

تحلیل داده‌محور و پیش‌بینی قیمت لاستیک طبیعی SMR با استفاده از مدل‌های یادگیری ماشین: واکاوی رفتار بازار مالزی و چین بر پایه شاخص‌های بازار و موجودی

اشکان شجاعی^{۱*} و محمدرضا بخارائی^۲

۱- مدیر تحقیق و توسعه شرکت پلی ویسن

۲- مدیر فروش شرکت پلی ویسن

ashkanshojaee48@gmail.com

چکیده: این پژوهش به بررسی پویایی عرضه و تقاضای جهانی لاستیک طبیعی نوع SMR و پیش‌بینی روند قیمتی آن با استفاده از روش‌های هوش مصنوعی و یادگیری ماشین می‌پردازد. داده‌های ماهانه‌ی ۲۰۲۴ تا ۲۰۲۵ شامل تولید، صادرات، موجودی انبار و قیمت SMR در مالزی، به همراه شاخص تولید تایر در چین به‌عنوان نماینده‌ی تقاضای نهایی، مورد استفاده قرار گرفت. پس از مهندسی ویژگی‌ها و استخراج شاخص‌های کلیدی بازار، مانند تغییر موجودی و عرضه‌ی خالص، رابطه‌ی متقابل عرضه‌ی مالزی و تقاضای چین در قالب یک چارچوب تجربی تحلیل شد. سپس سه مدل شامل رگرسیون Ridge، جنگل تصادفی (Random Forest) و XGBoost به‌عنوان الگوریتم‌های هوش مصنوعی برای پیش‌بینی قیمت ماه‌های آینده به کار گرفته شد. نتایج نشان داد که ترکیب شاخص‌های عرضه و موجودی با شاخص‌های تولید صنعتی می‌تواند درک دقیق‌تری از رفتار قیمتی SMR فراهم سازد. چارچوب پیشنهادی می‌تواند به‌عنوان ابزاری کاربردی برای تصمیم‌گیری در خرید، ذخیره‌سازی و سیاست‌گذاری تجاری در زنجیره‌ی تأمین لاستیک طبیعی مورد استفاده قرار گیرد.

واژه‌های کلیدی: لاستیک طبیعی SMR، هوش مصنوعی، یادگیری ماشین، شاخص‌های بازار و موجودی، مدل‌های تصادفی و تقویتی

مقدمه

لاستیک طبیعی، یکی از مواد اولیه در صنعت تایرسازی است و بیش از ۷۰ درصد از مصرف آن به تولید تایر اختصاص دارد [۱]. از میان انواع تجاری، Standard Malaysian Rubber (SMR) به‌دلیل کیفیت یکنواخت، پایداری فیزیکی و حجم تولید، جایگاه ویژه‌ای در تجارت بین‌المللی دارد [۲]. مالزی تولیدکننده این کائوچو است، درحالی‌که چین با تولید بیش از ۹۰۰ میلیون حلقه تایر در سال، بزرگ‌ترین مصرف‌کننده‌ی این ماده محسوب می‌شود [۳]. نوسانات قیمتی SMR مستقیم بر زنجیره‌ی تأمین تایر، هزینه‌ی مواد اولیه و بهای تمام‌شده‌ی محصول تأثیرگذار است [۴]. از این‌رو، تحلیل رفتار بازار و پیش‌بینی قیمت SMR برای برنامه‌ریزی صنایع لاستیک و تایر اهمیت راهبردی دارد. در دهه‌ی اخیر، مطالعات متعددی به بررسی اثرات عرضه، صادرات و موجودی انبار بر نوسانات قیمت پرداخته‌اند [۵ و ۶]، اما بیشتر آن‌ها مبتنی بر روش‌های کلاسیک آماری بوده‌اند. پیشرفت‌های اخیر در هوش مصنوعی و یادگیری ماشین امکان شناسایی روابط پیچیده میان متغیرهای اقتصادی را فراهم کرده است [۷]. این رویکردها در بازارهای کالایی نظیر نفت و مس، برای پیش‌بینی قیمت و تحلیل رفتار بازار نتایجی داشته‌اند [۸ و ۹]. با این حال، در مورد بازار SMR، پژوهش‌های داده‌محور محدود بوده و تنها بر قیمت یا تولید تمرکز داشته‌اند و نه بر ترکیب شاخص‌های عرضه، تقاضا و موجودی. در این پژوهش، با بهره‌گیری از داده‌های ماهانه‌ی ۲۰۲۴ تا ۲۰۲۵، تلاش شده است تا یک چارچوب تحلیلی و پیش‌بینی توسعه یابد که در آن عرضه‌ی مالزی و شاخص تقاضای چین یکپارچه مدل‌سازی شوند. به کارگیری سه الگوریتم هوش مصنوعی، روابط میان متغیرهای کلیدی بازار و روند آتی قیمت SMR پیش‌بینی شده است.

بخش تجربی


داده‌های مورد استفاده در این پژوهش شامل مجموعه‌ای از آمار ماهانه‌ی سال‌های ۲۰۲۴ تا ۲۰۲۵ است که از منابع رسمی گردآوری شده‌اند. اطلاعات مربوط به تولید، صادرات و موجودی انبار لاستیک طبیعی نوع SMR از پایگاه آماری مالزی و انجمن لاستیک مالزی استخراج شد. داده‌های مربوط به قیمت SMR از

گزارش‌های ماهانه‌ی بورس لاستیک مالزی دریافت شد. همچنین شاخص تولید تایر چین به‌عنوان نماینده‌ی تقاضای نهایی از پایگاه اداره ملی آمار چین دریافت شد [۱ تا ۳]. مجموع داده‌ها پس از پاک‌سازی شامل ۲۰ ماه متوالی بوده و برای همراه، متغیرهای تولید، صادرات، موجودی انبار، قیمت و شاخص تولید تایر چین مورد استفاده قرار گرفت. در مرحله‌ی پیش‌پردازش، برای استخراج الگوهای زمانی و رفتاری بازار، متغیرهای Δ Stocks (تغییر موجودی انبار)، Net Supply (عرضه‌ی خالص)، Lag Variables (Lag1)، Moving Averages (MA3) و Surplus Index ایجاد شد. مقادیر قیمتی با روش نرمال‌سازی خطی تبدیل شدند. داده‌ها در قالب یک سری زمانی پیوسته تنظیم شدند [۹].

سه مدل هوش مصنوعی رگرسیون Ridge، جنگل تصادفی (Random Forest) و XGBoost برای پیش‌بینی قیمت ماه‌های آینده SMR مورد استفاده قرار گرفتند. مدل‌ها در یک چارچوب اعتبارسنجی زمانی آموزش و آزمون شدند تا از نشت داده جلوگیری شود. برای ارزیابی عملکرد، شاخص‌های میانگین قدر مطلق خطا (MAE)، ریشه میانگین مربعات خطا (RMSE) به کار گرفته شدند [۵ تا ۸]. کلیدی تحلیل‌ها در محیط Python 3.12 و با استفاده از کتابخانه‌های Pandas، Scikit-learn و Matplotlib انجام گرفت. در مرحله‌ی تحلیل تصویری، رفتار قیمتی SMR، تغییر موجودی و ارتباط بین عرضه و تقاضا با استفاده از نمودارهای مقایسه‌ای بررسی شد. داده‌های مورد استفاده به دو بخش شامل ۱۵ ماه برای آموزش و ۵ ماه برای آزمون نهایی تقسیم شدند. به منظور ارزیابی پایداری مدل‌ها در داده‌های متوالی، از روش اعتبارسنجی سری زمانی؛ تقسیم‌بندی متوالی داده‌ها براساس ترتیب زمانی استفاده شد. دو شاخص میانگین قدر مطلق خطا، ریشه میانگین مربعات خطا برای سنجش دقت پیش‌بینی‌ها محاسبه شد.


نتیجه‌ها و بحث

براساس داده‌های ماهانه‌ی سال‌های ۲۰۲۴ تا ۲۰۲۵، بررسی عرضه، تقاضا و موجودی انبار SMR در مالزی و چین نشان داد که بازار دارای چرخه‌های تکرار شونده‌ی کمبود و مازاد عرضه است. کاهش تولید یا موجودی انبار معمولاً با افزایش قیمت هم‌زمان بوده است.




شکل ۱- مقایسه روند قیمت نرمال شده SMR با شاخص‌های عرضه و تقاضا: سمت چپ رابطه قیمت و تولید مالزی و سمت راست رابطه قیمت و تولید تایر چین براساس میانگین متحرک سه‌ماهه

همان‌طور که در شکل ۴ مشاهده می‌شود، شاخص مازاد/کمبود نوسانات چرخه‌ای و متناوبی را نشان می‌دهد. به‌طور کلی، شاخص مازاد/کمبود نشان می‌دهد که بازار SMR مالزی در بازه‌ی مورد بررسی بین فازهای کمبود و مازاد به‌صورت تناوبی در نوسان بوده و هیچ تعادل پایداری در عرضه برقرار نشده است.



شکل ۴- شاخص مازاد و کمبود SMR در مالزی (Surplus/Shortage Index)


همان‌طور که در شکل ۵ مشاهده می‌شود، نقشه‌ی همبستگی میان متغیرهای اصلی بازار SMR نشان می‌دهد که بیشترین همبستگی مثبت بین قیمت SMR و تولید تایر چین وجود دارد؛ به‌عبارتی، افزایش فعالیت صنعتی چین هم‌زمان با رشد قیمت SMR است. در مقابل، بیشترین همبستگی منفی میان موجودی انبار و قیمت SMR مشاهده می‌شود که بیانگر تأثیر مستقیم افزایش موجودی بر کاهش قیمت است.



شکل ۵- نقشه همبستگی بین متغیرهای کلیدی بازار SMR


در این پژوهش سه مدل یادگیری ماشین شامل Ridge، Random Forest و XGBoost برای پیش‌بینی ماهانه‌ی قیمت SMR مورد استفاده قرار گرفتند. هدف از این تحلیل، ارزیابی توان هر مدل در شناسایی الگوهای غیرخطی میان شاخص‌های اقتصادی و قیمت بود.

همان‌طور که در شکل ۱ سمت چپ مشاهده می‌شود، بین عرضه خالص مالزی و قیمت SMR رابطه‌ای معکوس ولی با تأخیر زمانی مشاهده می‌شود. این الگو نشان‌دهنده‌ی واکنش کند بازار جهانی نسبت به تغییرات عرضه‌ی واقعی است. در شکل ۱ سمت راست این مورد قابل ملاحظه است که افزایش تولید تایر چین با روند صعودی قیمت SMR هم‌زمان بوده و بیانگر رابطه‌ی مثبت میان تقاضای صنعتی و قیمت است. با این حال، در برخی دوره‌ها، تأخیر زمانی یک تا دو ماهه در واکنش قیمت نسبت به تغییرات تولید مشاهده می‌شود، که نشان‌دهنده‌ی اثر متقابل عرضه و رفتار ذخایر انبار در تنظیم نهایی قیمت بازار جهانی SMR است. روند شکل ۲ نشان می‌دهد که کاهش عرضه خالص مالزی معمولاً با افزایش تدریجی تولید تایر چین هم‌زمان شده است. با این حال، هم‌پوشانی کامل میان دو روند وجود ندارد و واکنش‌ها با تأخیر زمانی چندماهه بروز می‌کنند. به‌طور کلی، نمودار حاکی از آن است که عدم تعادل نسبی میان عرضه و تقاضا در مقاطع مختلف، یکی از عوامل نوسانات قیمت جهانی SMR بوده است.



شکل ۲- تراز جهانی SMR براساس عرضه خالص مالزی و تولید تایر چین

شکل ۳ میانگین متحرک سه‌ماهه نشان می‌دهد هر جا مصرف داخلی + صادرات از تولید پیشی گرفته، میله‌های $\Delta Stocks$ عمدتاً منفی شده‌اند (تخلیه‌ی موجودی)؛ برعکس، زمانی که تولید بالاتر بوده، $\Delta Stocks$ مثبت و نشانگر انباشت موجودی است. تغییر علامت $\Delta Stocks$ نقطه‌ی گذار بین کمبود کوتاه‌مدت و بازسازی ذخایر را مشخص می‌کند، بدون آن که روندی فراتر از این چرخه‌های فصلی ادعا شود.




شکل ۳- تولید، صادرات و تغییرات موجودی انبار در مالزی

قیمت را به‌خوبی شناسایی می‌کند.

نتایج مدل XGBoost (شکل ۸) نشان می‌دهد که با وجود نوسانات شدید داده‌های واقعی، روند کلی قیمت SMR به‌ویژه در افق کوتاه‌مدت ($t+1$) با دقت مناسبی بازتولید می‌شود. (MAE برابر با ۰٫۲۴۱، RMSE برابر با ۰٫۲۷۹) با افزایش افق پیش‌بینی، دقت اندکی کاهش‌یافته اما همچنان قابل‌قبول است و مدل در $t+3$ تغییرات جهت‌دار بازار را بهتر تشخیص می‌دهد، هرچند دامنه نوسان را کمتر برآورد می‌کند. این رفتار بیانگر واکنش تأخیری حدود یک تا دو ماهه بازار SMR نسبت به تغییرات عرضه و موجودی است و نشان می‌دهد XGBoost در ترکیب


با متغیرهای تأخیری می‌تواند ساختار زمانی بازار را به‌خوبی مدل‌سازی کند. یافته‌های این پژوهش نشان می‌دهد که نوسانات قیمت جهانی SMR عمدتاً از تغییرات عرضه مالزی و سطح موجودی انبار تأثیر می‌پذیرد و تولید تایر چین نقش اصلی را در سمت تقاضا ایفا می‌کند. تحلیل سری‌های زمانی ۲۰۲۴ تا ۲۰۲۵ بیانگر تأخیر یک تا دو ماهه در واکنش قیمت به شوک‌های عرضه و تقاضاست؛ به‌ویژه زمانی که کاهش موجودی با رشد تولید تایر چین هم‌زمان شود، احتمال جهش قیمتی افزایش می‌یابد. مدل‌های یادگیری ماشین، به‌ویژه XGBoost، توانستند جهت تغییرات بازار و اهمیت شاخص‌هایی مانند «صادرات ماه قبل» و «موجودی انبار» را با دقت مناسبی استخراج کنند. این چارچوب، مبنایی کاربردی برای تصمیم‌گیری در زنجیره تأمین تایر فراهم می‌سازد؛ ازجمله زمان‌بندی بهینه خرید، تنظیم سطح ذخایر و پایش شاخص‌های بازار جهت پیش‌بینی دوره‌های کمبود یا مازاد عرضه. در سطح کلان نیز می‌تواند به توسعه سامانه‌های هشدار زودهنگام و مدل‌های پیش‌بینی پیشرفته در تجارت مواد اولیه صنعت تایر منجر شود.

نتایج مدل Ridge Regression (شکل ۶) نشان می‌دهد که این مدل تنها روندهای آرام قیمت SMR را بازتولید می‌کند و در دوره‌های نوسان شدید دقت پایینی دارد. (MAE برابر با ۰٫۲۱۴، RMSE برابر با ۰٫۸۲۱) بنابراین، رویکرد خطی Ridge برای شناسایی رفتارهای غیرخطی و جهش‌های قیمتی بازار SMR کارایی محدودی دارد.




شکل ۶- نتایج مدل Ridge در پیش‌بینی قیمت SMR

نتایج مدل Random Forest (شکل ۷) نشان می‌دهد که متغیرهای «صادرات قبل»، «صادرات جاری» و «میانگین متحرک تولید تایر چین» بیشترین اثر را بر پیش‌بینی قیمت SMR دارند؛ به‌عبارت‌دیگر، تغییرات کوتاه‌مدت صادرات و روند تقاضای صنعتی چین محرک‌های اصلی نوسانات قیمت‌اند. این مدل با MAE برابر با ۰٫۲۲۴ و RMSE برابر با ۰٫۲۷۴ عملکرد بهتری نسبت به Ridge داشته و اگرچه نوسانات شدید را کاملاً بازتولید نمی‌کند، جهت حرکت بازار و روند کلی



شکل ۷- تحلیل مدل Random Forest: اهمیت ویژگی‌ها و عملکرد پیش‌بینی



شکل ۸- پیش‌بینی قیمت SMR با مدل XGBoost برای افق $t+1$ ، $t+2$ و $t+3$

مراجع

- [1] DOSM, Monthly Rubber Statistics of Malaysia, 2025.
- [2] Malaysian Rubber Board (MRB), SMR Production and Export Data, 2024.
- [3] MRE, Monthly SMR Price Bulletins, Kuala Lumpur, 2024.
- [4] CNBS, Monthly Tire Production Reports, Beijing, 2024.
- [5] Breiman, L. (2001). Random Forests. Machine Learning Journal.
- [6] Chen, T., & Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. KDD Conference.
- [7] Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning. MIT Press.
- [8] Nair, V., et al. (2024). Machine Learning Approaches for Commodity Price Forecasting. Applied Artificial Intelligence Journal.
- [9] Hyndman, R. J., & Athanasopoulos, G. (2021). Forecasting: Principles and Practice, OTexts.