



پژوهش‌های نوین در تصمیم‌گیری

دوره ۱۰، شماره ۵، زمستان ۱۴۰۴، صص ۱۲۸-۱۲۷

نوع مقاله: پژوهشی

ارائه مدل پیش‌بینی انتشار کربن با در نظر گرفتن نقش تأمین‌کنندگان در مدیریت زنجیره تأمین با استفاده از الگوریتم تقویت گرادیان سبک (مطالعه موردی صنایع شیمیایی تهران (خاوران))

هادی ابراهیمی^۱، مریم شعار^{۲*}، علی حاجیها^۳، مهزاد اسمعیلی فلک^۴

۱. دانشجوی دکتری، گروه مدیریت صنعتی، واحد تهران شمال، دانشگاه آزاد اسلامی، تهران، ایران

۲. استادیار، گروه مدیریت صنعتی، واحد تهران شمال، دانشگاه آزاد اسلامی، تهران، ایران

۳. استادیار، گروه مدیریت صنعتی، واحد تهران شمال، دانشگاه آزاد اسلامی، تهران، ایران

۴. دانشیار، گروه مهندسی عمران، واحد تهران شمال، دانشگاه آزاد اسلامی، تهران، ایران

تاریخ پذیرش: ۱۴۰۴/۱۰/۰۵

تاریخ دریافت: ۱۴۰۴/۰۷/۱۱

چکیده

هدف از این مقاله، ارائه مدل پیش‌بینی انتشار کربن با در نظر گرفتن نقش تأمین‌کنندگان می‌باشد که می‌تواند نقش بسزایی در کاهش دی‌اکسید کربن منطقه داشته باشد. برای تعیین متغیرهای تأثیرگذار از ادبیات تحقیق و نظرات خبرگان (۲۰ نفر) با روش دلفی فازی استفاده شد که در نهایت ۸ متغیر تأثیرگذار انتخاب شدند. برای مدل‌سازی، الگوریتم تقویت گرادیان سبک (LGB) به دلیل توانایی در ثبت وابستگی‌های غیرخطی و بهینه‌ساز جستجوی عروس دریایی (JSO) برای تنظیم دقیق ابرپارامترها انتخاب شدند. نوآوری پژوهش در زمینه تلفیق LGB و JSO برای افزایش دقت پیش‌بینی، و همچنین، در نظر گرفتن هم‌زمان نقش تأمین‌کنندگان به عنوان متغیرهای تأثیرگذار در پیش‌بینی انتشار کربن می‌باشد. مدل‌ها با ۵۹۹۷ داده از صنایع شیمیایی تهران (خاوران) (۲۰۲۵-۲۰۲۲) در پایتون اجرا شدند. نتایج نشان داد LGB_JS0 با R^2 برابر ۰/۹۹۱۸، ۰/۹۵۳۸ و ۰/۹۶۰۶ در مراحل آموزش، اعتبارسنجی و آزمایش، عملکرد بهتری نسبت به سایر مدل‌ها دارد. دما، فشار و زمان ذخیره‌سازی مهم‌ترین پارامترهای مؤثر شناسایی شدند.

کلیدواژه‌ها: الگوریتم تقویت گرادیان سبک، انتشار کربن، پیش‌بینی، تأمین‌کنندگان، مدیریت زنجیره تأمین.



۱- مقدمه و بیان مسئله

آلودگی یکی از چالش‌های قرن حاضر است و کشورها در تلاشند تا از طریق معاهدات بین‌المللی آن را کاهش دهند. طبق برآوردهای بانک جهانی، ارزیابی خسارات زیست‌محیطی در ایران، همان‌طور که در گزارش سالانه هزینه تخریب محیط‌زیست گزارش شده است، تقریباً ۵ تا ۱۰ درصد از تولید ناخالص داخلی^۱ را تشکیل می‌دهد. براساس گزارش بانک جهانی، ایران جزء کشورهایی با انتشار بالای دی‌اکسیدکربن^۲ است؛ بنابراین، تحقیق در زمینه انتشار آلودگی اهمیت پیدا می‌کند [۱]. اولین گام در جهت دستیابی به اهداف توسعه صنعتی سالم و پایدار، شناسایی پیامدهای مختلف فعالیت‌های صنعتی است که یکی از آن‌ها آلودگی هوا است. اگرچه اشکال مختلف آلودگی زیست‌محیطی به هم پیوسته هستند و می‌توانند به یکدیگر تبدیل شوند، اما آنچه آلودگی هوا را مهم‌تر می‌کند، نقش هوا به عنوان حیاتی‌ترین عنصر برای بقای انسان، اثرات متنوع و اغلب برگشت‌ناپذیر آلاینده‌ها بر سلامت انسان و توانایی محدود انسان در کاهش و کنترل آلودگی هوا است. انتشار گازهای گلخانه‌ای که منجر به گرمایش جهانی، تغییرات دما، اختلال در اکوسیستم و تغییرات آب‌وهوایی در کشورها می‌شود، یکی از نگرانی‌های کلیدی بین‌المللی است. دی‌اکسیدکربن^۲ گاز گلخانه‌ای اصلی است و از احتراق سوخت‌های فسیلی مانند زغال سنگ و نفت تولید می‌شود [۲]. تمرکز این پژوهش بر صنایع شیمیایی تهران (خوران) از چند جنبه حائز اهمیت است: در ابتدا می‌توان گفت که، صنایع شیمیایی به دلیل ماهیت فرآیندهای تولیدی خود، جزء پرمصرف‌ترین صنایع از نظر انرژی بوده و سهم قابل توجهی در انتشار گازهای گلخانه‌ای دارند. همچنین، تنوع بالای مواد اولیه و محصولات در این صنعت، پیچیدگی زنجیره تأمین را افزایش داده و نقش تأمین‌کنندگان را در انتشار کربن پررنگ‌تر می‌سازد. در ادامه نیز می‌توان بیان کرد که، تمرکز جغرافیایی صنایع شیمیایی در کلان‌شهر تهران، این منطقه را به یکی از کانون‌های بحرانی آلودگی هوا تبدیل کرده است که مستقیماً بر سلامت میلیون‌ها شهروند تأثیر می‌گذارد. و در انتها، صنایع شیمیایی به دلیل استفاده از فرآیندهای فشار و دمای بالا، پتانسیل بالایی برای کاهش انتشار کربن از طریق بهینه‌سازی پارامترهای عملیاتی دارند. بنابراین، پیش‌بینی دقیق انتشار کربن در این صنایع با در نظر گرفتن نقش تأمین‌کنندگان،

^۱. Gross Domestic Product (GDP).

^۲. Carbon Dioxide (CO₂).

^۳. Carbon Dioxide Emissions (CE).



گامی اساسی در جهت مدیریت زیست‌محیطی پایدار منطقه محسوب می‌شود. افزایش انتشار کربن در یک کشور می‌تواند منجر به نشت دی‌اکسیدکربن شود که به طور بالقوه به افزایش سطح دی‌اکسیدکربن در کشور دیگر کمک می‌کند. استراتژی‌های مختلفی برای کاهش انتشار کربن پیشنهاد شده است. یکی از مهم‌ترین وظایف در زمینه توسعه پایدار، جداسازی رشد اقتصادی از اثرات زیست‌محیطی است (دستیابی به حداقل مصرف انرژی با کمترین هزینه و با کمترین اثرات مضر بر محیط زیست). برای دستیابی به این هدف، اصول توسعه پایدار که پیشرفت اقتصادی و اجتماعی را تقویت می‌کنند، باید محقق شوند. افزایش استفاده از سوخت‌های فسیلی به عنوان پیامد صنعتی شدن را می‌توان به عنوان یکی از علل گرمایش جهانی ذکر کرد. افزایش آگاهی بین‌المللی از پیامدهای بلندمدت گرمایش جهانی منجر به همکاری بین‌المللی در کاهش انتشار گازهای گلخانه‌ای شده است. در این راستا، اندازه‌گیری دقیق میزان انتشار گازهای گلخانه‌ای توسط کشورها از اهمیت حیاتی برخوردار است [۳]. طبق گزارش پروژه افشای کربن^۱، بیش از نیمی از شرکت‌کنندگان اظهار داشتند که اگر تأمین‌کنندگان انتشار کربن خود را مدیریت نکنند، معاملات تجاری خود را با آن‌ها کاهش خواهند داد. با افزایش آگاهی از تغییرات اقلیمی، شرکت‌ها فشار فزاینده‌ای را بر تأمین‌کنندگان خود برای مدیریت انتشار گازهای گلخانه‌ای خود اعمال می‌کنند و آن را به عنوان شرط کلیدی برای ادامه روابط تجاری در نظر می‌گیرند. در نتیجه، تمایل تأمین‌کنندگان برای به حداقل رساندن انتشار گازهای گلخانه‌ای به یکی از معیارهای اصلی انتخاب تأمین‌کننده تبدیل می‌شود. بنابراین، تأمین‌کنندگان باید ارزیابی جامعی از قابلیت‌های موجود خود در مدیریت دی‌اکسیدکربن انجام دهند و اهداف واضح و قابل اندازه‌گیری را برای کاهش بیشتر انتشار گازهای گلخانه‌ای تعیین کنند تا در محیط کسب‌وکار جهانی و رقابتی باقی بمانند [۴]. با وجود مطالعات متعدد در زمینه پیش‌بینی انتشار کربن و همچنین تحقیقات گسترده در حوزه انتخاب تأمین‌کننده، شکاف قابل توجهی در ادبیات پژوهش وجود دارد: کمتر مطالعه‌ای به صورت هم‌زمان به تأثیر ویژگی‌های تأمین‌کنندگان بر انتشار کربن در زنجیره تأمین پرداخته است. به عبارت دیگر، مدل‌های موجود عمدتاً انتشار کربن را بر اساس متغیرهای عملیاتی و محیطی پیش‌بینی می‌کنند، بدون آنکه نقش تأمین‌کنندگان را به عنوان یکی از ارکان اصلی زنجیره تأمین

^۱ Carbon Disclosure Project (CDP).



در نظر بگیرند. علاوه بر این، تلفیق الگوریتم‌های پیشرفته یادگیری ماشین مانند تقویت گرادیان سبک با بهینه‌سازهای فراابتکاری نظیر جستجوی عروس دریایی برای افزایش دقت پیش‌بینی در این حوزه کمتر مورد توجه قرار گرفته است. پژوهش حاضر در صدد پر کردن این شکاف دوگانه (مفهومی و روش‌شناختی) با ارائه مدلی جامع برای پیش‌بینی انتشار کربن با در نظر گرفتن نقش تأمین‌کنندگان در صنایع شیمیایی تهران (خاوران) است. بنابراین، نوآوری اصلی این پژوهش در تلفیق سه حوزه است: حوزه محتوایی (نقش تأمین‌کنندگان در انتشار کربن)، حوزه روش‌شناختی (ترکیب LGB و JSO)، و حوزه کاربردی (قابلیت پیاده‌سازی در صنعت). این تلفیق سه‌گانه، وجه تمایز اصلی پژوهش حاضر از مطالعات پیشین است و آن را در زمره پژوهش‌های میان‌رشته‌ای با قابلیت کاربرد عملی قرار می‌دهد.

۲- مبانی نظری و پیشینه پژوهش

مرور پیشینه مطالعات، نقش کلیدی در درک مفاهیم نظری، تبیین جایگاه پژوهش حاضر، کشف خلأهای موجود و ترسیم مسیر میان‌رشته‌ای مدل دارد. بر این اساس و متناسب با هدف پژوهش، این مطالعه به کاربرد موفقیت‌آمیز یادگیری ماشین در زمینه انتشار کربن پرداخته است. موضوع انتشار کربن توجه گسترده‌ای در میان پژوهشگران داخلی و خارجی به خود جلب کرده است. در این بخش، ابتدا مهم‌ترین و مرتبط‌ترین مطالعات مرور، سپس با رویکردی انتقادی تحلیل می‌شود و در نهایت جایگاه پژوهش حاضر تبیین می‌گردد.

۲-۱- مرور انتقادی پیشینه پژوهش در ایران

مطالعات داخلی در حوزه انتشار کربن عمدتاً بر دو محور پیش‌بینی روند انتشار کربن در سطح ملی و ارائه مدل‌های بهینه‌سازی برای کاهش کربن متمرکز بوده است. باقری و انصاری سامانی (۱۴۰۰) با استفاده از روش $ARFIMA^1$ به پیش‌بینی انتشار کربن در ایران پرداختند و پیش‌بینی کردند انتشار کربن تا سال ۲۰۳۵ به ۷۴۵,۸۷۶ هزار تن برسد، اما محدودیت اصلی آن عدم تفکیک بخش‌های صنعتی و عدم توجه به نقش زنجیره تأمین است [۵]. زارع احمدآبادی و همکاران (۱۴۰۳) مدل ریاضی مبتنی بر تلفیق تحلیل پوششی داده‌های شبکه‌ای و تئوری بازی‌ها را برای حداقل‌سازی کربن ارائه دادند، اما ضعف اصلی آن عدم استفاده از داده‌های

¹ Autoregressive Fractionally Integrated Moving Average (ARFIMA).



واقعی میدانی و اتکا صرف بر داده‌های فرضی است [6]. همچنین شیخ‌تاجیان و همکاران (۱۴۰۴) جذب و بازیابی کربن را با استفاده از تلفیق بهینه‌سازی تعاملی و تئوری راف مبتنی بر تسلط انجام دادند که اگرچه از نظر روش‌شناسی ارزشمند است، اما فاقد جنبه پیش‌بینی بوده و بیشتر بر بهینه‌سازی فناوری‌های جذب کربن متمرکز است [7]. مرور مطالعات داخلی نشان می‌دهد که نخست، تمرکز اصلی بر پیش‌بینی در سطح کلان (کشور) بوده و به صنایع خاص و ویژگی‌های آن‌ها توجه نشده است. دوم، نقش تأمین‌کنندگان و زنجیره تأمین در انتشار کربن در نظر گرفته نشده است. سوم، روش‌های به‌کار گرفته شده عمدتاً کلاسیک (ARFIMA) یا بهینه‌سازی ریاضی هستند و از ظرفیت الگوریتم‌های پیشرفته یادگیری ماشین استفاده نشده است.

۲-۲- مرور انتقادی پیشینه پژوهش در خارج از کشور

مطالعات بین‌المللی در پیش‌بینی انتشار کربن از منظر روش‌شناسی به سه نسل تقسیم می‌شوند. نسل اول: مدل‌های آماری کلاسیک: مطالعات اولیه عمدتاً از مدل‌های رگرسیونی و سری زمانی استفاده می‌کردند. برای مثال، زو و چن (۲۰۲۳) با استفاده از استراتژی تجزیه چندگانه، مصرف انرژی و انتشار کربن در چین را پیش‌بینی کردند [8]. رن و همکاران (۲۰۲۳) نیز با استفاده از هویت کایا و شبیه‌سازی چند سناریویی، اوج انتشار کربن در منطقه شهری پکن-تیانجین-هبی^۱ را پیش‌بینی و ارزیابی نمودند [9]. نقاط قوت این مطالعات، سادگی و تفسیرپذیری بالای آن‌هاست، اما ضعف اصلی آن‌ها ناتوانی در مدل‌سازی روابط غیرخطی و پیچیده است. نسل دوم: الگوریتم‌های یادگیری ماشین منفرد: با پیشرفت محاسباتی، مطالعات به سمت استفاده از الگوریتم‌های یادگیری ماشین گرایش یافتند. در مطالعه‌ای انتشار کربن با استفاده از یادگیری انتقال فازی شهودی^۲ پیش‌بینی شد. طبق منابع موجود، بین تولید ناخالص داخلی و انتشار کربن همبستگی وجود داشت که می‌توان از آن برای تخمین دقیق‌تر تولید ناخالص داخلی به طور بهینه استفاده کرد. با این حال، کمبود داده‌ها یک تنگنای بزرگ ایجاد کرد [۱۰]. بات و همکاران (۲۰۲۳) با استفاده از تکنیک‌های یادگیری ماشین به پیش‌بینی و کاهش انتشار کربن زیست‌محیطی جهانی پرداختند و نتیجه گرفتند که سطح بحرانی دی‌اکسید کربن تا سال

^۱. Beijing-Tianjin-Hebei (BTH).

^۲. Intuitionistic Fuzzy Transfer Learning (IFTL).



۲۰۴۷ به ۵۰۰ قسمت در یک میلیون خواهد رسید [۱۱]. ناتاراجان و همکاران (۲۰۲۳) انتشار کربن وسایل نقلیه سبک را با الگوریتم‌های مختلف یادگیری ماشین پیش‌بینی کردند و نشان دادند که مدل تقویت حتی با یک ویژگی ورودی نیز عملکرد قابل قبولی دارد [۱۲]. اگرچه این مطالعات دقت بالاتری نسبت به مدل‌های کلاسیک داشتند، اما محدودیت آن‌ها عدم بهینه‌سازی سیستماتیک ابرپارامترها و حساسیت به تنظیمات اولیه است.

نسل سوم: مدل‌های ترکیبی و فراابتکاری: جدیدترین مطالعات به سمت تلفیق الگوریتم‌های یادگیری ماشین با بهینه‌سازهای فراابتکاری حرکت کرده‌اند. همچنین مصرف انرژی و انتشار کربن ایالات متحده با استفاده از یک مدل رگرسیون به طور جامع پیش‌بینی شد. منابع اصلی مصرف انرژی و انتشار کربن، روندها و تمایلات این منابع، محرک‌ها و الگوهای انتشار گازهای گلخانه‌ای، توسعه کم کربن و ردپای کربن، و ابتکارات ایالات متحده برای کاهش انتشار گازهای گلخانه‌ای و چالش‌ها مورد بررسی قرار گرفت. این مطالعه، انتشار گازهای گلخانه‌ای مرتبط با سوخت‌های فسیلی را از سال ۲۰۲۵ تا ۲۰۵۰ پیش‌بینی کرد و نتایج را با استفاده از میانگین درصد خطای مطلق برای دقت مقایسه کرد [۱۳]. چین و همکاران (۲۰۲۳) با ترکیب الگوریتم شکارچیان دریایی بهبودیافته و رگرسیون بردار پشتیبان چند هسته‌ای، مدلی برای پیش‌بینی انتشار کربن چین ارائه دادند [۱۴]. یون و همکاران (۲۰۲۲) نیز قیمت انتشار کربن را با مدل هیبریدی NAGARCHSK و شبکه GRU پیش‌بینی کردند [۱۵]. در مطالعه‌ای که توسط گو و همکاران^۱ (۲۰۲۱) انجام شد، هدف آن پیش‌بینی انتشار کربن در کشورهای بریکس (برزیل، روسیه، هند، چین و آفریقای جنوبی) با استفاده از یک مدل خاکستری انباشته‌نمایی بود. این مقاله یک مدل خاکستری جدید را پیشنهاد می‌کند که یک پارامتر نمایی را برای تنظیم وزن داده‌ها با تنظیم اندازه پارامتر معرفی می‌کند. این مدل برای مطالعه انتشار کربن در کشورهای بریکس به کار گرفته شد [۱۶]. همچنین مطالعه‌ای توسط نامبوری و اقبال^۲ در سال ۲۰۲۰ انجام گرفت که هدف آن پیش‌بینی انتشار کربن در ایالات متحده با استفاده از یادگیری ماشین بود. داده‌های ماهانه انتشار کربن از اداره اطلاعات انرژی ایالات متحده^۳ تهیه شد. تجزیه و تحلیل داده‌های پیش‌پردازش‌شده، سه بخش اصلی مسئول انتشار کربن قابل توجه را شناسایی کرد:

^۱. Guo et al.
^۲. Namboori & Iqbal

^۳. U.S. Energy Information Administration
(EIA).



تولید برق مبتنی بر زغال‌سنگ، تولید برق مبتنی گاز طبیعی و کل مصرف انرژی الکتریکی. پیش‌بینی انتشار کربن از این سه بخش با استفاده از مدل‌های میانگین متحرک خودرگرسیون یکپارچه، ماشین بردار پشتیبانی، ماشین بردار پشتیبان با بهینه‌سازی ازدحام ذرات و Prophet انجام شد [۱۷]. در پژوهشی دیگر انتشار کربن کشورهای آسیایی با استفاده از مدل‌های میانگین متحرک خودرگرسیون یکپارچه و هموارسازی نمایی ساده پیش‌بینی شد. داده‌های انتشار کربن از تولید گرما و برق، صنایع تولیدی، ساختمان‌های مسکونی و تجاری، حمل‌ونقل و سایر منابع برای کشورهای آسیایی از جمله ژاپن، بنگلادش، چین، پاکستان، هند، سریلانکا، ایران، سنگاپور و نیپال از سال ۱۹۷۱ تا ۲۰۱۴ برای این تحقیق جمع‌آوری شد [۱۸]. در مطالعه‌ای که توسط پروتسان^۱ (۲۰۱۷) انجام شد، هدف تخمین انتشار کربن ناشی از مصرف انرژی در بخش‌های صنعتی تایلند بود. برای این مطالعه، جداول ورودی-خروجی از سال‌های ۲۰۰۰ تا ۲۰۱۵ در تایلند برای تخمین انتشار کربن، رشد جمعیت و رشد تولید ناخالص داخلی استفاده شد [۱۹]. این مطالعات گام مهمی به جلو هستند، اما همچنان دو خلأ اساسی دارند: نخست، تمرکز صرف بر بهینه‌سازی روش‌شناختی بدون توجه به متغیرهای زمینه‌ای مانند نقش تأمین‌کنندگان؛ دوم، عدم بررسی کاربرد عملی مدل‌ها در تصمیم‌گیری‌های زنجیره تأمین. علاوه بر مطالعات فوق، پژوهش‌هایی نیز مستقیماً به ارتباط تأمین‌کنندگان و انتشار کربن پرداخته‌اند. شاو و همکاران^۲ (۲۰۱۲) با استفاده از AHP فازی و برنامه‌ریزی خطی چندهدفه، مدلی برای انتخاب تأمین‌کننده در زنجیره تأمین کم‌کربن توسعه دادند [۴]. صالحی (۲۰۲۲) نیز معیارهای مؤثر در انتخاب تأمین‌کنندگان را با رویکرد کاهش کربن بررسی کرده است [۲۰]. این مطالعات از نظر مفهومی ارزشمندند، اما فاقد جنبه پیش‌بینی بوده و بیشتر به انتخاب تأمین‌کننده می‌پردازند تا پیش‌بینی میزان انتشار.

۲-۳- شکاف‌های پژوهشی و جایگاه پژوهش حاضر

براساس مرور انتقادی انجام شده، می‌توان شکاف‌های پژوهشی ادبیات موجود را از سه منظر اصلی تحلیل کرد.

شکاف مفهومی: بین دو دسته مطالعات «پیش‌بینی انتشار کربن» و «انتخاب تأمین‌کننده سبز» شکاف مفهومی عمیقی وجود دارد. مطالعات پیش‌بینی، بر متغیرهای کلان یا عملیاتی متمرکزند

^۱. Pruethsan.

^۲. Shaw et al.



و نقش تأمین‌کنندگان را نادیده می‌گیرند، در حالی که مطالعات انتخاب تأمین‌کننده به پیش‌بینی میزان انتشار ناشی از انتخاب‌های مختلف نمی‌پردازند. پژوهش حاضر با تلفیق این دو حوزه، مدلی ارائه می‌دهد که ضمن در نظر گرفتن ویژگی‌های تأمین‌کنندگان (مانند مقدار ورودی، کیفیت، زمان ذخیره‌سازی)، قابلیت پیش‌بینی کمی انتشار کربن را نیز دارد. در این زمینه، به نتایج مقاله شاو و همکاران (۲۰۱۲) نیز اشاره می‌توان کرد [۴].

شکاف روش‌شناختی: سه نسل از مدل‌ها (کلاسیک، منفرد، ترکیبی) شناسایی شد. مدل‌های ترکیبی نسل سوم، علی‌رغم پیشرفته‌تر بودن، عمدتاً از بهینه‌سازهای رایج مانند ازدحام ذرات یا الگوریتم ژنتیک استفاده کرده‌اند و پتانسیل بهینه‌سازهای جدیدتر نظیر جستجوی عروس دریایی (JSO) بررسی نشده است. پژوهش حاضر با تلفیق الگوریتم تقویت گرادیان سبک (LGB) و بهینه‌ساز جستجوی عروس دریایی (JSO) به منظور تنظیم بهینه ابرپارامترها و افزایش دقت پیش‌بینی، گامی در جهت غنی‌سازی نسل سوم مدل‌ها برمی‌دارد.

شکاف جغرافیایی: با وجود آنکه ایران از کشورهای با انتشار بالای کربن است، مطالعات داخلی با روش‌های پیشرفته یادگیری ماشین محدود بوده و مطالعه‌ای که صنایع شیمیایی تهران (خاوران) را با رویکرد زنجیره تأمین بررسی کرده باشد، یافت نشد.

پژوهش حاضر با هدف پر کردن شکاف‌های مفهومی و روش‌شناختی، مدل ترکیبی JSO_LGB را برای پیش‌بینی انتشار کربن با در نظر گرفتن هشت متغیر تأثیرگذار مرتبط با تأمین‌کنندگان در صنایع شیمیایی تهران (خاوران) ارائه می‌دهد. این مدل ضمن بهره‌گیری از قابلیت‌های الگوریتم تقویت گرادیان سبک (LGB) در شناسایی الگوهای غیرخطی و پیچیده، با استفاده از بهینه‌ساز جستجوی عروس دریایی (JSO) ابرپارامترها را به صورت بهینه تنظیم کرده و دقت پیش‌بینی را افزایش می‌دهد. کاربرد عملی این مدل در انتخاب تأمین‌کنندگان با ردپای کربن کمتر، جنبه کاربردی پژوهش را نیز پوشش می‌دهد.

۳- روش‌شناسی پژوهش

محدوده مکانی مطالعه شامل صنایع شیمیایی واقع در تهران و محدوده زمانی آن از فروردین ۱۴۰۱ تا بهمن ۱۴۰۳ است. محدوده موضوعی در حوزه مدیریت زنجیره تأمین سبز و انتشار کربن قرار دارد. جامعه آماری شامل متخصصان مرتبط با مدیریت زنجیره تأمین در حوزه‌های شیمی و مهندسی شیمی با تمرکز بر پیش‌بینی انتشار کربن است. حجم نمونه برابر با جامعه



آماري و متشکل از ۲۰ نفر است که با روش نمونه‌گیری قضاوتی و هدفمند انتخاب شدند. برای تعیین متغیرهای تأثیرگذار، با استفاده از ادبیات تحقیق و نظرات خبرگان، پارامترهایی نظیر قیمت، توانایی فناوری، سازگاری، کیفیت، وضعیت مالی، ریسک، تجربه، گارانتی، زمان، تجهیزات، شهرت، مهارت‌های سازمانی، توانایی مدیریت، کیفیت تولید، توانایی همکاری و چابکی شناسایی شد [۲۰]. جدول شماره ۱ پارامترهای تأثیرگذار تأمین‌کنندگان بر انتشار کربن تولیدکننده را که بر اساس مطالعات کتابخانه‌ای و نظرات خبرگان جمع‌آوری شده است نشان می‌دهد.

جدول ۱: پارامترهای تأثیرگذار جمع‌آوری شده براساس مطالعات کتابخانه‌ای و نظرات خبرگان صنعت

ردیف	معیار	مؤلفه	نام منابع
۱	هزینه (A)	قیمت (A_1)، هزینه (A_2)، میزان مصرف منابع (A_3)، هزینه دور عمر یک محصول (A_4)	خبرگان، صالحی (۲۰۲۲)، [۱۸]. شاو و همکاران (۲۰۱۲)، [۴].
۲	کیفیت (B)	مقدار تأیید شده (B_1)، مقدار تأیید شده ارفاقی (B_2)، کیفیت (B_3)، مرجوعی کیفیت (B_4)، کیفیت کنترل وارده (B_5)	خبرگان، صالحی (۲۰۲۲)، [۱۸]. شاو و همکاران (۲۰۱۲)، [۴].
۳	مقدار ورودی (C)	تعداد ورودی‌ها (C_1)، مقدار کل ورودی‌ها (C_2)، درصد اقلام دیر تحویل داده شده (C_3)، تقاضا (C_4)	خبرگان، شاو و همکاران (۲۰۱۲)، [۴].
۴	مدیریت زنجیره تأمین سبز (D)	محصول سبز (D_1)، طراحی سبز (D_2)، تصویر سبز (D_3)، صلاحیت سبز (D_4)	صالحی (۲۰۲۲)، [۱۸]. شاو و همکاران (۲۰۱۲)، [۴].
۵	پارامترهای زیست محیطی (E)	دمای محیط (E_1)، فشار محیط (E_2)، روزهای نگهداری در انبار صنعتی تا زمان تولید (E_3)، هزینه‌های زیست‌محیطی (E_4)، سیستم مدیریت محیطی (E_5)، طراحی زیست‌محیطی (E_6)، کنترل آلودگی (E_7)، میزان انتشار گازهای گلخانه‌ای (E_8)، میزان تولید آلودگی (E_9)، کارآمدی محیطی (E_{10})، صلاحیت‌های محیطی (E_{11})	خبرگان، صالحی (۲۰۲۲)، [۱۸]. شاو و همکاران (۲۰۱۲)، [۴].
۶	پارامترهای مدیریتی (F)	صلاحیت‌های مدیریتی (F_1)، مدیریت خرید (F_2)، مدیریت R&D (F_3)، مدیریت فرآیند (F_4)، قابلیت تکنولوژی (F_5)	شاو و همکاران (۲۰۱۲)، [۴].



بعد از مشخص شدن مؤلفه‌های تأثیرگذار، نوبت به انتخاب و تعیین مهم‌ترین آن‌ها براساس پرسشنامه دلفی فازی است. برای شناسایی متغیرهای تأثیرگذار تأمین‌کنندگان بر انتشار کربن از روش دلفی فازی استفاده شد. فرآیند اجرا به شرح زیر است:

۱- تشکیل گروه خبرگان: پانل خبرگان این پژوهش شامل ۲۰ نفر از متخصصان و مدیران ارشد با حداقل ۱۰ سال سابقه کار در حوزه‌های مدیریت زنجیره تأمین، صنایع شیمیایی و مهندسی محیط زیست بود. انتخاب خبرگان به روش هدفمند و قضاوتی انجام شد و ملاک‌های ورود شامل: (۱) داشتن حداقل مدرک کارشناسی ارشد در رشته‌های مرتبط، (۲) داشتن حداقل ۱۰ سال سابقه کار اجرایی یا مدیریتی در صنایع شیمیایی، و (۳) آشنایی با مفاهیم مدیریت زنجیره تأمین و انتشار کربن بود. ترکیب پانل شامل ۱۲ مدیر ارشد زنجیره تأمین، ۵ کارشناس ارشد مهندسی شیمی و ۳ متخصص محیط زیست بود.

۲- دوره‌های دلفی: فرآیند در سه دور انجام شد. در راند اول، ۴۶ مؤلفه اولیه براساس ادبیات شناسایی و با طیف لیکرت ۵ نقطه‌ای فازی مثلثی (بسیار کم‌اهمیت (۰،۰،۰/۲۵)، کم اهمیت (۰،۰/۵، ۰،۰/۲۵)، متوسط (۰،۰/۷۵، ۰،۰/۵، ۰،۰/۲۵)، مهم (۰، ۰،۰/۷۵، ۰،۰/۵) و بسیار مهم (۰،۱، ۰،۰/۷۵)) ارزیابی شدند. در دور دوم، نتایج تجمیع شده به همراه نظرات کل گروه برای خبرگان ارسال شد تا ارزیابی مجدد انجام دهند. دور سوم برای نهایی‌سازی نظرات و دستیابی به اجماع انجام گردید. ۳- شاخص توافق: برای سنجش اجماع از شاخص توافق فازی (FAI) و ضریب همبستگی کندال (W) استفاده شد. مقادیر این شاخص‌ها در راندهای اول تا سوم به ترتیب (۰،۰/۷۱، ۰،۰/۸۴) برای FAI و (۰،۰/۳۲، ۰،۰/۵۴، ۰،۰/۷۳) برای ضریب کندال بود. بنابراین، معیار توقف فرآیند دلفی، دستیابی به شاخص توافق فازی بالای ۰/۷ و ضریب کندال معنی‌دار در سطح ۰/۰۵ بود که در دور سوم محقق گردید.

۴- تجمیع و غیرفازی‌سازی: نظرات خبرگان با روش میانگین فازی تجمیع و با روش میانگین هندسی غیرفازی‌سازی شدند. مؤلفه‌هایی با امتیاز غیرفازی شده $\leq 0/75$ به عنوان متغیرهای نهایی انتخاب شدند.

۵- نتایج: از ۴۶ مؤلفه اولیه، ۸ متغیر کلیدی با اجماع قوی خبرگان انتخاب و به عنوان ورودی مدل پیش‌بینی معرفی شدند. که جدول شماره ۲ مقادیر انتخاب پارامترهای مؤثر بر انتشار کربن صنایع شیمیایی را نشان می‌دهد.



جدول ۲: مقدار وزنی پارامترهای تأثیرگذار جمع‌آوری شده براساس روش دلفی فازی

مقدار	مؤلفه	معیار	مقدار	مؤلفه	معیار
۰/۸۷	(E _۱)	E	۰/۷۷	(A _۱)	A
۰/۸۴	(E _۲)		۰/۵۹	(A _۲)	
۰/۸۸	(E _۳)		۰/۶۹	(A _۳)	
۰/۷۱	(E _۴)		۰/۷۳	(A _۴)	
۰/۵۸	(E _۵)		۰/۸۵	(B _۱)	B
۰/۶۰	(E _۶)		۰/۸۱	(B _۲)	
۰/۶۷	(E _۷)		۰/۷۱	(B _۳)	
۰/۶۲	(E _۸)		۰/۶۳	(B _۴)	
۰/۶۰	(E _۹)		۰/۶۳	(B _۵)	
۰/۶۰	(E _{۱۰})		۰/۷۸	(C _۱)	C
۰/۶۵	(E _{۱۱})	۰/۸۱	(C _۲)		
		۰/۶۰	(C _۳)		
		۰/۶۱	(C _۴)		
۰/۶۶	(F _۱)	F	۰/۵۸	(D _۱)	D
۰/۶۸	(F _۲)		۰/۶۵	(D _۲)	
۰/۶۴	(F _۳)		۰/۶۶	(D _۳)	
۰/۶۶	(F _۴)		۰/۶۳	(D _۴)	
۰/۶۱	(F _۵)				

پارامترهای زیر به عنوان متغیرهای ورودی برای مدل پیش‌بینی انتشار کربن انتخاب شدند. هشت پارامتر ورودی انتخاب شده عبارتند از:

- ۱- تعداد ورودی‌ها^۱: نشان‌دهنده فراوانی حمل‌ونقل کالا از تولیدکننده به تأسیسات است.
- ۲- مقدار کل ورودی‌ها^۲: نشان‌دهنده مقدار کل کالاهای دریافتی توسط تأسیسات از منابع خارجی است. افزایش مقادیر واردات اغلب به حمل‌ونقل با تقاضای انرژی بالاتر نیاز دارد، به ویژه هنگامی که حمل‌ونقل از راه دور یا بین‌المللی مورد نیاز است.
- ۳- مقدار تأییدشده^۳: نشان‌دهنده مقدار واقعی مواد دریافتی و پردازش شده است. این معیار

^۱. Number of Arrivals (NoA).

^۱. Confirmed Quantity (CQ).

^۲. Imported Quantity (IQ).



ارتباط نزدیکی با حجم مواد اولیه ورودی به تولید و متعاقباً انرژی مورد استفاده در طول عملیات تولید دارد.

۴- مقدار تأییدشده ارفاقی^۱: اغلب مربوط به مواد اضافی یا حساس به زمان است. این مواد ممکن است نیاز به حمل‌ونقل سریع‌تر، شرایط ذخیره‌سازی خاص داشته باشند یا در صورت عدم استفاده زود هنگام منجر به ضایعات شوند. چنین شرایطی ممکن است به دلیل تقاضای فوری حمل‌ونقل یا نیازهای انرژی تکمیلی برای نگهداری، انتشار گازهای گلخانه‌ای را افزایش دهد.

۵- روزهای نگهداری در انبار صنعتی تا زمان تولید^۲: به عنوان یک معیار حیاتی برای ارزیابی مصرف انرژی انبار عمل می‌کند. انبارها از برق برای روشنایی، تنظیم دما و سیستم‌های امنیتی استفاده می‌کنند. مدت زمان طولانی ذخیره‌سازی منجر به افزایش مصرف انرژی می‌شود، از این رو به انتشار غیرمستقیم کربن می‌افزاید. این متغیر به ویژه در موقعیت‌های حساس به دما یا رطوبت، مانند بخش‌های شیمیایی یا دارویی، مرتبط است.

۶- قیمت^۳: اگرچه قیمت شاخص مستقیمی از انتشار گازهای گلخانه‌ای نیست، اما اغلب ویژگی‌های اساسی مانند منشأ مواد، فرآیندهای تولید و کیفیت را نشان می‌دهد. محصولات ارزان قیمت ممکن است از فروشندگانی با انتشار گازهای گلخانه‌ای بالا تهیه شوند یا ممکن است از روش‌های تولید ناکارآمد استفاده کنند. برعکس، قیمت‌گذاری بالاتر ممکن است نشان‌دهنده اقلام دارای گواهی زیست‌محیطی یا تهیه‌شده از منابع محلی باشد که به حمل‌ونقل کمتری نیاز دارند. در نتیجه، قیمت‌گذاری به عنوان یک شاخص جایگزین برای پایداری رویه‌های تهیه مواد عمل می‌کند.

۷- دما^۴: دما یک عنصر حیاتی در چندین فرآیند صنعتی و شیمیایی است. دمای عملیاتی بالا اغلب به انرژی بیشتری برای گرمایش نیاز دارد که بسته به منبع انرژی، ممکن است منجر به انتشار قابل توجه کربن شود. نظارت بر شرایط دما، ارزیابی نیازهای انرژی حرارتی و تأثیر آن‌ها بر کل اثر زیست‌محیطی، تولید را تسهیل می‌کند. دما بر شدت انرژی فرآیندهای شیمیایی و صنعتی تأثیر می‌گذارد.

^۱. Confirmed Discount Quantity (CDQ).

^۲. Days of Storage in the Industrial Warehouse until Production (Str).

^۳. Price (Pri).

^۴. Temperature (Tem).



۸- فشار^۱: سیستم‌های فشار بالا اغلب به دستگاه‌های پرانرژی، از جمله کمپرسورها و راکتورهای تقویت‌شده، وابسته هستند. این سیستم‌ها اغلب به دلیل نیاز به یک منبع انرژی ثابت، ردپای کربن بالایی دارند. گنجاندن فشار به عنوان ورودی به ارزیابی بار انرژی فرآیندهای تحت فشار و تأثیر آن‌ها بر انتشار کلی کمک می‌کند.

۳-۱- روش اعتبارسنجی مدل (رویکرد ترکیبی تقسیم داده و اعتبارسنجی متقابل) برای ارزیابی دقیق و بی‌طرفانه عملکرد مدل‌های توسعه‌یافته، از یک رویکرد ترکیبی دو سطحی استفاده شده است که در آن ابتدا داده‌ها به سه مجموعه آموزش، اعتبارسنجی و آزمایش تقسیم شده و سپس بر روی مجموعه آموزش، اعتبارسنجی متقابل اجرا گردیده است. این رویکرد ضمن جلوگیری از نشت داده، امکان بهینه‌سازی ابرپارامترها و ارزیابی نهایی را به طور هم‌زمان فراهم می‌کند. در ادامه، جزئیات این فرآیند تشریح می‌شود:

۳-۱-۱- سطح اول: تقسیم داده‌ها

در سطح اول، کل مجموعه داده شامل ۵۹۹۷ رکورد، به سه زیرمجموعه مستقل با نسبت ۱۰/۱۰/۸۰ تقسیم شد. این تقسیم‌بندی به صورت کاملاً تصادفی و با تفکیک زمانی انجام شد تا از نشت داده بین مجموعه‌های مختلف جلوگیری شود. نحوه تخصیص داده‌ها به شرح زیر است:

* مجموعه آموزش: ۸۰ درصد (۴۷۹۶ داده)، (هدف: آموزش مدل و اجرای اعتبارسنجی متقابل)؛
* مجموعه اعتبارسنجی: ۱۰ درصد (۶۰۰ داده)، (هدف: تنظیم ابرپارامترها و جلوگیری از بیش‌برازش)؛
* مجموعه آزمایش: ۱۰ درصد (۶۰۰ داده)، (هدف: ارزیابی نهایی عملکرد مدل (داده‌های دیده‌نشده)).
مجموعه آموزش برای یادگیری الگوها و برازش اولیه مدل استفاده شد. مجموعه اعتبارسنجی برای تنظیم ابرپارامترها و تصمیم‌گیری درباره توقف آموزش به کار گرفته شد، تا از بیش‌برازش مدل بر داده‌های آموزش جلوگیری شود. مجموعه آزمایش صرفاً یک بار و در انتهای فرآیند مدل‌سازی برای ارزیابی نهایی عملکرد مدل بر روی داده‌های کاملاً دیده‌نشده مورد استفاده قرار گرفت و هیچ نقشی در فرآیند آموزش یا تنظیم ابرپارامترها نداشت.

۳-۱-۲- سطح دوم: اعتبارسنجی متقابل: بر روی مجموعه آموزش

پس از تفکیک داده‌ها، بر روی مجموعه آموزش (۴۷۹۶ داده)، اعتبارسنجی متقابل ده‌گانه اجرا

^۱. Pressure (Pre).



شد. هدف از این مرحله، بهینه‌سازی ابرپارامترهای مدل و اطمینان از پایداری عملکرد مدل در مواجهه با زیرمجموعه‌های مختلف داده‌های آموزشی بود. مراحل اجرای اعتبارسنجی متقابل ده‌گانه به شرح زیر است:

- ۱- مجموعه آموزش به ۱۰ بخش تقریباً مساوی تقسیم می‌شود.
- ۲- در هر تکرار، ۹ بخش برای آموزش مدل و ۱ بخش برای اعتبارسنجی درون‌حلقوی استفاده می‌شود.
- ۳- این فرآیند ۱۰ بار تکرار می‌شود تا هر بخش دقیقاً یک بار نقش اعتبارسنجی را ایفا کند.
- ۴- عملکرد نهایی برای هر ترکیب از ابرپارامترها، میانگین عملکرد روی ۱۰ تکرار محاسبه می‌شود.
- ۵- ترکیب ابرپارامترهایی که کمترین میانگین RMSE را در اعتبارسنجی متقابل داشته‌اند، به عنوان ابرپارامترهای بهینه انتخاب می‌شوند.

نکته مهم: مجموعه اعتبارسنجی خارجی که در سطح اول جدا شده بود، در این مرحله هیچ‌گونه نقشی نداشت و صرفاً برای تأیید نهایی ابرپارامترهای انتخاب شده و جلوگیری از نشت داده استفاده گردید.

۳-۱-۳- مزایای رویکرد ترکیبی و جلوگیری از نشت داده

استفاده هم‌زمان از تقسیم داده و اعتبارسنجی متقابل با رعایت دقیق جداسازی مجموعه‌ها، مزایای زیر را به همراه دارد:

- ۱- جلوگیری از نشت داده: با جدا کردن مجموعه اعتبارسنجی و آزمایش در سطح اول و عدم دخالت آن‌ها در فرآیند اعتبارسنجی متقابل، اطمینان حاصل می‌شود که هیچ اطلاعاتی از این مجموعه‌ها به فرآیند آموزش و بهینه‌سازی نشت نمی‌کند. این امر ارزیابی نهایی را بی‌طرفانه و واقع‌بینانه می‌سازد.
 - ۲- بهینه‌سازی دقیق ابرپارامترها: اعتبارسنجی متقابل ده‌گانه بر روی مجموعه آموزش، امکان جستجوی جامع‌تر در فضای ابرپارامترها را فراهم می‌کند و از انتخاب ابرپارامترهای متناسب با یک زیرمجموعه خاص جلوگیری می‌نماید.
 - ۳- ارزیابی بی‌طرفانه: مجموعه آزمایش که تا انتهای فرآیند مدل‌سازی کنار گذاشته شده بود، امکان ارزیابی نهایی کاملاً بی‌طرفانه از عملکرد مدل را فراهم می‌کند.
 - ۴- تکرارپذیری: با ثبت اعداد تصادفی در فرآیند تقسیم داده‌ها، امکان تکرارپذیری دقیق نتایج برای سایر پژوهشگران فراهم شده است.
- این رویکرد ترکیبی ضمن رفع تناقض روش‌شناختی، استانداردهای لازم برای اعتبارسنجی



مدل‌های یادگیری ماشین در پژوهش‌های علمی را رعایت کرده و از نشت داده جلوگیری می‌نماید.

پس از بررسی تمام ویژگی‌ها، ۸۰ درصد (۴۷۹۶) از مجموعه داده‌ها برای آموزش و ایجاد مدل اختصاص یافت. علاوه بر این، ۱۰ درصد (۶۰۰) از مجموعه داده‌ها برای اعتبارسنجی مدل کنار گذاشته شد و ۱۰ درصد دیگر (۶۰۰) برای آزمایش تعیین گردید. در مجموع، ۵۹۹۷ نقطه داده برای انجام این پژوهش استفاده شد. مجموعه داده‌های جدید با استفاده از رابطه (۱) بین ۰ و ۱ نرمال‌سازی شدند تا قابلیت اطمینان آن‌ها افزایش یابد. برای افزایش انعطاف‌پذیری و تعمیم‌پذیری مدل‌های پیش‌بینی، از تصادفی‌سازی استفاده شد. مجموعه داده‌ها به صورت تصادفی به بخش‌های آموزش، اعتبارسنجی و ارزیابی تقسیم شدند تا از بیش‌برازش مدل جلوگیری شود و ارزیابی عینی از مدل یادگیری ماشین ارائه گردد. علاوه بر این، جدول شماره ۳ داده‌های آماری جامع برای متغیرهای مستقل و وابسته را در طول مراحل یادگیری، اعتبارسنجی و ارزیابی نشان می‌دهد. به منظور دستیابی به بالاترین سطح عملکرد ممکن از مدل، تصادفی‌سازی نیز در فرآیندهای اعتبارسنجی متقابل و اصلاح فرارامتر ادغام شد. همچنین نرمال‌سازی تضمین می‌کند که تمام ویژگی‌های ورودی در مقیاس ثابتی باشند، که برای بهبود مدل مانند الگوریتم تقویت گرادیان سبک^۱ (LGB) که به بزرگی ویژگی‌ها حساس هستند، ضروری است. از طریق فرآیند نرمال‌سازی، ویژگی‌ها به یک محدوده ثابت می‌رسند که این تکنیک را قادر می‌سازد تا ارزش هر ویژگی را به طور دقیق ارزیابی کند.

نکته مهم در خصوص نرمال‌سازی: لازم به توضیح است که الگوریتم تقویت گرادیان سبک (LGB) به عنوان یک الگوریتم مبتنی بر درخت تصمیم، ذاتاً به مقیاس ویژگی‌ها حساس نیست. الگوریتم‌های درخت پایه مانند LGB براساس تقسیم‌بندی آستانه‌ای کار می‌کنند و تنها ترتیب مقادیر برای آن‌ها اهمیت دارد، نه دامنه یا مقیاس آن‌ها. بنابراین، این الگوریتم‌ها نیازی به نرمال‌سازی یا استانداردسازی ویژگی‌ها ندارند.

با وجود این، نرمال‌سازی در پژوهش حاضر به دو دلیل مشخص انجام شده است که باید از ضرورت آن برای مدل LGB تفکیک شود:

۱- یکسان‌سازی مقیاس برای تحلیل‌های حساسیت: بخش مهمی از یافته‌های این پژوهش شامل

^۱ Light Gradient Boosting (LGB).



تحلیل حساسیت با روش FAST (شکل ۶) و محاسبه همبستگی‌های اسپیرمن (شکل ۵) است. این تحلیل‌ها برای تفسیرپذیری و اعتبارسنجی نتایج ضروری هستند و به مقیاس یکسان ویژگی‌ها نیاز دارند. نرمال‌سازی صرفاً برای این تحلیل‌های مکمل انجام شده است.

۲- امکان مقایسه با سایر الگوریتم‌ها: در این پژوهش، عملکرد LGB با الگوریتم‌هایی مانند SVR، MLP، RBF و ANFIS مقایسه شده است که همگی به شدت به مقیاس ویژگی‌ها حساس هستند. برای اینکه مقایسه بین مدل‌ها منصفانه و مبتنی بر داده‌های یکسان باشد، نرمال‌سازی روی کل داده‌ها اعمال شد. با این حال، تأکید می‌شود که آموزش نهایی مدل LGB با داده‌های نرمال‌شده و نرمال‌نشده آزمایش شد و تفاوت معناداری در عملکرد آن مشاهده نگردید که تأییدی بر عدم حساسیت این الگوریتم به مقیاس ویژگی‌هاست. بنابراین، نرمال‌سازی اعمال‌شده در این پژوهش، نه به دلیل ضرورت برای الگوریتم LGB، بلکه به دلیل نیازهای تحلیلی و مقایسه‌ای صورت گرفته است و این موضوع نباید به عنوان حساسیت LGB به مقیاس ویژگی‌ها تفسیر شود.

در نتیجه‌ی پاک‌سازی و ساختاردهی داده‌ها، الگوریتم توانست بر تشخیص الگوهای معنادار تمرکز کند که منجر به افزایش دقت مورد انتظار شد. فرآیند آزمون با نرمال‌سازی ویژگی‌ها تسریع شد که پایداری عددی را نیز افزایش داد. این امر به ویژه زمانی صادق بود که از مدل بهینه‌ساز جستجوی عروس دریایی^۱ (JSO) برای رویه‌های تنظیم فرامتر استفاده شد. علاوه بر این، درک و تفسیر پیش‌بینی‌های مدل با استفاده از تجسم ویژگی‌ها و داده‌های نرمال‌سازی شده افزایش یافت که منجر به ارائه بینش‌های شفاف‌تر در مورد رفتار مدل شد.

$$X_j = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad \text{رابطه (۱)}$$

مقدار نرمال شده‌ی پارامتر خاص	X_j
مقدار غیر نرمال شده پارامتر خاص	X_i
بالاترین مقدار پارامتر خاص	X_{\max}
کمترین مقدار پارامتر خاص	X_{\min}

درمورد انتخاب تقویت‌گرادیان سبک (LGB) برای پیش‌بینی انتشار کربن (CEs) در زنجیره‌های تأمین صنعتی براساس ارزیابی سیستماتیک چندین چارچوب یادگیری ماشین، از

^۱ Jellyfish Search Optimizer (JSO).



جمله مدل‌های کلاسیک مانند رگرسیون بردار پشتیبان (SVR)، پرسپترون چند لایه (MLP)، شبکه‌های تابع پایه شعاعی (RBF) و سیستم‌های استنتاج عصبی-فازی تطبیقی (ANFIS) انجام شد. در حالی که SVR، MLP، RBF و ANFIS کاربرد خود را در رگرسیون و وظایف مدل‌سازی غیرخطی نشان داده‌اند، محدودیت‌هایی دارند که اثربخشی آن‌ها را در مجموعه داده‌های زنجیره تأمین بزرگ، پیچیده و با ابعاد بالا کاهش می‌دهد. LGB، به عنوان چارچوب‌های تقویت گرادیان، با اصلاح خطاهای باقیمانده و ثبت وابستگی‌های غیرخطی ظریف، پیش‌بینی‌ها را به طور تکراری بهبود می‌بخشد و وابستگی‌های غیرخطی ظریف را مؤثرتر از SVR، MLP، RBF یا ANFIS ثبت می‌کند. علاوه بر این LGB، مقیاس‌پذیری و کارایی محاسباتی را از طریق رشد درخت برگ‌محور و ترکیب ویژگی مبتنی بر هیستوگرام افزایش می‌دهد و آن را برای مجموعه داده ۵۹۹۷ ورودی مورد استفاده در این مطالعه مناسب می‌سازد. علاوه بر این، این مدل معیارهای اهمیت ویژگی را ارائه می‌دهند که تفسیرپذیری و بینش‌های عملی در مورد عوامل زنجیره تأمین که بیشترین تأثیر را بر CE‌ها دارند، تسهیل می‌کند - مزیتی که به راحتی با شبکه‌های عصبی یا ANFIS قابل دستیابی نیست.

۳-۲- الگوریتم تقویت گرادیان سبک

تقویت گرادیان سبک (LGB) یک چارچوب یادگیری ماشین (ML) است که از GBDT^۱ یا GB درخت‌های تصمیم‌گیری (DT) استفاده می‌کند. برای پرداختن به مسائل مربوط به طبقه‌بندی و رگرسیون، از الگوریتم‌های DT استفاده می‌کند و از GB برای ترکیب وزنی درختان متعدد استفاده می‌کند ([۲۱] و [۲۲]). این روش از دو تکنیک پیشرفته، بسته‌بندی ویژگی‌های انحصاری (EFB) و نمونه‌برداری یک‌طرفه مبتنی بر گرادیان (GOSS) استفاده می‌کند که دقت و کارایی آموزش الگوریتم را به طور قابل توجهی بهبود می‌بخشند. با استفاده از این استراتژی‌ها، LGB قادر است زمان آموزش را برای مجموعه داده‌های بزرگ به طور چشمگیری کاهش دهد بدون اینکه عملکرد پیش‌بینی را قربانی کند. GOSS تکنیکی است که LGB برای نمونه‌برداری از نمونه‌هایی با گرادیان‌های بزرگتر به منظور افزایش کارایی آموزش استفاده می‌کند. داده‌های گرادیان به دست آمده از هر نمونه برای آموزش هر درخت در الگوریتم‌های GBDT معمولی استفاده می‌شود. GOSS فقط نمونه‌هایی با گرادیان‌های

^۱. Gradient Boosting Decision Trees (GBDT).



بزرگتر را نمونه‌برداری می‌کند که هزینه محاسبات را کاهش می‌دهد. گرادیان هر نمونه ابتدا g_i تعیین می‌شود و سپس نمونه‌هایی با گرادیان‌های بزرگتر با استفاده از روش زیر انتخاب می‌شوند:

$$\text{رابطه (۲)} \quad \text{Sampling Probability } (i) = \begin{cases} \frac{|g_i|}{\sum_{i=1}^n |g_i|}, & |g_i| > \delta \\ \frac{|g_i|}{\delta}, & \text{otherwise} \end{cases}$$

گرادیان نمونه i	g_i
یک آستانه از پیش تعیین شده	δ
تعداد نمونه‌ها	n

برای نمونه‌هایی با گرادیان‌های کمتر، از مقدار نمونه‌گیری کاهش یافته استفاده می‌شود که تأثیر آن‌ها را بر محاسبه کاهش می‌دهد. رویکرد EFB با ترکیب ویژگی‌های پراکنده در ویژگی‌های انحصاری، به دنبال کاهش ابعاد در فضای ویژگی است. این استراتژی با ادغام ویژگی‌ها با اطلاعات قابل مقایسه، میزان محاسبات مورد نیاز در طول آموزش را کاهش می‌دهد و بیشتر برای مدیریت داده‌های پراکنده، به ویژه هنگامی که مقدار ویژگی‌ها قابل توجه است، استفاده می‌شود. ویژگی‌های مشابه در EFB با هم ترکیب می‌شوند، زمانی که شباهت بین هر جفت ویژگی تعیین می‌شود. LGB با استفاده از یک تکنیک بهینه‌سازی مبتنی بر هیستوگرام اضافی، استفاده از حافظه را کاهش داده و محاسبه گرادیان را سرعت می‌بخشد:

- ۱- مقداردهی اولیه پیش‌بینی: LGB از میانگین برچسب‌های اطلاعات آموزشی برای تعیین مقدار پیش‌بینی شده برای هر جفت میکروبیوم-بیماری استفاده می‌کند.
- ۲- اندازه‌گیری گرادیان: گرادیان تابع کاهش برای هر مثال آموزشی i به صورت رابطه (۳) تعیین می‌شود.

$$\text{رابطه (۳)} \quad g_i = \frac{\partial L(y_i, f(x_i))}{\partial f(x_i)}$$

عملکرد از دست رفته	L
برچسب واقعی	y_i
مقدار پیش‌بینی شده	$f(x_i)$

- ۳- ساخت درخت DT: برای سرعت بخشیدن به فرآیند ساخت درخت، نمونه‌هایی با گرادیان‌های بیشتر با استفاده از تکنیک نمونه‌گیری GOSS انتخاب می‌شوند.



۴- به‌روزرسانی پیش‌بینی: نتیجه درخت جدید بر روی مقادیر پیش‌بینی شده فعلی اعمال می‌شود و پیش‌بینی‌ها را برای زوج‌های میکروبیوم-بیماری به‌روز می‌کند.

۵- آموزش تکراری: تا زمانی که تعداد از پیش تعیین شده درخت‌ها حاصل شود یا همگرایی خطا رخ دهد، چارچوب با استفاده از گرادیان نزولی و ساختارهای درختی متعدد، به صورت تکراری بهینه می‌شود.

مقدار $P(y=1|x)$ هر زوج میکروبیوم-بیماری، که نشان‌دهنده احتمال ارتباط میکروبیوم با بیماری است، توسط LGB در پایان آموزش تولید می‌شود. فرمول زیر برای طبقه‌بندی پیش‌بینی نهایی \hat{y} بر اساس عدد احتمال استفاده می‌شود:

$$\hat{y} = \begin{cases} 1, & P(y=1|x) > 0.5 \\ 0, & P(y=1|x) \leq 0.5 \end{cases} \quad \text{رابطه (۴)}$$

\hat{y} برچسب پیش‌بینی شده

۰ همبستگی

۱ وابستگی

جدول ۳. تحلیل اکتشافی داده‌ها: گرایش مرکزی و پراکندگی متغیرها

ویژگی	واحد	مرحله	ویژگی‌های آماری							
			مینیمم	ماکزیمم	میانگین	چولگی	کشیدگی	انحراف معیار	میانه	مد
NoA	-	آموزش	۱	۶۱۰	۲۳۴/۹۴۵	-۰/۴۸۲	-۱/۷۲۲	۲۸۷/۸۷۱۷	۱۰	۱
		اعتبارسنجی	۱	۶۱۰	۲۵۰/۸۳	-۰/۳۶۹۷	-۱/۸۲۵	۲۹۱/۲۸	۱۰	۶۱۰
		آزمایش	۱	۶۱۰	۲۴۹/۵۰۸	-۰/۳۷۸۹	-۱/۸۱۱	۲۸۹/۷۴۱۹	۱۰	۶۱۰
IQ	کیلوگرم	آموزش	۳۳۰	۱۴۲۰-۴۹۲۰	۵۴۹۴۳۳۴	-۰/۴۶۴۶	-۱/۷۴۷	۶۷۳۸۸۰۱	۱۷۱۳۵۰	۱۴۲۰-۴۹۲۰
		اعتبارسنجی	۴۲۰	۱۴۲۰-۴۹۲۰	۵۸۶۶۳۳۹	-۰/۳۵۲	-۱/۸۴۵	۶۸۱۶۶۲۲	۱۷۱۳۵۰	۱۴۲۰-۴۹۲۰
		آزمایش	۴۲۰	۱۴۲۰-۴۹۲۰	۵۸۴۱۴۵	-۰/۳۵۸۵	-۱/۸۳۴	۶۷۸۴۸۸۵	۱۷۱۳۵۰	۱۴۲۰-۴۹۲۰
CQ	کیلوگرم	آموزش	۰	۱۴۲۰-۴۹۲۰	۵۴۷۹۴۰۹	-۰/۴۷۰۶	-۱/۷۲۹	۶۷۳۰۵۶۲	۱۷۱۳۵۰	۱۴۲۰-۴۹۲۰
		اعتبارسنجی	۰	۱۴۲۰-۴۹۲۰	۵۸۵۰۹۹۹	-۰/۳۵۸۳	-۱/۸۳۸	۶۸۰۸۹۴۵	۱۷۱۳۵۰	۱۴۲۰-۴۹۲۰
		آزمایش	۰	۱۴۲۰-۴۹۲۰	۵۸۳۳۵۹	-۰/۳۶۵۶	-۱/۸۲۵	۶۷۷۵۹۲۱	۱۷۱۳۵۰	۱۴۲۰-۴۹۲۰
CDQ	کیلوگرم	آموزش	۰	۳۶۱۶۶۰	۱۴۷۸۶/۳۷	۴/۶۷۳۹	۱۹/۸۷۳	۷۱۰۵۹/۰۷	۰	۰
		اعتبارسنجی	۰	۳۶۱۶۶۰	۱۵۲۱۵/۷	۴/۵۹۵۶	۱۹/۱۹۳	۷۲۲۵۴/۵۹	۰	۰
		آزمایش	۰	۳۶۱۶۶۰	۱۷۷۲۰/۵	۴/۲۱۷۵	۱۵/۸۵۴	۷۷۵۲۷/۵۶	۰	۰

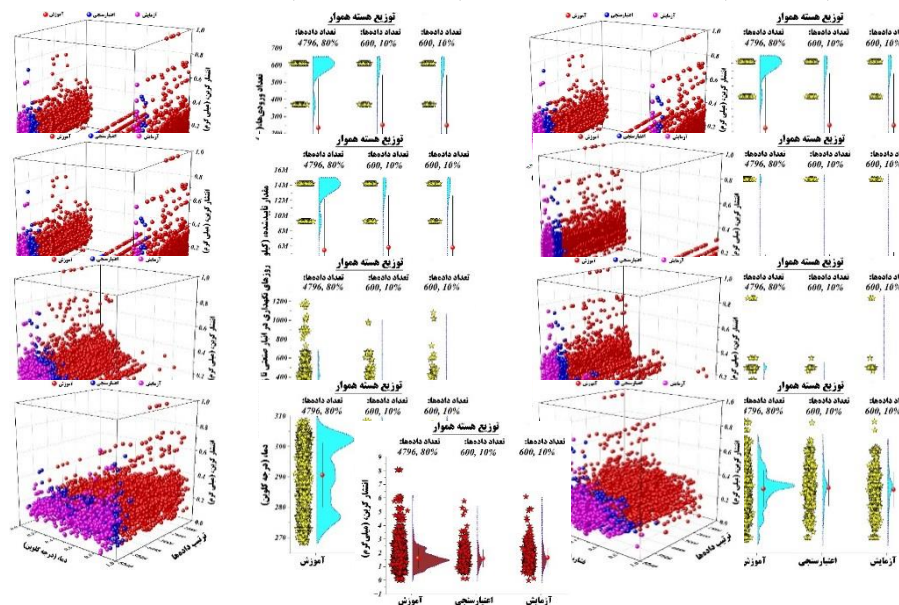


ویژگی	واحد	مرحله	ویژگی‌های آماری							
			مینیم	ماکزیم	میانگین	چولگی	کشیدگی	انحراف معیار	میان	مد
Str	روز	آموزش	۰	۱۱۹۹	۱۳۵/۱۰۴	۲/۳۶۰۸	۷/۷۸۱۱	۱۳۸/۱۷۹۶	۶۹/۵	۰
		اعتبارسنجی	۰	۹۸۶	۱۲۲/۲۳۶۷	۲/۳۸۱۳	۷/۳۷۵۰	۱۳۸/۱۲۶۱	۶۶	۲۳
		آزمایش	۰	۱۰۸۱	۱۱۸/۲۴۶	۲/۹۰۵۵	۱۲/۹۷۱	۱۲۲/۶۴۲	۶۸	۰
Pri	ریال	آموزش	۰	۱۵۲۴۳۷۲	۹۰۲۱۲/۰۱	۴/۳۱۲۳	۲۵/۴۳۴	۱۴۹۱۳۳/۹	۵۸۲۹۵/۸۴۹	۱۰۲۲۸۷/۴
		اعتبارسنجی	۰	۷۸۱۲۸۴/۵	۸۲۴۹۶/۸۹	۳/۶۴۲۳	۱۴/۱۰۹	۱۲۵۲۰۴/۳	۵۸۲۹۵/۸۵	۱۰۲۲۸۷/۴
		آزمایش	۰	۱۵۲۴۳۷۲	۹۲۱۶۸/۴	۴/۸۷۷	۳۰/۷۶	۱۶۶۱۱۵/۶	۵۸۹۲۵/۸۵	۱۰۲۲۸۷/۴
Tem	درجه کلوین	آموزش	۲۶۸/۳۵	۳۰۸/۵	۲۹۰/۶۴۶	-۰/۲۳۳۱	-۱/۳۲۷	۱۰/۶۱۸۲	۲۹۱/۵۵	۳۰۲/۹۵
		اعتبارسنجی	۲۶۸/۳۵	۳۰۸/۵	۲۹۰/۵۰۹	-۰/۳۶۱	-۱/۳۰۵	۱۰/۴۶۶	۲۹۱	۳۰۲/۹۵
		آزمایش	۲۷۱/۴	۳۰۷/۶۵	۲۹۰/۹۲۳	-۰/۲۴۸	-۱/۲۹۲	۱۰/۱۱۷۳	۲۹۲/۷۵	۳۰۲/۹۵
Pre	کیلو پاسکال	آموزش	۸۹/۳۲۸۵	۹۲/۳۶۲	۹۰/۶۴۳۸	-۰/۱۱۸۹	۰/۵۵۰۴	-۰/۴۷۱۷۳	۹۰/۷۳	۹۰/۷۳
		اعتبارسنجی	۸۹/۳۹۲	۹۲/۳۲۴	۹۰/۶۶۵	-۰/۱۱۳	۰/۵۴۴۳	۰/۴۵۲۵	۹۰/۷۳	۹۰/۷۳
		آزمایش	۸۹/۳۹۲	۹۲/۳۶۲	۹۰/۶۲۲	-۰/۲۴۷	۰/۹۰۳۳	۰/۴۵۵۵	۹۰/۷۳	۹۰/۷۳
هدف: CE	میلی گرم	آموزش	۰/۰۰۱۲۴	۸/۰۶۴۹۰۴	۱/۶۱۱۶۱۷	۲/۱۷۷۴	۱۱/۲۰۰	-۰/۷۲۲۰۶	۱/۴۹۴۵۴۰۶	۱/۱۱۹۵۳۹
		اعتبارسنجی	۰/۱۲۱۰۱	۵/۷۸۰۶	۱/۵۹۸۷	۱/۵۱۴۴	۵/۶۳۵۷	-۰/۶۶۳۸	۱/۴۸۰۱	۱/۵۲۱۱
		آزمایش	۰/۰۰۱۲۴	۶/۱۰۳۹	۱/۶۵۸۵	۱/۵۲۸۹	۵/۳۲۱۲	-۰/۷۱۰۳۴	۱/۵۲۱۱	۱/۵۲۱۱

شکل ۱ پیوند بین عواملی که به عنوان پیش‌بینی‌کننده عمل می‌کنند و نتیجه موردنظر و توزیع هسته هموار هر متغیر وجود دارد، را نشان می‌دهد. این نوع نمودار از طریق شفاف‌سازی توزیع داده‌ها در چندین زیرمجموعه و تأثیر پارامترهای ورودی بر متغیر هدف، بینش‌هایی در مورد الگوهای داده‌ها و تفکیک‌پذیری برای ارزیابی مدل ارائه می‌دهد. طبق شکل داده‌های ورودی، به گونه‌ای توزیع شده‌اند که در سراسر گروه‌های آموزش، اعتبارسنجی و آزمایش سازگار هستند. داده‌های آموزشی عمدتاً در نواحی مرکزی و راست نمودار قرار دارند که نشان می‌دهد بخش بیشتری از مجموعه داده‌ها برای آموزش مدل اختصاص داده شده است. علاوه بر این، طیف وسیع‌تری از این مقادیر ورودی و مقادیر CE در داده‌های اعتبارسنجی و آزمایش با توزیع یکنواخت‌تر گنجانده شده است. این نشان می‌دهد که توزیع مجموعه داده‌ها عادلانه است، بنابراین تضمین می‌کند که مدل روی نمونه‌های متنوع آموزش داده می‌شود و در عین حال مقدار کافی از داده‌های دیده نشده را برای اهداف آزمایش و اعتبارسنجی حفظ



می‌کند. با اختصاص ۸۰٪ از داده‌ها به آموزش و ۱۰٪ برای هر کدام از اعتبارسنجی و آزمایش، شکل توزیع هسته هموار شده، پارامترها را در سراسر مجموعه داده‌های یادگیری، اعتبارسنجی و ارزیابی مورد استفاده برای پیش‌بینی CE نشان می‌دهد. هر زیرمجموعه داده‌ها را از طریق منحنی‌های چگالی سایه‌دار آبی، نقاط قرمز نشان دهنده مقادیر میانگین و نقاط داده منفرد برچسب‌گذاری شده برای نشان دادن الگوهای توزیع یکنواخت در تمام زیرمجموعه‌ها را ارائه می‌دهد. این توزیع متعادل تضمین می‌کند که آموزش و ارزیابی مدل با حفظ ویژگی‌های آماری ثابت در هر بخش از مجموعه داده‌ها، قابل اعتماد خواهد بود.



شکل ۱. توزیع کلی متغیرها در مجموعه داده‌ها برای پیش‌بینی انتشار کربن

۳-۳- فرآیند توسعه مدل

فرمول‌بندی یک مدل ترکیبی شامل ادغام چندین الگوریتم یا روش برای بهره‌برداری از نقاط قوت فردی آن‌ها، با هدف بهبود عملکرد و دقت است. هدف، افزایش تعمیم‌پذیری و دقت پیش‌بینی و در عین حال کاهش سوءگیری‌ها یا محدودیت‌هایی است که ممکن است از به‌کارگیری یک رویکرد واحد ناشی شود. مجموعه داده‌ها تحت رویه‌های پیش‌پردازش مختلفی از جمله تصادفی‌سازی، مقیاس‌بندی، نرمال‌سازی، اعتبارسنجی متقابل و ارزیابی قرار گرفته



است. پس از آن، ابرپارامترهایی که مهم‌ترین آن‌ها در نظر گرفته شده است در جدول شماره ۴ نشان داده شده‌اند و مدل اساسی (LGB) از آنجایی که برای کار مورد نظر مناسب تشخیص داده شده است، انتخاب شد. پس از این، از یک رویکرد بهینه‌سازی معروف به JSO برای تعیین ابرپارامترهای بهینه LGB یا تنظیم پارامترهای مدل برای بهینه‌سازی استفاده شد. در مورد انتخاب این مدل نیز می‌توان گفت که در مقایسه با تکنیک‌های بهینه‌سازی مرسوم مانند جستجوی شبکه‌ای، جستجوی تصادفی و سایر الگوریتم‌های فراابتکاری (مانند بهینه‌سازی ازدحام ذرات، الگوریتم‌های ژنتیک یا بهینه‌سازی نهنگ)، JSO تعادل منحصر به فردی از اکتشاف و بهره‌برداری را ارائه می‌دهد که از رفتار تطبیقی جستجوی غذا در عروس دریایی الهام گرفته شده است. استراتژی‌های حرکت تطبیقی آن امکان همگرایی سریع‌تر به بهینه سراسری را فراهم می‌کند و در عین حال از حداقل‌های محلی اجتناب می‌کند و در نتیجه انتخاب ابرپارامتر دقیق‌تر و قوی‌تری را به همراه دارد. این امر به ویژه برای مجموعه داده‌های غیرخطی با ابعاد بالا که در آن‌ها بهینه‌سازهای سنتی ممکن است به آرامی همگرا شوند یا در راه‌حل‌های غیربهینه به دام بیفتند، مفید است. با استفاده از JSO، مدل به تعمیم‌پذیری و دقت پیش‌بینی بهتری دست یافت و از مدل‌های مبتنی بر درخت بهینه نشده و سایر مدل‌های یادگیری ماشین کلاسیک (ANFIS, RBF, MLP, SVR) عملکرد بهتری داشت.

اعتبارسنجی متقابل ده‌گانه یک روش ارزیابی مدل است که داده‌ها را به ۱۰ بخش مساوی یا "چین" تقسیم می‌کند. مجموعه داده‌ها برای آموزش، اعتبارسنجی و ارزیابی به زیرگروه‌هایی با نسبت ۱۰/۱۰/۸۰ تقسیم شدند. متعاقباً، مدل آموزشی با استفاده از مجموعه داده‌ها توسعه داده شدند. تعداد زیادی از مدل با ترکیبات ابرپارامترهای متنوع آموزش داده خواهند شد و اثربخشی هر مدل ارزیابی خواهد شد. پس از پایان تلاش تحقیقاتی، داده‌های مطالعه به طور دقیق ارزیابی شدند تا مشخص شود کدام ابرپارامترها بیشترین مزیت را دارند. توجه ویژه‌ای نیز به مقادیر جذر میانگین مربعات خطا^۱ (RMSE) که به عنوان تابع هدف انتخاب شده بودند، معطوف شد. اثربخشی تکنیک نهایی با استفاده از یک مجموعه آزمون مجزا برای تعیین عملکرد آن بر روی داده‌های ناشناخته قبلی ارزیابی شد.

^۱. Root Mean Square Error (RMSE).



۳-۴- الگوریتم بهینه‌ساز جستجوی عروس دریایی

در سال ۲۰۲۱، چو و ترونگ^۱ بهینه‌سازی جستجوی عروس دریایی مصنوعی (JSO) را ایجاد کردند [۲۳]، که یکی دیگر از روش‌های بهینه‌سازی قوی تحت تأثیر طبیعت است. اقدامات عروس دریایی در آب به عنوان مدلی برای JS عمل کرد. حرکت در اقیانوس موجود، حرکات غیرفعال و فعال گروهی، تکنیک متناوب این حرکات مختلف و شکوفایی همگرایی عروس دریایی از جمله پدیده‌هایی هستند که JS مدل‌سازی می‌کند. این اقدامات در مراحل زیر به صورت عددی بیان می‌شوند.

مرحله ۱: مقداردهی اولیه: از نقشه آشوب غیرخطی برای مقداردهی اولیه عروس‌های دریایی در طول مرحله راه‌اندازی استفاده می‌شود. تابعی که به عنوان نقشه آشوب لجستیک شناخته می‌شود، از یک الگوی خاص برای تولید انواع اعداد صحیح در یک محدوده مشخص استفاده می‌کند. نویسندگان با در نظر گرفتن تنوع نقشه لجستیک، اولین دسته عروس‌های دریایی را با استفاده از رابطه (۵) ایجاد کردند.

$$X_i^j = lb^j + LCV \times (ub^j - lb^j) \quad \text{رابطه (۵)}$$

$$LCV = \eta \times LCV \quad \text{رابطه (۶)}$$

LCV عددی که در بازه (۰,۱) تولید می‌کند

η متغیری با مقدار \in

$$0 < LCV \leq 1, \quad \text{رابطه (۷)}$$

$$LCV(0) \in (0, 1),$$

$$LCV(0) \notin \{0, 0.25, 0.5, 0.75, 1\}$$

مرحله ۲: جریان اقیانوسی: از آنجا که جریان‌های اقیانوسی شامل مقادیر زیادی منابع غذایی هستند، برای عروس‌های دریایی حیاتی هستند. رابطه (۸) ممکن است برای تقلید جهت جریان اقیانوسی مورد استفاده قرار گیرد.

$$Dir = \frac{1}{NoJS} \sum Dir_i = \frac{1}{NoJS} \sum (JS^* - e_c JS_i) = JS^* - e_c \times \frac{\sum JS_i}{NoJS} = JS^* - e_c \mu \quad \text{رابطه (۸)}$$

NoJS تعداد کل عروس‌های دریایی در یک دسته

^۱.Chou & Truong



JS_i آمین عروس دریایی

JS^* بزرگترین عروس دریایی کشف شده تا به امروز

e_c عامل حاکم بر جاذبه

μ میانگین مکان همه عروس‌های دریایی

عبارت زیر برای رابطه (۸) است:

$$Dir = JS^* - df \quad \text{رابطه (۹)}$$

$$df = e_c \mu \quad \text{رابطه (۱۰)}$$

df تفاوت بین میانگین موقعیت همه عروس‌های دریایی و بهترین موقعیت

عروس‌های دریایی

طبق فرض توزیع نرمال فضا، عروس‌های دریایی به احتمال زیاد در فاصله $\pm\beta\sigma$ از موقعیت میانگین خود قرار دارند. در نتیجه:

$$Df = \beta \times \sigma \times \text{rand}^f(0,1) \quad \text{رابطه (۱۱)}$$

$$\sigma = \text{rand}^a(0,1) \times \mu \quad \text{رابطه (۱۲)}$$

σ توزیع یکنواخت

β ضریب توزیع = ۳

$$df = \beta \times \text{rand}^f(0,1) \times \text{rand}^a(0,1) \times \mu \quad \text{رابطه (۱۳)}$$

$$e_c = \beta \times \text{rand}(0,1) \quad \text{رابطه (۱۴)}$$

در نتیجه، می‌توان حرکت جریان اقیانوسی را از طریق موارد زیر تعیین کرد:

$$Dir = JS^* - \beta \times \text{rand}(0,1) \times \mu \quad \text{رابطه (۱۵)}$$

اکنون، در رابطه (۱۶)، مکان عروس دریایی به‌روزرسانی می‌شود.

$$JS_i = JS_i + \text{rand}(0,1) \times Dir \quad \text{رابطه (۱۶)}$$

مرحله ۳: ازدحام عروس‌های دریایی: در یک دسته، عروس‌های دریایی به دو صورت حرکت می‌کنند: فعال و غیرفعال. اکثر عروس‌های دریایی در ابتدا غیرفعال حرکت می‌کنند، اما با رشد دسته، به تدریج شروع به حرکت فعال می‌کنند. عروس‌های دریایی در حالی که در حرکت غیرفعال هستند، در نزدیکی محیط اطراف خود حرکت می‌کنند. فرمول این حرکت که بهره‌برداری از JS را ارائه می‌دهد، در زیر آمده است:

$$JS_i = JS_i + \gamma \times \text{rand}(0,1) \times (ub - lb) \quad \text{رابطه (۱۷)}$$

γ طول حرکت که توسط ضریب حرکت تعیین می‌شود



عروس دریایی (JS_i) که به طور تصادفی از میان گروه انتخاب می‌شود، در طول حرکت فعال در جهتی که توسط عروس دریایی دیگر (JS_j) تعیین می‌شود، حرکت می‌کند. عروس دریایی اگر شایستگی آن (مقدار غذا در موقعیتش) بیشتر از JS_i باشد، به سمت JS_j می‌رود؛ در غیر این صورت، به دور شدن از JS_j ادامه می‌دهد. رابطه‌های (۱۸) و (۱۹)، هنگامی که در JS استفاده می‌شوند، این نوع عمل را تکرار می‌کنند.

$$JS_i = JS_i + \text{rand}(0, 1) \times \text{step} \quad \text{رابطه (۱۸)}$$

$$\text{step} = \begin{cases} JS_i - JS_j & \text{if } JS_j \text{ has better fitness than } JS_i \\ JS_j - JS_i & \text{other wise} \end{cases} \quad \text{رابطه (۱۹)}$$

ممکن است تصمیم‌گیری بین حرکت فعال و غیرفعال دشوار باشد. بنابراین، برای انتخاب یکی از این تاکتیک‌های حرکتی، یک سیستم کنترل زمان در JS پیشنهاد شده است. حرکات در جهت جریان اقیانوس نیز توسط سیستم کنترل زمان مدیریت می‌شوند.

مرحله ۴: مکانیسم کنترل زمان: در الگوریتم جستجوی عروس دریایی (JS)، عروس‌های دریایی ابتدا به صورت غیرفعال توسط جریان‌های اقیانوسی جابه‌جا شده و دسته تشکیل می‌دهند. با گذشت زمان، به تدریج حرکت فعال (تهاجمی) را ترجیح می‌دهند. این روند تغییر رفتار توسط مکانیسم کنترل زمان تنظیم می‌شود که در رابطه (۲۰) ارائه شده است [۲۴].

$$C(It) = \left| \left(1 - \frac{It}{\text{MaxIt}} \right) \times (2 \times \text{rand}) - 1 \right| \quad \text{رابطه (۲۰)}$$

$C(It)$ در طول زمان از ۱ تا ۰ در نوسان است.

وقتی مقدار $C(It)$ بزرگتر از C_0 باشد، عروس‌های دریایی با حضور در اقیانوس سفر می‌کنند و وقتی $C(It)$ کمتر از C_0 باشد، عروس‌های دریایی با استفاده از حرکات فعال یا غیرفعال درون دسته مهاجرت می‌کنند. در تکنیک JS ، C_0 به ۰/۵ تغییر می‌کند.

"Start"	
% Initialization	
۱	: Initialize jellyfishes using Logistic chaotic map using equation ۲
۲	: Calculate JS's fitness and select JS*
۳	: for It = ۱: MaxIt
۴	: for i = ۱: NoJS
۵	: Calculate time control parameter using equation ۱۷
۶	: if $C(It) \geq C_0$



```

% Ocean current movements
۷      Update ith jellyfish using equation ۱۴
۸      else
% Inside swarm movement
۹      if rand(۰,۱) ≥ ۱ - C(It)
% Passive motion
۱۰     Update ith jellyfish using equation ۱۵
۱۱     else
% Active motion
۱۲     Update ith jellyfish using equation ۱۶
۱۳     end if
۱۴     end if
۱۵     Check ith jellyfish feasibility and apply greedy selection mechanism
۱۶     Calculate fitness of ith jellyfish and update JS*
۱۷     end for
۱۸     end for
۱۹     Return JS*
“Finish”

```

شکل ۲. شبکه‌کد نشان دهنده مراحل اصلی JSO پیشنهادی

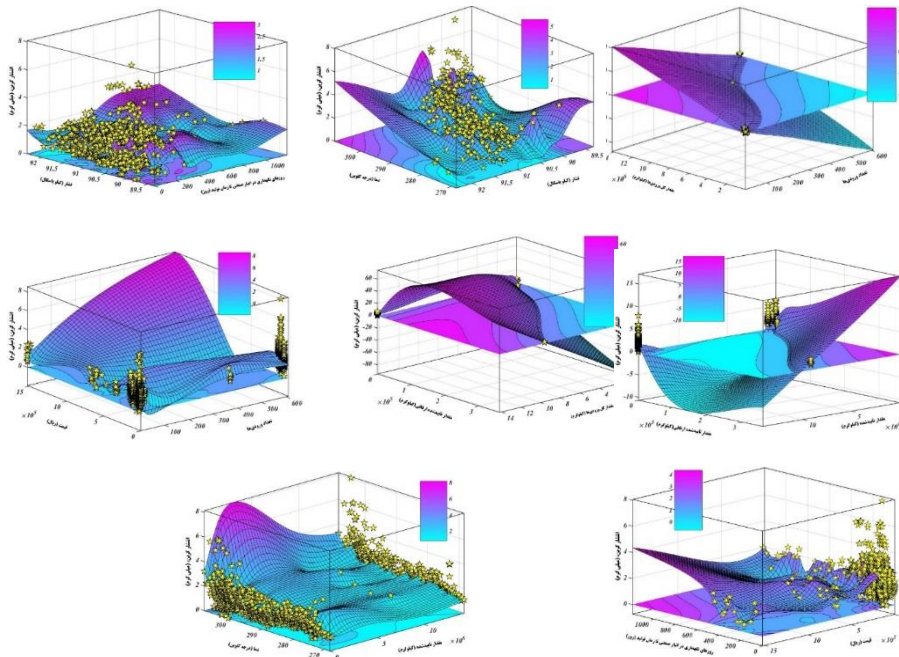
جدول ۴. تنظیمات فرایارامتر برای مدل توسعه‌یافته که از طریق JSO بهینه شده است.

مقدار	فرایارامترها	الگوریتم ترکیبی	مقدار	پارامتر	الگوریتم بهینه‌سازی
۵۲۶	تعداد برگ‌ها	LGB _{JSO}	۱۰۰	تعداد تکرارها	JSO
۱۳۸	حداکثر عمق		۲۰	تعداد جمعیت	
۰/۶۳۹	نرخ آموزش		۵	تعداد اجراها	
۱۳۲	برآورد n کنندگان		۳	β	
dart	نوع تقویت		۰/۱	γ	



۴- یافته‌های پژوهش

با استفاده از درون‌یابی اسپلاین، نمودارهای سطحی سه‌بعدی (شکل ۳) برای CE، تعاملات پیچیده و غیرخطی بین CE و چندین جفت متغیر ورودی را نشان می‌دهند. این نمایش‌ها واکنش‌های CE را به ترکیبی از NoA، IQ، CQ، CDQ، Str، Pri، Tem و Pre نشان می‌دهند. این شکل‌ها به‌طور کلی حساسیت CE به متغیرهای محیطی و تجربی را نشان می‌دهند، بنابراین کارایی درون‌یابی اسپلاین را در ثبت الگوهای پیچیده و تعاملات بین متغیرهای ورودی برجسته می‌کنند. Tem با ایجاد تغییرات چشمگیر در نمودارهای سطحی سه‌بعدی، بیشترین و غیرخطی‌ترین تأثیر را بر CE دارد. در مقابل، Pre و Pri هیچ تأثیری ندارند؛ CQ و Str تأثیرات متوسطی با انتقال‌های روان‌تر از خود نشان می‌دهند. Tem متغیر اصلی برای به حداکثر رساندن CE است؛ بقیه نقش‌های حمایتی ایفا می‌کنند.



شکل ۳. نمودار سطح سه‌بعدی تولید شده با استفاده از درون‌یابی اسپلاین برای مدل‌سازی رابطه بین متغیرهای ورودی و انتشار کربن



۴-۱- نقش تحلیل همبستگی در پژوهش (ارتباط با مدل یادگیری ماشین)

در این بخش، پیش از ارائه نتایج همبستگی، لازم است نقش و جایگاه این تحلیل در چارچوب کلی پژوهش تبیین شود تا ارتباط آن با مدل اصلی (LGB) به وضوح مشخص گردد. اگرچه الگوریتم LGB به عنوان یک مدل مبتنی بر درخت تصمیم، الزاماً به روابط خطی یا یکنواخت وابسته نیست، اما تحلیل همبستگی اسپیرمن در این پژوهش دارای سه کارکرد کلیدی است که در ادامه تشریح می‌شود:

۴-۱-۱- تحلیل اکتشافی داده‌ها

نخستین و مهم‌ترین کارکرد تحلیل همبستگی، درک ساختار داده‌ها و روابط اولیه بین متغیرها پیش از مدل‌سازی است. تحلیل همبستگی اسپیرمن به عنوان بخشی از تحلیل اکتشافی داده‌ها، امکان شناسایی الگوهای اولیه، روابط بالقوه و ساختار وابستگی بین متغیرها را فراهم می‌کند. این تحلیل به محقق کمک می‌کند تا:

۱- شناخت اولیه از داده‌ها: پیش از اجرای هر مدل پیچیده، درک روابط دوتایی بین متغیرها به محقق دید کلی از ماهیت داده‌ها می‌دهد.

۲- تشکیل فرضیات اولیه: همبستگی‌های بالا می‌توانند به عنوان مبنایی برای فرضیات اولیه درباره روابط علی یا ساختاری بین متغیرها عمل کنند.

۳- راهنمایی برای تحلیل‌های عمیق‌تر: نتایج همبستگی می‌تواند مسیر تحلیل‌های پیچیده‌تر مانند تحلیل مؤلفه‌های اصلی یا تحلیل عاملی را مشخص کند.

در این پژوهش، تحلیل همبستگی اسپیرمن نشان داد که برخی متغیرها (مانند IQ و CQ) همبستگی بسیار بالایی دارند که منجر به تحلیل همخطی و بررسی پیامدهای آن برای مدل شد (بخش ۴-۲). این نشان می‌دهد که تحلیل همبستگی به عنوان محرک تحلیل‌های تکمیلی عمل کرده است.

۴-۱-۲- شناسایی همخطی و مدیریت آن

همان‌طور که در بخش ۴-۲ به تفصیل آمده است، تحلیل همبستگی اسپیرمن امکان شناسایی همخطی شدید بین متغیرهای مستقل را فراهم کرد. اگرچه مدل‌های مبتنی بر درخت مانند LGB نسبت به همخطی مقاوم هستند، اما آگاهی از وجود همخطی بالا برای موارد زیر ضروری است:



- ۱- تفسیر دقیق‌تر اهمیت متغیرها: با دانستن وجود هم‌خطی، می‌توان اهمیت متغیرها را با احتیاط بیشتری تفسیر کرد و از نسبت دادن اهمیت به یک متغیر خاص خودداری نمود.
 - ۲- طراحی آزمایش‌های حساسیت: همبستگی بالا منجر به طراحی آزمایش‌های حذف متغیر شد تا پایداری مدل و توزیع اهمیت بین متغیرهای همبسته بررسی گردد.
 - ۳- پیشنهاد برای پژوهش‌های آتی: شناسایی هم‌خطی، زمینه را برای پیشنهاد استفاده از روش‌های کاهش ابعاد (مانند PCA) در پژوهش‌های آینده فراهم کرد.
- به این ترتیب، تحلیل همبستگی نه به عنوان یک هدف نهایی، بلکه به عنوان ابزاری برای تشخیص و مدیریت چالش‌های مدل‌سازی به کار گرفته شده است.

۳-۱-۴- مقایسه با تحلیل حساسیت FAST

سومین کارکرد تحلیل همبستگی، فراهم کردن زمینه برای مقایسه با نتایج تحلیل حساسیت FAST است. تحلیل حساسیت FAST (شکل ۶) اهمیت کلی هر متغیر را در خروجی مدل نشان می‌دهد، در حالی که همبستگی اسپیرمن روابط دوتایی بین متغیرها را آشکار می‌کند. مقایسه این دو تحلیل می‌تواند نکات ارزشمندی ارائه دهد:

به عنوان مثال، در این پژوهش مشاهده شد که:

جدول ۵. تفسیر روابط متغیرها در مدل با استفاده از تحلیل همبستگی اسپیرمن و FAST

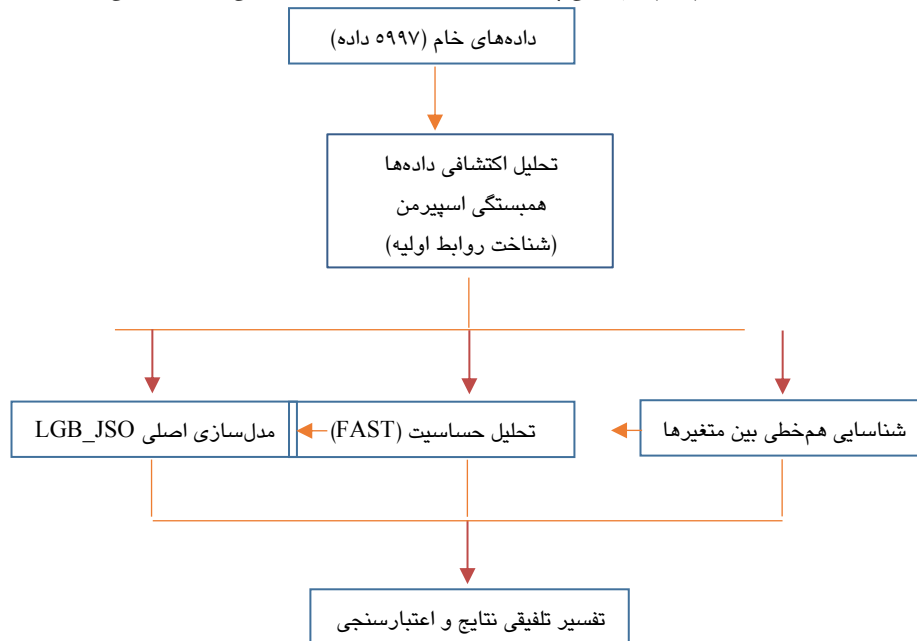
ردیف	نام متغیر	همبستگی با	اهمیت متغیر با CE در (St) FAST	تفسیر
۱	CQ	IQ (۰/۹۸۷)	۰/۹۰۶	CQ همبستگی بالا با IQ اما اهمیت مستقل در مدل
۲	Pre	Tem (-۰/۷۰۹)	۰/۸۴۰	Pre همبستگی منفی با Tem اما اهمیت بالا در مدل

این مقایسه نشان می‌دهد که اگرچه IQ و CQ همبستگی بالایی با یکدیگر دارند، اما هر دو در تحلیل FAST اهمیت بالایی کسب کرده‌اند که تأیید می‌کند مدل توانسته است اطلاعات منحصر به فرد هر یک را استخراج کند. این یافته از طریق تلفیق دو تحلیل (همبستگی و FAST) به دست آمده است.



۴-۱-۴- جمع‌بندی: جایگاه تحلیل همبستگی در چارچوب پژوهش

در مجموع، تحلیل همبستگی اسپیرمن در این پژوهش نه به عنوان یک هدف مستقل یا جایگزینی برای مدل یادگیری ماشین، بلکه به عنوان ابزاری مکمل در کنار سایر تحلیل‌ها به کار گرفته شده است. شکل ۴ چارچوب کلی پژوهش و جایگاه تحلیل همبستگی را نشان می‌دهد:



شکل ۴. چارچوب کلی پژوهش و جایگاه تحلیل همبستگی را نشان می‌دهد.

این چارچوب نشان می‌دهد که تحلیل همبستگی در کنار سایر تحلیل‌ها (هم‌خطی، FAST، مدل‌سازی) به درک جامع‌تری از داده‌ها و رفتار مدل منجر شده است. به عبارت دیگر، تحلیل همبستگی بخشی از یک رویکرد یکپارچه برای تحلیل داده و اعتبارسنجی نتایج است و نه یک تحلیل مجزا و نامرتب با مدل اصلی. بنابراین، ارائه همبستگی اسپیرمن در این پژوهش صرفاً یک گزارش آماری نیست، بلکه حلقه‌ای از زنجیره تحلیل‌های مکمل است که به شفافیت، اعتبار و تفسیرپذیری نتایج کمک می‌کند.



۲-۴- تحلیل همخطی و پیامدهای آن برای مدل

ماتریس همبستگی اسپیرمن در شکل ۵، همبستگی‌های بالایی را بین برخی از متغیرهای مستقل نشان می‌دهد که نیاز به تحلیل دقیق‌تری دارد. به عنوان نمونه بالاترین همبستگی مشاهده شده بین دو متغیر مقدار کل ورودی‌ها (IQ) و مقدار تأییدشده (CQ) با ضریب ۰/۹۸۷ است که نشان‌دهنده همخطی شدید بین این دو متغیر می‌باشد. همچنین همبستگی این دو متغیر با خودشان ۰/۹۹ است که امری طبیعی محسوب می‌شود. در ادامه، به تحلیل این پدیده و پیامدهای آن برای مدل پیشنهادی پرداخته می‌شود.

۲-۴-۱- دلایل همخطی بالا بین IQ و CQ

همخطی بالا بین مقدار کل ورودی‌ها (IQ) و مقدار تأییدشده (CQ) از نظر مفهومی قابل توجیه است. در فرآیندهای زنجیره تأمین صنایع شیمیایی، معمولاً بخش عمده‌ای از مواد اولیه واردشده به تأسیسات، پس از بازرسی و کنترل کیفیت، تأیید شده و وارد خط تولید می‌شوند. بنابراین، انتظار می‌رود این دو متغیر همبستگی بالایی با یکدیگر داشته باشند. با این حال، وجود مواردی مانند مواد مردود (که تأیید نمی‌شوند) یا تفاوت‌های زمانی بین ورود و تأیید، باعث می‌شود این همبستگی کامل نبوده و اطلاعات منحصر به فردی در هر دو متغیر باقی بماند.

۲-۴-۲- پیامدهای همخطی برای مدل‌های پیش‌بینی

همخطی بالا می‌تواند پیامدهای زیر را برای مدل‌های پیش‌بینی به همراه داشته باشد:

- ۱- افزایش واریانس ضرایب: در مدل‌های رگرسیونی پارامتریک، همخطی بالا منجر به افزایش واریانس برآورد ضرایب و کاهش پایداری آن‌ها می‌شود.
- ۲- مخدوش شدن تفسیر اهمیت متغیرها: در مدل‌های مبتنی بر درخت مانند LGB، اهمیت متغیرها بر اساس کاهش ناخالصی محاسبه می‌شود. در صورت وجود همخطی بالا، اهمیت متغیرها ممکن است بین متغیرهای همبسته تقسیم شود و تفسیر دقیق آن‌ها را دشوار سازد.
- ۳- افزایش پیچیدگی مدل: وجود متغیرهای همبسته ممکن است منجر به افزایش ابعاد مدل بدون افزودن اطلاعات جدید شود.

۲-۴-۳- رویکرد این پژوهش برای مدیریت همخطی

با توجه به ماهیت الگوریتم مورد استفاده و اهداف پژوهش، رویکرد زیر برای مدیریت همخطی اتخاذ شده است:



۱- استفاده از الگوریتم مقاوم به همخطی: الگوریتم تقویت گرادیان سبک (LGB) به عنوان یک الگوریتم مبتنی بر درخت، در مقایسه با مدل‌های پارامتریک (مانند رگرسیون خطی) نسبت به همخطی مقاوم‌تر است. درخت‌های تصمیم با انتخاب یک متغیر در هر گره برای تقسیم، به طور طبیعی اثر همخطی را کاهش می‌دهند. اگر دو متغیر همبسته باشند، درخت ممکن است یکی را انتخاب کرده و دیگری را کمتر به کار گیرد.

۲- حفظ متغیرها به دلیل اهمیت مفهومی: علیرغم همخطی بالا، هر دو متغیر IQ و CQ از نظر مفهومی حائز اهمیت هستند و جنبه‌های متفاوتی از فرآیند زنجیره تأمین را نشان می‌دهند. IQ نشان‌دهنده حجم مواد ورودی (مرتبط با حمل‌ونقل) و CQ نشان‌دهنده حجم مواد مصرفی واقعی (مرتبط با تولید) است. حذف یکی از این متغیرها می‌تواند به از دست رفتن اطلاعات مفهومی مهم منجر شود.

۳- بررسی اهمیت متغیرها در مدل نهایی: برای اطمینان از پایداری مدل، اهمیت متغیرها در مدل LGB_JS0 سناریوهای مختلف (حذف یکی از متغیرهای همبسته) مقایسه شد. نتایج نشان می‌دهد که:

* حذف هر یک از متغیرهای همبسته به تنهایی، کاهش اندکی در عملکرد مدل ایجاد می‌کند (حدود ۲/۵ درصد)، اما حذف هم‌زمان هر دو منجر به کاهش قابل توجه عملکرد (حدود ۴/۸ درصد) می‌شود. این نشان می‌دهد که هر دو متغیر حاوی اطلاعات مفیدی برای پیش‌بینی هستند و همخطی بالا منجر به کاهش شدید کارایی مدل نشده است.

* در مدل کامل، اهمیت IQ و CQ به ترتیب در رتبه‌های ۴ و ۵ قرار دارند که نشان می‌دهد هر دو متغیر سهم قابل توجهی در پیش‌بینی دارند و اهمیت بین آن‌ها به طور متوازن تقسیم شده است.


* در سناریوهای حذف یک متغیر، اهمیت متغیر باقی‌مانده افزایش می‌یابد که نشان‌دهنده جذب بخشی از اطلاعات متغیر حذف‌شده توسط متغیر همبسته است.

۴-۲-۴- نتیجه‌گیری درباره همخطی در مدل

براساس تحلیل‌ها، اگرچه همخطی بالایی بین IQ و CQ وجود دارد، اما به دلیل مقاوم بودن الگوریتم درخت‌پایه LGB در برابر همخطی، عدم کاهش چشمگیر عملکرد با حذف هر یک از متغیرها (در عین ضرورت وجود هر دو برای حداکثر دقت)، تأیید سهم قابل توجه هر دو متغیر



توسط تحلیل حساسیت FAST و همچنین اولویت بودن دقت پیش‌بینی و حفظ ساختار مفهومی مدل (نه تفسیر ضرایب) در این پژوهش، این همخطی مشکل جدی برای مدل ایجاد نکرده است. ضریب همبستگی رتبه‌ای اسپیرمن، روند و قدرت رابطه آماری بین دو متغیر مرتب یا ترتیبی را ارزیابی می‌کند. این همبستگی می‌تواند برای داده‌های ترتیبی یا داده‌هایی که معیارهای همبستگی پیرسون را برآورده نمی‌کنند، مورد استفاده قرار گیرد، زیرا به رتبه داده‌ها متکی است. همبستگی پیرسون، همبستگی‌های خطی را با استفاده از داده‌های نسبی یا فاصله‌ای بررسی می‌کند. همبستگی منفی کامل با ضریب -1 ، همبستگی مثبت کامل با مقدار $+1$ و عدم وجود هرگونه ارتباط با ضریب 0 نشان داده می‌شود. این روش به جای فرض تعامل خطی، به دنبال یک پیوند یکنواخت است، که وضعیتی است که در آن متغیرها در یک جهت حرکت می‌کنند اما ممکن است با سرعت‌های مختلف تغییر کنند. اسپیرمن اغلب یک شاخص قابل اعتماد است زیرا مبتنی بر یک سیستم مبتنی بر رتبه‌بندی است که حساسیت آن را به داده‌های پرت کاهش می‌دهد. در شکل ۴، IQ، CDQ و Pre قوی‌ترین ارتباط ($0/99$) را با خودشان دارند. از سوی دیگر، CQ/IQ بالاترین همبستگی مثبت ($0/987$) و Pre/Tem بیشترین همبستگی منفی ($-0/709$) را دارند.




شکل ۵. ماتریس همبستگی اسپیرمن که روابط یکنواخت بین متغیرها را نشان می‌دهد.

یک نمونه برجسته از نرم‌افزار متن‌باز معاصر که برای آزمایش حساسیت طراحی شده است، کتابخانه تحلیل حساسیت^۱ است. تحلیل حساسیت برای دستیابی به بسیاری از اهداف مهم در

^۱.Sensitivity Analysis Library (SALib).



تحقیقات یادگیری ماشین بسیار مهم است. اهداف شامل ارزیابی تأثیر تغییرات متغیر ورودی بر نتایج مدل، تعیین دقیق عناصر ضروری مؤثر بر عملکرد مدل، بهبود درک رفتار مدل در سناریوهای مختلف، بهینه‌سازی پارامترهای ورودی برای دستیابی به نتایج مطلوب و امکان‌پذیر کردن ارزیابی ریسک از طریق شناسایی اجزای حساس است [۲۵]. SALib روش‌های زیادی را برای انجام تحلیل‌های حساسیت گسترده ارائه می‌دهد، از جمله روش مشهور آزمون حساسیت دامنه فوری^۱. FAST خروجی‌های مدل را به اجزای جداگانه مرتبط با پارامترهای ورودی تجزیه می‌کند. این روش تجزیه، عناصری را آشکار می‌کند که تأثیر کم و قابل توجهی بر نتایج شبیه‌سازی دارند. معیارهای حساسیت مانند S_1 و S_T برای این روش که منحصر به معماری FAST است، ضروری هستند. شکل ۵ نتایج تحلیل حساسیت بر روی عوامل ورودی مرتبط با متغیر هدف را که با استفاده از رویکرد FAST انجام شده است، نشان می‌دهد. این نتایج، بینش‌های اساسی در مورد تأثیر هر ویژگی ورودی بر خروجی مدل ارائه می‌دهد و اهمیت نسبی و سهم چندین جنبه را در تولید نتیجه نهایی نشان می‌دهد. در میان تمام ویژگی‌های بررسی شده، ویژگی‌های S_{tr} و CQ به ترتیب با مقادیر 0.1439 و 0.0579 ، بیشترین و کمترین مقادیر S_1 را دارند، در حالی که متغیرهای IQ و Pre در ST دارای مقادیر 0.616 و 0.8992 هستند.



شکل ۶. تحلیل اهمیت ویژگی با استفاده از روش FAST، که تأثیر متغیرهای ورودی بر خروجی مدل را برجسته می‌کند.

^۱ Fourier Amplitude Sensitivity Test (FAST).





۴-۳- معیارهای ارزیابی عملکرد

چندین معیار آماری برای ارزیابی عملکرد مدل‌ها استفاده شد؛ هر کدام دیدگاه متفاوتی در مورد دقت پیش‌بینی شده ارائه می‌دهند. با مقادیر نزدیک‌تر به ۱ که نشان‌دهنده برازش بیشتر است، ضریب تعیین (R^2) میزان تطابق مقادیر پیش‌بینی شده با داده‌های واقعی را می‌سنجد. در حالی که RMSE نرمال شده (NRMSE) را نسبت به محدوده داده‌ها یا میانگین برای مقایسه مقیاس‌بندی می‌کند، جذر میانگین مربعات خطا (RMSE) انحراف معیار خطاهای پیش‌بینی را نشان می‌دهد. میانگین درصد خطا (MPE) که نشان‌دهنده سوگیری مدل است، میانگین درصد اختلاف بین داده‌های پیش‌بینی شده و واقعی را محاسبه می‌کند. میانگین مربعات خطای لگاریتمی (MSLE) و ریشه دوم آن (RMSLE)، با ارزیابی اشتباهات در مقیاس لگاریتمی، پیش‌بینی‌های کمتر از حد انتظار را شدیدتر جریمه می‌کنند و زمانی که مقادیر هدف چندین بزرگی را پوشش می‌دهند، ارزش پیدا می‌کنند. ضریب نابرابری تیل (TIC) دقت پیش‌بینی را ارزیابی می‌کند؛ مقادیر حدود ۰ نشان‌دهنده عملکرد بالاتر است. با مقادیر نزدیک به یک که نشان‌دهنده تطابق زیاد است، شاخص تطابق ویلموت (WI) میزان انعکاس صادقانه پیش‌بینی‌ها از حقایق مشاهده شده را اندازه‌گیری می‌کند. شاخص پراکندگی (SI) RMSE را با میانگین مشاهدات نرمال می‌کند تا خطای پیش‌بینی را نسبت به اندازه داده‌ها نشان دهد؛ عدم قطعیت در سطح اطمینان ۹۵ درصد ($U_{95\%}$) محدوده‌ای را نشان می‌دهد که پیش‌بینی می‌شود ۹۵ درصد از خطاهای پیش‌بینی در آن قرار گیرند.

۵- نتیجه‌گیری و پیشنهادها

این بخش ارزیابی کاملی از عملکرد مدل‌های ترکیبی ایجاد شده برای پیش‌بینی CE ارائه می‌دهد. رویه LGB همراه با مدل‌های ترکیبی $(LGB-JSO)$ با استفاده از روش‌های محاسباتی پیشرفته، دقت پیش‌بینی را افزایش می‌دهند. شکل ۷ نمودارهای پراکندگی را نشان می‌دهد که مقادیر واقعی و پیش‌بینی شده برای مدل‌های ترکیبی را مقایسه می‌کنند و R^2 را در هر سه مرحله نشان می‌دهند.





شکل ۷. نمودارهای پراکندگی مقادیر واقعی در مقابل مقادیر پیش‌بینی شده برای مدل‌های ترکیبی، که R^2 را در مراحل آموزش، اعتبارسنجی و آزمایش نشان می‌دهد. داده‌های مورد استفاده در مراحل آموزش و اعتبارسنجی به ارزیابی قابلیت اطمینان مدل کمک می‌کنند. علاوه بر این، جدول شماره ۶ ارزیابی‌های مدل را در مراحل آموزش، اعتبارسنجی و آزمایش خلاصه می‌کنند. به هر روش، رتبه‌بندی امتیازی اختصاص داده می‌شود تا به طور سیستماتیک دقت پیش‌بینی شده هر دو مدل منفرد و ترکیبی را بهبود بخشد. جدول ۶. نتایج مرحله آموزش، اعتبارسنجی و آزمایش: مقایسه قابلیت‌های پیش‌بینی مدل با استفاده از شاخص‌های عملکرد

مرحله	معیارها	مقادیر معیارها		مرحله	معیارها	مقادیر معیارها		مرحله	معیارها	مقادیر معیارها	
		LGB _{JSO}	LGB			LGB _{JSO}	LGB			LGB _{JSO}	LGB
تحلیل بخش آزمایشی	R^2	-۰/۹۶۰۶	-۰/۷۱۷۱	تحلیل بخش آموزش و اعتبارسنجی	R^2	-۰/۹۹۱۸	-۰/۸۴۰۱	تحلیل بخش اعتبارسنجی	R^2	-۰/۹۵۲۸	-۰/۷۴۲۱
	RMSE	-۰/۸۴۲۷	-۰/۲۸۴۵		RMSE	-۰/۰۶۶۷	-۰/۳۰۲۵		RMSE	-۰/۸۴۳۱	-۰/۳۴۱۴
	NRMSE	-۰/۰۲۳۴	-۰/۰۶۳۰		NRMSE	-۰/۰۰۸۳	-۰/۰۳۷۵		NRMSE	-۰/۰۲۵۲	-۰/۰۶۰۲
	MPE	-۰/۱۸۰۸	-۴/۸۵۲۵		MPE	-۰/۰۶۱۴	-۶/۲۷۵۰		MPE	-۱/۲۴۴۷	-۵/۵۱۴۱
	MSLE	-۰/۰۰۲۷	-۰/۰۱۶۸		MSLE	-۰/۰۰۰۱	-۰/۰۱۱۷		MSLE	-۰/۰۰۲۹	-۰/۰۱۴۸
	RMSLE	-۰/۰۵۲۱	-۰/۱۲۹۵		RMSLE	-۰/۰۰۹۳	-۰/۱۰۸۱		RMSLE	-۰/۰۵۳۸	-۰/۱۲۱۵
	TIC	-۰/۰۳۹۸	-۰/۱۰۹۰		TIC	-۰/۰۱۸۹	-۰/۰۸۷۰		TIC	-۰/۰۴۱۴	-۰/۱۰۰۱
	WI	-۰/۹۸۹۳	-۰/۸۹۸۲		WI	-۰/۹۹۷۹	-۰/۹۴۳۵		WI	-۰/۹۸۷۸	-۰/۹۱۱۹
	$U_{۹۵\%}$	-۰/۳۹۴۹	۱/۰۶۵۲		$U_{۹۵\%}$	-۰/۱۸۵۰	-۰/۸۳۸۵		$U_{۹۵\%}$	-۰/۳۹۶۹	-۰/۹۴۶۸
	SI	-۰/۰۸۶۱	-۰/۲۳۱۸		SI	-۰/۰۴۱۴	-۰/۱۸۷۷		SI	-۰/۰۸۹۵	-۰/۲۱۳۶

یافته‌ها نشان می‌دهد که LGB و LGB_{JSO} به احتمال زیاد پیش‌بینی‌های دقیقی از CE ارائه می‌دهند. براساس معیارهای آماری تعیین‌شده برای ارزیابی عملکرد، LGB_{JSO} در مقایسه با سایر مدل‌ها، دقت و قابلیت اطمینان بیشتری را نشان می‌دهد. در طول مراحل یادگیری،



اعتبارسنجی و ارزیابی، LGB_JS0 به بالاترین مقادیر R^2 ، (۰/۹۹۱۸، ۰/۹۵۳۸ و ۰/۹۶۰۶) دست می‌یابد، در حالی و LGB، (۰/۸۴۰۱، ۰/۷۴۲۱ و ۰/۷۱۷۱) دست می‌یابند. داده‌ها روند عملکردی را نشان دادند که با یکی از معیارهای پیش‌بینی شده مطابقت داشت و بهترین مدل با WI مطابقت داشت. علاوه بر این، معیارهای مبتنی بر خطا متنوعی، مانند RMSE، NRMSE، MSLE، MPE، TIC، $U_{95\%}$ و SI، همراه با اندازه‌گیری‌های عملکردی که قبلاً توضیح داده شد، ایجاد می‌شوند. کمترین مقدار در بین این معیارها نشان می‌دهد که دقت افزایش یافته است. چارچوب LGB_JS0 در مقایسه با چارچوب جایگزین، دقت بالاتری را نشان داد، همانطور که با بررسی مقادیر هدف (CE) که کمترین نتایج را برای مدل LGB_JS0 ایجاد کردند، مشهود است. از نتایج به دست آمده می‌توان در انتخاب تأمین‌کننده برای انتشار کربن کم استفاده کرد. به طوری که اگر اطلاعات لازم با توجه به کالای یا مواد اولیه خریداری شده و پارامترهای تأثیرگذار را از هر تأمین‌کننده دریافت کنیم و در مدل گذاشته و از خروجی مدل میزان انتشار کربن آن کالا را پیش‌بینی نمود و سپس در مورد استفاده یا عدم استفاده آن در خطوط تولیدی بحث نمود و در نهایت در ادامه دادن همکاری و خرید مجدد از آن تأمین‌کننده به بیان اعلام نظر پرداخت.

۵-۱- محدودیت‌ها و چشم‌انداز پژوهش‌های آینده

در این پژوهش، مشکلاتی نظیر کمبود کارشناسان خبره، نبود سیستم سخت‌افزاری و نرم‌افزاری به‌روز، کمبود زمان، محدودیت مکانی و دشواری دسترسی به پاسخ‌دهندگان وجود داشت. پژوهشگر با رفع این محدودیت‌ها توانست انحراف علمی را به حداقل برساند. امید است کاستی‌ها توسط محققان بعدی جبران شود.

۵-۲- پیشنهادها

در این پژوهش، مدل بهبودیافته یادگیری ماشین هیبریدی (LGB_JS0) قابلیت کاربرد در بخش صنعت برای پیش‌بینی انتشار کربن دارد. این مدل می‌تواند در سیستم‌های مدیریت زنجیره تأمین، لجستیک سبز، برنامه‌ریزی تولید، گزارش‌های پایداری شرکتی (مانند ESG، CDP و GRI) و داشبوردهای نظارت بلادرنگ گنجانده شود. بر این اساس، پیشنهاد می‌گردد در پژوهش‌های آتی، عوامل مؤثر بر نقش تأمین‌کنندگان در انتشار کربن در سازمان‌های دیگر با بهره‌گیری از مدل‌های جدید مطالعه و نتایج با پژوهش حاضر مقایسه شود. همچنین جهت



تسهیل دسترسی به اطلاعات و خروجی مدل، طراحی و ساخت نرم‌افزار اختصاصی این مدل توصیه می‌گردد تا صنایع تولیدی با تغییر پارامترهای مرتبط با زنجیره تأمین خود بتوانند از آن استفاده کنند.

۷- منابع

- [۱] Robertson, K., Loza-Balbuena, I., & Ford-Robertson, J. (۲۰۰۴). Monitoring and economic factors affecting the economic viability of afforestation for carbon sequestration projects. *Environmental Science & Policy*, ۷(۶), ۴۶۵-۴۷۵. <https://doi.org/10.1016/j.envsci.2004.07.002>
- [۲] Xu, Z., Liu, L., & Wu, L. (۲۰۲۱). Forecasting the carbon dioxide emissions in ۵۳ countries and regions using a non-euigap grey model. *Environmental Science and Pollution Research*, ۲۸, ۱۵۶۵۹-۱۵۶۷۲. <https://doi.org/10.1007/s11356-020-11638-7>
- [۳] Köne, AÇ., & Büke, T. (۲۰۱۰). Forecasting of CO_۲ emissions from fuel combustion using trend analysis. *Renewable and Sustainable Energy Reviews*, ۱۴(۹), ۲۹۰۶-۲۹۱۵. <https://doi.org/10.1016/j.rser.2010.06.006>
- [۴] Shaw, K., Shankar, R., Yadav, SS., & Thakur, LS. (۲۰۱۲). Supplier selection using fuzzy AHP and fuzzy multi-objective linear programming for developing low carbon supply chain. *Expert Systems with Applications*, ۳۹, ۸۱۸۲-۸۱۹۲. <https://doi.org/10.1016/j.eswa.2012.01.149>
- [۵] Bagheri, S., & Ansari Samani, H. (۲۰۲۱). Forecast of carbon dioxide emissions in Iran and polluting sectors: Long-term memory approach. *Journal of Iranian Economic Issues, Institute for Humanities and Cultural Studies (IHCS) Biannual Journal*, ۸(۲), ۶۷-۹۰. [in Persian]. <https://doi.org/10.30465/ce.2021.6691>
- [۶] Zare Ahmadabadi, H., Rajaei, F., Mirghafoori, SH., & Zamzam, F. (۲۰۲۴). Policymaking on the performance of green innovation ecosystem using the combined modeling of NDEA and Game Theory. *Modern Research in Decision Making*, ۹(۴), ۱۲۰-۱۵۳. [in Persian]
- [۷] Sheikhtajian, S., Bagherinejad, J., & Mohammdi, E. (۲۰۲۵). Application of a dominance-based rough set approach in the interactive portfolio selection of carbon capture and storage technologies. *Modern Research in Decision Making*, ۱۰(۲), ۲۷-۵۲. [in Persian]
- [۸] Zhou, C., & Chen, X. (۲۰۲۳). Forecasting China's energy consumption and carbon emission based on multiple decomposition strategy. *Energy Strategy Reviews*, ۴۹,



Article ۱۰۱۱۶۰. <https://doi.org/۱۰.۱۰۱۶/j.esr.۲۰۲۳.۱۰۱۱۶۰>

- [۹] Ren, J., Bai, H., Zhong, S., & Wu, Z. (۲۰۲۳). Prediction of CO₂ emission peak and reduction potential of Beijing-Tianjin-Hebei urban agglomeration. *Journal of Cleaner Production*, ۴۲۵, Article ۱۳۸۹۴۵. <https://doi.org/۱۰.۱۰۱۶/j.jclepro.۲۰۲۳.۱۳۸۹۴۵>
- [۱۰] Kumar, S., Shukla, AK., Muhuri, PK., & Lohani, QMD. (۲۰۲۳). CO₂ emission based GDP prediction using intuitionistic fuzzy transfer learning. *Ecological Informatics*, ۷۷, Article ۱۰۲۲۰۶. <https://doi.org/۱۰.۱۰۱۶/j.ecoinf.۲۰۲۳.۱۰۲۲۰۶>
- [۱۱] Bhatt, H., Davawala, M., Joshi, T., Shah, M., & Unnarkat, A. Forecasting and mitigation of global environmental carbon dioxide emission using machine learning techniques. (۲۰۲۲). *Cleaner Chemical Engineering*, ۵, Article ۱۰۰۰۹۵. <https://doi.org/۱۰.۱۰۱۶/j.clce.۲۰۲۳.۱۰۰۰۹۵>
- [۱۲] Natarajan, Y., Wadhwa, G., Sri Preethaa, K.R., & Paul, A. (۲۰۲۳). Forecasting Carbon Dioxide Emissions of Light-Duty Vehicles with Different Machine Learning Algorithms. *Electronics*, ۱۲, Article ۲۲۸۸. <https://doi.org/۱۰.۳۳۹۰/electronics۱۲۱۰۲۲۸۸>
- [۱۳] Keerthana, KB., Wu, S-W., Wu, M-E., & Kokulnathan, T. (۲۰۲۳). The United States energy consumption and carbon dioxide emissions: a comprehensive forecast using a regression model. *Sustainability*, ۱۵, Article ۷۹۳۲. <https://doi.org/۱۰.۳۳۹۰/su۱۵۱۰۷۹۳۲>
- [۱۴] Qin, X., Zhang, S., Dong, X., Zhan, Y., Wang, R., & Xu, D. (۲۰۲۳). China's carbon dioxide emission forecast based on improved marine predator algorithm and multi-kernel support vector regression. *Environmental Science and Pollution Research*, ۳۰, ۵۷۳۰-۵۷۴۸. <https://doi.org/۱۰.۱۰۰۷/s۱۱۳۵۶-۰۲۲-۲۲۳۰۲-۷>
- [۱۵] Yun, P., Zhang, C., Wu, Y., & Yang, Y. (۲۰۲۲). Forecasting Carbon Dioxide Price Using a Time-Varying High-Order Moment Hybrid Model of NAGARCHSK and Gated Recurrent Unit Network. *International Journal of Environmental Research and Public Health*, ۱۹, Article ۸۹۹. <https://doi.org/۱۰.۳۳۹۰/ijerph۱۹۰۲۰۸۹۹>
- [۱۶] Guo, J., Liu, W., Tu, L., & Chen, Y. (۲۰۲۱). Forecasting carbon dioxide emissions in BRICS countries by exponential cumulative grey model. *Energy Reports*, ۷, ۷۲۳۸-۷۲۵۰. <https://doi.org/۱۰.۱۰۱۶/j.egy.۲۰۲۱.۱۰۰۷۵>
- [۱۷] Namboori, S., & Iqbal, M. (۲۰۲۰). Forecasting Carbon Dioxide Emissions in the United States using Machine Learning. *School of Computing-National College of Ireland*, ۱-۲۳. MSc Research Project
- [۱۸] Fatima, S., Ali, SS., Zia, SS., Hussain, E., Fraz, TR., & Khan, MS. (۲۰۱۹). Forecasting Carbon Dioxide Emission of Asian Countries Using ARIMA and Simple Exponential Smoothing Models: Forecasting Carbon Dioxide Emission of Asian Countries Using



ARIMA and Simple Exponential Smoothing Models. *Int J Econ Environ Geol*, ۱۰(۱), ۶۴-۶۹. ISSN: ۲۲۲۳-۹۵۷X

- [۱۹] Sutthichaimethee, Pruethsan. (۲۰۱۷). Varimax Model to Forecast the Emission of Carbon Dioxide from Energy Consumption in Rubber and Petroleum Industries Sectors in Thailand. *Journal of Ecological Engineering*, ۱۸(۳), ۱۱۲-۱۱۷. <https://doi.org/10.12911/22998993/70200>
- [۲۰] Salehi, A. Effective Selection of Suppliers. Last Line Publications, Tehran, (۲۰۲۲). [in Persian]
- [۲۱] Shaker, B., Yu, M-S., Song, JS., Ahn, S., Ryu, JY., Oh, K-S., & Na, D. (۲۰۲۱). LightBBB: computational prediction model of blood-brain-barrier penetration based on LightGBM. *Bioinformatics*, ۳۷(۸), ۱۱۳۵-۱۱۳۹. <https://doi.org/10.1093/bioinformatics/btaa918>
- [۲۲] Chen, C., Zhang, Q., Ma, Q., & Yu, B. (۲۰۱۹). LightGBM-PPI: Predicting protein-protein interactions through LightGBM with multi-information fusion. *Chemometrics and Intelligent Laboratory Systems*, ۱۹۱, ۵۴-۶۴. <https://doi.org/10.1016/j.chemolab.2019.06.003>
- [۲۳] Chou, J-S., & Truong, D-N. (۲۰۲۱). A novel metaheuristic optimizer inspired by behavior of jellyfish in ocean. *Applied Mathematics and Computation*, ۳۸۹, Article ۱۲۵۵۳۵. <https://doi.org/10.1016/j.amc.2020.125535>
- [۲۴] Fossette, S., Putman, NF., Lohmann, KJ., Marsh, R., & Hays, GC. (۲۰۱۲). A biologist's guide to assessing ocean currents: a review. *MARINE ECOLOGY PROGRESS SERIES*, ۴۵۷, ۲۸۵-۳۰۱. <https://doi.org/10.3354/meps-09581>
- [۲۵] Iwanaga, T., Usher, W., & Herman, J. (۲۰۲۲). Toward SALib ۲.۰: Advancing the accessibility and interpretability of global sensitivity analyses. *Socio-Environmental Systems Modeling*, ۴, Article ۱۸۱۵۵. <https://doi.org/10.18174/sesmo.18155>