصله بین دو بازآموزی قادر به واکنش سریع به تغییرات ناگهانی نیست. با وجود این محدودیت، GODFIS همچنان نسبت به روش‌های آفلاین و کلاسیک دقت و پایداری بالاتری ارائه داد. به طور کلی، مقایسه این دو سناریو نشان می‌دهد که یادگیری برخط بیشترین دقت و سازگاری را برای GODFIS فراهم می‌کند. با این حال، حتی در چارچوب پنجره لغزان نیز این الگوریتم عملکردی بهتر از تمامی روش‌های مقایسه‌ای دارد. از این رو، در محیط‌های واقعی خرده‌فروشی که با داده‌های پراکنده، ناپایدار و غیرایستا مواجه‌اند، GODFIS در قالب یادگیری برخط کارایی بیشتری نشان می‌دهد.

جمع‌بندی اعتبارسنجی روی داده‌های واقعی:

نتایج مطالعه موردی نشان می‌دهد که GODFIS در پیش‌بینی تقاضا و مدیریت موجودی عملکردی برتر نسبت به روش‌های کلاسیک و هوش مصنوعی رایج دارد. مهم‌ترین یافته‌ها عبارتند از:

۱. بهبود قابل توجه دقت پیش‌بینی در تمامی الگوهای تقاضا، به‌ویژه در داده‌های ناپایدار؛
۲. قابلیت سازگاری سریع با تغییرات بازار از طریق یادگیری برخط؛



۳. جلوگیری از کهنه‌شدن مدل به واسطه به‌روزرسانی پویای قوانین؛

۴. بهبود ملموس شاخص‌های عملیاتی زنجیره تأمین.

در پیاده‌سازی عملی این الگوریتم در زنجیره خرده‌فروشی مورد مطالعه، روزهای موجودی از ۱۴۴ به ۷۸ روز کاهش یافت (۴۶٪ کاهش)، موجودی مازاد ۲۴٪ کاهش یافت و نرخ کمبود کالا از ۱۷٪ به ۲٪ رسید. این نتایج نشان می‌دهد که GODFIS نه تنها در محیط‌های آزمایشگاهی بلکه در شرایط واقعی نیز قادر است تصمیم‌های پیش‌بینی را به بهبودهای عملیاتی قابل توجه در مدیریت موجودی تبدیل کند.

در مجموع، GODFIS با ترکیب یادگیری تطبیقی برخط، بهینه‌سازی سراسری و ساختار فازی تکاملی چارچوبی مؤثر برای پیش‌بینی تقاضا در محیط‌های پویا ارائه می‌دهد و می‌تواند به‌عنوان ابزاری کارآمد در سیستم‌های هوشمند مدیریت زنجیره تأمین مورد استفاده قرار گیرد.

۵- نتیجه‌گیری و پیشنهادها

این پژوهش با هدف ارائه یک چارچوب پیش‌بینی تقاضای خرده‌فروشی در محیط‌های واقعی، غیرایستا و پرنویز، الگوریتم GODFIS را توسعه و ارزیابی کرد. یافته‌های تجربی، چه در داده‌های معیار و چه در داده‌های واقعی یک فروشگاه زنجیره‌ای ایرانی، به‌وضوح نشان می‌دهند که GODFIS توانسته است محدودیت‌های ساختاری و عملکردی رایج در سیستم‌های فازی تکاملی (EFS) را برطرف کند و عملکردی پایدار، دقیق و سازگار با تغییرات محیطی ارائه دهد. نخست، نتایج حاصل از مجموعه داده‌های معیار نشان داد که GODFIS از نظر دقت پیش‌بینی، تعداد قوانین، و کارایی محاسباتی نسبت به مدل‌های مطرح در ادبیات—از جمله eTS، DENFIS، ALMMo و نسخه‌های بهینه‌سازی‌شده آن‌ها—برتری معناداری دارد. این برتری عمدتاً ناشی از دو مؤلفه کلیدی است: (۱) تشخیص دقیق ساختار داده‌ها با استفاده از خوشه‌بندی مبتنی بر مرکز ثقل در چارچوب GOECA، که سبب شکل‌گیری قوانین پایدارتر و کمتر وابسته به توزیع لحظه‌ای داده‌ها می‌شود؛ (۲) بهینه‌سازی سراسری بخش تالی که برخلاف روش‌های متداول مبتنی بر به‌روزرسانی محلی، کلیه پارامترهای مدل را هم‌زمان و هماهنگ تنظیم می‌کند. این ویژگی باعث می‌شود GODFIS از مشکل تاریخی «عدم یکپارچگی بخش مقدم و تالی» که در اکثر EFS‌ها موجود مشاهده می‌شود، عبور کند.



دوم، ارزیابی GODFIS بر روی داده‌های واقعی خرده‌فروشی ایران—که از شدیدترین سطوح نوسان، شکست ساختاری و عدم قطعیت برخوردارند—نشان داد که این الگوریتم توانایی بالایی در مواجهه با رفتارهای ناگهانی و غیرخطی تقاضا دارد. در سناریوی یادگیری برخط، GODFIS توانست نسبت به تمامی روش‌های کلاسیک (مانند ARIMA و رگرسیون) و روش‌های هوش مصنوعی آفلاین و آنلاین، بین ۲۰ تا ۶۵ درصد بهبود در شاخص‌های RMSE و NDEI ایجاد کند. این سطح از بهبود به‌ویژه در الگوهای تقاضای Erratic و Lumpy که همواره دشوارترین الگوهای پیش‌بینی هستند، برجسته‌تر بود. دلیل این عملکرد مطلوب، به‌روزرسانی بلادرنگ قوانین، حذف قواعد کم‌اثر، و انطباق مستمر با ساختار جدید داده‌ها است که به GODFIS امکان می‌دهد بسیاری از رفتارهای غیرمنتظره بازار را به‌سرعت جذب و مدل‌سازی کند.

اگرچه در سناریوی پنجره لغزان الگوریتم‌های ایستا به طور طبیعی نسبت به سناریوی اول از انعطاف‌پذیری بیشتری برخوردارند، اما همچنان به طور معناداری GODFIS، دقیق‌تر از تمامی روش‌های رقیب عمل کرد. این یافته تأیید می‌کند که مکانیزم‌های طراحی‌شده در GODFIS حتی در این شرایط نیز ساختاری پایدار و مقاوم ایجاد می‌کنند. به‌صورت جمع‌بندی، نتایج این پژوهش نشان می‌دهد که:

- ✓ GODFIS می‌تواند به‌عنوان یک چارچوب عملیاتی قابل‌اتکا برای پیش‌بینی تقاضای خرده‌فروشی در محیط‌های واقعی به کار گرفته شود.
 - ✓ این الگوریتم در داده‌های متداول و داده‌های پراکنده، در الگوهای تقاضای متفاوت و در هر دو سناریوی یادگیری، عملکردی پایدار و برتر ارائه می‌دهد.
 - ✓ ماهیت تکاملی، بهینه‌سازی سراسری، و ساختار مبتنی بر مرکز ثقل، این مدل را برای کاربردهای وسیع‌تر در صنایع با داده‌های جریانی و غیرایستا نیز مناسب می‌سازد.
- با وجود کیفیت بالای نتایج به‌دست‌آمده، یکی از مسیرهای پیشنهادی برای تحقیقات آتی، ایجاد همبستگی و یکپارچه‌سازی کامل بین فرایندهای بهینه‌سازی مقدم و تالی و توسعه روش‌هایی برای بهینه‌سازی هم‌زمان این دو بخش می‌باشد.



۶- منابع

- [۱] ۱. Hosseini, M. and M. Karkabood, *Presenting a Hybrid Model for Predicting Consumer Purchase Intent Based on Machine Learning and Social Media Feedback*. Journal of Modern Research in Decision Making, ۲۰۲۰. ۱۰(۳): p. ۸۷-۱۱۶.
- [۲] ۲. Zarei, A. and M.A. Siah Sarani Kojouri, *Discovery and analysis of shopping behavior of older customers decide to buy organic products: The combination of clustering and decision tree*. Journal of Modern Research in Decision Making, ۲۰۱۷. ۴(۳): p. ۱۴۷-۱۷۲.
- [۳] ۳. Majhi, B. and C.M. Anish, *Multiobjective optimization based adaptive models with fuzzy decision making for stock market forecasting*. Neurocomputing, ۲۰۱۵. ۱۶۷: p. ۵۰۲-۵۱۱.
- [۴] ۴. Ma, S., R. Fildes, and T. Huang, *Demand forecasting with high dimensional data: The case of SKU retail sales forecasting with intra- and inter-category promotional information*. European Journal of Operational Research, ۲۰۱۶. ۲۴۹(۱): p. ۲۴۵-۲۵۷.
- [۵] ۵. Schneider, M.J. and S. Gupta, *Forecasting sales of new and existing products using consumer reviews: A random projections approach*. International Journal of Forecasting, ۲۰۱۶. ۳۲(۲): p. ۲۴۳-۲۵۶.
- [۶] ۶. Wang, Y., et al., *Improved LSTM-Based Time-Series Anomaly Detection in Rail Transit Operation Environments*. IEEE Transactions on Industrial Informatics, ۲۰۲۲. ۱۸(۱۲): p. ۹۰۲۷-۹۰۳۶.
- [۷] ۷. Kong, W., et al., *Short-Term Residential Load Forecasting Based on LSTM Recurrent Neural Network*. IEEE Transactions on Smart Grid, ۲۰۱۹. ۱۰(۱): p. ۸۴۱-۸۵۱.
- [۸] ۸. Huang, T., R. Fildes, and D. Soopramanien, *The value of competitive information in forecasting FMCG retail product sales and the variable selection problem*. European Journal of Operational Research, ۲۰۱۴. ۲۳۷(۲): p. ۷۳۸-۷۴۸.
- [۹] ۹. Lahmiri, S., *A variational mode decomposition approach for analysis and forecasting of economic and financial time series*. Expert Systems with Applications, ۲۰۱۶. ۵۵: p. ۲۶۸-۲۷۳.
- [۱۰] ۱۰. Alves Portela Santos, A., N. Carneiro Affonso da Costa, and L. dos Santos Coelho, *Computational intelligence approaches and linear models in case studies of forecasting exchange rates*. Expert Systems with Applications, ۲۰۰۷. ۳۳(۴): p. ۸۱۶-۸۲۳.
- [۱۱] ۱۱. Armstrong, J.S., K.C. Green, and A. Graefe, *Golden rule of forecasting: Be conservative*. Journal of Business Research, ۲۰۱۵. ۶۸(۸): p. ۱۷۱۷-۱۷۳۱.
- [۱۲] ۱۲. Guo, Z.X., W.K. Wong, and M. Li, *A multivariate intelligent decision-making model for retail sales forecasting*. Decision Support Systems, ۲۰۱۳. ۵۵(۱): p. ۲۴۷-۲۵۵.
- [۱۳] ۱۳. Chen, T. and C. Guestrin, *XGBoost: A Scalable Tree Boosting System*. Kdd'16: Proceedings of the 22nd Acm Sigkdd International Conference on Knowledge Discovery and Data Mining, 785-794. ۲۰۱۶, DOI.
- [۱۴] ۱۴. Ke, G., et al., *Lightgbm: A highly efficient gradient boosting decision tree*. Advances in neural information processing systems, ۲۰۱۷. ۳۰.



- [۱۵] ۱۵. Angelov, P.P. and X. Gu, *Toward Anthropomorphic Machine Learning*. Computer, ۲۰۱۸. ۵۱(۹): p. ۱۸–۲۷.
- [۱۶] ۱۶. Joseph, R.V., et al., *A hybrid deep learning framework with CNN and Bi-directional LSTM for store item demand forecasting*. Computers and Electrical Engineering, ۲۰۲۲. ۱۰۳: p. ۱۰۸۳۵۸.
- [۱۷] ۱۷. Garibaldi, J.M., *The need for fuzzy AI*. IEEE/CAA Journal of Automatica Sinica, ۲۰۱۹. ۶(۳): p. ۶۱۰–۶۲۲.
- [۱۸] ۱۸. Syntetos, A.A., et al., *Supply chain forecasting: Theory, practice, their gap and the future*. European Journal of Operational Research, ۲۰۱۶. ۲۵۲(۱): p. ۱–۲۶.
- [۱۹] ۱۹. Nagai, S., et al. *Zero-shot Demand Forecasting for Products with Limited Sales Periods*. in *2024 IEEE International Conference on Big Data (BigData)*. ۲۰۲۴.
- [۲۰] ۲۰. Ulrich, M., et al., *Classification-based model selection in retail demand forecasting*. International Journal of Forecasting, ۲۰۲۲. ۳۸(۱): p. ۲۰۹–۲۲۳.
- [۲۱] ۲۱. Verstraete, G., E.-H. Aghezzaf, and B. Desmet, *A data-driven framework for predicting weather impact on high-volume low-margin retail products*. Journal of Retailing and Consumer Services, ۲۰۱۹. ۴۸: p. ۱۶۹–۱۷۷.
- [۲۲] ۲۲. Badorf, F. and K. Hoberg, *The impact of daily weather on retail sales: An empirical study in brick-and-mortar stores*. Journal of Retailing and Consumer Services, ۲۰۲۰. ۵۲: p. ۱۰۱۹۲۱.
- [۲۳] ۲۳. Sagaert, Y.R., et al., *Tactical sales forecasting using a very large set of macroeconomic indicators*. European Journal of Operational Research, ۲۰۱۸. ۲۶۴(۲): p. ۵۵۸–۵۶۹.
- [۲۴] ۲۴. Güven, İ. and F. Şimşir, *Demand forecasting with color parameter in retail apparel industry using artificial neural networks (ANN) and support vector machines (SVM) methods*. Computers & Industrial Engineering, ۲۰۲۰. ۱۴۷: p. ۱۰۶۶۷۸.
- [۲۵] ۲۵. Seyam, A., et al. *Machine Learning-Driven Daily Demand Forecasting for Fresh Produce: A Case Study with Bananas*. in *2024 Twelfth International Conference on Advanced Cloud and Big Data (CBD)*. ۲۰۲۴. IEEE.
- [۲۶] ۲۶. Huber, J. and H. Stuckenschmidt, *Daily retail demand forecasting using machine learning with emphasis on calendric special days*. International Journal of Forecasting, ۲۰۲۰. ۳۶(۴): p. ۱۴۲۰–۱۴۳۸.
- [۲۷] ۲۷. Wang, C.-H., *Considering economic indicators and dynamic channel interactions to conduct sales forecasting for retail sectors*. Computers & Industrial Engineering, ۲۰۲۲. ۱۶۵: p. ۱۰۷۹۶۵.
- [۲۸] ۲۸. S, B.S. and M. Suresh. *A Comprehensive Analysis of Retail Sales Forecasting Using Machine Learning and Deep Learning Methods*. in *2023 International Conference on Data Science and Network Security (ICDSNS)*. ۲۰۲۳.
- [۲۹] ۲۹. Punia, S., et al., *Deep learning with long short-term memory networks and random forests for demand forecasting in multi-channel retail*. International Journal of Production Research, ۲۰۲۰. ۵۸(۱۶): p. ۴۹۶۴–۴۹۷۹.



- [۳۰] ۳۰. Ben Hdia, S., Z. Neji Ben Salem, and H. Bouziri. *Hybrid Deep Learning Models for Short-Term Forecasting Item Demands in Retail*. ۲۰۲۰. Cham: Springer Nature Switzerland.
- [۳۱] ۳۱. Bharadwaj, A.A. and M. Gunasekaran, *Forecasting of Product Demand Using Hybrid Regression Model in Comparison with Autoregressive Integrated Moving Average Model*, in *Information Visualization for Intelligent Systems*. ۲۰۲۰. p. ۱۷-۲۸.
- [۳۲] ۳۲. Škrjanc, I., et al., *Evolving fuzzy and neuro-fuzzy approaches in clustering, regression, identification, and classification: A Survey*. Information Sciences, ۲۰۱۹. ۴۹۰: p. ۳۴۴-۳۶۸.
- [۳۳] ۳۳. Leite, D., I. Škrjanc, and F. Gomide, *An overview on evolving systems and learning from stream data*. Evolving Systems, ۲۰۲۰. ۱۱(۲): p. ۱۸۱-۱۹۸.
- [۳۴] ۳۴. K. Kasabov, N., *On-line learning, reasoning, rule extraction and aggregation in locally optimized evolving fuzzy neural networks*. Neurocomputing, ۲۰۰۱. ۴۱(۱): p. ۲۵-۴۵.
- [۳۵] ۳۵. Angelov, P. and R. Buswell, *Identification of evolving fuzzy rule-based models*. IEEE Transactions on Fuzzy Systems, ۲۰۰۲. ۱۰(۵): p. ۶۶۷-۶۷۷.
- [۳۶] ۳۶. Kasabov, N.K. and S. Qun, *DENFIS: dynamic evolving neural-fuzzy inference system and its application for time-series prediction*. IEEE Transactions on Fuzzy Systems, ۲۰۰۲. ۱۰(۲): p. ۱۴۴-۱۵۴.
- [۳۷] ۳۷. Angelov, P.P. and D.P. Filev, *An approach to online identification of Takagi-Sugeno fuzzy models*. IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics), ۲۰۰۴. ۳۴(۱): p. ۴۸۴-۴۹۸.
- [۳۸] ۳۸. Angelov, P. and D. Filev. *Simpl_eTS: a simplified method for learning evolving Takagi-Sugeno fuzzy models*. in *The 14th IEEE International Conference on Fuzzy Systems, 2005. FUZZ '05*. ۲۰۰۵.
- [۳۹] ۳۹. Angelov, P. and X. Zhou. *Evolving Fuzzy Systems from Data Streams in Real-Time*. in *2006 International Symposium on Evolving Fuzzy Systems*. ۲۰۰۶.
- [۴۰] ۴۰. Angelov, P., *Evolving Takagi-Sugeno Fuzzy Systems from Streaming Data (eTS+)*, in *Evolving Intelligent Systems*. ۲۰۱۰. p. ۲۱-۵۰.
- [۴۱] ۴۱. Baruah, R.D. and P. Angelov, *DEC: Dynamically Evolving Clustering and Its Application to Structure Identification of Evolving Fuzzy Models*. IEEE Transactions on Cybernetics, ۲۰۱۴. ۴۴(۹): p. ۱۶۱۹-۱۶۳۱.
- [۴۲] ۴۲. Lughofer, E.D., *FLEXFIS: A Robust Incremental Learning Approach for Evolving Takagi-Sugeno Fuzzy Models*. IEEE Transactions on Fuzzy Systems, ۲۰۰۸. ۱۶(۶): p. ۱۳۹۳-۱۴۱۰.
- [۴۳] ۴۳. Rubio, J.d.J., *SOFMLS: Online Self-Organizing Fuzzy Modified Least-Squares Network*. IEEE Transactions on Fuzzy Systems, ۲۰۰۹. ۱۷(۶): p. ۱۲۹۶-۱۳۰۹.
- [۴۴] ۴۴. Lemos, A., W. Caminhas, and F. Gomide, *Multivariable Gaussian Evolving Fuzzy Modeling System*. IEEE Transactions on Fuzzy Systems, ۲۰۱۱. ۱۹(۱): p. ۹۱-۱۰۴.
- [۴۵] ۴۵. Pratama, M., et al., *PANFIS: A Novel Incremental Learning Machine*. IEEE Transactions on Neural Networks and Learning Systems, ۲۰۱۴. ۲۵(۱): p. ۵۵-۶۸.



- [۴۶] ۴۶.Maciél, L., F. Gomide, and R. Ballini, *Enhanced evolving participatory learning fuzzy modeling: an application for asset returns volatility forecasting*. *Evolving Systems*, ۲۰۱۴. ۵(۲): p. ۷۵–۸۸.
- [۴۷] ۴۷.Maciél, L., R. Ballini, and F. Gomide, *Evolving possibilistic fuzzy modelling*. *Journal of Statistical Computation and Simulation*, ۲۰۱۷. ۸۷(۷): p. ۱۴۴۶–۱۴۶۶.
- [۴۸] ۴۸.Pratama, M., et al., *An Incremental Learning of Concept Drifts Using Evolving Type-2 Recurrent Fuzzy Neural Networks*. *IEEE Transactions on Fuzzy Systems*, ۲۰۱۷. ۲۵(۵): p. ۱۱۷۵–۱۱۹۲.
- [۴۹] ۴۹.Bao, R.J., et al., *Correntropy-Based Evolving Fuzzy Neural System*. *IEEE Transactions on Fuzzy Systems*, ۲۰۱۸. ۲۶(۳): p. ۱۳۲۴–۱۳۳۸.
- [۵۰] ۵۰.Samanta, S., M. Pratama, and S. Sundaram, *A novel Spatio-Temporal Fuzzy Inference System (SPATFIS) and its stability analysis*. *Information Sciences*, ۲۰۱۹. ۵۰۵: p. ۸۴–۹۹.
- [۵۱] ۵۱.Ge, D. and X.-J. Zeng, *Learning data streams online — An evolving fuzzy system approach with self-learning/adaptive thresholds*. *Information Sciences*, ۲۰۲۰. ۵۰۷: p. ۱۷۲–۱۸۴.
- [۵۲] ۵۲.Gu, X., et al., *Multiobjective Evolutionary Optimization for Prototype-Based Fuzzy Classifiers*. *IEEE Transactions on Fuzzy Systems*, ۲۰۲۳. ۳۱(۵): p. ۱۷۰۳–۱۷۱۵.
- [۵۳] ۵۳.Hu, L., et al., *Hierarchical Evolving Fuzzy System: A Method for Multidimensional Chaotic Time Series Online Prediction*. *IEEE Transactions on Fuzzy Systems*, ۲۰۲۴. ۳۲(۶): p. ۳۳۲۹–۳۳۴۱.
- [۵۴] ۵۴.Gu, X., Q. Shen, and P.P. Angelov, *Particle Swarm Optimized Autonomous Learning Fuzzy System*. *IEEE Transactions on Cybernetics*, ۲۰۲۱. ۵۱(۱۱): p. ۵۳۵۲–۵۳۶۳.
- [۵۵] ۵۵.Hu, L., et al., *MIIPSO-EFS: Learning system with self-optimized parameters for chaotic time series online prediction*. *Knowledge-Based Systems*, ۲۰۲۵. ۳۱۰: p. ۱۱۲۸۷۸.
- [۵۶] ۵۶.Ge, D. and X.-J. Zeng, *Learning evolving T–S fuzzy systems with both local and global accuracy – A local online optimization approach*. *Applied Soft Computing*, ۲۰۱۸. ۶۸: p. ۷۹۵–۸۱۰.
- [۵۷] ۵۷.Gu, X. and P. Angelov, *Self-boosting first-order autonomous learning neuro-fuzzy systems*. *Applied Soft Computing*, ۲۰۱۹. ۷۷: p. ۱۱۸–۱۳۴.
- [۵۸] ۵۸.Fernandez, A., et al., *Evolutionary Fuzzy Systems for Explainable Artificial Intelligence: Why, When, What for, and Where to?* *IEEE Computational Intelligence Magazine*, ۲۰۱۹. ۱۴(۱): p. ۶۹–۸۱.
- [۵۹] ۵۹.Gu, X., et al., *Autonomous learning for fuzzy systems: a review*. *Artificial Intelligence Review*, ۲۰۲۳. ۵۶(۸): p. ۷۵۴۹–۷۵۹۵.
- [۶۰] ۶۰.Hong, Y.-S.T. and P.A. White, *Hydrological modeling using a dynamic neuro-fuzzy system with on-line and local learning algorithm*. *Advances in Water Resources*, ۲۰۰۹. ۳۲(۱): p. ۱۱۰–۱۱۹.
- [۶۱] ۶۱.Soltic, S., et al. *Dynamic Neuro-fuzzy Inference and Statistical Models for Risk Analysis of Pest Insect Establishment*. ۲۰۰۴. Berlin, Heidelberg: Springer Berlin Heidelberg.



- [۶۲] ۶۲. Talei, A., et al., *Runoff forecasting using a Takagi–Sugeno neuro-fuzzy model with online learning*. Journal of Hydrology, ۲۰۱۳. ۴۸۸; p. ۱۷–۳۲.
- [۶۳] ۶۳. Ravi, V., E.R. Srinivas, and N.K. Kasabov. *On-Line Evolving Fuzzy Clustering*. in *International Conference on Computational Intelligence and Multimedia Applications (ICCIMA 2007)*. ۲۰۰۷.
- [۶۴] ۶۴. Lughofer, E., *EFS Approaches for Regression and Classification*, in *Evolving Fuzzy Systems – Methodologies, Advanced Concepts and Applications*. ۲۰۱۱, Springer Berlin Heidelberg: Berlin, Heidelberg. p. ۹۳–۱۶۴.
- [۶۵] ۶۵. Angelov, P.P. and X. Zhou, *Evolving Fuzzy-Rule-Based Classifiers From Data Streams*. IEEE Transactions on Fuzzy Systems, ۲۰۰۸. ۱۶(۶): p. ۱۴۶۲–۱۴۷۵.
- [۶۶] ۶۶. Yen, J., W. Liang, and C.W. Gillespie, *Improving the interpretability of TSK fuzzy models by combining global learning and local learning*. IEEE Transactions on Fuzzy Systems, ۱۹۹۸. ۶(۴): p. ۵۳۰–۵۳۷.
- [۶۷] ۶۷. Mackey, M.C. and L. Glass, *Oscillation and Chaos in Physiological Control Systems*. Science, ۱۹۷۷. ۱۹۷(۴۳۰۰): p. ۲۸۷–۲۸۹.
- [۶۸] ۶۸. Alcalá-fdez, J., et al., *KEEL Data-Mining Software Tool: Data Set Repository, Integration of Algorithms and Experimental Analysis Framework*. Journal of Multiple-Valued Logic & Soft Computing, ۲۰۱۱. ۱۷.
- [۶۹] ۶۹. Ge, D. and X.J. Zeng, *A Self-Evolving Fuzzy System Which Learns Dynamic Threshold Parameter by Itself*. IEEE Transactions on Fuzzy Systems, ۲۰۱۹. ۲۷(۸): p. ۱۶۲۵–۱۶۳۷.
- [۷۰] ۷۰. Rong, H.J., Z.X. Yang, and P.K. Wong, *Robust and Noise-Insensitive Recursive Maximum Correntropy-Based Evolving Fuzzy System*. IEEE Transactions on Fuzzy Systems, ۲۰۲۰. ۲۸(۹): p. ۲۲۷۷–۲۲۸۴.
- [۷۱] ۷۱. Angelov, P.P., X. Gu, and J.C. Principe, *Autonomous Learning Multimodel Systems From Data Streams*. IEEE Transactions on Fuzzy Systems, ۲۰۱۸. ۲۶(۴): p. ۲۲۱۳–۲۲۲۴.
- [۷۲] ۷۲. Dovžan, D., V. Logar, and I. Škrjanc, *Implementation of an Evolving Fuzzy Model (eFuMo) in a Monitoring System for a Waste-Water Treatment Process*. IEEE Transactions on Fuzzy Systems, ۲۰۱۵. ۲۳(۵): p. ۱۷۶۱–۱۷۷۶.
- [۷۳] ۷۳. Rong, H.-J., et al., *Extended sequential adaptive fuzzy inference system for classification problems*. Evolving Systems, ۲۰۱۱. ۲(۲): p. ۷۱–۸۲.
- [۷۴] ۷۴. Angelov, P., *Fuzzily Connected Multimodel Systems Evolving Autonomously From Data Streams*. IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics), ۲۰۱۱. ۴۱(۴): p. ۸۹۸–۹۱۰.
- [۷۵] ۷۵. Pratama, M., S.G. Anavatti, and E. Lughofer, *GENEFIS: Toward an Effective Localist Network*. IEEE Transactions on Fuzzy Systems, ۲۰۱۴. ۲۲(۳): p. ۵۴۷–۵۶۲.
- [۷۶] ۷۶. Nguyen, N.N., W.J. Zhou, and C. Quek, *GSETSK: a generic self-evolving TSK fuzzy neural network with a novel Hebbian-based rule reduction approach*. Applied Soft Computing, ۲۰۱۵. ۳۵: p. ۲۹–۴۲.



- [۷۷] ۷۷. Subramanian, K. and S. Suresh, *A meta-cognitive sequential learning algorithm for neuro-fuzzy inference system*. Applied Soft Computing, ۲۰۱۲. ۱۲(۱۱): p. ۳۶۰۳–۳۶۱۴.
- [۷۸] ۷۸. Rong, H.-J., et al., *Sequential Adaptive Fuzzy Inference System (SAFIS) for nonlinear system identification and prediction*. Fuzzy Sets and Systems, ۲۰۰۶. ۱۵۷(۹): p. ۱۲۶۰–۱۲۷۵.
- [۷۹] ۷۹. Kasabov, N., *Evolving fuzzy neural networks for supervised/unsupervised online knowledge-based learning*. IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics), ۲۰۰۱. ۳۱(۶): p. ۹۰۲–۹۱۸.
- [۸۰] ۸۰. Syntetos, A.A., J.E. Boylan, and J.D. Croston, *On the categorization of demand patterns*. Journal of the Operational Research Society, ۲۰۰۵. ۵۶(۵): p. ۴۹۵–۵۰۳.