

پیش‌بینی اختلالات زنجیره تأمین به کمک داده‌کاوی در مسیر پایداری و هوش مصنوعی

سعیده نادری^۱

^۱ دکترای مهندسی صنایع - برنامه‌ریزی و مدیریت تولید، گروه صنایع، دانشگاه آزاد تهران مرکز. تهران، ایران.

نام نویسنده مسئول:

سعیده نادری

Email: naderisaeide9@gmail.com

تاریخ دریافت: ۱۴۰۴/۰۱/۳۰

تاریخ پذیرش: ۱۴۰۴/۰۲/۲۹

چکیده

در دنیای پیچیده و همیشه در حال تغییر امروز، نگرانی‌ها در مورد کمبود داده‌های کافی با نگرانی‌ها در مورد داده‌های بیش از حد برای مدیریت زنجیره تأمین (SCM) جایگزین شده است. (حجم داده‌های تولید شده از تمام بخش‌های زنجیره تأمین، ماهیت تحلیل SCM را تغییر داده است. با افزایش حجم داده‌ها، کارایی و اثربخشی روش‌های سنتی کاهش یافته است. محدودیت‌های این روش‌ها در تجزیه و تحلیل و تفسیر حجم زیادی از داده‌ها، محققان را بر آن داشته تا روش‌هایی تولید کنند که توانایی بالایی در تجزیه و تحلیل و تفسیر کلان داده‌ها دارند شناخته‌شده‌ترین تکنیک‌های هوش مصنوعی (AI) با توسعه یک چارچوب مفهومی، مشارکت تکنیک‌های ML در انتخاب و تقسیم‌بندی تأمین‌کنندگان، پیش‌بینی ریسک‌های زنجیره تأمین، و تخمین تقاضا و فروش، تولید، مدیریت موجودی، حمل‌ونقل و توزیع، توسعه پایدار (SD) و اقتصاد دایره‌ای (CE) و محدودیت‌ها را مورد بحث قرار می‌دهد. جهت‌های تحقیقاتی آتی داده شده است.

واژگان کلیدی: الگوریتم یادگیری ماشین، الگوریتم، اختلال زنجیره تأمین، داده کاوی، پایداری.

۱. مقدمه

در محیط رقابتی امروز، ظهور انقلاب فناوری اطلاعات، جهانی شدن اقتصادی و انتظارات بالای مشتریان باعث تغییرات مختلفی در مدیریت زنجیره تأمین شرکت‌ها (SCM) شده است که اهمیت رقابت بین زنجیره‌های تأمین را به جای شرکت‌ها برجسته می‌کند [۱-۳]. SCM یکپارچه سازی فعال فعالیت‌های زنجیره تأمین از تأمین کنندگان اصلی از طریق مصرف کنندگان نهایی است که خدمات، محصولات و اطلاعاتی را ارائه می‌دهد که ارزش مشتری را به حداکثر می‌رساند و به مزیت رقابتی پایدار دست می‌یابد [۴]. در عصر داده‌های بزرگ، حجم زیادی از داده‌های تعاملی به طور معمول در صنایع مختلف فرآیندی ایجاد جمع آوری و بایگانی می‌شوند و این داده‌ها واقعاً دارایی مهمی در عملیات، کنترل و طراحی فرآیند هستند. استفاده هوشمندانه از این داده‌ها و استخراج اطلاعات و دانش از آنها پتانسیل زیادی برای بهره‌مندی دارد. رشد انفجاری در حجم داده‌ها از بخش‌های مختلف SCM، شرکت‌ها را مجبور به توسعه و پیاده‌سازی فناوری‌های جدیدی کرده است که قادر به تفسیر سریع و هوشمندانه حجم زیادی از داده‌ها هستند [۵، ۶] زیرا سیستم پشتیبانی تصمیم سنتی نمی‌تواند به طور رضایت‌بخشی با کلان

داده‌ها مواجه شود. از این رو، در عصر کلان داده، متخصصان زنجیره تامین به دنبال مدیریت کلان داده برای رسیدن به زنجیره تامین هوشمند هستند. روش‌های هوش مصنوعی (AI) مناسب‌ترین روش‌ها برای مقابله با این چالش مرتبط با کلان داده‌ها هستند. تکنیک‌های یادگیری ماشینی (ML) را می‌توان به عنوان زیرشاخه‌های محبوب در هوش مصنوعی در نظر گرفت که با استفاده از مجموعه داده‌های بزرگ، الگوهای بین متغیرها را به طور خودکار شناسایی و استخراج می‌کنند [۷]. الگوریتم‌های ML می‌توانند الگوهای ناشناخته را در میان داده‌ها شناسایی کنند، بینش جدیدی ایجاد کنند و محققان را به سمت مقصدهای مناسب هدایت کنند. تکنیک‌های ML را می‌توان در زمینه‌های متفاوتی از جمله تولید، عملیات، مراقبت‌های بهداشتی و مسکن استفاده کرد [۸]. علاوه بر این، ML به طور گسترده در مدیریت مناطق و جنبه‌های مختلف زنجیره تامین استفاده می‌شود. اخیراً الگوریتم‌های ML و کاربردهای آن در مدیریت زنجیره تامین مورد توجه محققان قرار گرفته است. نقاط ضعف روش‌های سنتی در تجزیه و تحلیل کلان داده‌ها، محققان را به استفاده از روش‌های ML سوق داده است که توانایی بالایی برای تجزیه و تحلیل و تفسیر حجم زیادی از داده‌ها دارند. (دلایل زیادی برای جایگزینی روش‌های سنتی با تکنیک‌های ML وجود دارد. اول اینکه، روش‌های سنتی نمی‌توانند مسائل غیرخطی را که در زنجیره‌های تامین دنیای واقعی گسترده هستند، حل کنند. تکنیک‌های ML می‌توانند این مشکل غیرخطی را به طور رضایت‌بخشی حل کنند. دوم، روش‌های سنتی قادر به مقابله با داده‌های بزرگ و بدون ساختار که از مناطق مختلف زنجیره تامین می‌آیند، نیستند. تکنیک‌های ML بسیار قوی‌تر از روش‌های آماری سنتی در شناخت و پیش‌بینی مؤثرترین عوامل بر عملکرد زنجیره تامین هستند (ما، ML را می‌توان به عنوان ابزار مهمی برای کمک به شرکت‌ها در تجزیه و تحلیل داده‌های بزرگ در SCM در نظر گرفت.

جستجوی اطلاعات و دانش جدید با استفاده از تجزیه و تحلیل داده‌های بزرگ می‌تواند به پیش‌بینی روندهای آینده کمک کند، که می‌تواند منجر به تصمیم‌گیری آگاهانه در بخش‌های مختلف SCM شود و یک پارادایم ارزشمند برای شرکت‌ها ایجاد کند. فناوری‌های نوظهور مانند اینترنت اشیا (IoT)، بلاک چین و تکنیک‌های یادگیری عمیق پیشرفته (ADL) می‌توانند زنجیره‌های تامین را به مکانیزم خودآگاهی مجهز کنند که در آن اشیاء عملیاتی مختلف به طور همزمان به هم متصل می‌شوند. SCM واقعاً به چنین سیستم هوشمند خودسازگاری برای مدیریت نوسانات تقاضای مشتری نیاز دارد. افزایش شفافیت و اتصال زنجیره تامین از طریق فناوری‌های IoT و بلاک چین می‌تواند نشانه خوبی برای رویارویی با تقاضاهای در حال تغییر مشتریان باشد. (می‌تواند جریانی از داده‌ها و اطلاعات بلادرنگ را بین بخش‌های مختلف زنجیره‌های تامین در هر نقطه از جهان ارائه دهد. (در ادبیات نیاز شدیدی به بررسی کاربردهای مختلف تکنیک‌های ML در بخش‌های مختلف زنجیره‌های تامین وجود دارد، زیرا اکثر آثار یک، دو یا حوزه‌های محدودی از زنجیره تامین را در نظر گرفته‌اند. بنابراین، این مقاله چارچوبی را توسعه می‌دهد که در آن متداول‌ترین الگوریتم‌های ML در مدیریت مناطق مختلف زنجیره تامین مورد بحث قرار خواهند گرفت.

۲. یادگیری ماشینی

تکنیک‌های ML برای آموزش ماشین‌ها به کار می‌روند که چگونه به طور خودکار حجم زیادی از داده‌ها را کارآمدتر مدیریت کنند. گاهی اوقات استخراج الگوها یا اطلاعات از حجم زیاد داده‌ها و تفسیر آنها با تکنیک‌های سنتی غیرممکن است [۱۵]. (فراوانی مجموعه داده‌های موجود باعث افزایش تقاضا برای تکنیک‌های ML شده است. تکنیک‌های ML به طور گسترده در صنایع مختلف از پزشکی گرفته تا ارتش برای کشف و استخراج دانش و اطلاعات از داده‌ها استفاده می‌شود. مطالعات زیادی توسط ریاضیدانان و برنامه نویسان انجام شده است که منجر به توسعه الگوریتم‌های مختلف ML شده است [۱۶]. در این مقاله، مروری بر کاربرد تکنیک‌های SML در نظر گرفته شده است. در برآورد تقاضا و فروش [۱۷-۱۹]، حمل و نقل و توزیع [۲۰-۲۲]، تولید [۲۳-۲۵]، کنترل موجودی [۲۲، ۲۶]، انتخاب تامین کننده و تقسیم بندی [۲۷-۳۰]، و غیره برخی از معروف ترین الگوریتم‌های یادگیری با شرح مختصری در جدول ۱ نشان داده شده است.

۳. یادگیری ماشینی در مدیریت زنجیره تامین

با وجود تعداد زیادی از انتشارات در زمینه ML و SCM به طور جداگانه، تعداد انتشاراتی که به کاربردهای الگوریتم‌های ML در مدیریت زنجیره تامین پرداخته‌اند، کافی نیست [۳۸]. از سوی دیگر، ارتباط کافی بین محققان و دست اندرکاران این

حوزه وجود ندارد. ممکن است ناشی از دانش ناکافی پزشکان در مورد قدرت و مزایای الگوریتم‌های ML در حل مسائل SCM باشد. در این بخش مروری بر کاربرد معروف‌ترین الگوریتم‌های ML در مدیریت مسائل مرتبط با زنجیره تامین شامل انتخاب تامین کننده، تقسیم بندی تامین کننده، پیش بینی ریسک زنجیره تامین، برآورد تقاضا و فروش، تولید، مدیریت موجودی و حمل و نقل ارائه شده است.

جدول ۱: الگوریتم‌های پرکاربرد ML.

نوع یادگیری	الگوریتم	توضیحات
یادگیری تحت نظارت	درخت تصمیم	با استفاده از مقادیر مرتبط، درخت‌های تصمیم (DTs) ویژگی‌ها را در گروه‌های مختلف دسته‌بندی می‌کنند که می‌توانند برای اهداف طبقه‌بندی اعمال شوند [۳۱].
	نایو بیز	Naïve Bayes را می‌توان به بهترین نحو برای خوشه بندی و طبقه بندی اشیاء به کار برد [۳۲].
	ماشین بردار پشتیبانی	با کار بر روی محاسبات حاشیه، ماشین بردار پشتیبانی (SVM) می‌تواند به بهترین شکل برای اهداف طبقه بندی اعمال شود [۳۳].
	K-نزدیک ترین همسایه	در نزدیکترین همسایه (KNN)، یادگیرنده معمولاً از داده‌های آموزشی استفاده می‌کند. هنگامی که داده‌های آزمون به زبان آموز معرفی می‌شود، هر دو داده را با هم مقایسه می‌کند. در اینجا، K بیشتر داده‌های همسایه از یک مجموعه آموزشی گرفته شده است. (اکثریت K گرفته می‌شود که به عنوان کلاس جدید برای داده‌های آزمون عمل می‌کند [۳۴].
	شبکه عصبی تحت نظارت	با استفاده از شبکه عصبی نظارت شده (SNN)، خروجی پیش‌بینی شده و خروجی واقعی با هم مقایسه می‌شوند و با توجه به خطای شناسایی شده، پارامترها اصلاح شده و دوباره به عنوان ورودی شبکه عصبی در نظر گرفته می‌شوند [۱۵].
یادگیری بدون نظارت	K-به معنای خوشه بندی است	با استفاده از شباهت خوشه‌های داده‌ها، الگوریتم خوشه‌بندی K-means (KM) خوشه‌های K را تعریف می‌کند که در آن مرکز خوشه‌ها میانگین مقادیر است [۳۵].
	تجزیه و تحلیل مؤلفه‌های اصلی	تجزیه و تحلیل مؤلفه اصلی (PCA) می‌تواند محاسبات سریع تر و آسان تر را فراهم کند زیرا بعد داده‌ها را کاهش می‌دهد [۳۴].
	شبکه عصبی بدون نظارت	شبکه عصبی بدون نظارت (UNN) داده‌ها را بر اساس شباهت‌هایشان دسته بندی می‌کند. از آنجایی که خروجی ناشناخته است، UNN همبستگی بین ورودی‌های مختلف را در نظر می‌گیرد و آنها را در گروه‌های مختلف طبقه بندی می‌کند [۱۵].
یادگیری نیمه نظارتی	خودآموزی	خودآموزی ابتدا استفاده از داده‌های برچسب دار را طبقه بندی می‌کند و سپس از داده‌های بدون برچسب به عنوان ورودی استفاده می‌شود [۱۵].
	دستگاه بردار پشتیبانی انتقالی	ماشین بردار پشتیبانی انتقالی (TSVM) به عنوان توسعه SVM، داده‌های برچسب دار و بدون برچسب را در نظر می‌گیرد تا اطمینان حاصل کند که حاشیه بین آنها به حداکثر می‌رسد [۱۵].
یادگیری گروهی	تقویت	تقویت از دو نوع متغیر استفاده می‌کند، یعنی یادگیرندگان ضعیف و یادگیرندگان قوی. با گروه بندی یادگیرندگان ضعیف و تبدیل آنها به یادگیرندگان قوی، هدف آن کاهش تعصب و واریانس است [۳۶].
	کوله بری	Bagging ابزار دیگری است که می‌تواند برای کاهش واریانس و افزایش دقت و پایداری ML استفاده شود [۳۷].

۱.۳. کاربرد الگوریتم‌های یادگیری ماشین در انتخاب تامین کننده

انتخاب تامین کننده را می‌توان به عنوان فعالیت اصلی در عملکرد خرید در نظر گرفت [۳۹]. با توجه به نقش مهم تامین کنندگان در زمان، هزینه و کیفیت، مدیران زنجیره تامین تلاش زیادی برای فرآیند انتخاب تامین کننده انجام داده‌اند. (فرآیند انتخاب الکترونیکی را می‌توان با تکنیک‌های MCDM که شامل عوامل متضاد مختلفی است پوشش داد. (بنابراین، یافتن تعادل مناسب بین این عوامل وظیفه مهمی برای مدیران خرید است. تکنیک‌های MCDM از تصمیم گیرندگان در ارزیابی مجموعه‌ای از گزینه‌ها حمایت می‌کنند [۲۷]. از طرف دیگر، روش‌های MCDM به روش‌های توصیفی و ایستا مانند سایر روش‌های سنتی طبقه‌بندی می‌شوند، در حالی که در بازار رقابتی امروزی، روش‌های تحلیل پیش‌بینی کننده قطعاً مفیدتر از روش‌های توصیفی هستند تکنیک یادگیری و تکنیک یادگیری Q به عنوان یک تکنیک یادگیری تقویتی (RL) بارها توسط محققان برای حل مشکل انتخاب تامین کننده استفاده شده است. در ادامه نحوه اعمال برخی از تکنیک‌های ML برای حل مشکل انتخاب تامین کننده مورد بحث قرار گرفته است.

۱.۱.۳. انتخاب تامین کننده با استفاده از تکنیک ترکیبی DT و P-SVM.

یکی از تکنیک‌های ML است که در مسائل طبقه بندی که مجموعه داده بزرگ نیست و می‌توان با یک مدل مشابه مدل سازی کرد، استفاده می‌شود. علاوه بر این، این طبقه‌بندی کننده می‌تواند زمانی استفاده شود که فقط چند ویژگی در دسترس باشد یا مدلی مورد نیاز باشد که بتوان آن را به صورت ساده‌تر تجسم و توضیح داد. DT یک روش موثر و سریع برای طبقه بندی مجموعه داده‌ها ارائه می‌دهد. اخیراً DT در حوزه‌های مختلف استفاده شده است [۴۰-۴۲]. علاوه بر این، DT‌ها را می‌توان به عنوان جایگزینی برای یافتن راه حل برای یک مسئله چند طبقه‌ای که دارای پیش بینی کننده‌های باینری است، استفاده کرد، زیرا دارای ساختار سلسله مراتبی است [۲۷]. (ساختار سلسله مراتبی شامل شاخه‌ها و گره‌ها می‌شود. Baryannis و همکاران [۱۳] خروجی‌های تکنیک‌های SVM و DT را در منطقه زنجیره تامین مقایسه کردند. (نتایج مطالعه آنها نشان داد که مدل‌های پیش‌بینی SVM داده‌ها را برای طبقه‌بندی و تحلیل رگرسیون تجزیه و تحلیل می‌کنند. با در نظر گرفتن نتایج پایین‌تر برای معیارهای مختلف، مدل‌های SVM همچنین می‌توانند نتایج خوبی را در سراسر دقت به دست آورند. معیارهای همراه کننده در سناریوهای مختلف، در مورد DT results، می‌توان مشاهده کرد که نتایج کاملاً مشابه بوده است.

در این بخش، ماشین بردار پشتیبانی پتانسیل (P-SVM) به عنوان یک رویکرد جدید به SVM اصلی پیشنهاد شده توسط هوکرایتر و اوپرمایر [۴۳] معرفی می‌شود که با ترکیب می‌شود تا مشکل انتخاب تامین کننده را حل کند. P-SVM می‌تواند برای ساخت طبقه بندی کننده‌های باینری و انتخاب ویژگی‌های مختلف به طور همزمان استفاده شود. (تکنیک ترکیبی توسعه یافته توسط Guo و همکاران [۲۷] (بر اساس P-SVM و DT) یک تامین کننده را بر اساس سه مرحله ارزیابی و انتخاب می‌کند:

مرحله ۱. با استفاده از نمونه‌های آموزشی، DT را از طریق الگوریتم Kruskal سازگار تولید می‌کند (برای اطلاعات بیشتر در مورد الگوریتم Kruskal، به Guo, Yuan, Tian [۲۷]، صفحه ۶۹۸۴ مراجعه کنید).


مرحله ۲. P-SVM برای ساخت طبقه بندی کننده‌های باینری و انتخاب ویژگی‌های گره‌های مرتبط استفاده می‌شود.

مرحله ۳. P-SVM با استفاده از مقادیر نمونه‌های جدید به عنوان ورودی طبقه‌بندی کننده‌های باینری، تامین کنندگان را ارزیابی می‌کند و بهترین را بر اساس DT انتخاب می‌کند.

در روش تکنیک‌های ترکیبی DT و P-SVM همانطور که در شکل ۱ نشان داده شده است، در گره‌های A، B و C، طبقه بندی کننده‌های باینری با استفاده از ویژگی‌های انتخاب شده تعریف می‌شوند. به عنوان مثال، نمونه‌های کلاس ۲ از کلاس‌های ۱، ۳، و ۴ نمونه جدا می‌شوند که در گره‌های B و C طبقه بندی می‌شوند. (بنابراین، نمونه‌های جدید فقط باید در هر یک از گره‌ها به عنوان زیرمجموعه‌ای از ویژگی‌های اولیه تعریف شوند. علاوه بر این، برای تشکیل یک سیستم سلسله مراتبی، برخی از زیرمجموعه‌ها با استفاده از P-SVM به دست می‌آیند. به عنوان مثال، زمانی که آنها با یک مجموعه نمونه با کلاس ۲ تعریف شوند، باید آنها را با کلاس ۲ تعریف کرد. از نمونه‌های کلاس‌های ۱، ۳، و ۴ جدا شده‌اند، علاوه بر این، نمونه‌های کلاس ۳ باید با زیرمجموعه‌ای از ویژگی‌هایی که با B مشخص شده‌اند، توصیف شوند. که تامین کنندگان باید با توجه به بسیاری از معیارها

ارزیابی شوند (تعداد معیارها، انجام فشرده سازی ثابت را برای تصمیم گیران به منظور تعیین وزن معیارها دشوار می کند و سپس ارزیابی عملکرد هر تامین کننده بالقوه را با توجه به هر معیار وزنی باروش سنتی بسیار پیچیده می کند). تکنیک ترکیبی P-SVM-DT به نتایج بسیار بهتری نسبت به روش های MCDM سنتی و SVM اصلی در حل مشکل انتخاب تامین کننده به دلیل سه دلیل زیر منجر می شود [۲۷]:

- (I) معرفی ساختار سلسله مراتبی تکنیک ترکیبی P-SVM-DT تعداد طبقه بندی کننده های باینری را کاهش می دهد.
(II) ترکیب با الگوریتم Kruskal، ساختار سلسله مراتبی P-SVM-DT برای افزایش دقت و کاهش زمان محاسبه در طبقه بندی های مختلف طراحی شده است.
(III) برای ارتقای عملکرد تعمیم، P-SVM "آموزنده ترین" ویژگی ها را برای توسعه طبقه بندی کننده ها انتخاب می کند.




شکل ۱: ساختار تکنیک ترکیبی P-SVM و DT [۲۷].

۲.۱.۳. انتخاب تامین کننده با استفاده از یادگیری تقویتی.
RL برخلاف سایر روش های ML نیازی به مدلی از محیط ندارد و قابلیت یادگیری آنلاین را دارد. در این بخش، تکنیک یادگیری Q به عنوان یکی از تکنیک های RL که به طور گسترده دنبال می شود برای حل مشکل انتخاب تامین کننده معرفی می شود. Croson و Valluri [۲۸] یک تکنیک یادگیری Q اصلاح شده را برای ارزیابی و انتخاب تامین کنندگان پیشنهاد کرده اند. Q-learning یک الگوریتم RL بدون مدل است که به اقدامات با نتایج مثبت پاداش می دهد و اقدامات با نتایج منفی را جریمه می کند. در این راستا، $Q_t(a_i)$ ارزش تامین کننده را در سطح کیفیت a_i در زمان t نشان می دهد. ارزش تامین کننده در سطح کیفیت a_i در زمان $t+1$ ، با معادله زیر به روز می شود:

$$Q_{t+1}(a_i) = Q_t(a_i) + \alpha [P_{t+1}(a_i) + Q_t(a_i)] \quad (1)$$

معادله یادگیری Q با معادله (۱) نشان داده می شود که در آن فرض ضریب تخفیف ۱ است و بین دوره ها ۱ در نظر گرفته می شود. در اینجا $P_{t+1}(a_i)$ سود تامین کنندگان در سطح کیفی a_i است. حالت های مختلف فرآیند تصمیم مارکوف شامل سطوح مختلف کیفیتی است که تامین کنندگان می توانند در سطح ۱ کیفیت تولید کنند. از ۰ تا ۱. (الگوریتم های اصلاح شده یادگیری Q برای به دست آوردن همگرایی سریع تر استفاده شده اند. در الگوریتم اولیه، اگر عوامل تأمین کننده شرط رسیدن به «کالاهای درجه یک» را برآورده کنند، سطح کیفیت برای دریافت پاداش انتخاب می شود؛ اما در الگوریتم اصلاح شده، همه سطوح کیفیت انتخاب شده پایین تر از سطح کیفی انتخاب شده خواهد بود. جریمه شده است (همانطور که در شکل ۲ الف)، ۰.۵ سطح خاصی از کیفیت است و تمام سطوح دیگر بالاتر از ۰.۵ پاداش داده می شود (در شکل ۲ ب) نشان داده شده است،

که در آن ۰.۵ سطح کیفیت انتخاب شده است، و می‌توان مشاهده کرد که تمام سطوح کیفیت پایین‌تر از ۰.۵ جریمه می‌شوند. (منطق پشت استفاده از اقدامات جریمه یا پاداش به توانایی تامین کننده برای برآورده کردن الزامات تعریف شده در سطح کیفیت انتخابی مربوط می‌شود. (به این معنی است که اگر تامین کنندگان به سطح کیفیت انتخاب شده برسند، به احتمال زیاد در دوره‌های بعدی به سطح بالاتری می‌رسد که می‌تواند با سود بیشتر پاداش داده شود. با این حال، اگر تامین کنندگان نتوانند نیازهای تامین کننده را در سطح کیفی انتخاب شده برآورده کنند.



شکل ۲: RL تحت الگوریتم یادگیری اصلاح شده [۲۸].

۲.۳. کاربرد الگوریتم‌های یادگیری ماشین در تقسیم بندی تامین کنندگان.
تقسیم‌بندی تامین‌کننده یکی از فعالیت‌های استراتژیک هر سازمانی است که از طریق آن تامین‌کنندگان بر اساس شباهت‌هایشان به گروه‌هایی دسته‌بندی می‌شوند. قراردادهای مدیریت و رسیدگی به امور تامین کنندگان در هر گروه مشابه و با تامین کنندگان در گروه‌های دیگر متفاوت است. تقسیم‌بندی تامین‌کننده، کارایی و اثربخشی روابط با تامین‌کنندگان را ارتقا می‌دهد و منجر به توسعه و بهبود عملکرد سازمان می‌شود [۲۹، ۴۴]. بررسی ادبیات بخش‌بندی نشان می‌دهد که تقسیم‌بندی تامین‌کننده در مقایسه با تقسیم‌بندی مشتری توجه کمی را به خود جلب کرده است و هنوز در مراحل اولیه است. در حالی که تقسیم بندی مشتری یکی از اهداف سمت تقاضای بازار است، تقسیم بندی تامین کننده بر اهداف سمت عرضه بازار تمرکز دارد [۳۰].

به طور کلی تقسیم بندی بازار را می‌توان به سه دسته به شرح زیر تقسیم کرد:

(الف) تقسیم بندی مشتریان یا مصرف کنندگان نهایی

(ب) تقسیم بندی مشتریان صنعتی یا سمت تقاضا در بازار B2B2

(ج) تقسیم بندی تامین کنندگان یا طرف عرضه شده بازار B2B

در حالی که ادبیات تحقیق برای دو مورد اول نسبتاً غنی است، مورد سوم - تقسیم‌بندی تامین‌کننده - نسبتاً نادیده گرفته شده است و مطالعات کمی به منظور ارائه ابزاری عملی که می‌تواند در شرایط دنیای واقعی اعمال و اجرا شود، انجام شده است [۴۵]. بررسی تقسیم‌بندی تامین‌کننده نشان می‌دهد که در اکثر مطالعات تحقیقاتی در این زمینه، از روش‌های MCDM در شرایط فازی برای ارزیابی و بخش‌بندی تامین‌کنندگان استفاده شده است. برخی از این مطالعات در جدول ۲ ارائه شده‌اند. بیشتر روش‌های MCDM که در جدول ۲ ذکر شده‌اند، روش‌های مبتنی بر متخصص و/یا مبتنی بر مقایسه زوجی هستند. یکی از معایب مهم این روش‌ها ضعف در برخورد با داده‌های بزرگ است. (بنابراین، محققان توجه خود را به استفاده از روش‌های ML در ارزیابی و مدیریت تامین کنندگان جلب کرده‌اند [۵۱-۵۳] که حتی کارآمدتر از روش‌های سنتی هستند. در این بخش، کاربرد ML در تقسیم‌بندی تامین‌کننده مورد توجه قرار گرفته است. Bai و همکاران [۱۴] یک روش MCDM-ML را برای ارزیابی و بخش‌بندی تامین‌کنندگان پیشنهاد کردند. در ادامه، مراحل پیشنهادی تامین‌کنندگان MC ارائه شده است:

مرحله ۱. مجموعه ای از معیارها را برای ارزیابی تامین کنندگان مشخص کنید

مرحله ۲. ارزیابی و امتیاز دادن به تامین کنندگان با توجه به هر یک از معیارهای وزنی با استفاده از روش MCDM برتر (مانند آنتروپی، PROMETHEE، و TOPSIS) (تکنیک برای ترتیب اولویت بر اساس شباهت به راه حل ایده آل (TOPSIS))

مرحله ۳. تعیین اهمیت/وزن هر معیار با استفاده از روش وزنی MCDM (به عنوان مثال، آنتروپی، AHP، و BWM)

مرحله ۴. تامین کنندگان را بر اساس امتیاز آنها با استفاده از روش ML نظارت شده/بدون نظارت (به عنوان مثال، K-means، فازی C-means، SVM، و DT) تقسیم بندی کنید.

۳.۳. کاربرد الگوریتم‌های یادگیری ماشین در مدیریت ریسک‌های زنجیره تامین.

مدیریت ریسک زنجیره تامین (SCRM) به تلاش‌های هماهنگ و مشترک همه طرف‌های درگیر در یک زنجیره تامین برای ارزیابی، شناسایی، نظارت و کاهش ریسک‌ها با هدف افزایش استحکام و انعطاف‌پذیری، کاهش آسیب‌پذیری زنجیره تامین و تضمین تداوم و سودآوری اشاره دارد. SCRM طیف گسترده‌ای از اقدامات و تصمیمات را در بر می‌گیرد که منجر به طیف وسیعی از راه حل‌ها شده است که توسط بسیاری از محققان دنبال می‌شود.

(۱) تجزیه و تحلیل تصمیم‌گیری چند معیاره (MCDA). (دسته است شامل رویکردهای تثبیت شده برای ارزیابی معیارهای مختلف مرتبط با ریسک است که بر عملکرد زنجیره تامین تأثیر می‌گذارد، و همچنین کارایی راه‌حل‌های بالقوه، مانند AHP ترکیبی، رویکرد [56] PROMETHEE، و رویکرد TOPSIS-CRITIC فازی یکپارچه [۵۷، ۵۸]. روش‌های مبتنی بر برنامه‌ریزی فازی یا بهینه‌سازی تصادفی و قوی را در بر می‌گیرد [۵۱، ۵۴، ۵۹، ۶۰] (۳) تکنیک‌های هوش مصنوعی در حوزه SCRM یا معمولاً تحقیقات زنجیره تامین [۶۱] اخیراً به دلیل در دسترس بودن مقادیر زیادی از داده‌ها و همچنین افزایش موفقیت‌آمیز ML بوده است. همچنین منجر به استفاده از پتانسیل تکنیک‌های هوش مصنوعی در SCRM توسط محققان در فرآیندهایی مانند پیش‌بینی، شناسایی ریسک، ارزیابی و پاسخ شده است [۶۲-۶۹].

جدول ۲: روش‌های پرکاربرد در تقسیم بندی تامین کنندگان.

نویسندگان	روش مورد استفاده برای تقسیم بندی تامین کنندگان
رضایی و اورت [۴۶]	تقسیم‌بندی تامین‌کننده با استفاده از دو معیار کلی توانایی و تمایل تامین‌کنندگان با استفاده از منطق فازی
رضایی و اورت [۴۵]	تقسیم بندی تامین کننده با استفاده از دو معیار کلی توانایی و تمایل تامین کنندگان با استفاده از AHP3 فازی
رضایی و همکاران [۴۷]	تقسیم‌بندی تامین‌کننده با استفاده از دو معیار کلی توانایی و تمایل تامین کنندگان، با استفاده از تکنیک BWM (بهترین روش (BWM)).
سگورا و ماروتو [۴۸]	تقسیم‌بندی تامین‌کننده با استفاده از دو بعد استراتژیک و حیاتی با استفاده از تکنیک‌های MAUT (نظریه سودمندی چند ویژگی (MAUT)) و PROMETHEE (روش سازمان رتبه‌بندی ترجیحی برای غنی‌سازی ارزیابی‌ها (PROMETHEE)).
رضایی و همکاران [۴۴]	تقسیم‌بندی تامین‌کننده بر اساس معیارهای محیطی با استفاده از تکنیک‌های ELECTRE (حذف و انتخاب واقعیت ترجمه (ELECTRE)) TRI-rC
رضایی و فلاح لاجیمی [۴۹]	تقسیم‌بندی تامین‌کننده بر اساس رویکرد ترکیبی ماتریس‌های PPM (ماتریس خرید نمونه کارها (PPM)) و SPP (ماتریس پتانسیل تامین‌کننده (SPM)) با استفاده از تکنیک BWM
پارکوهی و همکاران [۵۰]	انتخاب و تقسیم‌بندی تامین‌کنندگان بر اساس انعطاف‌پذیری آنها با استفاده از تکنیک‌های DEMATEL (آزمایشگاه آزمایشی و ارزیابی تصمیم‌گیری (DEMATEL)) و SAW (خاکستری (سنجشی افزودنی ساده (SAW)).

یک چارچوب داده محور برای مدیریت ریسک‌های زنجیره تامین شامل دو مرحله کلی است:

(i) شناسایی ریسک. شناسایی ریسک اولین فعالیت در SCRM است. محققان مختلف از الگوریتم‌ها و روش‌های مختلفی برای شناسایی ریسک‌ها استفاده کرده‌اند. تکنیک‌های طبقه‌بندی و خوشه‌بندی مانند SVM و DT تکنیک‌هایی هستند که به طور گسترده برای شناسایی ریسک‌ها استفاده می‌شوند. پس از شناسایی SCR، زمان ارزیابی ریسک‌ها و پیشنهاد برخی فعالیت‌های مناسب برای کاهش خطرات است.

(ب) ارزیابی ریسک و پاسخ. ML و تجزیه و تحلیل داده‌های بزرگ نیز برای مقابله با ارزیابی ریسک استفاده شده است. شبکه‌های عصبی مصنوعی (ANN) و شبکه‌های بیزی دو تکنیک پرکاربرد ML هستند که پتانسیل قابل قبولی در مدل‌سازی برای ارزیابی ریسک نشان داده‌اند [۷۰، ۷۱].

در ادامه، چارچوبی برای ادغام تکنیک‌های هوش مصنوعی در فرآیند SCRM پیشنهاد شده است که می‌تواند پیش‌بینی ریسک زنجیره تامین را افزایش دهد. (هدف این چارچوب دو طرفه ایجاد هم‌افزایی و تعامل بین هوش مصنوعی و متخصصان زنجیره تامین است: هر تصمیمی که باید توسط کارشناسان هوش مصنوعی اتخاذ شود، همیشه به ورودی‌های خاص زنجیره تامین بستگی دارد، در حالی که مدل‌های توسعه یافته و نتایج تولید شده باید قابل تفسیر باشند تا تصمیم‌گیری بر اساس آنها باشد یا بتوانند بر روی چارچوب تصمیم‌گیری SCRM تاثیر بگذارند. در شکل، نقطه کانونی بر روی وظایف اصلی درگیر در یک روش هوش مصنوعی مبتنی بر داده است (سمت راست شامل وظایف سنتی است که در یک فرآیند استاندارد SCRM دخیل هستند. همانطور که می‌توان درک کرد، این چارچوب بر اساس هم‌افزایی موثر بین تیمی از متخصصان هوش مصنوعی مبتنی بر داده و تیمی از متخصصان مدیریت ریسک در یک زنجیره تامین ساخته شده است.

۳.۴. کاربرد الگوریتم‌های یادگیری ماشین در برآورد تقاضا/فروش.

در SCM، برنامه ریزی بر اساس برآورد فروش/تقاضا است. با معرفی تحلیل‌های غیرخطی، تکنیک‌های ML برای پیش‌بینی و پیش‌بینی دقیق تقاضا، فروش و موجودی مورد استفاده قرار گرفته‌اند که منجر به بهینه‌سازی عملکرد زنجیره تامین می‌شود. یک سیستم پیش‌بینی هوشمند منجر به بهینه‌سازی عملکرد، کاهش هزینه‌ها و افزایش فروش و سود می‌شود. در این مورد، لازم است که پارامترهای مرتبط با متغیرهای توضیحی متعدد به متغیرهای وابسته آنها به صورت کاملاً غیرخطی مرتبط شوند. تکنیک‌های ML با متفاوت بودن از روش‌های سنتی مانند هموارسازی نمایی، میانگین متحرک، روش سری‌های زمانی و روش باکس-جنکینز، معمولاً به شدت به دقت داده‌های تاریخی متکی نیستند، بنابراین تکنیک‌های ML به عنوان جایگزین‌های عالی برای پیش‌بینی و برنامه‌ریزی تقاضا در SCM معرفی شده‌اند [۷۲]. به عنوان مثال، [omassey 73] یک مدل پیش‌بینی را با روش‌های پیشرفته مانند داده‌کاوی و منطق فازی برای فروش پیشنهاد کرد. (عملکرد مدل eir قابل اعتمادتر از مدل‌های سنتی است. (آیا مدل در شرایطی مانند فصلی بودن شدید فروش، تقاضای بی‌ثبات و تعداد وسیعی از اقلام با چرخه عمر کوتاه یا عدم وجود داده‌های فازی تاریخی برای پس‌زمینه سیستم‌های ریخته‌گری به خوبی کار می‌کند. (سیستم است که امکان تولید مدلی را فراهم می‌کند که به طور خودکار رویکرد متخصص را هنگامی که پیش‌بینی‌های شهودی را با توجه به متغیرهای توضیحی انجام می‌دهد، بازسازی می‌کند. (مراحل دیگر برای پیاده‌سازی این سیستم پیش‌بینی فازی به شرح زیر مورد نیاز است:

(۱) حذف تأثیر متغیرهای توضیحی از فروش تاریخی

(۲) استفاده از فروش پایه به عنوان داده‌های حاصل برای پیش‌بینی خط پایه سال آینده، به عنوان مثال، استفاده از یک


تکنیک پیش‌بینی اولیه با توجه به میانگین فصلی

(۳) افزودن تأثیر متغیرهای توضیحی در مورد سال آینده به این پیش‌بینی پایه


۵.۳. کاربرد الگوریتم‌های یادگیری ماشین در مدیریت موجودی.

ذخیره سازی هزینه‌های مهمی در SCM دارد. به عنوان مثال، هزینه‌های سالانه ذخیره‌سازی در زنجیره‌های تامین حدود ۱۵ تا ۳۵ درصد کل ارزش تجاری آنها است [۷۴]. مدیریت موجودی زنجیره تامین به دنبال کاهش هزینه‌ها، افزایش تنوع محصول و همچنین بهبود خدمات مشتری است. با این حال، تخمین دقیق، پیش‌بینی و جدول ۲: (e) روش‌های پرکاربرد در

تقسیم‌بندی تأمین‌کننده. روش مؤلفان برای تقسیم‌بندی تأمین‌کننده رضایی و اورت [۴۶] تقسیم‌بندی تأمین‌کننده با استفاده از دو معیار کلی توانایی تأمین‌کنندگان و تمایل با استفاده از منطق فازی رضایی و اورت [۴۵] «رضایی و همکاران [۴۷] تقسیم‌بندی تأمین‌کننده با استفاده از دو معیار کلی توانایی و تمایل تأمین‌کنندگان، با استفاده از تکنیک BMW (بهترین روش تقسیم‌بندی تأمین‌کننده با استفاده از دو معیار کلی توانایی و تمایل تأمین‌کنندگان، با استفاده از MAUT (BWM) Segura و Maroto [۴۸] تقسیم‌بندی تأمین‌کننده با استفاده از دو بعد استراتژیک و حیاتی با استفاده از MAUT (روش ارزیابی مطلوبیت چندگانه برای سازمان‌دهی MATHEE (PROMETHEE)) تکنیک‌ها رضایی و همکاران [۴۴] تقسیم‌بندی تأمین‌کننده بر اساس معیارهای محیطی با استفاده از ELECTRE (حذف و انتخاب واقعیت ترجمه‌کننده (ELECTRE)) تکنیک‌های TRI-rc رضایی و فلاح لاجیمی [۴۹] تقسیم‌بندی تأمین‌کننده بر اساس رویکرد ترکیبی PPM (PPM) و پتانسیل SPP ماتریس (SPM)) با استفاده از تکنیک BMW پارکویی و همکاران. [۵۰] انتخاب و تقسیم‌بندی تأمین‌کنندگان بر اساس انعطاف‌پذیری آن‌ها با استفاده از تکنیک‌های DEMATEL (آزمایشگاه آزمایش و ارزیابی تصمیم‌گیری (DEMATEL)) و SAW خاکستری (سنجش افزودنی ساده (SAW)) برای دسترسی به اطلاعات مربوط به همه این اهداف توسط قوانین تصمیم‌گیری سنتی دشوار است زیرا این اطلاعات معمولاً بر اساس تجربه و قضاوت خود مدیران اختراع بالا هستند. بنابراین، ورودی موجودی یک پارامتر نامشخص است. در سال‌های اخیر، ناکارآمدی روش‌های سنتی در مواجهه با عدم قطعیت، محققان را به استفاده از هوش مصنوعی سوق داده است. ابزارهای ML می‌توانند الگوهای قابل مقایسه ورودی سریع در مجموعه داده‌های انبار را بررسی کنند. گوموس و همکاران [۲۶] از شبکه‌های عصبی برای پیش‌بینی زمان سرب استفاده کرد. (آنها از تقاضای فازی عصبی در یک زنجیره تأمین چند طبقه استفاده کردند. (نتایج نشان داد که مدل پیشنهادی آنها به طور موثر عملکرد مدیریت موجودی را بهبود می‌بخشد. علاوه بر این، ML عملکرد کارآمدی را برای تحویل داخلی یا بازرسی خودکار آسیب در داخل مراکز لجستیک نشان داده است. در نتیجه، ابزارهای ML قادر به یافتن الگوهای پنهان شده و کشف نشده نیستند.



شکل ۳: چارچوب پیش‌بینی ریسک مبتنی بر داده [۵۴].



شکل ۴: سیستم پیش بینی فازی [۷۳].

۶.۳. کاربرد الگوریتم‌های یادگیری ماشین در حمل و نقل و توزیع.

مشکلات مسیریابی خودرو (VRPs) به عنوان یکی از کاربردی ترین مسائل در SCM طبقه بندی می‌شوند [۷۵-۸۰]. حل VRP یکی از کاربردهای بالا و شناخته شده ML در SCM است. (مسیر بهینه برای حمل و نقل وسایل نقلیه یک مسئله مهم در SCM برای ارائه محصولات و خدمات به موقع به مشتریان است؛ در بیشتر موارد، مسیریابی فراتر از توانایی مغز انسان است. ابزارهای ML عملکرد عالی برای تجزیه و تحلیل مجموعه داده‌های بزرگ و متنوع و پیش بینی دقیق پارامترها دارند. Cirovic et al. توسط یک الگوریتم بازپخت شبیه سازی شده (این مدل عملکرد مسیرهای شبکه توزیع را ارزیابی می‌کند. الگوریتم‌های ML قادر به تولید مسیرهای تحویل بهتر با کاوش عینی و به موقع الگوی حمل و نقل، رفتار مصرف کنندگان، زیرساخت‌ها و وسایل نقلیه هستند.

۷.۳. کاربرد الگوریتم‌های یادگیری ماشین در تولید.

ابزارهای ML با در نظر گرفتن محدودیت‌های متعدد، برنامه ریزی تولید و دقت برنامه ریزی کارخانه را بهبود می‌بخشند. ابزارهای ML همچنین تعادل محدودیت‌ها را به‌طور مؤثرتری نسبت به مواردی که در گذشته به‌صورت دستی انجام می‌شد، ممکن می‌سازد، به‌ویژه برای تولیدکنندگانی که به گردش‌های کاری تولید سفارشی و ساخت به سهام متکی هستند. تولیدکنندگان می‌توانند از ابزارهای ML برای کاهش تأخیر زنجیره تامین برای قطعات و قطعات مورد استفاده در سفارشی‌ترین محصولات خود استفاده کنند. به عنوان مثال، در مواجهه با مقررات مختلف تولید و الزامات سفارشی سازی هر کشور، چن و همکاران. [۸۲] از NN ها برای گروه بندی نیازهای سفارشی سازی مشابه استفاده کرد. (en، آنها از اطلاعات موجود برای انتخاب قطعات برای مدیران تولید استفاده کردند، که به میزان قابل توجهی هزینه را در طول زنجیره تامین در مقایسه با تصمیمات انسانی کاهش داد. به طور کلی، ابزارهای ML می‌توانند پیش‌بینی زمان تولید را با زمان پاسخ کوتاه‌تر انجام دهند.

۸.۳. کاربرد الگوریتم‌های یادگیری ماشین در توسعه پایدار.

در صنایع مختلف، ظهور تمرکززدایی در سطح ساختار سازمانی دامنه SCM را محدود می‌کند در حالی که تمرکز بر عملکرد پایدار [۸۳-۸۷]. از نظر کمیت و زمان، ML دارای ورودی‌های قابلیت بلادرنگ مرتبط با فعالیت‌ها و منابع است [۸۸]. بر این اساس، ML داده‌ها را جمع‌آوری و به کار می‌گیرد، تجزیه و تحلیل انجام می‌دهد و ورودی‌های مورد نیاز را برای تصمیم‌گیری در مورد رویارویی با امور انجام شده ارائه می‌کند. ML به صنایع اجازه می‌دهد تا دخالت انسان را به حداقل برسانند و اثربخشی و کارایی فرآیندهای کاری را به طور همزمان به حداکثر برسانند. تمرکز بر تقاضای مشتری و برنامه ریزی تولید در SCM سنتی راه موثری نیست و به همین دلیل است که مفهوم SCM پایدار مطرح می‌شود [۸۹]. علاوه بر این،

فقدان عینیت در متخصصان انسانی، کار تحقیقاتی را بر روی تجزیه و تحلیل داده‌ها بر روی پیش بینی تقاضا در SCM سنتی محدود می‌کند. در واقع، ادبیات SCM نشان می‌دهد که تحلیل در زنجیره تامین سنتی به شدت تحت‌تاثیر سوگیری‌های تصمیم‌گیرندگان و حدس‌های غیرمنطقی بازار است. با توجه به این، گنجاندن ML بهترین انتخاب است. به عنوان مثال، ML برنامه ریزی تولید بهتری را ارائه می‌دهد زیرا به مدیران کمک می‌کند تا نیازهای مصرف کنندگان و الگوهای خرید آنها را تحت سناریوهای مختلف شناسایی کنند. از سوی دیگر، برای یک SCM پایدار، ML به دلیل پتانسیل بالای آن برای مقابله با عدم قطعیت و حفظ صنایع برای رویارویی موثر با چالش‌های نزدیک می‌تواند نقش حیاتی ایفا کند. به عنوان یک مورد واقعی، شارما و همکاران. [۸۹] یک بررسی جامع در مورد کاربرد تکنیک‌های ML در کشاورزی پایدار SCM انجام داد، که در آن ۹۳ مقاله بررسی شد.

۹.۳. کاربرد الگوریتم‌های یادگیری ماشین در اقتصاد دایره‌ای.

CE یک رویه سیستمی است که به حفظ فعالیت‌های مربوط به جریان‌های معکوس در زنجیره‌های تامین از جمله استفاده از منابع، بازیابی، بازیافت، استفاده مجدد، تعمیر، ساخت مجدد و نوسازی کمک می‌کند [۹۰]. این انگیزه استفاده مجدد دائمی از مواد برای کاهش ضایعات و همچنین هدایت تقاضا به سمت مصرف منابع طبیعی است [۸۶]. الگوریتم‌های هوش مصنوعی و ML می‌توانند به عنوان پلتفرم‌های کارآمد برای تبدیل سریع به CE عمل کنند. (در اینجا سه عامل کلیدی CE وجود دارد که تکنیک‌های ML را می‌توان به شرح زیر اعمال کرد:

- (i) طراحی مواد، اجزا و محصولات دایره‌ای. بدیهی است که ابزارهای ML می‌توانند توسعه مواد و محصولات جدید مانند نمونه سازی و آزمایش سریع مبتنی بر ML را تسهیل کنند.
 - (ii) مدل‌های کسب و کار دایره ای را اجرا کنید. ML می‌تواند گردش محصول را از طریق پیش بینی هوشمند تقاضا، قیمت گذاری، مدیریت موجودی، نگهداری پیش بینی شده و غیره بهبود بخشد.
 - (iii) بهینه سازی زیرساخت‌های دایره‌ای. ML می‌تواند تولید مجدد قطعات، مرتب‌سازی و جداسازی محصولات، و بازیافت مواد را بهبود بخشد که می‌تواند زیرساخت لجستیک معکوس را فراهم کند.
- به عنوان یک مطالعه اخیر، ویلتر و همکاران. [۹۱] کاربرد هوش مصنوعی را در تفکیک زباله‌های جامد شهری (MSW) طبق اصول CE بررسی کرد. ML به عنوان یکی از کارآمدترین فناوری‌ها برای تفکیک خودکار زباله مورد بحث قرار گرفت.

۴. چارچوبی برای کاربرد ML در SCM

در بخش‌های قبل، کاربرد تکنیک‌های ML در حوزه‌های مختلف SCM مورد بحث قرار گرفت. در این بخش، یک چارچوب مفهومی برای ارائه یک نمای کلی از خروجی‌های کاربرد ML در هر حوزه SCM ارائه شد که با استفاده از روش‌های سنتی نمی‌توان به آن دست یافت. علاوه بر این، اطلاعات مفیدی در مورد شرایط لازم و کافی برای استفاده موثر از ML در SCM ارائه شد یکی از مهم ترین خروجی‌های بکارگیری تکنیک‌های ML مانند SVM در ارزیابی تامین کننده، استخراج برخی از ویژگی‌های اصلی است که می‌تواند تاثیر قابل توجهی بر فرآیندهای انتخاب تامین کننده و تقسیم بندی داشته باشد. علاوه بر این، استفاده از تکنیک‌های ML می‌تواند با کاهش تعداد ویژگی‌های اعمال شده برای طبقه بندی، زمان ارزیابی تامین کنندگان را بر اساس معیارها کاهش دهد. (خروجی‌های بکارگیری ML در SCRM پیش بینی، ارزیابی و کاهش ریسک‌ها به صورت هوشمند است. علاوه بر این، بکارگیری ML در SCRM می‌تواند ایجاد یک زنجیره تامین قوی و انعطاف پذیر را امکان پذیر سازد و از تداوم و سودآوری سازمان اطمینان حاصل کند. یکی از خروجی‌های به کارگیری دقیق‌ترین روش‌های ML در تقاضا و فروش به صورت سنتی، پیش بینی تقاضا و فروش است. این امر منجر به کاهش هزینه‌های موجودی می‌شود. تکنیک‌های ML می‌توانند الگوهای موجودی پنهان را تشخیص دهند و سیستم‌های توزیع می‌توانند با ایجاد مسیرهای تحویل بهتر و بررسی رفتار مصرف کننده منجر به تحویل به موقع محصول به مشتریان مربوطه شوند. (یکی دیگر از فعالیت‌های SCM که با محدودیت‌های متعددی روبرو بوده، برنامه‌ریزی تولید است. یک سیستم برنامه‌ریزی تولید مناسب باید به طور موثر با این محدودیت‌ها برخورد شود. تکنیک‌های ML می‌توانند محدودیت‌ها را در گردش‌های کاری تولید سفارشی و ساخت به سهام

متعادل کنند و به طور موثر دقت برنامه‌ریزی و زمان‌بندی تولید را بهبود بخشند. همانطور که قبلاً ذکر شد، روش‌های سنتی اخیراً در استفاده از داده‌های تحقیقاتی با مشکلاتی ضعیف مواجه شده‌اند. از تکنیک‌های ML در مدیریت زنجیره تامین [۱۳، ۱۴، ۵۲، ۵۳] که حتی کارآمدتر از تکنیک‌های سنتی در برخورد با تعداد زیادی از داده‌ها هستند.

(I) (ماهیت اکثر تکنیک‌های مبتنی بر هوش مصنوعی یادگیری داده‌های تاریخی است و سپس در مورد نمونه‌های جدید تصمیم می‌گیرند.) (این تکنیک‌ها قادر به مقابله با تغییرات و انقلاب‌های بزرگ در موقعیت‌های مشکل نیستند. به عنوان مثال، شیوع COVID-19 تغییرات بزرگ و غیرقابل پیش‌بینی در محیط‌های تجاری ایجاد کرده است که تکنیک‌های ML نمی‌توانند عملکرد قابل قبولی را تحت شرایطی که در مواجهه با مشکل پیش‌بینی می‌کنند، قابل قبول باشد. هوش مصنوعی با شرایطی مواجه است که هیچ شباهتی به آنچه در گذشته آموخته و با آن روبرو بوده است ندارد و اثربخشی و کارایی روش‌های هوش مصنوعی می‌تواند به طور چشمگیری کاهش یابد.

(II) (در مورد اعتبار و عادلانه بودن تکنیک‌های ML در برخی موارد تردید وجود دارد. در قلب مشکل این واقعیت است که تکنیک‌های ML مدل‌های بهینه را از داده‌هایی که داده می‌شوند محاسبه می‌کنند. به این معنی که آنها می‌توانند در نهایت مشکلاتی را که قرار است اصلاح کنند، تکرار کنند [۹۲].

(بنابراین، همانطور که در پایین شکل ۵ ذکر شد، خروجی‌های تکنیک‌های ML در SCM باید بر اساس مطلوبیت منطقی و امکان سنجی فرهنگی آنها پایش، ارزیابی و کنترل شوند. به عبارت دیگر، خروجی‌های روش‌های مبتنی بر هوش مصنوعی باید توسط عامل انسانی (متخصص SCM) ارزیابی شوند تا اطمینان حاصل شود که خروجی‌ها و استراتژی‌های به دست آمده از آنها به صورت غیرقابل انجام و راهبردهای فرهنگی به دست آمده است. یا خروجی‌های برنامه ML در SCM موثر، کارآمد و کافی هستند.

۵. نتیجه گیری و دلالت‌های مدیریتی و جهت گیری آینده پژوهی

(این مقاله با هدف ارائه مروری بر کاربرد تکنیک‌های ML در حوزه‌های مختلف زنجیره تامین است. در این راستا، پس از بررسی مختصری از تکنیک‌های پرکاربرد نظارت شده، بدون نظارت و نیمه نظارتی ML، کاربرد هر یک در مدیریت حوزه‌های مختلف زنجیره تامین ارائه شد. بر این اساس، انتخاب تامین کننده، تقسیم‌بندی تامین کننده، پیش‌بینی توسعه ریسک زنجیره تامین، تقسیم بندی تامین کننده پایدار، پیش‌بینی توسعه ریسک زنجیره تامین، توسعه پایدار زنجیره تامین اقتصاد دایره ای در SCM به عنوان مهم ترین حوزه‌ها مورد بحث قرار گرفت. در بخش انتخاب تامین کننده، دو روش مختلف یادگیری ماشین توضیح داده شد توصیف کرد. (اول، مراحل طراحی یک چارچوب مبتنی بر داده برای پیش‌بینی ریسک‌های زنجیره تامین معرفی شد. چهارم، استفاده از یک سیستم پیش‌بینی فازی به عنوان یکی از تکنیک‌های یادگیری ماشینی پرکاربرد در برآورد تقاضا/فروش توضیح داده شد. در نهایت، خلاصه‌ای از کاربردهای الگوریتم‌های ML در مدیریت موجودی، حمل و نقل و هدف اصلی این مقاله معرفی شد. با استفاده از ML در مدیریت زنجیره تامین، محدودیت‌هایی وجود دارد، به عنوان مثال، با توجه به مخاطبان هدف این مقاله (مبتدیان و مدیران صنعت)، ارائه جزئیات الگوریتم‌های ML امکان پذیر نبود و گاهی اوقات نیز ترسیم فلوچارت‌هایی برای آشنایی مبتدیان و مدیران با فرآیند پیاده سازی و استفاده از این حوزه ارائه می‌شد در یک صنعت خاص، کاربرد ML به طور کلی در SC‌های مختلف در نظر گرفته شد. بدیهی است که ماهیت صنعت و نوع و حجم داده‌ها در انتخاب الگوریتم مناسب تاثیر بسزایی دارد. (بنابراین پیشنهاد می‌شود مدیران در استفاده از الگوریتم‌های مختلف دقت کافی داشته باشند و تناسب الگوریتم انتخابی را با ماهیت داده‌ها و قابلیت تفسیر آن برای صنعت در نظر بگیرند. (بعضی از صنایع هستند که در مراحل اولیه استفاده از تکنیک‌های ML برای بهبود فرآیندهای مختلف زنجیره تامین خود هستند. به عنوان مثال، فضای بسیار خوبی در حوزه تامین انرژی‌های تجدیدپذیر وجود دارد تا در حوزه تامین انرژی‌های تجدیدپذیر فضای زیادی وجود دارد. (همچنین شکاف بزرگی در استفاده از قدرت مدل بهینه سازی ریاضی و یادگیری ماشین به منظور طراحی و بهینه سازی SC وجود دارد که می‌تواند در مطالعات تحقیقاتی آتی مورد توجه قرار گیرد. علاوه بر این، چارچوب ارائه شده را می‌توان با استفاده از مدل سازی معادلات ساختاری در برخی صنایع در مطالعات تحقیقاتی آتی مورد آزمایش قرار داد. هوش

مصنوعی برای مناطق مختلف زنجیره تامین بر اساس روندهای تحقیقاتی پیش‌بینی‌شده هوش مصنوعی، ما کاوش بیشتر در کاربرد تکنیک‌های RL در قیمت‌گذاری بلادرنگ را پیشنهاد می‌کنیم. بیشتر کاربردهای تکنیک‌های هوش مصنوعی در حوزه SCM به مشکلات SCM نسبتاً ساختار یافته (به خوبی تعریف شده)، عملیاتی و تاکتیکی محدود می‌شوند. تحقیقات آینده می‌تواند به کاربرد تکنیک‌های هوش مصنوعی (به ویژه سیستم‌های مبتنی بر عامل) برای حل انواع مسائل نرم اما استراتژیک SCM بپردازد. (دلیل اصلی این است که ارائه راه حل‌های کارآمد برای مشکل SCM به دلیل پیچیدگی ذاتی و ماهیت نامناسب مشکل، مانند روابط برون سپاری، مدیریت ارتباط با تامین کننده، هماهنگی زنجیره تامین و اتحاد استراتژیک بین شرکای زنجیره تامین، بسیار گران یا دشوار است.

منابع

- 1) Z. Dai, F. Aqlan, K. Gao, and Y. Zhou, "A two-phase method for multi-echelon location-routing problems in supply chains," *Expert Systems with Applications*, vol. 115, pp. 618–634, 2019.
- 2) S. C. Koh, S. Saad, and S. Arunachalam, "Competing in the 21st century supply chain through supply chain management and enterprise resource planning integration," *International Journal of Physical Distribution and Logistics Management*, vol. 36, no. 6, pp. 455–465, 2006.
- 3) S. Sadeghi, N. Rasouli, and G. Jandaghi, "Identifying and prioritizing contributing factors in supply chain competitiveness by using PLS-BWM techniques (case study: payam shoes company)," *World Scientific News*, vol. 49, no. 2, pp. 117–143, 2016.
- 4) D. M. Lambert, M. C. Cooper, and J. D. Pagh, "Supply chain management: implementation issues and research opportunities," *International Journal of Logistics Management*, vol. 9, no. 2, pp. 1–20, 1998.
- 5) S. S. Darvazeh, I. R. Vanani, and F. M. Musolu, "Big data analytics and its applications in supply chain management," in *New Trends in the Use of Artificial Intelligence for the Industry 4.0*, IntechOpen, London, UK, 2020.
- 6) S. Tiwari, H. M. Wee, and Y. Daryanto, "Big data analytics in supply chain management between 2010 and 2016: insights to industries," *Computers and Industrial Engineering*, vol. 115, pp. 319–330, 2018.
- 7) B. Biggio and F. Roli, "Wild patterns: ten years after the rise of adversarial machine learning," *Pattern Recognition*, vol. 84, pp. 317–331, 2018.
- 8) F. M. Musolu, S. Sadeghi Darvazeh, and I. Raeesi Vanani, "Deep learning and its applications in medical imaging," in *Internet of @ings for Healthcare Technologies*, pp. 137–153, Springer, Singapore, 2021.
- 9) S. Piramuthu, "Machine learning for dynamic multi-product supply chain formation," *Expert Systems with Applications*, vol. 29, no. 4, pp. 985–990, 2005.
- 10) I. M. Cavalcante, E. M. Frazzon, F. A. Forcellini, and D. Ivanov, "A supervised machine learning approach to data driven simulation of resilient supplier selection in digital manufacturing," *International Journal of Information Management*, vol. 49, pp. 86–97, 2019.
- 11) Y. Zhu, C. Xie, G.-J. Wang, and X.-G. Yan, "Predicting China's SME credit risk in supply chain finance based on machine learning methods," *Entropy*, vol. 18, no. 5, p. 195, 2016.
- 12) P. Priore, B. Ponte, R. Rosillo, and D. de la Fuente, "Applying machine learning to the dynamic selection of replenishment policies in fast-changing supply chain environments," *International Journal of Production Research*, vol. 57, no. 11, pp. 3663–3677, 2019.
- 13) G. Baryannis, S. Dani, and G. Antoniou, "Predicting supply chain risks using machine learning: the trade-off between performance and interpretability," *Future Generation Computer Systems*, vol. 101, pp. 993–1004, 2019.
- 14) C. Bai, J. Rezaei, and J. Sarkis, "Multicriteria green supplier segmentation," *IEEE Transactions on Engineering Management*, vol. 64, no. 4, pp. 515–528, 2017.
- 15) A. Dey, "Machine learning algorithms: a review," *International Journal of Computer Science and Information Technologies*, vol. 7, no. 3, pp. 1174–1179, 2016.

- 16) M. Bowles, *Machine Learning in Python: Essential Techniques for Predictive Analysis*, John Wiley and Sons, Hoboken, NJ, USA, 2015.
- 17) R. Carbonneau, K. Laframboise, and R. Vahidov, "Application of machine learning techniques for supply chain demand forecasting," *European Journal of Operational Research*, vol. 184, no. 3, pp. 1140–1154, 2008.
- 18) A. Ning, H. Lau, Y. Zhao, and T. T. Wong, "Fulfillment of retailer demand by using the MDL-optimal neural network prediction and decision policy," *IEEE Transactions on Industrial Informatics*, vol. 5, no. 4, pp. 495–506, 2009.
- 19) Y. Pan, R. Pavur, and T. Pohlen, "Revisiting the effects of forecasting method selection and information sharing under volatile demand in SCM applications," *IEEE Transactions on Engineering Management*, vol. 63, no. 4, pp. 377–389, 2016.
- 20) M. Maghrebi, C. Sammut, and S. T. Waller, "Feasibility study of automatically performing the concrete delivery dispatching through machine learning techniques," *Engineering, Construction and Architectural Management*, vol. 22, no. 5, pp. 573–590, 2015.
- 21) S. Mercier and I. Uysal, "Neural network models for predicting perishable food temperatures along the supply chain," *Biosystems Engineering*, vol. 171, pp. 91–100, 2018.
- 22) S. Shervais, T. T. Shannon, and G. G. Lendaris, "Intelligent supply chain management using adaptive critic learning," *IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans*, vol. 33, no. 2, pp. 235–244, 2003.
- 23) W. W. C. Chung, K. C. M. Wong, and P. T. K. Soon, "An ANN-based DSS system for quality assurance in production network," *Journal of Manufacturing Technology Management*, vol. 18, no. 7, pp. 836–857, 2007.
- 24) C. Liu, T. Shu, S. Chen, S. Wang, K. K. Lai, and L. Gan, "An improved grey neural network model for predicting transportation disruptions," *Expert Systems with Applications*, vol. 45, pp. 331–340, 2016.
- 25) H. Wu, G. Evans, and K.-H. Bae, "Production control in a complex production system using approximate dynamic programming," *International Journal of Production Research*, vol. 54, no. 8, pp. 2419–2432, 2016.
- 26) A. T. Gumus, A. F. Guneri, and F. Ulengin, "A new methodology for multi-echelon inventory management in stochastic and neuro-fuzzy environments," *International Journal of Production Economics*, vol. 128, no. 1, pp. 248–260, 2010.
- 27) X. Guo, Z. Yuan, and B. Tian, "Supplier selection based on hierarchical potential support vector machine," *Expert Systems with Applications*, vol. 36, no. 3, pp. 6978–6985, 2009.
- 28) A. Valluri and D. Croson, "Agent learning in supplier selection models," *Decision Support Systems*, vol. 39, no. 2, pp. 219–240, 2005.
- 29) W. Jiang and J. Liu, "Inventory financing with overconfident supplier based on supply chain contract," *Mathematical Problems in Engineering*, vol. 2018, Article ID 5054387, 12 pages, 2018.
- 30) S. Erevelles and T. H. Stevenson, "Enhancing the business-to-business supply chain: insights from partitioning the supply side," *Industrial Marketing Management*, vol. 35, no. 4, pp. 481–492, 2006.
- 31) S. B. Kotsiantis, I. D. Zaharakis, and P. E. Pintelas, "Machine learning: a review of classification and combining techniques," *Artificial Intelligence Review*, vol. 26, no. 3, pp. 159–190, 2006.
- 32) D. Lowd and P. Domingos, "Naive Bayes models for probability estimation," in *Proceedings of the 22nd International Conference on Machine Learning*, pp. 529–536, Germany, August 2005.
- 33) A. Karatzoglou, D. Meyer, and K. Hornik, "Support vector machines in R," *Journal of Statistical Software*, vol. 15, no. 9, pp. 1–28, 2006.
- 34) P. Harrington, *Machine Learning in Action*, Manning Publications Co, Shelter Island, NY, USA, 2012.
- 35) S. Shalev-Shwartz, Y. Singer, N. Srebro, and A. Cotter, "Pegasos: primal estimated sub-gradient solver for SVM," *Mathematical Programming*, vol. 127, no. 1, pp. 3–30, 2011.

-
- 36) Z.-H. Zhou, "When semi-supervised learning meets ensemble learning," in Proceedings of the International Workshop on Multiple Classifier Systems, pp. 529–538, Springer, Reykjavik, Iceland, June 2009.
 - 37) A. Lemmens and C. Croux, "Bagging and boosting classification trees to predict churn," Journal of Marketing Research, vol. 43, no. 2, pp. 276–286, 2006.
 - 38) M. Bertolini, D. Mezzogori, M. Neroni, and F. Zammori, "Machine learning for industrial applications: a comprehensive literature review," Expert Systems with Applications, vol. 175, Article ID 114820, 2021.
 - 39) Q. Pang, T. Yang, M. Li, and Y. Shen, "A fuzzy-grey multicriteria decision making approach for green supplier selection in low-carbon supply chain," Mathematical Problems in Engineering, vol. 2017, Article ID 9653261, 9 pages, 2017.
 - 40) G. A. Levow, "Characterizing and recognizing spoken corrections in human-computer dialogue," in Proceedings of the 36th Annual Meeting of the Association for Computational Linguistics and 17th International Conference on Computational Linguistics, vol. 1, pp. 736–742, Quebec, Canada, August 1998.
 - 41) M. K. Markey, G. D. Tourassi, and C. E. Floyd, "Decision tree classification of proteins identified by mass spectrometry of blood serum samples from people with and without lung cancer," Proteomics, vol. 3, no. 9, pp. 1678–1679, 2003.
 - 42) B. Zmazek, L. Todorovski, S. Džeroski, J. Vaupotić, and I. Kobal, "Application of decision trees to the analysis of soil radon data for earthquake prediction," Applied Radiation and Isotopes, vol. 58, no. 6, pp. 697–706, 2003.
 - 43) S. Hochreiter and K. Obermayer, "Support vector machines for dyadic data," Neural Computation, vol. 18, no. 6, pp. 1472–1510, 2006.
 - 44) J. Rezaei, M. Kadziński, C. Vana, and L. Tavasszy, "Embedding carbon impact assessment in multi-criteria supplier segmentation using ELECTRE TRI-rC," Annals of Operations Research, pp. 1–23, 2017.
 - 45) J. Rezaei and R. Ortt, "Multi-criteria supplier segmentation using a fuzzy preference relations based AHP," European Journal of Operational Research, vol. 225, no. 1, pp. 75–84, 2013.
 - 46) J. Rezaei and R. Ortt, "A multi-variable approach to supplier segmentation," International Journal of Production Research, vol. 50, no. 16, pp. 4593–4611, 2012.
 - 47) J. Rezaei, J. Wang, and L. Tavasszy, "Linking supplier development to supplier segmentation using Best Worst Method," Expert Systems with Applications, vol. 42, no. 23, pp. 9152–9164, 2015.
 - 48) M. Segura and C. Maroto, "A multiple criteria supplier segmentation using outranking and value function methods," Expert Systems with Applications, vol. 69, pp. 87–100, 2017.
 - 49) J. Rezaei and H. Fallah Lajimi, "Segmenting supplies and suppliers: bringing together the purchasing portfolio matrix and the supplier potential matrix," International Journal of Logistics Research and Applications, vol. 22, pp. 1–18, 2018.
 - 50) S. V. Parkouhi, A. S. Ghadikolaei, and H. F. Lajimi, "Resilient supplier selection and segmentation in grey environment," Journal of Cleaner Production, vol. 207, pp. 1123–1137, 2019.
 - 51) G. Baryannis, S. Dani, S. Validi, and G. Antoniou, "Decision support systems and artificial intelligence in supply chain risk management," in Revisiting Supply Chain Risk, pp. 53–71, Springer, Cham, Switzerland, 2019.
 - 52) A. Bruzzone and A. Orsoni, "AI and simulation-based techniques for the assessment of supply chain logistic performance," in Proceedings of the 36th Annual Simulation Symposium, pp. 154–164, IEEE, Florida, FL, USA, March 2003.
 - 53) K. Zhao and X. Yu, "A case based reasoning approach on supplier selection in petroleum enterprises," Expert Systems with Applications, vol. 38, no. 6, pp. 6839–6847, 2011.

- 54) G. Baryannis, S. Validi, S. Dani, and G. Antoniou, "Supply chain risk management and artificial intelligence: state of the art and future research directions," *International Journal of Production Research*, vol. 57, no. 7, pp. 2179–2202, 2019.
- 55) J. Luo, X. Zhang, and X. Jiang, "Multisources risk management in a supply chain under option contracts," *Mathematical Problems in Engineering*, vol. 2019, Article ID 7482584, 12 pages, 2019.
- 56) S. Prasanna Venkatesan and S. Kumaran, "Supply chain risk prioritisation using a hybrid AHP and PROMETHEE approach," *International Journal of Services and Operations Management*, vol. 13, no. 1, pp. 19–41, 2012.
- 57) R. Rostamzadeh, M. K. Ghorabae, K. Govindan, A. Esmaceli et al., "Evaluation of sustainable supply chain risk management using an integrated fuzzy TOPSIS- CRITIC approach," *Journal of Cleaner Production*, vol. 175, pp. 651–669, 2018.
- 58) M. Abdel-Basset and R. Mohamed, "A novel plithogenic TOPSIS- CRITIC model for sustainable supply chain risk management," *Journal of Cleaner Production*, vol. 247, Article ID 119586, 2020.
- 59) Y. H. Lee, P. Golinska-Dawson, and J. Z. Wu, "Mathematical models for supply chain management," *Mathematical Problems in Engineering*, vol. 2016, Article ID 6167290, 4 pages, 2016.
- 60) S. S. Darvazeh, M. Amiri, and F. M. Mooseloo, "Artificial intelligence and its application in data-driven optimization," in *@e Open Access Book, Data Mining*, IntechOpen, London, UK, 2021.
- 61) R. Toorajipour, V. Sohrabpour, A. Nazarpour, P. Oghazi, and M. Fischl, "Artificial intelligence in supply chain management: a systematic literature review," *Journal of Business Research*, vol. 122, pp. 502–517, 2021.
- 62) H. Chen, Y. Zhu, K. Hu, and X. Li, "Virtual enterprise risk management using artificial intelligence," *Mathematical Problems in Engineering*, vol. 2010, Article ID 572404, 20 pages, 2010.
- 63) Y. Fan, L. Heilig, and S. Voß, "Supply chain risk management in the era of big data," in *Design, User Experience, and Usability: Design Discourse*, pp. 283–294, Springer, Cham, Switzerland, 2015.
- 64) M. He, H. Ji, Q. Wang, C. Ren, and R. Lougee, "Big data fueled process management of supply risks: sensing, prediction, evaluation and mitigation," in *Proceedings of the Winter Simulation Conference 2014*, pp. 1005–1013, IEEE, Savannah, GA, USA, December 2014.
- 65) D. Zage, K. Glass, and R. Colbaugh, "Improving supply chain security using big data," in *Proceedings of the 2013 IEEE International Conference on Intelligence and Security Informatics*, pp. 254–259, IEEE, Seattle, WA, USA, June 2013.
- 66) S. Ye, Z. Xiao, and G. Zhu, "Identification of supply chain disruptions with economic performance of firms using multicategory support vector machines," *International Journal of Production Research*, vol. 53, no. 10, pp. 3086–3103, 2015.
- 67) W. Yan, J. He, and A. J. C. Trappey, "Risk-aware supply chain intelligence: AI-enabled supply chain and logistics management considering risk mitigation," *Advanced Engineering Informatics*, vol. 42, Article ID 100976, 2019.
- 68) L. Malviya, P. Chittora, P. Chakrabarti, R. S. Vyas, and S. Poddar, "Backorder prediction in the supply chain using machine learning," *Materials Today: Proceedings*, 2021.
- 69) S. S. Kamble, A. Gunasekaran, V. Kumar, A. Belhadi, and C. Foropon, "A machine learning based approach for predicting blockchain adoption in supply chain," *Technological Forecasting and Social Change*, vol. 163, Article ID 120465, 2021.
- 70) S.-S. Leu and C.-M. Chang, "Bayesian-network-based safety risk assessment for steel construction projects," *Accident Analysis and Prevention*, vol. 54, pp. 122–133, 2013.
- 71) L. Zhang, X. Wu, M. J. Skibniewski, J. Zhong, and Y. Lu, "Bayesian-network-based safety risk analysis in construction projects," *Reliability Engineering and System Safety*, vol. 131, pp. 29–39, 2014.

- 72) D. Ni, Z. Xiao, and M. K. Lim, "A systematic review of the research trends of machine learning in supply chain management," *International Journal of Machine Learning and Cybernetics*, pp. 1 – 20, 2019.
- 73) S. Omassey, "Sales forecasts in clothing industry: the key success factor of the supply chain management," *International Journal of Production Economics*, vol. 128, no. 2, pp. 470–483, 2010.
- 74) S. G. Timme and C. Williams-Timme, "(e real cost of holding inventory," *Supply Chain Management Review*, vol. 7, no. 4, pp. 30–37, 2003.
- 75) E. B. Tirkolaee, A. Goli, A. Faridnia, M. Soltani, and G.-W. Weber, "Multi-objective optimization for the reliable pollution-routing problem with cross-dock selection using Pareto-based algorithms," *Journal of Cleaner Production*, vol. 276, Article ID 122927, 2020.
- 76) M. Alinaghian, E. B. Tirkolaee, Z. K. Dezaki, S. R. Hejazi, and W. Ding, "An augmented Tabu search algorithm for the green inventory-routing problem with time windows," *Swarm and Evolutionary Computation*, vol. 60, Article ID 100802, 2021.
- 77) E. B. Tirkolaee and N. S. Aydın, "A sustainable medical waste collection and transportation model for pandemics," *Waste Management and Research*, Article ID 0734242X211000437, 2021.
- 78) E. B. Tirkolaee, P. Abbasian, and G.-W. Weber, "Sustainable fuzzy multi-trip location-routing problem for medical waste management during the COVID-19 outbreak," *Science of the Total Environment*, vol. 756, Article ID 143607, 2021.
- 79) M. Yousefi Nejad Attari, A. Ebadi Torkayesh, B. Malmir, and E. Neyshabouri Jami, "Robust possibilistic programming for joint order batching and picker routing problem in warehouse management," *International Journal of Production Research*, pp. 1–19, 2021.
- 80) N. Furian, M. O'Sullivan, C. Walker, and E. Çela, "A machine learning-based branch and price algorithm for a sampled vehicle routing problem," *OR Spectrum*, pp. 1–40, 2021.
- 81) G. 'Cirović, D. Pamučar, and D. Božanić, "Green logistic vehicle routing problem: routing light delivery vehicles in urban areas using a neuro-fuzzy model," *Expert Systems with Applications*, vol. 41, no. 9, pp. 4245–4258, 2014.
- 82) M.-K. Chen, T.-W. Tai, and T.-Y. Hung, "Component selection system for green supply chain," *Expert Systems with Applications*, vol. 39, no. 5, pp. 5687–5701, 2012.
- 83) H. R. Vandchali, S. Cahoon, and S.-L. Chen, "Creating a sustainable supply chain network by adopting relationship management strategies," *Journal of Business-To-Business Marketing*, vol. 27, no. 2, pp. 125–149, 2020.
- 84) H. R. Vandchali, S. Cahoon, and S.-L. Chen, "(e impact of supply chain network structure on relationship management strategies: an empirical investigation of sustainability practices in retailers," *Sustainable Production and Consumption*, vol. 28, pp. 281–299, 2021.
- 85) H. R. Vandchali, S. Cahoon, and S. L. Chen, "(e impact of power on the depth of sustainability collaboration in the supply chain network for Australian food retailers," *International Journal of Procurement Management*, vol. 14, no. 2, pp. 165–184, 2021.
- 86) D. Wang and Y. Zhang, "Implications for sustainability in supply chain management and the circular economy using machine learning model," *Information Systems and E-Business Management*, pp. 1–13, 2020.
- 87) P. Wang, "On defining artificial intelligence," *Journal of Artificial General Intelligence*, vol. 10, no. 2, pp. 1–37, 2019.
- 88) D. Nagar, S. Raghav, A. Bhardwaj, R. Kumar, P. L. Singh, and R. Sindhvani, "Machine learning: best way to sustain the supply chain in the era of industry 4.0," *Materials Today: Proceedings*, 2021.
- 89) R. Sharma, S. S. Kamble, A. Gunasekaran, V. Kumar, and A. Kumar, "A systematic literature review on machine learning applications for sustainable agriculture supply chain performance," *Computers and Operations Research*, vol. 119, Article ID 104926, 2020.
- 90) B. T. Hazen, I. Russo, I. Confente, and D. Pellathy, "Supply chain management for circular economy: conceptual framework and research agenda," *@e International Journal of Logistics Management*, vol. 32, no. 2, pp. 510–537, 2021.

- 91) H. Wilts, B. R. Garcia, R. G. Garlito, L. S. Gómez, and E. G. Prieto, "Artificial intelligence in the sorting of municipal waste as an enabler of the circular economy," Resources, vol. 10, no. 4, p. 28, 2021.
- 92) D. D. Cremer, What Does Building a Fair AI Really Entail?, Harvard Business Review, Massachusetts, MA, USA, 2020, <https://hbr.org/2020/09/what-does-building-a-fair-ai-reallyentail>.