

ارائه چارچوبی برای پیش‌بینی وضعیت تحویل کالای مراقبت‌های بهداشتی و مدیریت زنجیره تأمین مراقبت‌های بهداشتی داده‌محور برپایه تکنیک ماشین بردار پشتیبان و بهینه‌سازی بیزی: مطالعه موردی زنجیره تأمین مراقبت‌های بهداشتی جهانی آژانس جهانی توسعه ایالات متحده

فرید دانشگر^۱، علی رجب‌زاده قطری^{۲*}، محمد علی افشار کاظمی^۳

- ۱- دانشجوی رشته دکتری مدیریت فناوری اطلاعات، گروه مدیریت فناوری اطلاعات، دانشکده مدیریت و اقتصاد، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.
- ۲- استاد، گروه مدیریت صنعتی، دانشکده مدیریت و اقتصاد، دانشگاه تربیت مدرس، تهران، ایران.
- ۳- دانشیار، گروه مدیریت صنعتی، دانشکده مدیریت و اقتصاد، دانشگاه آزاد اسلامی، واحد تهران مرکزی، تهران، ایران.

دریافت: ۱۴۰۲/۹/۲۹

پذیرش: ۱۴۰۳/۵/۱۰

چکیده

تحويل به موقع داروها، تجهیزات پزشکی و سایر لوازم ضروری برای مراقبت از بیمار بسیار حیاتی بوده و اغلب می‌تواند نجات‌دهنده باشد. تأخیر تحويل در زنجیره تأمین مراقبت‌های بهداشتی می‌تواند منجر به افزایش هزینه‌ها و چالش‌های عملیاتی برای سازمان‌های حوزه سلامت شده و بر مراقبت از بیمار و ثبات مالی تأثیر بگذارد. مدیریت زنجیره تأمین کارآمد و قابل اعتماد برای کاهش این خطرها و اطمینان از عملکرد یکپارچه در صنعت مراقبت‌های بهداشتی بسیار حائز اهمیت است. این پژوهش به

E-mail: alirajabzadeh@modares.ac.ir

* نویسنده مسئول مقاله:



مسئله تأخیر در تحویل کالای مراقبت‌های بهداشتی در زنجیره تأمین مراقبت‌های بهداشتی جهانی آژانس جهانی توسعه ایالات متحده پرداخته و یک چارچوب برای پیش‌بینی وضعیت تحویل کالاهای مراقبت‌های بهداشتی ارائه می‌نماید. همچنین ویژگی‌هایی که بیشترین تأثیر را در پیش‌بینی وضعیت تحویل کالا داشته‌اند، برای مدیریت زنجیره تأمین مراقبت‌های بهداشتی داده‌محور تعیین می‌کند. روش پژوهش مطالعه پیش‌رو، علم طراحی است که یک چارچوب برپایه روش ماشین‌بردار پشتیبان و بهینه‌سازی بیزی برای پیش‌بینی وضعیت تحویل کالاهای مراقبت‌های بهداشتی را ارائه کرده و عملکردهای مختلف الگوریتم‌های طبقه‌بندی برای پیش‌بینی وضعیت تحویل کالای مراقبت‌های بهداشتی را مقایسه کرده است. نتایج نشان می‌دهد که چارچوب ارائه‌شده برپایه روش ماشین‌بردار پشتیبان و بهینه‌سازی بیزی منجر به دقت طبقه‌بندی ۹۵ درصد می‌شود که در مقایسه با دیگر روش‌های به‌کار گرفته‌شده برای پیش‌بینی تأخیر تحویل عملکرد بهتری دارد. نتایج حاصل نشان داد که ویژگی‌های کشور مقصد، روش حمل، تأمین‌کننده و مکان تولید تأثیرگذارترین ویژگی‌ها در پیش‌بینی وضعیت تحویل می‌باشند.

واژه‌های کلیدی: یادگیری ماشین، مدل پیش‌بینی، تأخیر در تحویل، زنجیره تأمین مراقبت‌های بهداشتی.

۱- مقدمه

مدیریت زنجیره تأمین مراقبت‌های بهداشتی با ارائه کارآمد داروها، تجهیزات پزشکی و سایر لوازم ضروری به مراکز بهداشتی و درمانی، نقش مهمی در تضمین دسترسی به خدمات مراقبت‌های بهداشتی با کیفیت ایفا می‌کند که برنامه‌ریزی، تهیه، ذخیره‌سازی، توزیع و مدیریت محصولات مراقبت‌های بهداشتی با تمرکز بر تحویل به‌موقع و مؤثر آنها به کاربران نهایی می‌باشد. پیش‌بینی دقیق وضعیت تحویل از اهمیت بالایی در مدیریت زنجیره تأمین مراقبت‌های بهداشتی برخوردار است، زیرا امکان تصمیم‌گیری فعال را فراهم می‌کند و سازمان‌های حوزه سلامت را قادر می‌سازد تا عملیات خود را بهینه کنند [۱]. ناتالی پریوت و دیوید گنسالوز (۲۰۱۴)، تأخیر در تحویل را یکی از ۱۰ چالش برتر زنجیره تأمین مراقبت‌های بهداشتی جهانی اعلام کردند. چندین چالش در مدیریت زنجیره تأمین مراقبت‌های بهداشتی وجود دارد که مانع از تحویل کارآمد محصولات مراقبت‌های بهداشتی می‌شود [۲]. این چالش‌ها شامل موارد زیر



است، اما محدود به آنها نمی‌شود: تنوع در تقاضا و عرضه، زیرساخت‌های ناکافی، هماهنگی ضعیف بین ذینفعان، عدم دید و وجود محصولات تقلبی یا نامرغوب. علاوه بر این، پیچیدگی سیستم‌های مراقبت‌های بهداشتی به‌ویژه در محیط‌های محدود به منابع، این چالش‌ها را تشدید می‌کند [۳]. برای غلبه بر این موانع، پیش‌بینی دقیق وضعیت تحویل ضروری است. پیش‌بینی دقیق وضعیت تحویل برای بهینه‌سازی مدیریت زنجیره تأمین مراقبت‌های بهداشتی بسیار مهم است، زیرا تصمیم‌گیری فعال را ممکن می‌سازد و تخصیص کارآمد منابع را آسان می‌کند. با پیش‌بینی وضعیت تحویل محصولات مراقبت‌های بهداشتی، سازمان‌های حوزه سلامت می‌توانند از انباشت بیش از حد کالا جلوگیری کنند و منابع را به‌طور مناسب تخصیص دهند. این پیش‌بینی به مداخله‌های به‌موقع مانند تغییر مسیر محموله‌ها یا تسریع فرایندها اجازه می‌دهد تا از دسترسی بی‌وقفه محصولات مراقبت‌های بهداشتی حیاتی اطمینان حاصل شود. علاوه بر این، پیش‌بینی دقیق وضعیت تحویل، دید، شفافیت و مسئولیت‌پذیری زنجیره تأمین را افزایش می‌دهد و منجر به بهبود عملکرد کلی می‌شود. پیش‌بینی دقیق وضعیت تحویل، نقشی حیاتی در پرداختن به این چالش‌ها با امکان تصمیم‌گیری فعال و آسان‌سازی تخصیص کارآمد منابع ایفا می‌کند. اجرای پیش‌بینی دقیق وضعیت تحویل، عملکرد کلی زنجیره‌های تأمین مراقبت‌های بهداشتی را افزایش می‌دهد. دسترسی به‌موقع به محصولات مراقبت‌های بهداشتی با کیفیت و بهبود نتایج سلامت را تضمین می‌کند.

۲- یادگیری ماشین در زنجیره تأمین مراقبت‌های بهداشتی

یادگیری ماشین به طیف وسیعی از الگوریتم‌ها اشاره دارد که پیش‌بینی‌های هوشمند را براساس مجموعه داده انجام می‌دهند. این مجموعه داده‌ها اغلب بزرگ هستند، شاید از صدها هزار داده منحصر به فرد تشکیل شده باشند. پیشرفت‌های اخیر در یادگیری ماشین به سطحی از درک معنایی و استخراج اطلاعات دست پیدا کرده است که گاه توانایی تشخیص الگوهای انتزاعی با دقت بیشتر از متخصصان انسانی را دارد [۴]. یادگیری ماشین در حوزه‌های گوناگون پیش‌بینی تقاضا، بهینه‌سازی لجستیک، پشتیبانی تصمیم، انتخاب تأمین‌کننده، مدیریت موجودی، مدیریت خطرپذیری در زنجیره تأمین به کار گرفته شده است. استفاده از هوش مصنوعی و زنجیره تأمین



مبتنی بر داده برای تصمیم‌گیری در شرایط همه‌گیری، کارایی دولت را از منظر کاهش اختلال افزایش می‌دهد. همچنین به آنها کمک می‌کند تا تقاضای افزایش پیدا کرده در زنجیره تأمین مراقبت‌های بهداشتی را در طول همه‌گیری کنترل کنند [۵]. گارتنر^۱ پیش‌بینی می‌کند که تا انتهای سال ۲۰۲۴، ۵۰ درصد از سازمان‌های زنجیره تأمین^۲ روی برنامه‌هایی سرمایه‌گذاری خواهند کرد که از هوش مصنوعی و قابلیت‌های تحلیلی پیشرفته پشتیبانی می‌کنند [۶]. یکی از چالش‌های مهم در مدیریت زنجیره تأمین مراقبت‌های بهداشتی، توانایی ردیابی و پیش‌بینی دقیق وضعیت تحویل کالای مراقبت‌های بهداشتی [۷]. تأخیر، تغییر مسیر و شرایط پیش‌بینی نشده می‌تواند به‌طور چشمگیری بر تحویل به‌موقع تجهیزات پزشکی و به‌طور بالقوه بر مراقبت از بیمار تأثیر بگذارد [۸]. بنابراین، نیاز روزافزونی به پیاده‌سازی روش‌های پیشرفته یادگیری ماشین برای پیش‌بینی دقیق وضعیت تحویل و کاهش اختلال‌های احتمالی وجود دارد. مطالعه ادبیات موجود نشان داد که کار محدودی در زمینه پیش‌بینی وضعیت تحویل در زنجیره تأمین مراقبت‌های بهداشتی وجود دارد. درضمن در هیچ‌یک از پژوهش‌ها به موضوع تفسیرپذیری و تعیین ویژگی‌ها با بیشترین تأثیر در پیش‌بینی وضعیت تحویل پرداخته نشده است. با دانش بر مؤثرترین ویژگی‌ها در پیش‌بینی وضعیت تحویل، می‌توان با پیکربندی مناسب زنجیره تأمین مراقبت‌های بهداشتی از تأخیر در تحویل کالای مراقبت‌های بهداشتی جلوگیری کرد. به‌علاوه در پژوهش‌های داخلی به مسئله پیش‌بینی وضعیت تحویل کالا در زنجیره تأمین به‌ندرت پرداخته شده است و روش‌های یادگیری ماشین به‌کار گرفته نشده است. مطالعات پیشین تنها به ارزیابی داده‌های دستگاه‌های حسگر و داده‌های مسیر حمل‌ونقل پرداخته و یا اقدام به ردیابی لحظه‌ای محموله‌ها در زمان واقعی و بهینه‌سازی لجستیک پرداخته‌اند. آژانس توسعه ایالات متحده، USAID، آژانس توسعه جهانی پیشرو در جهان است که کمک‌های توسعه‌ای را برای کمک به کشورها در سفر رشد خود به سوی خوداتکایی ارائه می‌دهد. زنجیره تأمین کالای مراقبت‌های بهداشتی در آژانس بین‌المللی توسعه ایالات متحده نقش بسیار حیاتی در حفظ سلامت عمومی جوامع دارد. این زنجیره با چالش‌های فراوانی

1. Gartner, Inc.
2. Supply Chain Organizations



روبه‌رو است که تحویل به‌موقع کالاهای بهداشتی را دشوار می‌سازد. برای اطمینان از تأمین به‌موقع و با کیفیت محصولات مراقبت‌های بهداشتی بررسی و بهبود چالش‌ها از اهمیت ویژه‌ای برخوردار است. این پژوهش به ارائه یک چارچوب برپایه روش ماشین بردار پشتیبان و بهینه‌سازی بیزی جهت پیش‌بینی وضعیت تحویل کالاهای مراقبت‌های بهداشتی با به‌کارگیری داده‌های زنجیره تأمین مراقبت‌های بهداشتی آژانس توسعه ایالات متحده (USAID) از سال ۲۰۰۶ تا ۲۰۱۵ می‌پردازد.

چارچوب ارائه‌شده می‌تواند با داده‌های محلی دیگر کشورها از جمله ایران تطبیق داده شده و در جهت ارتقای زنجیره تأمین مراقبت‌های بهداشتی به‌کار گرفته شود. این موضوع به‌خصوص در شرایط بحرانی مانند پاندمی‌ها از اهمیت ویژه‌ای برخوردار است. این انعطاف‌پذیری یکی از مزایای بزرگ مدل‌های داده‌محور محسوب می‌شود. پیاده‌سازی و استفاده از روش‌های پیشرفته در زنجیره تأمین مراقبت‌های بهداشتی می‌تواند به ارتقای سطح دانش و فناوری در کشورهای مختلف کمک کرده و زمینه‌ساز پژوهش‌های بیشتر در این حوزه باشد. با توجه به ایجاد زیرساخت‌های داده‌محور حوزه مدیریت زنجیره تأمین در ایران و عدم به‌کارگیری روش‌های یادگیری ماشین به‌خصوص در حوزه پیش‌بینی وضعیت تحویل کالا، توسعه و به‌کارگیری مدل‌های پیش‌بینی برپایه یادگیری ماشین محسوس بوده و منجر به کاهش هزینه و بهینه‌سازی منابع خواهد شد. پژوهش پیش‌رو بر چگونگی بهبود مشکلات تأخیر در تحویل و پیش‌بینی آن تمرکز کرده است و هدف اصلی آن ارائه چارچوبی برای پیش‌بینی وضعیت تحویل کالا در زنجیره تأمین مراقبت‌های بهداشتی و تعیین متغیرهای (ویژگی‌های) مهمی است که بر پیش‌بینی وضعیت تحویل بیشترین تأثیر را دارند.

۳- پیشینه پژوهش

ون آندل (۲۰۱۸) دو راهبرد برای تجمیع حمل‌ونقل معرفی کردند. آنها یک خط‌مشی مبتنی بر زمان را ارائه نمودند که حداکثر زمان انتظار را قبل از انتشار محموله‌ها تعیین کرده و با به‌کارگیری تجزیه و تحلیل خوشه‌ای تأمین‌کنندگانی را که از نظر جغرافیایی به یکدیگر نزدیک هستند و اغلب به محل‌های تولید یکسان ارسال می‌کنند، گروه‌بندی می‌کند. استفاده از این راهبردها به‌طور جداگانه فقط مزایای جزئی را به همراه دارد، در حالیکه ترکیب آنها منجر به



هم‌افزایی قوی می‌شود [۹]. میلوانسویچ و پتکوویچ (۲۰۲۱) جنبه‌های مختلف و حیاتی خود جمع‌آوری را از دیدگاه مشتریان در نظر گرفته و دسته‌بندی‌های نهفته مصرف‌کننده خدمات را مشخص کردند. هدف اصلی این مطالعه ایجاد مدلی برای تخمین اینکه آیا یک محموله محصول به‌موقع تحویل می‌شود یا خیر، است. آنها مشتریان خود را با استفاده از روش‌های پیشرفته یادگیری ماشین برای انجام این کار مطالعه کردند و دریافتند که ارائه تخفیف بیشترین تأثیر را بر حمل‌ونقل یک محصول برپایه تجارت الکترونیک دارد [۱۰]. کئونگ و همکاران (۲۰۲۱) موضوع تأخیر حمل‌ونقل و پیش‌بینی فروش را بررسی کردند. آنها دریافتند که دسته‌بندی محصول و عوامل جغرافیایی بر نوسان‌های فروش یا تأخیرهای قابل‌توجه تأثیر گذاشته است [۱۱]. النها و همکاران (۲۰۲۱) پیش‌بینی پویایی زمان انتظار را که یک ارائه‌دهنده لجستیک می‌تواند برای بهینه‌سازی یکپارچگی حمل‌ونقل موقت استفاده کند، مطالعه کردند. آنها از روش‌های یادگیری ماشین مانند رگرسیون لجستیک و رگرسیون خطی برای انجام پیش‌بینی استفاده کردند. مدل ارائه‌شده به‌وسیله آنها دقت معقولی در پیش‌بینی زمان هفته تحویل سفارش را نشان داد [۱۲]. گارگ و همکاران (۲۰۲۱) از روش‌های پردازش زبان طبیعی عمیق برای ساخت روشی جدید برای ردیابی محموله‌ها در یک سازمان لجستیک استفاده کردند. هدف از این مطالعه ایجاد یک روش هوشمند برای نظارت و ردیابی محموله است. روش پیشنهادی آنها با تکیه بر تکنیکی برای جمع‌آوری و انتشار داده‌های لجستیکی منجر به دقت شناسایی چشمگیری شد [۱۳].

اوبید و همکاران (۲۰۲۱) سه مدل پیش‌بینی را بررسی کردند تا ببینند کدام یک به بهترین وجه با نیازهای صنعت کشتیرانی استرالیا برای پیش‌بینی کوتاه‌مدت و بلندمدت تقاضای واردات سازگار است. نتایج نشان می‌دهد که مدل پرافیت^۱ برای پیش‌بینی تقاضای محموله کانتینری در مقایسه با سایر مدل‌ها بهتر عمل می‌کند [۱۴]. هاتیکال و همکاران (۲۰۲۰) یک مدل پیش‌بینی برای تعیین زمان حمل‌ونقل برای محموله‌های وارداتی اقیانوسی با استفاده از روش‌های یادگیری ماشین و نیز با در نظر گرفتن منافع ذینفعان مختلف از جمله فرستنده، حامل، حمل‌کننده کالا و گیرنده ارائه دادند. آنها تعیین کردند که رگرسیون لجستیک چندجمله‌ای که با روش درخت تصمیم دنبال می‌شود، بهترین طبقه‌بندی‌کننده با بالاترین دقت است [۱۵].

1. Prophet



ارماگون و همکاران (۲۰۲۰) مدل‌هایی را برای درک و پیش‌بینی موفقیت حمل‌ونقل جمعیت^۱ ارائه کردند و از نتایج برای ایجاد انگیزه‌هایی برای بهبود عملکرد سیستم و تجارب کاربر استفاده کردند. برای پیش‌بینی وضعیت درخواست‌های حمل‌ونقل جمعیت، از روش یادگیری ماشین تصادفی جنگل استفاده کردند. آنها نشان دادند که احتمال دریافت پیشنهاد به‌شدت تحت تأثیر سطح پاداش و زمان ارسال درخواست حمل‌ونقل بوده و محموله‌های بزرگ‌تر، به مکان‌های خارج از ایالت و محموله‌های هم‌تا به هم‌تا با افزایش حساسیت همراه هستند که شاید بازتابی از ریسک‌های بالاتر درک‌شده مرتبط با چنین معاملات می‌باشد [۱۶]. ون (۲۰۱۱) با استفاده از تئوری پیش‌بینی خاکستری، چند مدل پیش‌بینی محموله را برای قابلیت تطبیق (CTM)^۲ زنجیره تأمین ارائه کرد. در مقایسه با مدل‌های رگرسیون، میانگین متحرک یکپارچه اتورگرسیون^۳ (ARIMA) و مدل‌های شبکه عصبی، روش‌های پیشنهادی پیش‌بینی‌هایی را ارائه کرد که دقیق‌تر بودند. درنهایت، نتایج عددی نشان داد که دقت پیش‌بینی حامل تحت CTM با میزان اشتراک اطلاعات افزایش پیدا می‌کند [۱۷]. پولیم و همکاران (۲۰۱۷) مدت زمان حمل‌ونقل را با استفاده از داده‌های زمان سفر از محموله‌های قبلی و یک روش مبتنی بر داده پیش‌بینی کردند. آنها در مطالعه خود از مدل‌های درختی و رویکردهای رگرسیون استفاده کردند [۱۸]. فابین استینبرگ و همکاران (۲۰۲۳) یک مدل یادگیری ماشین جدید برای پیش‌بینی تحویل‌های دیر هنگام تأمین‌کننده محصولات با حجم کم و تنوع بالا با کاربرد در صنعت ماشین‌آلات آلمانی ارائه دادند. آنها نشان دادند که نیازی به کاهش ابعاد ویژگی‌های ورودی با ابعاد بالا نیست و میزان تأخیر بسیار قبل‌تر قابل پیش‌بینی است به‌طوری‌که بتوان اقدام‌های لازم را به‌عمل آورد [۱۹]. نوشین سالاری و همکاران (۲۰۲۲) پیش‌بینی زمان تحویل و تعهد در زمان واقعی را برای خرده‌فروشی آنلاین بررسی کردند. مدل‌های مبتنی بر یادگیری ماشین پیشنهادی آنها منجر به عملکرد پیش‌بینی بالایی شد. آنها نشان دادند که چارچوب آنها پتانسیل ارائه زمان تحویل وعده داده‌شده بهتر از نظر فروش، هزینه و دقت را در مقایسه با زمان تعیین‌شده به‌وسیله JD.com دارد [۲۰]. رسول اوزدمیر و همکاران (۲۰۲۴) یک رویکرد


1. Crowd Shipping
2. Capable-To-Match
3. Autoregressive Moving-Average Model



STP جدید برای پیش‌بینی زمان وضعیت تحویل پیشنهاد دادند. الگوریتم STPMPA^۱ پیشنهادی آنها نسبت به الگوریتم‌های بهینه‌سازی مقایسه‌شده، عملکرد بهتری برای مسئله پیش‌بینی زمان تحویل ارائه کرد [۲۱]. سپس مقاله بخش ۳ روش‌شناسی پژوهش را تشریح می‌کند. بخش ۴ چارچوب پیشنهادی را ارائه کرده است. در بخش ۵ نتایج حاصل از چارچوب ارائه‌شده بررسی شده است. بخش ۶ در انتها نیز به نتیجه‌گیری می‌پردازد.

۴- روش پژوهش

علم طراحی^۲، یک روش پژوهش است که بر ایجاد و ارزیابی مصنوعات یا راه‌حل‌هایی برای رسیدگی به مشکلات یا چالش‌های خاص تمرکز دارد. در رویکرد علم طراحی، فرایند پژوهش شامل چرخه‌های تکراری طراحی، ساخت و ارزیابی مصنوعات است. این مصنوعات می‌توانند محصولات ملموس، سیستم‌های نرم‌افزاری، مدل‌های مفهومی و چارچوب‌ها یا روش‌ها باشند [۲۲]. روش پژوهش مطالعه پیش‌رو، علم طراحی است که منجر به ارائه یک چارچوب می‌شود (شکل ۱).



شکل ۱. فرایند روش‌شناسی علم طراحی [۲۲]

1. Shipment Time Prediction Marine Predators Algorithm
2. Design Science



آژانس توسعه بین‌المللی ایالات متحده (USAID)، یک آژانس مستقل از دولت فدرال ایالات متحده است که مسئولیت اصلی اداره کمک‌های خارجی غیرنظامی و کمک‌های توسعه‌ای را بر عهده دارد. مجموعه داده پژوهش به‌وسیله خدمات داده آژانس توسعه ایالات متحده^۱ ارائه شده است. این مجموعه داده اطلاعات مربوط به حمل‌ونقل کالای مراقبت‌های بهداشتی را ارائه می‌دهد. به‌طور خاص، مجموعه داده محموله‌های آزمایشگاهی ضد رتروویروسی (ARV) و HIV را به کشورهای حمایت‌شده شناسایی می‌کند. مجموعه داده اطلاعات ۱۰۳۰۰ درخواست حمل‌ونقل را در یک دوره ۹ ساله از سال ۲۰۰۶ تا ۲۰۱۵ ثبت کرده است که ۱۰۳۰۰ ردیف دارد و هرکدام یک محموله ارائه می‌دهد و همچنین ۳۳ ستون که ویژگی‌های مجموعه داده می‌باشد. جدول ۱ خلاصه‌ای از توصیف ویژگی‌ها را نشان می‌دهد. این مجموعه داده برای ارائه چارچوبی برای پیش‌بینی وضعیت کالاهای مراقبت‌های بهداشتی و تعیین مهم‌ترین عوامل مؤثر در پیش‌بینی به‌کار گرفته شده است. شرح ویژگی‌های داده در جدول ۱ ارائه شده است.

۴-۱- روش ماشین بردار پشتیبان

ماشین بردار پشتیبان، یک طبقه‌بندی‌کننده دوتایی است که با استفاده از نگاشت داده‌ها از فضای ورودی اصلی به فضایی با بعد بالاتر برای جداسازی آنها عمل می‌کند. این مدل ابرصفحه‌ای را جستجو می‌کند که فاصله‌اش با داده‌های دو کلاس ماکزیمم است. درواقع هدف اصلی طبقه‌بندی‌کننده ماشین بردار پشتیبان دستیابی به یک تابع $f(x)$ است که این تابع تعیین‌کننده ابرصفحه است [۲۳]. دیگر الگوریتم‌های محبوبی که می‌توانند برای طبقه‌بندی باینری استفاده شوند، عبارت است از رگرسیون لجیستیک، نزدیک‌ترین همسایه (KNN) و درخت تصمیم که در این پژوهش به‌کار گرفته شده و سپس کارایی آنها بررسی و مقایسه شده است (جدول ۱).

1. USAID Data Services (<https://2012-2017.usaid.gov/data/dataset/0162a542-4f2e-4fe2-ad5d-f6ed2344056>)



جدول ۱. شرح ویژگی‌های داده

متغیرها	شرح
project code	کد طرح
Pq	شماره پیشنهاد قیمت (PQ)
po / so #	
asn/dn #	شماره ارسال: یادداشت حمل‌ونقل پیشرفته (ASN) برای تحویل مستقیم یا یادداشت تحویل (DN) برای تحویل از RDC
Country	کشور مقصد
managed by	دفتر مدیریت: SCMS یا دفتر مدیریت برنامه (PMO) در ایالات متحده یا دفتر مربوط به آن SCMS
fulfill via	روشی که از طریق آن حمل‌ونقل انجام شد: از راه ارسال مستقیم از فروشنده یا از انبار موجود در RDCها
vendor incoterm	اینکوترم فروشنده (همچنین به‌عنوان شرایط تجاری جهانی شناخته می‌شود) برای تحویل مستقیم
shipment mode	روش ارسال کالاها
pq first sent to client date	تاریخ ارسال اولیه عملیات کارایی
po sent to vendor date	تاریخ ارسال سفارش خرید به تأمین‌کننده
scheduled delivery date	تاریخ تحویل پیش‌بینی شده فعلی
delivered to client date	تاریخ تحویل به مشتری
delivery recorded date	تاریخی که تحویل به مشتری در سیستم‌های اطلاعاتی SCMS ثبت شد.
product group	گروه محصول برای آیتم، یعنی ARV، HRDT
sub classification	طبقه‌بندی‌های فرعی محصول مربوطه را مشخص می‌کند، مانند اینکه آیا ARV ها برای کودکان هستند یا بزرگسالان، آیا یک محصول مالاریا یک درمان ترکیبی مبتنی بر آرتیمیترین (ACT) است یا خیر.
Vendor	نام فروشنده
item description	نام و فرمول محصول از Partnership for Supply Chain Management (PFSCM) Item Master
molecule/test type	دارو(های) فعال یا نوع کیت تست
Brand	نام عمومی یا برند برای کالا
Dosage	دوز و واحد آیتم
dosage form	فرم دوز برای آیتم (قرص، محلول خوراکی، تزریقی و غیره)
unit of measure (per pack)	مقدار بسته (قرص یا کیت تست) استفاده‌شده برای محاسبه قیمت واحد
line item quantity	مقدار کل (بسته) کالا در هر خط
line item value	ارزش کل کالا به ازای هر قلم خط



متغیرها	شرح
pack price	قیمت هر بسته (عرضه یک ماه ARV، بسته ۶۰ کیت تست)
unit price	قیمت هر قرص (برای داروها) یا هر آزمایش (برای کیت های آزمایش)
manufacturing site	محل تولید کالای خط را برای ارسال مستقیم و از تحویل RDC شناسایی می‌کند.
first line designation	مشخص می‌کند که آیا خط مورد نظر مجموع هزینه‌های حمل و نقل و وزن مربوط به همه موارد موجود در ASN DN را نشان می‌دهد.
weight (kilograms)	وزن برای همه خطوط در ASN DN
freight cost (usd)	هزینه‌های حمل و نقل مربوط به تمام خطوط در ASN DN مربوط به آن
line item insurance (usd)	هزینه اقلام ردیف بیمه که با اعمال نرخ ثابت سالیانه برای هزینه کالا ایجاد می‌شود.

۴-۲- ابزارها

ابزارهای به کار گرفته شده در این مطالعه به شرح زیر است:

آناکوندا^۱

یک توزیع^۲ زبان‌های برنامه‌نویسی پایتون و R برای محاسبات علمی می‌باشد.

ژوپیتِر نوت بوک^۳

یک پلتفرم محاسباتی تعاملی مبتنی بر وب که برای برنامه‌نویسی پایتون به کار گرفته شده است.

کتابخانه‌های پایتون:


کتابخانه‌های ... NumPy, Pandas, Matplotlib, Keras, برای پیش‌پردازش و ساخت مدل به کار گرفته شده است.

-
1. Anaconda
 2. Distribution
 3. Jupyter Notebook



۴-۳- پیش‌پردازش داده‌ها

پیش‌پردازش داده‌ها، یک مرحله مهم در تجزیه و تحلیل محسوب می‌شود که شامل تبدیل داده‌های خام به قالبی مناسب برای تجزیه و تحلیل است و نقش مهمی در تضمین کیفیت، دقت داده‌ها و بهبود عملکرد الگوریتم‌های یادگیری ماشین و داده‌کاوی ایفا می‌کند. شکل ۲ مراحل پیش‌پردازش داده‌ها را نشان می‌دهد.



شکل ۲. مراحل پیش‌پردازش داده

۴-۴- پاکسازی داده

پاکسازی داده‌ها، یک گام اساسی در پیش‌پردازش داده است که بر شناسایی و تصحیح داده‌های نادرست یا متناقض تمرکز دارد. ویژگی «اینکوترم فروشنده» و «دوز» با تعداد زیادی مقادیر گمشده غیرقابل جایگزینی بود که به همین علت حذف شدند. ویژگی «روش ارسال» دارای مقادیر گم‌شده بود که با مقادیر مکرر جایگزین شد. ویژگی «شرح اقلام» نیز حذف شد چون دیگر ویژگی‌ها آن را پوشش دادند. ویژگی‌های «تاریخ ارسال اولیه صلاحیت عملکرد» و

1. Dosage
2. Shipment Mode
3. Item Description
4. Pq First Sent To Client Date



«تاریخ ارسال سفارش خرید به تأمین‌کننده^۱» تعداد زیادی مقادیر گم‌شده داشتند که برای جایگزینی آنها میانگین تفاضل دو ویژگی به ازای کل رکوردها که از جنس تعداد روز بود، محاسبه شد.

$$(po\ date)_n - (pq\ date)_n = x_n\ days \quad (n=1\dots, m \quad m = \text{تعداد رکوردها}) \quad (۱)$$

$$x = \frac{\sum_{i=1}^m x_i}{m} \quad (۲)$$

۴-۵- نرمال‌سازی

ویژگی‌های «قیمت هر بسته^۲»، «قیمت هر واحد^۳»، «وزن^۴»، «هزینه ارسال^۵» و «هزینه اقلام ردیف بیمه^۶» که از نوع عددی بودند، با استفاده از روش min-max به بازه ۰-۱ مقیاس‌بندی دوباره شدند. مقیاس‌بندی حداقل حداکثر که به‌عنوان نرمال‌سازی حداقل حداکثر نیز شناخته می‌شود، روشی است که برای مقیاس و عادی‌سازی ویژگی‌های عددی در یک مجموعه داده استفاده می‌شود. این ویژگی‌ها را تغییر مقیاس می‌دهد تا مقادیری در محدوده خاصی داشته باشند، به‌طور معمول بین ۰ و ۱.

فرمول مقیاس min-max به شرح زیر است:

$$x_scaled = (x - \min(x)) / (\max(x) - \min(x)) \quad (۳)$$

x مقدار اصلی یک ویژگی است.

x_scaled مقدار مجدد مقیاس شده است.

min(x) حداقل مقدار ویژگی در مجموعه داده است.

max(x) حداکثر مقدار ویژگی در مجموعه داده است.

روش کدبندی وان-هات^۷، یک متغیر باینری برای هر دسته ایجاد می‌کند. مقادیر ویژگی‌های از نوع رسته‌ای با استفاده از روش کدبندی وان-هات به ۰ و ۱ تبدیل می‌شوند.

-
1. Po Sent To Vendor Date
 2. Pack Price
 3. Unit Price
 4. Weight
 5. Freight Cost
 6. Line Item Insurance
 7. One-hot Encoding



به این ترتیب ویژگی‌های رسته‌ای که مقادیر رسته‌ای داشتند، به ویژگی‌هایی با مقادیر ۰ و ۱ تبدیل شدند. ویژگی‌های «مقدار بسته (قرص یا کیت تست)»^۱ و «مقدار کل (بسته) کالا در هر خط»^۲ به علت دارا بودن مقادیر یکتای بسیار زیاد به سه دسته مقیاس‌بندی مجدد شدند.

۴-۶- کاهش ابعاد^۳

ماتریس همبستگی، همبستگی بین تمام جفت مقادیر ممکن در یک جدول را نشان می‌دهد. ماتریس همبستگی شامل سطرها و ستون‌هایی است که متغیرها را نشان می‌دهد. هر خانه در جدول حاوی ضریب همبستگی است. با تشکیل ماتریس همبستگی، ویژگی‌ها با ضریب همبستگی بالای ۸/۰ برای جلوگیری از بیش برآزش حذف شدند. اگر کوواریانس x و y را به صورت و انحراف معیار متغیر x و y را به صورت صورت σ_x و σ_y نشان دهیم، ضریب همبستگی پیرسون با نماد r یا ρ به صورت زیر محاسبه می‌شود.

$$\rho(X, Y) = \frac{\text{Cov}(x, y)}{\sigma_x \sigma_y} \quad (۴)$$

۴-۶-۱- حل مسئله داده نامتعادل^۴

یک رویکرد برای پرداختن به مشکل عدم تعادل کلاس، نمونه‌گیری دوباره تصادفی مجموعه داده آموزشی است. دو رویکرد اصلی برای نمونه‌برداری دوباره تصادفی یک مجموعه داده نامتعادل، حذف نمونه‌ها از کلاس اکثریت، به نام کم نمونه‌برداری و تکرار نمونه‌هایی از کلاس اقلیت به نام بیش نمونه‌برداری^۵ است. برای انجام بیش نمونه‌برداری، روش بیش نمونه‌برداری اقلیت مصنوعی^۶ (SMOTE) به کار گرفته شده است.

-
1. Unit of Measure (per pack)
 2. Line Item Quantity
 3. Dimensionality Reduction
 4. Imbalanced Data
 5. Oversampling
 6. Synthetic Minority Over-Sampling Technique



۴-۷- مهندسی ویژگی^۱

مهندسی ویژگی به فرایند ایجاد متغیرهای ورودی جدید از داده‌های موجود اشاره دارد [۲۴]. در پژوهش پیش‌رو از دو ویژگی «تاریخ تحویل برنامه‌ریزی شده»^۲ و «تاریخ تحویل به مشتری»^۳ یک ویژگی جدید یا همان ویژگی کلاس ایجاد شده است. برای هر نمونه، اگر تاریخ تحویل به مشتری بعد از تاریخ تحویل برنامه‌ریزی شده باشد، مقدار ویژگی کلاس «با تأخیر»^۴ و در غیراین صورت «به‌موقع»^۵ در نظر گرفته شده است.

۴-۸- مدل‌سازی و تنظیم هایپرپارامترها در ماشین بردار پشتیبان

هایپرپارامترها گروهی از عوامل هستند که در تست و آموزش برای پشتیبانی از فرایند یادگیری به‌کار می‌روند [۲۵]. تنظیم هایپرپارامترها در ماشین بردار پشتیبان یک مرحله اساسی در بهینه‌سازی عملکرد مدل است. C (پارامتر هزینه خطا) و گاما (پارامتر کرنل) و هسته مهم‌ترین فرایپرپارامترها در ساخت مدل ماشین بردار پشتیبان می‌باشند که می‌توانند تأثیر زیادی بر دقت مدل داشته باشند [۲۶].


۴-۹- روش بهینه‌سازی بیزی^۶

اصطلاح «بهینه‌سازی بیزی (BO)» به روشی اشاره دارد که می‌تواند به‌صورت متوالی برای بهینه‌سازی پارامترهای هر تابع جعبه سیاه $f(x)$ استفاده شود [۲۷]. برای ساخت یک مدل طبقه‌بندی مؤثر برای پیش‌بینی وضعیت تحویل کالا، ماشین بردار پشتیبان به همراه بهینه‌سازی بیزی برای تنظیم هایپرپارامترها به‌کار گرفته شده است. برای این منظور با استفاده از یک نقطه شروع تصادفی در فضای هایپرپارامتر، روش بیزی به‌طور مکرر پیکربندی هایپرپارامتر آتی را با

-
1. Feature Engineering
 2. Scheduled Delivery Date
 3. Delivered To Client Date
 4. Late
 5. On-Time
 6. Bayesian Optimization



در نظر گرفتن مدل موجود ارزیابی می‌کند تا تعیین کند هریک از آنها مدل را بهبود می‌بخشد یا خیر. رویه بهینه‌سازی بیزی در شکل ۳ نشان داده شده است.



شکل ۳. رویه بهینه‌سازی بیزی [۲۷]

۴-۱۰- اعتبارسنجی و ارزیابی مدل

اعتبارسنجی متقاطع k-fold، استاندارد طلایی برای ارزیابی مدل یادگیری ماشین است که یک تخمین قوی از عملکرد مدل بر داده‌های دیده‌نشده^۱ ارائه می‌دهد. در این پژوهش مقدار k برابر

1. Unseen Data




با ۵ در نظر گرفته شده است. این کار با تقسیم مجموعه داده آموزشی به ۵ زیرمجموعه و آموزش مدل‌ها روی همه زیرمجموعه‌ها به‌جز زیرمجموعه کنار گذاشته شده، انجام گرفت و سپس عملکرد مدل روی مجموعه داده اعتبارسنجی کنار گذاشته شده ارزیابی شد. این فرایند تا زمانی تکرار شد که به همه زیرمجموعه‌ها فرصت داده شود تا به‌عنوان مجموعه اعتبارسنجی کنار گذاشته شوند. سپس میانگین معیار عملکرد در تمام مدل‌هایی که ایجاد شده بودند، محاسبه شد.

۵- چارچوب پیشنهادی مبتنی بر تکنیک ماشین بردار پشتیبان و

بهینه‌سازی بیزی

در این پژوهش، از یک مجموعه داده واقعی برای توسعه یک مدل ترکیبی ماشین بردار پشتیبان و بهینه‌سازی بیزی جهت طبقه‌بندی وضعیت تحویل کالا استفاده شده است. بخش‌های جداگانه از کل مجموعه داده برای اهداف آموزش و تست به‌کار گرفته می‌شوند. به‌منظور ساخت یک مدل طبقه‌بندی مؤثر برای پیش‌بینی وضعیت تحویل کالا، از ماشین بردار پشتیبان به همراه بهینه‌سازی بیزی برای تنظیم هایپرپارامترها استفاده می‌شود. شناسایی متغیرهایی که می‌خواهیم به‌عنوان پیش‌بینی‌کننده استفاده کنیم و نتیجه‌ای که می‌خواهیم به‌دست آوریم، گام‌های اولیه در توسعه یک مدل طبقه‌بندی از ماشین بردار پشتیبان هستند. مرحله بعدی اجرای جستجوها برای بهینه‌سازی هایپرپارامترهای ماشین بردار پشتیبان است. درنهایت، هایپرپارامترهای تنظیم‌شده ماشین بردار پشتیبان در طبقه‌بندی به‌کار گرفته شده و عملکرد مدل با استفاده از داده تست ارزیابی می‌شود. شکل ۴ بهینه‌سازی بیزی برای مدل یادگیری ماشین، ماشین بردار پشتیبان جهت طبقه‌بندی وضعیت تحویل کالا را نشان می‌دهد.



شکل ۴. چارچوب پیشنهادی مبتنی بر روش ماشین بردار پشتیبان و بهینه سازی بیزی

۶- نتایج طبقه بندی و معیارهای ارزیابی

نتایج حاصل از پیاده سازی مدل پیشنهادی در ساختار ماتریس اغتشاش قبل از و بعد از اعمال روش بیش نمونه برداری (جدول ۴-۸) و تنظیم هایپرپارامترها (جدول ۳ و ۲) به شرح جدول های زیر مشخص شده است. همچنین در ادامه نمودار Accuracy (شکل ۵) و منحنی ROC (شکل ۶) و جدول خطاهای نوع ۱ و ۲ (جدول های ۲-۱۲) ارائه شده است. برای ارزیابی مدل های طبقه بندی چهار معیار مختلف Accuracy, Recall, Precision و F1 score به کار گرفته شد که Accuracy با استفاده از فرمول ۵ زیر قابل محاسبه است.

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN} \quad (5)$$



مقدار Recall نیز با استفاده از فرمول ۶ زیر قابل محاسبه می‌باشد:

$$\text{Recall} = \frac{TP}{TP + FN} \quad (۶)$$

مقدار Precision با استفاده از فرمول ۷ قابل محاسبه است:

$$\text{Precision} = \frac{TP}{TP + FP} \quad (۷)$$

مقدار F1 score نیز با استفاده از فرمول ۸ قابل محاسبه است:

$$\text{F1 score} = \frac{2 * \text{Recall} * \text{Precision}}{\text{Recall} + \text{Precision}} \quad (۸)$$

جدول ۲. فضای جستجوی هایپرپارامترها

هایپرپارامترها	مقادیر
C	[۰.۱/۰, ۱, ۱۰, ۱۰۰]
Gamma	[۰.۰۱/۰, ۱, ۱۰, ۱۰۰]
Kernel	['liner', 'poly', 'rbf']

جدول ۳. نتایج تنظیم هایپرپارامترها با روش Bayesian optimization

هایپرپارامترها	مقدار بهینه
C	۱۰۰
Gamma	۱۰۰
Kernel	Rbf

جدول ۴. ماتریس اغتشاش قبل از اعمال پیش‌نمونه‌گیری و تنظیم هایپرپارامترها

	طبقه‌بندی شده در کلاس تحویل به موقع	طبقه‌بندی شده در کلاس تحویل با تأخیر
کلاس تحویل به موقع	۱۲۴۵	۸۲
کلاس تحویل با تأخیر	۱۵۷	۳۵



جدول ۵. معیارهای ارزیابی مدل قبل از اعمال بیش‌نمونه‌گیری و تنظیم هایپرپارامترها

	precision	recall	F1-score	accuracy
تحویل به موقع	۸۷/۰	۹۶/۰	۹۱/۰	۸۴/۰
تحویل با تأخیر	۵۱/۰	۲۵/۰	۳۳/۰	

جدول ۶. ماتریس اغتشاش بعد از اعمال بیش‌نمونه‌گیری و تنظیم هایپرپارامترها

	طبقه‌بندی شده در کلاس تحویل با تأخیر	طبقه‌بندی شده در کلاس تحویل به موقع
کلاس تحویل به موقع	۱۲۸	۱۱۸۷
کلاس تحویل با تأخیر	۱۲۵۸	۵۲


جدول ۷. معیارهای ارزیابی بعد از اعمال بیش‌نمونه‌گیری و تنظیم هایپرپارامترها

	precision	recall	F1-score	accuracy
تحویل به موقع	۹۸/۰	۹۱/۰	۹۴/۰	۹۵/۰
تحویل با تأخیر	۹۲/۰	۹۹/۰	۹۵/۰	


جدول ۸. خطای نوع ۱ و ۲

	TP rate	FP rate
تحویل به موقع	۹۰/۰	۰۱/۰
تحویل با تأخیر	۰۴/۰	۹۶/۰

Train: ۰.۹۸ , Test: ۰.۹۵



شکل ۵. منحنی accuracy مربوط به ماشین بردار پشتیبان



شکل ۶. منحنی ROC مربوط به ماشین بردار پشتیبان

۶-۱- مقایسه الگوریتم‌های مختلف طبقه‌بندی برای بررسی کارایی مدل

نتایج حاصل [۲۸] از طبقه‌بندی با الگوریتم‌های مختلف به شرح جدول‌های ۹-۱۳ ارائه می‌شود. نتایج نشان می‌دهد که چارچوب پیشنهادی برپایه روش پایه ماشین بردار پشتیبان و بهینه‌سازی بیزی بیشترین دقت طبقه‌بندی کل و دقت بالای طبقه‌بندی کلاس تحویل با تأخیر را دارد.

جدول ۹. نتایج طبقه‌بندی با الگوریتم رگرسیون لجستیک

	precision	recall	F1-score	accuracy
تحویل به موقع	۰/۸۴	۰/۶۳	۰/۷۲	۰/۷۵
تحویل با تأخیر	۰/۷۰	۰/۸۸	۰/۷۸	

جدول ۱۰. نتایج طبقه‌بندی با الگوریتم نزدیک‌ترین همسایه

	precision	recall	F1-score	accuracy
تحویل به موقع	۹۴/۰	۷۳/۰	۸۲/۰	۸۴/۰
تحویل با تأخیر	۷۸/۰	۹۵/۰	۸۶/۰	



جدول ۱۱. نتایج طبقه‌بندی با الگوریتم درخت تصمیم

	precision	recall	F1-score	accuracy
تحويل به موقع	۱۰۰	۸۶/۰	۹۲/۰	۹۳/۰
تحويل با تأخیر	۸۸/۰	۱	۹۳/۰	

جدول ۱۲. نتایج طبقه‌بندی با چارچوب ارائه‌شده برپایه الگوریتم ماشین بردار پشتیبان

	precision	recall	F1-score	accuracy
تحويل به موقع	۹۸/۰	۹۱/۰	۹۴/۰	۹۵/۰
تحويل با تأخیر	۹۲/۰	۹۹/۰	۹۵/۰	

برای سنجش کارایی مدل ارائه‌شده صحت نتایج این مدل با الگوریتم‌های طبقه‌بندی دیگری مقایسه شده‌اند. این الگوریتم‌ها عبارت است از:

جدول ۱۳. مقایسه نتایج صحت مدل‌ها

الگوریتم	درخت تصمیم	رگرسیون لجستیک	نزدیک‌ترین همسایه	ماشین بردار پشتیبان
صحت پیش‌بینی مدل	۹۳/۰	۷۵/۰	۸۴/۰	۹۵/۰

۶-۲- تفسیرپذیری^۱

تفسیرپذیری، یک خصوصیت کلیدی در یادگیری ماشین است که به ما کمک می‌کند تصمیم‌های مدل را درک کرده و اطمینان حاصل کنیم که چرا یک مدل خاص به چه نتایجی رسیده است. تفسیرپذیری باعث افزایش اعتماد به مدل و قابلیت اعتبارسنجی آن می‌شود. با استفاده از روش‌های تفسیرپذیری، اطلاعات مهم و تصمیم‌های مدل قابل فهم‌تر می‌شوند [۲۸].

1. Interpretability




۶-۳- انتخاب ویژگی پس از اجرای مدل^۱

انتخاب ویژگی پس از اجرای مدل مرحله‌ای از فرایند پس از اجرای مدل است که بهبود تفسیرپذیری مدل را هدف قرار می‌دهد. در این مرحله، تحلیل ویژگی‌های مهم، حذف ویژگی‌های غیرضروری یا تطبیق ویژگی‌ها با نیازهای خاص انجام می‌شود. در واقع هدف از انتخاب ویژگی پس از اجرای مدل، رتبه‌بندی و کمی کردن سهم ویژگی در پیش‌بینی‌های مدل و یا عملکرد مدل می‌باشد. این اقدام‌ها منجر به قابل فهم‌تر و تفسیرپذیرتر شدن مدل می‌شود [۲۹].

۶-۴- روش حذف ویژگی بازگشتی (RFE)^۲

روش حذف ویژگی بازگشتی یک الگوریتم انتخاب ویژگی به سبک پوشش^۳ است که همچنین از انتخاب ویژگی مبتنی بر فیلتر^۴ به صورت داخلی استفاده می‌کند. در گام نخست مجموعه داده آموزشی پژوهش با تمامی ویژگی‌ها آموزش داده شد. سپس با برآزش الگوریتم ماشین بردار پشتیبان، ویژگی‌ها رتبه‌بندی شده و ویژگی‌های کم اهمیت‌تر کنار گذاشته شدند. در هر مرحله از جستجو، ویژگی‌های کم اهمیت به طور مکرر قبل از بازسازی مدل حذف شدند (شکل ۷). به این ترتیب ۴ ویژگی کشور مقصد^۵، روش حمل^۶، تأمین‌کننده^۷ و مکان تولید^۸ از مجموعه ۳۳ ویژگی به عنوان مؤثرترین ویژگی‌ها تعیین شدند.

1. Post-Model Feature Selection
2. Recursive Feature Elimination
3. Wrapper
4. Filter
5. Country
6. Shipment
7. Supplier
8. Manufacturing Site



شکل ۷. رویه روش حذف ویژگی بازگشتی برای تعیین مهم‌ترین ویژگی‌ها

۷- نتیجه‌گیری

در این پژوهش یک چارچوب برپایه روش ماشین بردار پشتیبان و بهینه‌سازی بیزی برای پیش‌بینی وضعیت تحویل کالای مراقبت‌های بهداشتی ارائه شد و کارایی آن با الگوریتم‌های رگرسیون لجیستیک، نزدیک‌ترین همسایه و درخت تصمیم مقایسه شدند. مجموعه داده استفاده‌شده مربوط به داده‌های زنجیره تأمین مراقبت‌های بهداشتی آژانس بین‌المللی توسعه ایالات متحده شامل بر ۱۰۳۰۰ نمونه و ۳۳ ویژگی و کلاس باینری بود که ۱ نشان‌دهنده تحویل به موقع و ۰ نشان‌دهنده تحویل با تأخیر است. نتایج پژوهش نشان می‌دهد که



چارچوب ارائه‌شده برپایه روش پایه ماشین بردار پشتیبان و بهینه‌سازی بیزی منجر به دقت طبقه‌بندی ۹۵ درصد می‌شود که در مقایسه با دیگر روش‌ها، بالاترین دقت طبقه‌بندی را دارد. براساس نتایج حاصل‌شده مشخص شد که روش بیش‌نمونه‌گیری به‌کار گرفته‌شده تأثیر به‌سزایی در افزایش کارایی مدل داشته است. نتایج حاصل از ماتریس اغتشاش نیز نشان داد که خطای نوع اول^۱ (FP) بسیار ناچیز بوده و تنها ۱ درصد از تحویل‌های با تأخیر، به اشتباه در دسته تحویل به‌موقع قرار گرفته‌اند. با توجه به بیان مسئله و همچنین مجموعه داده نامتعادل، چالش طبقه‌بندی کلاس تحویل با تأخیر اهمیت دارد که نتایج نشان می‌دهد چارچوب ارائه‌شده برپایه ماشین بردار پشتیبان و بهینه‌سازی بیزی دقت بالاتری نسبت به دیگر روش‌ها در طبقه‌بندی کلاس مذکور می‌باشد. نتایج حاصل نشان داد که ویژگی‌های کشور مقصد، روش حمل، تأمین‌کننده و مکان تولید تأثیرگذارترین ویژگی‌ها در پیش‌بینی وضعیت تحویل می‌باشند. با به‌کارگیری چارچوب پیشنهادی برپایه روش ماشین بردار و بهینه‌سازی، بهینه‌سازی بیزی وضعیت تحویل کالای مراقبت‌های بهداشتی قابل پیش‌بینی بوده و همچنین با مدیریت مؤثر زنجیره تأمین برپایه چارچوب پیشنهادی می‌توان به نرخ بالای تحویل به‌موقع دست یافت. در هیچ‌یک از پژوهش‌ها به موضوع تفسیرپذیری و تعیین ویژگی‌ها با بیشترین تأثیر در پیش‌بینی وضعیت تحویل پرداخته نشده است. با دانش بر مؤثرترین ویژگی‌ها در پیش‌بینی وضعیت تحویل، می‌توان با پیکربندی مناسب زنجیره تأمین مراقبت‌های بهداشتی از تأخیر در تحویل کالای مراقبت‌های بهداشتی جلوگیری کرد. در پژوهش‌های داخلی نیز به مسئله پیش‌بینی وضعیت تحویل کالا در زنجیره تأمین به‌ندرت پرداخته شده است و درضمن روش‌های یادگیری ماشین به‌کار گرفته نشده است بلکه تنها به ارزیابی داده‌های دستگاه‌های حسگر و داده‌های مسیر حمل‌ونقل پرداخته و یا اقدام به ردیابی لحظه‌ای محموله‌ها در زمان واقعی و بهینه‌سازی تدارکات و پشتیبانی شده است.

یکی از موانع این پژوهش، کیفیت و دقت داده‌ها است که می‌تواند تأثیر زیادی بر عملکرد الگو داشته باشد. از این‌رو فرایند پیش‌پردازش داده‌ها برای دستیابی به داده باکیفیت یکی از چالش‌های اصلی بوده است. پیاده‌سازی و اعمال مدل ترکیبی ماشین بردار پشتیبان و

1. False Positive

بهینه‌سازی بیزی پرچالش است. حجم بالای داده‌ها و نیاز به محاسبه‌های پیچیده می‌تواند باعث افزایش زمان پردازش شود.

پیشنهاد می‌شود در پژوهش‌های آینده با استفاده از روش‌های خوشه‌بندی روی داده پژوهش پیش‌رو اقدام به کشف دانش در خوشه‌های ایجادشده شود و از این راه نیز به رویدادهای جدید در زنجیره تأمین مراقبت‌های بهداشتی اقدام شود که به این ترتیب می‌توان به هزینه‌های جهانی برای کالاهای بهداشتی خاص، درک محدوده‌ها، روندهای قیمت‌گذاری و همچنین حجم کالای مراقبت‌های بهداشتی موردنیاز (به تفکیک کشورها) دست پیدا کرد. همچنین برای پژوهش‌های آینده پیشنهاد می‌شود روش‌های یادگیری عمیق و مدل‌های ترکیبی یادگیری ماشین و مدل‌های عامل بنیان به کار گرفته شود. زمینه دیگری برای بهبود می‌تواند به کارگیری انواع مختلف روش‌های انتخاب ویژگی برای شناسایی مهم‌ترین ویژگی‌ها برای طبقه‌بندی باشد. در نهایت، اعتبارسنجی نتایج بر یک مجموعه داده مستقل جداگانه می‌تواند اعتماد بیشتری به استحکام و تعمیم‌پذیری مدل پیشنهادی ارائه دهد.

۸- منابع

- [1] Arora M, Gigras Y. Importance of supply chain management in healthcare of third world countries. *International Journal of Supply and Operations Management* 2018;5(1):101-6.
- [2] Privett N, Gonsalvez D. The top ten global health supply chain issues: perspectives from the field. *Operations Research for Health Care*. 2014;3(4):226-30.
- [3] Lugada E, Komakech H, Ochola I, Mwebaze S, Olowo Oteba M, Okidi Ladwar D. Health supply chain system in Uganda: current issues, structure, performance, and implications for systems strengthening. *Journal of Pharmaceutical Policy and Practice*. 2022;15(1):14.
- [4] Nichols JA, Herbert Chan HW, Baker MA. Machine learning: applications of artificial intelligence to imaging and diagnosis. *Biophysical Reviews*. 2019;11:111-8.
- [5] دانشگر ف، قطری رز، کاظمی ا. «کسب دانش از زنجیره تأمین سلامت: روندها، تحلیل، نگرانی‌ها، پاسخ‌ها به همه‌گیری کوید-۱۹»، پژوهش‌های نوین در تصمیم‌گیری. ۱۴۰۲، (۴): ۸۷-۱۴۸.



- [6] Hippold S. Gartner Predicts the Future of Supply Chain Technology Stamford: Gartner; 2021 [updated April 14, 2021; cited 2024 July 2th]. Available from: <https://www.gartner.com/en/articles/gartner-predicts-the-future-of-supply-chain-technology>.
- [7] Abbas K, Afaq M, Ahmed Khan T, Song W-C. A blockchain and machine learning-based drug supply chain management and recommendation system for smart pharmaceutical industry. *Electronics*. 2020;9(5):852.
- [8] Leite H, Lindsay C, Kumar M. COVID-19 outbreak: Implications on healthcare operations. *The TQM Journal*. 2020;33(1):247-56.
- [9] Van Andel B. A machine learning approach to shipment consolidation. *MaRBL*. 2018;2.
- [10] Milovancevic M, Petkovic D. Adaptive neuro fuzzy estimation of important factors for e-commerce product shipment delivery 8th International Conference on Transportation and Logistics; 3 December; Nis, Serbia 2021. p. 53.
- [11] Keung KL, Lee CK, Yiu YH, editors. A machine learning predictive model for shipment delay and demand forecasting for warehouses and sales data. 2021 IEEE International Conference on Industrial Engineering and Engineering Management (ieem); 2021: IEEE.
- [12] Alnahhal M, Ahrens D, Salah B. Dynamic lead-time forecasting using machine learning in a make-to-order supply chain. *Applied Sciences*. 2021;11(21):10105.
- [13] Garg R, Kiwelekar AW, Netak LD. Logistics and Freight Transportation Management: An NLP based Approach for Shipment Tracking. *Pertanika Journal of Science & Technology*. 2021;29(4).
- [14] Ubaid A, Hussain F, Saqib M. Container shipment demand forecasting in the Australian shipping industry: A case study of Asia–Oceania trade lane. *Journal of Marine Science and Engineering*. 2021;9(9):968.
- [15] Hathikal S, Chung SH, Karczewski M. Prediction of ocean import shipment lead time using machine learning methods. *SN Applied Sciences*. 2020;2(7):1272.
- [16] Ermagun A, Punel A, Stathopoulos A. Shipment status prediction in online crowd-sourced shipping platforms. *Sustainable Cities and Society*. 2020;53:101950.
- [17] Wen Y-H. Shipment forecasting for supply chain collaborative transportation management using grey models with grey numbers. *Transportation Planning and Technology*. 2011;34(6):605-24.
- [18] Polim R. Real-Time Supply Chain Analytics-Shipment Duration Prediction. 2016.



- [19] Steinberg F, Burggräf P, Wagner J, Heinbach B, Saßmannshausen T, Brintrup A. A novel machine learning model for predicting late supplier deliveries of low-volume-high-variety products with application in a German machinery industry. *Supply Chain Analytics* 2023;1:100003.
- [20] Salari N, Liu S, Shen Z-JM. Real-time delivery time forecasting and promising in online retailing: When will your package arrive? *Manufacturing & Service Operations Management* 2022;24(3):1421-36.
- [21] Özdemir R, Taşyürek M, Aslantaş V. Improved Marine Predators Algorithm and Extreme Gradient Boosting (XGBoost) for shipment status time prediction. *Knowledge-Based Systems*. 2024;294:111775.
- [22] Peffers K, Tuunanen T, Rothenberger MA, Chatterjee S. A design science research methodology for information systems research. *Journal of Management Information Systems* 2007;24(3):45-77.
- [23] Cristianini N, Shawe-Taylor J. An introduction to support vector machines and other kernel-based learning methods: Cambridge university press; 2000.
- [24] Anderson MR, Cafarella M, editors. Input selection for fast feature engineering. 2016 IEEE 32nd International Conference on Data Engineering (ICDE); 2016: IEEE.
- [25] Victoria AH, Maragatham G. Automatic tuning of hyperparameters using Bayesian optimization. *Evolving Systems* 2021;12:217-23.
- [26] Daneshgar F, Hoseini V. A New Framework of Credit Scoring System Based On Support Vector Machine for Credit Risk Management: Evidence from Banks and Financial Institutions. *Journal of Economic & Management Perspectives* 2017 Sep;11(3):557-65.
- [27] Frazier PI. A tutorial on Bayesian optimization. arXiv preprint arXiv:180702811. 2018.
- [28] Linardatos P, Papastefanopoulos V, Kotsiantis S. Explainable ai: A review of machine learning interpretability methods. *Entropy* 2020;23(1):18.
- [29] Molnar C. Interpretable machine learning: Morrisville: Lulu. com; 2020.