



طراحی مدل ترکیبی DEA-ANN برای پیش بینی و بهینه سازی مدیریت ریسک در زنجیره تأمین دیجیتال صنعت فولاد

| | | |
|------------------------------|-------------------------------|---|
| نادیا شاه محمدی ^۱ | تاریخ چاپ نهایی: ۱ تیر ۱۴۰۵ | شيوه استناددهی: شاه محمدی، نادیا، معین زاد، حسین، مهری نژاد، صفیه، و کرامتی، محمدعلی. (۱۴۰۵). طراحی مدل ترکیبی DEA-ANN برای پیش بینی و بهینه سازی مدیریت ریسک در زنجیره تأمین دیجیتال صنعت فولاد. یادگیری هوشمند و تحول مدیریت، ۲۴(۲)، ۲۵-۱. |
| حسین معین زاد ^۱ | تاریخ چاپ اولیه: ۲۵ بهمن ۱۴۰۴ | |
| صفیه مهری نژاد ^۲ | تاریخ پذیرش: ۱۳ بهمن ۱۴۰۴ | |
| محمدعلی کرامتی ^۱ | تاریخ بازنگری: ۵ بهمن ۱۴۰۴ | |
| | تاریخ ارسال: ۸ آبان ۱۴۰۴ | |

چکیده

هدف این پژوهش طراحی و اعتبارسنجی یک مدل هوشمند ترکیبی مبتنی بر تحلیل پوششی داده ها و شبکه عصبی مصنوعی به منظور پیش بینی و بهینه سازی ریسک در زنجیره تأمین دیجیتال صنعت فولاد است. پژوهش از نوع کاربردی و با رویکرد آمیخته انجام شد؛ بدین صورت که ابتدا با مرور نظام مند ادبیات و مصاحبه با خبرگان، ۱۶۰ ریسک شناسایی گردید و سپس با استفاده از پرسشنامه، شاخص های احتمال وقوع، شدت اثر و قابلیت کشف کمی سازی شدند. عدد اولویت ریسک محاسبه و به منظور بهینه سازی و استخراج کارایی متقاطع، مدل DEA به کار گرفته شد. در نهایت، خروجی DEA به عنوان داده آموزشی برای مدل شبکه عصبی مصنوعی استفاده شد. نتایج نشان داد مدل DEA-ANN با ساختار دو لایه پنهان و تنظیمات بهینه، قدرت تبیین بالایی داشته و قادر است تغییرات سطح ریسک و کارایی متقاطع را با دقت مناسب پیش بینی کند؛ به گونه ای که شاخص های خطا کاهش معنادار و ضریب تعیین در سطح مطلوبی قرار گرفت. مدل پیشنهادی ابزاری کارآمد برای پیش بینی ریسک و پشتیبانی از تصمیم گیری هوشمند در زنجیره تأمین دیجیتال فولاد فراهم می کند و می تواند جایگزینی مؤثر برای روش های سنتی ارزیابی ریسک باشد.

واژگان کلیدی: زنجیره تأمین دیجیتال، مدیریت ریسک، تحلیل پوششی داده ها، شبکه عصبی مصنوعی، صنعت فولاد

مشخصات نویسندگان:

۱. گروه مدیریت صنعتی، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران
۲. گروه مدیریت مالی، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران

پست الکترونیکی: moinzad@iauctb.ac.ir



© ۱۴۰۵ تمامی حقوق انتشار این مقاله متعلق به

نویسنده است.

انتشار این مقاله به صورت دسترسی آزاد مطابق با گواهی CC BY-NC 4.0 صورت گرفته است.



Designing a Hybrid DEA–ANN Model for Predicting and Optimizing Risk Management in the Digital Supply Chain of the Steel Industry

Nadia Shahmohamadi¹
Hossein Moeinzad^{1*}
Safiyeh Mehri Nejad²
Mohammadali Keramati¹

Submit Date: 30 October 2025
Revise Date: 25 January 2026
Accept Date: 02 February 2026
Initial Publish: 14 February 2026
Final Publish: 22 June 2026

How to cite: Shahmohamadi, N., Moeinzad, H., Mehri Nejad, S., & Keramati, M. (2026). Designing a Hybrid DEA–ANN Model for Predicting and Optimizing Risk Management in the Digital Supply Chain of the Steel Industry. *Intelligent Learning and Management Transformation*, 4(2), 1-25.

Abstract

This study aims to design and validate an intelligent hybrid DEA–ANN model to predict and optimize risk management in the digital supply chain of the steel industry. This applied mixed-method research identified 160 digital supply chain risks through a systematic literature review and expert interviews. Risk indicators including probability, severity, and detectability were quantified using questionnaires. Risk Priority Numbers were calculated, optimized via Data Envelopment Analysis with cross-efficiency, and subsequently used to train an Artificial Neural Network for predictive modeling. The results indicate that the hybrid DEA–ANN model, with an optimized two-hidden-layer architecture, demonstrates strong explanatory power and accurately predicts variations in risk efficiency, showing low prediction error and a satisfactory coefficient of determination. The proposed model provides an effective intelligent tool for risk prediction and decision support in digital steel supply chains and represents a robust alternative to conventional risk assessment approaches.

Keywords: *Digital supply chain, Risk management, Data Envelopment Analysis, Artificial Neural Network, Steel industry*

Authors' Information:

moinzad@iauctb.ac.ir

1. Department of Industrial Management, CT.C., Islamic Azad University, Tehran, Iran
2. Department of Financial Management, CT.C., Islamic Azad University, Tehran, Iran



© 2026 the authors. This is an open access article under the terms of the [CC BY-NC 4.0 License](https://creativecommons.org/licenses/by-nc/4.0/).

مقدمه

در دهه‌های اخیر، تحول دیجیتال به یکی از پیشران‌های بنیادین دگرگونی در ساختارها، فرآیندها و الگوهای تصمیم‌گیری سازمان‌ها تبدیل شده است. این تحول، که مبتنی بر هم‌افزایی فناوری‌هایی نظیر اینترنت اشیا، هوش مصنوعی، کلان‌داده، بلاک‌چین و سیستم‌های سایبر-فیزیکی است، نه تنها مدل‌های کسب‌وکار را بازتعریف کرده، بلکه منطق حاکم بر مدیریت زنجیره تأمین را نیز به‌طور اساسی دگرگون ساخته است (Pellicelli, 2021; Porter, 2023). زنجیره تأمین دیجیتال به‌عنوان برآیند این تحول، با هدف افزایش چابکی، شفافیت، هم‌زمانی اطلاعات و پاسخ‌گویی بلادرنگ به عدم قطعیت‌های محیطی شکل گرفته است، اما در عین حال، پیچیدگی ساختاری و وابستگی فناورانه آن، سطح جدیدی از ریسک‌های سیستمی، سایبری، عملیاتی و مالی را به همراه آورده است (Ali, 2022; Nasiri et al., 2020).

ادبیات کلاسیک زنجیره تأمین، ریسک را عمدتاً در قالب اختلالات فیزیکی، تأخیرهای لجستیکی و نوسانات عرضه و تقاضا تحلیل می‌کرد (Rao & Goldsby, 2009). با این حال، دیجیتالی‌شدن فرآیندها موجب ظهور گونه‌های نوینی از ریسک شده است که ماهیتی غیرخطی، شبکه‌ای و وابسته به داده دارند؛ ریسک‌هایی که اغلب به‌صورت آبخاری در کل شبکه منتشر می‌شوند و پیامدهای آن‌ها از یک گلوگاه فناورانه فراتر رفته و کل اکوسیستم زنجیره تأمین را تحت تأثیر قرار می‌دهند (Haicao et al., 2024; Ivanov et al., 2019). پژوهش‌های اخیر نشان می‌دهد که اگرچه فناوری‌های دیجیتال می‌توانند تاب‌آوری زنجیره تأمین را افزایش دهند، اما در صورت نبود چارچوب‌های هوشمند مدیریت ریسک، خود به منبعی برای تشدید عدم قطعیت و آسیب‌پذیری تبدیل می‌شوند (Fosso Wamba & Queiroz, 2022; Gupta, 2022).

در این میان، مدیریت ریسک زنجیره تأمین دیجیتال به‌عنوان یک حوزه میان‌رشته‌ای، نیازمند بازاندیشی مفهومی و روش‌شناختی است. ریسک دیگر صرفاً یک متغیر ایستا یا قابل رتبه‌بندی خطی نیست، بلکه پدیده‌ای پویا، چندبعدی و وابسته به تعاملات فناورانه، انسانی و سازمانی است (DuHadway et al., 2019; Song et al., 2024). مطالعات متعددی بر ضرورت گذار از رویکردهای سنتی شناسایی و رتبه‌بندی ریسک به سمت مدل‌های پیش‌بینی‌گر و تطبیقی تأکید کرده‌اند (Creazza et al., 2022; Özkanlısoy & Akkartal, 2020). این مسئله به‌ویژه در زنجیره‌های تأمین دیجیتال صنایع راهبردی، نظیر صنعت فولاد، اهمیت مضاعفی می‌یابد؛ چراکه هرگونه اختلال فناورانه یا سایبری می‌تواند به زیان‌های گسترده اقتصادی، توقف تولید و کاهش رقابت‌پذیری منجر شود (Ghadge et al., 2020; Mehrmanesh & Mirmahalleh, 2020).

صنعت فولاد به دلیل ماهیت سرمایه‌بر، گستردگی شبکه تأمین، وابستگی به فناوری‌های تولید پیشرفته و تعامل گسترده با بازارهای جهانی، یکی از حساس‌ترین صنایع نسبت به ریسک‌های زنجیره تأمین دیجیتال محسوب می‌شود. پژوهش‌ها نشان داده‌اند که ریسک‌های مالی، عملیاتی و فناورانه در این صنعت اغلب به‌صورت درهم‌تنیده عمل می‌کنند و ارزیابی مجزای آن‌ها قادر به تبیین رفتار واقعی سیستم نیست (Hosseinzadeh et al., 2020).

از این رو، استفاده از چارچوب‌های تحلیلی چندمعیاره و هوشمند برای شناسایی، تحلیل و پیش‌بینی ریسک‌ها، به یک ضرورت علمی و مدیریتی تبدیل شده است.

در ادبیات مدیریت ریسک، روش‌های متنوعی برای ارزیابی و اولویت‌بندی ریسک‌ها ارائه شده است؛ از جمله رویکردهای مبتنی بر FMEA، AHP، TOPSIS و نظریه مجموعه‌های راف و فازی (Abdel-Basset & Mohamed, 2020; Dias et al., 2020; Sadeghi, 2018). هرچند این روش‌ها در ساختاردهی قضاوت خبرگان و مقایسه نسبی ریسک‌ها مؤثر بوده‌اند، اما غالباً با محدودیت‌هایی همچون ایستایی، وابستگی شدید به قضاوت انسانی و ناتوانی در مدل‌سازی روابط غیرخطی مواجه‌اند (Araz et al., 2020; Smolarski et al., 2005). این محدودیت‌ها در محیط‌های دیجیتال که داده‌ها حجیم، پویا و به‌شدت به‌هم پیوسته‌اند، برجسته‌تر می‌شود.

در پاسخ به این چالش‌ها، گرایش فزاینده‌ای به استفاده از روش‌های مبتنی بر داده و هوش مصنوعی در مدیریت ریسک زنجیره تأمین شکل گرفته است. شبکه‌های عصبی مصنوعی به دلیل توانایی در یادگیری الگوهای غیرخطی، تعمیم‌پذیری و پیش‌بینی رفتار سیستم‌های پیچیده، به‌طور گسترده در ارزیابی ریسک‌های مالی، عملیاتی و فناورانه به کار گرفته شده‌اند (Dijie, 2022; Fu et al., 2022; Rezki & Mansouri, 2023). مرورهای نظام‌مند نیز نشان می‌دهد که ANN می‌تواند دقت پیش‌بینی ریسک را به‌طور معناداری نسبت به روش‌های سنتی افزایش دهد (Soori et al., 2023; Zogaan et al., 2025). با این حال، یکی از چالش‌های اصلی این رویکردها، فقدان یک مکانیسم معتبر برای وزندهی به ورودی‌ها و تفسیر کارایی نسبی ریسک‌ها در سطح سیستم است.

در این زمینه، تحلیل پوششی داده‌ها (DEA) به‌عنوان یک روش غیرپارامتریک و قدرتمند برای سنجش کارایی نسبی واحدهای تصمیم‌گیرنده، جایگاه ویژه‌ای یافته است. DEA امکان ارزیابی هم‌زمان چندین ورودی و خروجی را بدون نیاز به تعیین وزن‌های پیشینی فراهم می‌کند و در حوزه‌های مختلف برنامه‌ریزی، بهره‌وری و مدیریت ریسک به کار رفته است (Emrouznejad & Yang, 2018; Lee et al., 2022). مطالعات اخیر نشان داده‌اند که DEA می‌تواند نواقص شاخص‌های ساده‌ای مانند عدد اولویت ریسک را پوشش داده و تصویری جامع‌تر از وضعیت ریسک ارائه دهد (Nazari-Shirkouhi et al., 2023; Pan & Miao, 2023). با این حال، DEA به‌تنهایی ماهیتی توصیفی دارد و در مواجهه با داده‌های جدید یا سناریوهای آینده، نیازمند محاسبات مجدد است.

از این رو، ادبیات نوین به سمت مدل‌های ترکیبی DEA-ANN حرکت کرده است؛ مدل‌هایی که از DEA برای استخراج ساختار کارایی و از ANN برای یادگیری، پیش‌بینی و شبیه‌سازی رفتار آینده سیستم استفاده می‌کنند (Nazari-Shirkouhi et al., 2023; Singh et al., 2019). این رویکرد ترکیبی به‌ویژه در محیط‌های دیجیتال که تغییرات سریع و عدم قطعیت بالا حاکم است، مزیت قابل توجهی دارد و می‌تواند تصمیم‌گیری مدیریتی را از حالت واکنشی به حالت پیش‌نگر ارتقا دهد (Brintrup et al., 2024; Radanliev & et al., 2020).

در کنار این مباحث، مطالعات تجربی متعددی به نقش زنجیره تأمین دیجیتال در بهبود عملکرد سازمانی و کاهش ریسک‌های اختلال اشاره کرده‌اند (Lee et al., 2022; Rasi et al., 2019). با این حال، بخش قابل توجهی از این پژوهش‌ها یا به سطح مفهومی محدود مانده‌اند یا فاقد مدل‌های پیش‌بینی‌گر عملیاتی هستند (Alok et al., 2020; Schlüter & Henke, 2017). همچنین، در بستر کشورهای در حال توسعه و صنایع سنگین، از جمله فولاد، شکاف معناداری در کاربرد مدل‌های هوشمند ترکیبی برای مدیریت ریسک زنجیره تأمین دیجیتال مشاهده می‌شود (Karimzadegan & Kianous, 2021; Mitra et al., 2022; Pourjamshidi et al., 2021).

مرور جامع ادبیات نشان می‌دهد که اگرچه پژوهش‌های ارزشمندی در زمینه شناسایی ریسک، تاب‌آوری زنجیره تأمین و کاربرد هوش مصنوعی انجام شده است، اما همچنان فقدان مدلی یکپارچه، داده‌محور و پیش‌بینی‌گر که بتواند ریسک‌های زنجیره تأمین دیجیتال را به صورت پویا ارزیابی و بهینه‌سازی کند، به‌ویژه در صنعت فولاد، به‌عنوان یک خلأ پژوهشی برجسته باقی مانده است (Ghadge et al., 2020; Gupta, 2022; Song et al., 2024). این خلأ، ضرورت توسعه چارچوب‌هایی را آشکار می‌سازد که هم از توان تحلیلی DEA و هم از قابلیت یادگیری ANN بهره بگیرند.

بر این اساس، هدف این پژوهش طراحی و ارائه یک مدل ترکیبی DEA-ANN به منظور شناسایی، ارزیابی، پیش‌بینی و بهینه‌سازی مدیریت ریسک در زنجیره تأمین دیجیتال صنعت فولاد است.

روش‌شناسی

پژوهش حاضر از نوع مطالعه کاربردی و از نظر هدف، این تحقیق توسعه‌ای نیز محسوب می‌شود، چرا که تلاش می‌کند تا یک سیستم شاخص‌گذاری و مدل ارزیابی ریسک برای زنجیره تأمین دیجیتال تدوین کند. این مدل می‌تواند به سازمان‌ها کمک کند تا ریسک‌های موجود در زنجیره تأمین دیجیتال خود را به صورت سیستماتیک شناسایی کرده و برای بهبود مدیریت آنها اقدام کنند.

از لحاظ روش‌شناسی، پژوهش حاضر از یک روش تحقیق ترکیبی بهره می‌گیرد که شامل هر دو رویکرد کیفی و کمی است. در بخش کیفی، از مصاحبه‌های تخصصی و بررسی‌های موردی برای شناسایی عوامل کلیدی مرتبط با ریسک‌های زنجیره تأمین دیجیتال استفاده می‌شود. در بخش کمی، از روش‌های پیشرفته نظیر تحلیل پوششی داده‌ها و مدل‌های یادگیری ماشین برای تجزیه و تحلیل داده‌ها و اولویت‌بندی شاخص‌های ریسک استفاده خواهد شد.

این پژوهش همچنین از نظر ماهیت گردآوری داده‌ها، یک تحقیق توصیفی-تحلیلی است. در ابتدا، به توصیف وضعیت فعلی ریسک‌های زنجیره تأمین دیجیتال و عوامل مرتبط با آنها پرداخته می‌شود و سپس با استفاده از ابزارهای تحلیلی، داده‌ها مورد تجزیه و تحلیل قرار می‌گیرند تا نتایج دقیق‌تری درباره عوامل ریسک و نحوه مدیریت آنها به دست آید. جامعه آماری شامل کلیه صنایع مهم فولاد کشور است.

از نظر نوع مطالعه، این پژوهش از هر دو رویکرد کتابخانه‌ای و میدانی استفاده می‌کند:

۱. منابع کتابخانه‌ای (مرور ادبیات و پیشینه): در این بخش، اطلاعات و داده‌های موجود از منابع ثانویه مانند مقالات علمی معتبر داخل و خارج، کتب، منابع موجود در اینترنت، گزارش‌های تخصصی و مستندات مرتبط با زنجیره تأمین دیجیتال و ریسک‌های آن جمع‌آوری می‌شوند. مطالعه منابع کتابخانه‌ای به عنوان پایه‌ای برای توسعه مدل شاخص‌گذاری و ارزیابی ریسک مورد استفاده قرار می‌گیرد.

۲. مطالعه میدانی (مصاحبه و پرسشنامه): در این بخش، داده‌های اولیه از طریق مصاحبه نیمه ساختار یافته بصورت تخصصی و پرسش‌نامه‌ها جمع‌آوری می‌شود. این اطلاعات مستقیماً از افراد (مدیران میانی و مدیران بخش تدارکات شرکتهای تولید فولاد) و سازمان‌هایی که در زنجیره تأمین دیجیتال فعالیت دارند به دست می‌آید تا بتوانند با دقت بیشتری ریسک‌های موجود را شناسایی و مدیریت کنند. همچنین طراحی پروتکل مصاحبه شامل سوالات باز برای شناسایی ابعاد ریسک دیجیتال می‌باشد.

ابزار گردآوری داده‌ها در این تحقیق شامل دو بخش اصلی است:

۱. مصاحبه: در مرحله نخست، به منظور شناسایی ریسک‌های کلیدی زنجیره تأمین دیجیتال، با خبرگان منتخب مصاحبه‌های نیمه ساختار یافته انجام شد. پرسش‌ها به گونه‌ای طراحی شدند که ضمن داشتن ساختار کلی، انعطاف لازم برای طرح پرسش‌های تکمیلی در جریان مصاحبه نیز فراهم باشد. این امر امکان کشف ابعاد پنهان و تجربیات عملیاتی را فراهم کرد.

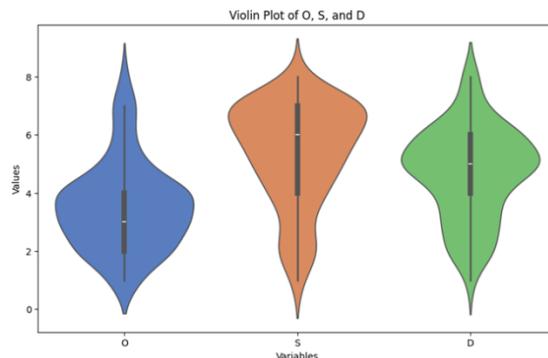
۲. پرسشنامه: در ادامه و پس از استخراج شاخص‌ها و ریسک‌های اولیه از مصاحبه‌ها، پرسشنامه‌ای طراحی شد تا دیدگاه‌های خبرگان در خصوص احتمال وقوع، شدت خسارت و قابلیت کشف هر ریسک گردآوری شود. این پرسشنامه مبنای کمی‌سازی ریسک‌ها و محاسبه عدد اولویت ریسک قرار گرفت. امتیازدهی به متغیرهای ریسک از عدد یک تا ده به ترتیب احتمال و شدت کم و کشف بالا تا احتمال قطعی و تاثیر خیلی زیاد و کشف بسیار سخت امتیازدهی شدند.

جهت شناسایی ریسک‌ها از عدد اولویت ریسک بر اساس

شاخص‌های ارزیابی ریسک شامل احتمال وقوع ریسک (P)، شدت خسارت ناشی از ریسک (S)، قابلیت کشف ریسک (D) استفاده شده است.

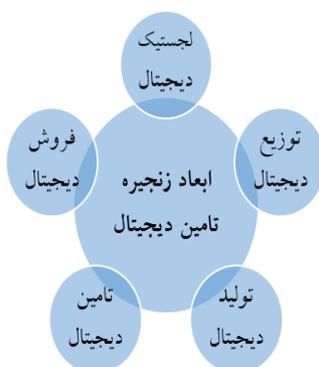
محاسبه عدد اولویت ریسک (ترکیب این سه عامل، شاخص اولویت ریسک $(RPN = P \times S \times D)$ (۱) می‌باشد. برای هر ۱۶۰ ریسک سه شاخص بدست آمده و بیشترین فراوانی در هر شاخص در نظر گرفته شده است.

نمودار ویولن برای بصری‌سازی و توزیع دیتا و تراکم احتمالی آن استفاده شده است. این نمودار شکل توزیع داده‌ها را نشان می‌دهد.



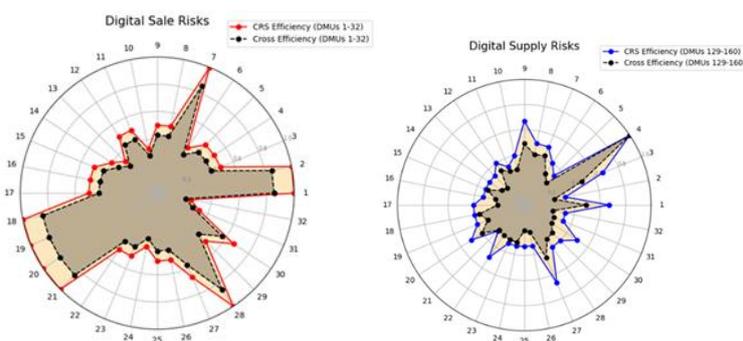
شکل ۱. نمودار ویولن

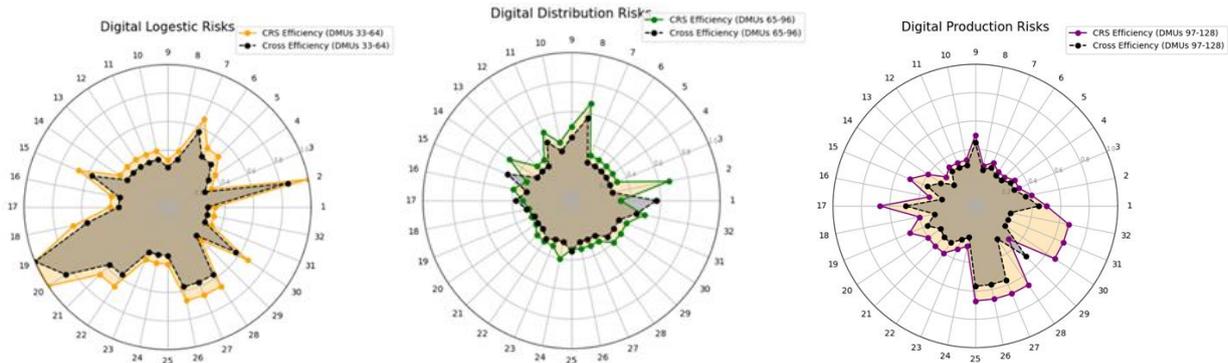
شناسایی ریسک‌ها به جهت افزایش دقت و افزایش داده‌های مدل در ۵ مرحله از زنجیره تامین دیجیتال مطابق به شرح شکل (۲) صورت می‌گیرد:



شکل ۲. ابعاد زنجیره تامین دیجیتال

از نمودار رادار جهت مقایسه متغیرهای کمی که همان ریسک‌های موجود در هر قسمت هستند استفاده شده است. شده است که برای هر ۵ مرحله از زنجیره تامین دیجیتال نموداری راداری ترسیم شده است.





شکل ۳. نمودار عنکبوتی

براساس نتایج بدست آمده از بررسی نمودار عنکبوتی، در هر بخش بیشترین و کمترین ریسکها مشخص شدند. بطوریکه در بخش فروش دیجیتال در زنجیره تامین ریسکهای نوسانات تقاضای بازار دیجیتال، ناتوانی در ارائه خدمات پس از فروش، ریسک قیمت گذاری نامناسب، ناتوانی در اجرای استراتژی‌های بازاریابی دیجیتال، افزایش هزینه‌های تبلیغات، مشکلات در مدیریت پایگاههای داده مشتریان، مشکلات در استفاده از استراتژی‌های فروش بین الملل دارای کمترین ریسک و نقض حریم خصوصی مشتریان، هزینه‌های بالای تبلیغات دیجیتال، ناتوانی در بازاریابی دیجیتال موثر، مشکلات در پیاده سازی سیستم‌های مدیریت ارتباط با مشتریان دارای بیشترین ریسک هستند.

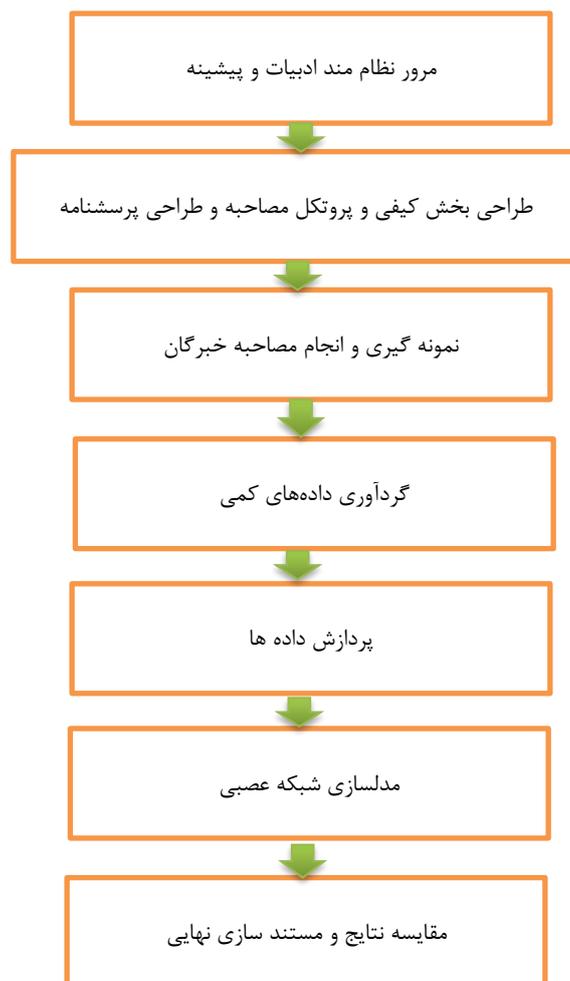
در بخش تولید دیجیتال زنجیره تامین، افزایش هزینه‌های تولید، فقدان زیرساختهای مناسب تولید، تاثیرات سیاسی بر تولید، مشکلات در مدیریت کیفیت جامع، اختلال در فرایندهای خودکار، اختلال ناشی از عدم هماهنگی بین واحدهای تولیدی و نظارت بر تولید برون سپاری شده دارای کمترین ریسک و ناتوانی در استفاده از تکنولوژی‌های جدید، نقض در تجهیزات تولید و از دست دادن نوآوری در تولید دارای بیشترین ریسک هستند.

در بخش لجستیک دیجیتال در زنجیره تامین اختلال در شبکه‌های ارتباطی، مشکلات در مدیریت ناوگان حمل و نقل، ناتوانی در پاسخگویی به تقاضاهای بالا، هزینه‌های اضافی لجستیک دیجیتال، کاهش کیفیت خدمات لجستیک دیجیتال دارای کمترین ریسک و خطرات ناشی از مدیریت ضعیف پلتفرم‌های دیجیتال، افزایش هزینه‌های حمل و نقل، افزایش هزینه‌های لجستیک در دوره‌های پرتراфик، کمبود نیروی متخصص در مدیریت لجستیک، مشکلات امنیتی در حمل کالاهای دیجیتال دارای بیشترین ریسک هستند.

در بخش توزیع دیجیتال زنجیره تامین، ناهماهنگی با پلتفرم‌های توزیع، تغییرات در سیاستهای توزیع بین الملل، تاخیر در توزیع بروز رسانی ها، ریسک قطعی اینترنت در مناطق هدف دارای کمترین ریسک و ناتوانی در توزیع محتواهای دیجیتال، هزینه‌های زیاد توزیع محتوا، خرابی سیستم‌های توزیع، تهدیدات سایبری در شبکه‌های توزیع دارای بیشترین ریسک هستند.

در بخش تامین منابع دیجیتال در زنجیره تامین، عدم دسترسی به منابع فنی، نوسانات قیمتی در خرید منابع دیجیتال، ریسک تامین کنندگان کلیدی، نقص در منابع اولیه، تأثیرات زیست محیطی تامین، افزایش تعرفه‌های واردات، مشکلات امنیتی حمل منابع دارای کمترین ریسک و نیاز به تامین منابع تخصصی، خرابی زیرساختهای فناوری، تأثیر تغییرات اقلیمی بر تامین هزینه‌های بالای منابع، نبود تامین کنندگان پشتیبان دارای بیشترین ریسک هستند.

مراحل اجرایی پژوهش در شکل ۴ آورده شده است.



شکل ۴. مراحل اجرایی پژوهش

یافته‌ها

در مرحله اول با استفاده از روش فراترکیب و مرور ادبیات متناسب با موضوع و پرسش اصلی تحقیق می‌پردازیم:

پرسش اصلی: چه ریسک‌ها، شاخص‌ها و الگوهای مرتبط با مدیریت ریسک در زنجیره تامین دیجیتال در صنایع فولاد وجود دارد که می‌تواند

مبنای طراحی مدل شبکه عصبی قرار گیرند؟

در مرحله دوم به جستجوی نظام مند مطالعات می‌پردازیم بطوریکه با استفاده از پایگاه‌های داده scopus,web of science,science direct,sid,iran dic و.... کلید واژه‌های ریسک،مدیریت ریسک زنجیره تامین،تحول دیجیتال،شبکه عصبی در پیش بینی ریسک،صنایع فولاد و ریسک تحول دیجیتال و.... در بازه زمانی ۲۰۰۰ تا ۲۰۲۵ مورد جستجو قرار گرفتند. مطالعات مرتبط با ریسک‌های زنجیره تامین دیجیتال و پژوهش‌های کیفی یا مروری داده‌های تجربی با تمرکز بر صنعت فولاد استخراج گردید. مقالات غیر مرتبط بدون ارتباط با مدیریت ریسک حذف گردید. مفاهیم مشابه ادغام و یک چهارچوب مفهومی اولیه مشخص گردید.

با استفاده از کدگذاری باز داده‌های خام حاصل از مصاحبه‌ها و یافته‌ها خط به خط بررسی و مفاهیم اولیه استخراج می‌شوند پژوهش حاضر به ریسک‌های زنجیره تامین دیجیتال می‌پردازد. بدین منظور شناسایی و طبقه بندی ریسک‌ها بر مبنای ادبیات و نظر خبرگان بدست می‌آید. همانطور که گفته شد شناسایی ریسک‌ها در دو مرحله بررسی ادبیات پژوهش: با استفاده از مقالات و تحقیقات گذشته و نظر خبرگان که شامل مدیران و متخصصان حوزه فناوری اطلاعات، تولید، لجستیک و زنجیره تامین در صنایع فولاد در هر مرحله از زنجیره تامین در حوزه مدیریت ریسک، زنجیره تامین دیجیتال صورت گرفته است. که در مجموع، این صنعت با ۱۶۰ ریسک کلیدی روبرو است که با توجه به نظر کارشناسان، این ریسک‌ها به عنوان مهم‌ترین و تأثیرگذارترین عوامل بر عملکرد زنجیره تامین فولاد شناخته شده‌اند. ریسک‌ها در هر ۵ مرحله زنجیره تامین تفکیک گردید. جدول زیر ریسک‌های موجود در زنجیره تامین دیجیتال را به تفکیکی نشان می‌دهد.

جدول ۱. ریسک‌های شناسایی شده در ۵ بعد زنجیره تامین دیجیتال

| فروش دیجیتال | لجستیک دیجیتال | توزیع دیجیتال | تولید دیجیتال | تامین منابع دیجیتال |
|--|--|---------------------------------------|----------------------------------|-------------------------------------|
| نوسانات تقاضای بازار دیجیتال | نقص در سیستم‌های مدیریت سفارش | ناتوانی در توزیع محتواهای دیجیتال | نقص در فرآیندهای تولید | عدم دسترسی به منابع فنی |
| ناتوانی در ارائه خدمات پس از فروش | اختلال در شبکه‌های ارتباطی | ناهماهنگی با پلتفرم‌های توزیع | کمبود منابع فنی یا انسانی | خرابی زیرساخت‌های فناوری |
| نقض حریم خصوصی مشتریان | مشکلات در مدیریت انبارهای دیجیتال | مشکلات در زیرساخت‌های اینترنتی | نوسانات کیفی محصولات دیجیتال | نوسانات قیمتی در خرید منابع دیجیتال |
| ناهماهنگی پرداخت | محدودیت‌های جغرافیایی برای ارسال | تغییرات ناگهانی در تقاضا | مشکلات در کنترل کیفیت | ریسک تأمین کنندگان کلیدی |
| اختلال در فرآیندهای فروش آنلاین | تأخیر در تحویل دیجیتال | نقص در فرآیند به‌روزرسانی محتوا | ریسک خطاهای سیستمی | تهدیدات سایبری |
| ناتوانی در هماهنگی با مشتریان بین‌المللی | مشکلات در هماهنگی بین زنجیره تامین دیجیتال | از دست رفتن داده‌های مشتریان | امنیت سایبری در فرآیند تولید | نقض حقوق مالکیت فکری |
| ریسک قیمت‌گذاری نامناسب | هزینه‌های اضافی لجستیک دیجیتال | ریسک سرقت داده‌ها در زمان توزیع | مشکلات هماهنگی بین بخش‌ها | تأخیر در تامین منابع |
| وابستگی به پلتفرم‌های واسط فروش | ناتوانی در پاسخگویی به افزایش تقاضا | تغییرات در سیاست‌های توزیع بین‌المللی | هزینه‌های زیاد زیرساخت‌های تولید | وابستگی به تأمین کنندگان خارجی |

| | | | | |
|---|--|--|---|-----------------------------------|
| هزینه‌های بالای تبلیغات دیجیتال | ریسک از دست دادن داده‌های لجستیکی | محدودیت‌های جغرافیایی در توزیع خودکار | اختلال در فرآیندهای انسانی | نقص در منابع اولیه |
| تهدیدات امنیتی در سیستم‌های فروش | وابستگی به شرکای تجاری ناپایدار | اختلال در سیستم‌های ابری | خطای انسانی در فرآیندهای تولید | مشکلات کیفیت منابع دیجیتال |
| از دست دادن مشتریان کلیدی | خرابی تجهیزات لجستیکی | تأخیر در توزیع به‌روزرسانی‌ها | نوسانات تقاضا | هزینه‌های بالای منابع |
| نقدینگی ناکافی برای فرآیندهای فروش | نقض امنیت در انتقال داده‌ها | هزینه‌های زیاد توزیع محتوا | نقص در تجهیزات تولید | امنیت دسترسی به داده‌های حساس |
| تغییرات در قوانین تجارت الکترونیک | عدم یکپارچگی سیستم‌های لجستیکی | خرابی سیستم‌های توزیع دیجیتال | نبود انعطاف‌پذیری در فرآیند تولید | ریسک تحریم‌ها و محدودیت‌های تجاری |
| نارضایتی مشتریان از کیفیت خدمات | اختلال در روندهای اتوماسیون | ریسک قطعی اینترنت در مناطق هدف | عدم بهره‌وری در استفاده از منابع تولید | تطبیق با استانداردهای بین‌المللی |
| کاهش بهره‌وری فروشندگان دیجیتال | کاهش کیفیت خدمات لجستیک دیجیتال | محدودیت‌های قانونی توزیع محتوا | از دست دادن نوآوری در تولید | تغییرات قانونی و مقرراتی |
| ناتوانی در بازاریابی دیجیتال مؤثر | خطرات ناشی از مدیریت ضعیف پلتفرم‌های لجستیک | تهدیدات سایبری در شبکه‌های توزیع | تأثیرات محیطی و اجتماعی فرآیند تولید | ناپایداری بازارهای تأمین دیجیتال |
| مشکلات در پیاده‌سازی سیستم‌های CRM | افزایش هزینه‌های حمل و نقل | مشکلات فنی در شبکه توزیع | افزایش هزینه‌های تولید | افزایش هزینه‌های منابع اولیه |
| ناتوانی در اجرای استراتژی‌های بازاریابی دیجیتال | ناتوانی در کاهش هزینه‌های انبارداری | افزایش هزینه‌های نگهداری شبکه | ناتوانی در استفاده از تکنولوژی‌های جدید | عدم وجود رقابت در بازار تأمین |
| افزایش هزینه‌های تبلیغات | مشکلات در مدیریت ناوگان حمل و نقل | ناتوانی در ارتقای پلتفرم‌های توزیع | فقدان نیروی کار متخصص منابع وارداتی | مشکلات مربوط به کیفیت |
| مشکلات در مدیریت پایگاه‌های داده مشتریان | ناتوانی در پاسخگویی به تقاضاهای بالا | نوسانات شدید در تقاضا | مشکلات در تولید نرم‌افزارهای سفارشی | تأثیرات زیست‌محیطی تأمین |
| کاهش تمایل مشتریان به خرید | مشکلات ناشی از تأخیر در ترخیص کالاها | ریسک‌های مرتبط با دسترسی کاربران به پلتفرم | ناتوانی در بهبود فرآیندهای تولید | نبود تأمین‌کنندگان پشتیبان |
| ناتوانی در جذب مشتریان جدید | مشکلات در مدیریت موجودی انبار | نقض قوانین حق نشر در توزیع محتوا | هزینه‌های به‌روزرسانی تجهیزات تولید | افزایش تعرفه‌های واردات |
| افزایش نرخ لغو سفارشات | افزایش هزینه‌های لجستیکی در دوره‌های پرترافیک | وابستگی به شرکت‌های واسطه برای توزیع | تأخیر در تولید محصولات سفارشی | تغییرات تقاضای بازار |
| افزایش هزینه‌های مدیریت مشتریان | کمبود نیروی متخصص در مدیریت لجستیک | کاهش کیفیت تجربه کاربر | ناتوانی در تولید مقیاس‌پذیر | کمبود منابع انرژی برای تأمین |
| مشکلات ناشی از رقابت با پلتفرم‌های بزرگ | مشکلات امنیتی در حمل کالاهای دیجیتال | تأثیرات محدودیت‌های دولتی بر توزیع | فقدان زیرساخت‌های مناسب تولید | تأمین منابع از مناطق پرخطر |
| کاهش سودآوری از طریق فروش دیجیتال | ریسک‌های ناشی از تأخیر در حمل و نقل بین‌المللی | افزایش هزینه‌های سرورها و خدمات ابری | تأثیرات سیاسی بر تولید | اختلال در تأمین منابع بحرانی |
| وابستگی بیش از حد به تخفیف‌ها برای جذب مشتریان | افزایش هزینه‌های سوخت | تأخیر در ارائه خدمات پشتیبانی به مشتریان | مشکلات در مدیریت کیفیت جامع | مشکلات امنیتی در حمل منابع |

| | | | | | |
|---|--|-------------------------------|--------------------------|---------------------------|----------------------------|
| مشکلات در اجرای ناتوانی در مدیریت تحویل‌های | مشکلات در توزیع به نیاز به تأمین قطعات | زمانبندی نامناسب در تأمین | مشکلات در توزیع محتوای | مشتریان بین‌المللی | کمیاپ |
| ناتوانی در ارائه خدمات | کامبود فضاهای انبار مناسب | افزایش هزینه‌های نیروی | ناهمخوانی توزیع محتوا با | فرهنگ محلی | کار |
| مشتریان به موقع | کاهش تعاملات مشتریان با | مشکلات ناشی از تغییرات اقلیمی | از دست رفتن اطلاعات | تأخیر در تحویل تولیدات | فقدان گواهی‌های بین‌المللی |
| پلتفرم | در حمل و نقل | مهم مشتریان | برای منابع | تأثیرات تغییرات اقلیمی بر | تأمین |
| ریسک‌های مرتبط با تغییرات | کاهش سرعت حمل و نقل به دلیل | عدم پشتیبانی از | مشکلات در نظارت بر | تولید برون‌سپاری شده | تأمین |
| قوانین مالیاتی | شرایط بحرانی | زیرساخت‌های قدیمی | اختلالات ناشی از عدم | نیاز به تأمین منابع تخصصی | تولید |
| مشکلات در استفاده از | افزایش زمان‌های تحویل | مشکلات در سیستم‌های | هماهنگی بین واحدهای | پایش محتوا | تولید |
| ابزارهای فروش پیشرفته | | | | | |

در تحلیل ریسک و مدیریت کیفیت، شناسایی و ارزیابی خطرات احتمالی در فرآیندها از اهمیت ویژه‌ای برخوردار است. شاخص عدد الویت ریسک بر اساس سه عامل کلیدی شامل احتمال وقوع، شدت تأثیر و قابلیت تشخیص تعیین می‌شود. برای ارزیابی شاخص عدد الویت ریسک در حوزه زنجیره تامین دیجیتال، از کارشناسان این حوزه درخواست شد تا با استفاده از مقیاس ۱ تا ۱۰، به هر یک از عوامل احتمال وقوع، شدت تأثیر و قابلیت تشخیص امتیاز دهند. امتیاز ۱ نشان‌دهنده کمترین میزان ریسک (احتمال وقوع بسیار کم، تأثیر جزئی و قابلیت تشخیص بالا) و امتیاز ۱۰ نشان‌دهنده بالاترین میزان ریسک (احتمال وقوع قطعی، تأثیر فاجعه‌بار و قابلیت تشخیص بسیار پایین) است. این امتیازات بر اساس تجربیات و دانش تخصصی این کارشناسان تعیین شد تا بتوان با دقت بیشتری خطرات و ریسک‌های موجود در فرآیندهای زنجیره تامین دیجیتال را شناسایی و ارزیابی کرد. با شاخص عدد الویت ریسک با فرمول (۱) محاسبه شد که می‌تواند به عنوان معیاری برای اولویت‌بندی و مدیریت بهینه ریسک‌ها در این حوزه به کار رود.

پس از شناسایی ریسک‌ها مرحله تحلیل و ارزیابی ریسک صورت می‌گیرد. تبدیل ریسک‌های کیفی به کمی یکی از چالش‌های مهم در مدیریت ریسک است که به کمک آن می‌توان تصمیم‌گیری‌ها را دقیق‌تر و مستندتر انجام داد.

شاخص عدد الویت ریسک با وجود کاربردش در ارزیابی ریسک‌ها، به دلیل ترکیب ساده متغیرهایش، محدودیت‌هایی دارد. این روش نمی‌تواند به طور کامل تمام پیچیدگی‌ها و ارتباطات متقابل بین این عوامل را به خوبی نشان دهد. این نقاط ضعف و محدودیت‌ها باعث می‌شود که عدد الویت ریسک به عنوان تنها ابزار برای ارزیابی ریسک، کامل نباشد و بهتر است در کنار سایر روش‌ها و ابزارهای تحلیل ریسک استفاده شود. روش تحلیل پوششی داده‌ها قادر است بهینه‌سازی بیشتری ارائه داده و نواقص عدد الویت ریسک را پوشش داده و ارزیابی جامع‌تری از ریسک‌ها ارائه کند. سیستم‌ها یا فرآیندهای پیچیده که شامل زیرسیستم‌ها و اجزای مختلف هستند، ناکارآمد است. به همین دلیل، در این پژوهش

از روش تحلیل پوششی داده‌ها برای رفع مشکلات مربوط به محاسبات عدد الویت ریسک استفاده شده است. این روش همچنین قادر است وزن‌های عوامل ریسک را به درستی تنظیم کرده و روابط مستقیم و غیرمستقیم بین حالت‌های خرابی را در نظر بگیرد.

ارزیابی کارایی نسبی: تحلیل پوششی داده‌ها به مقایسه عملکرد واحدها نسبت به یکدیگر کمک می‌کند و به‌طور خاص می‌تواند ریسک‌های موجود در هر واحد را از منظر کارایی آن ارزیابی کند. این روش می‌تواند به شناسایی نقاط ضعف و همچنین تعیین اولویت‌های ریسک در واحدهای مختلف کمک کند.

۲- چند بعدی بودن معیارها: تحلیل پوششی داده‌ها می‌تواند همزمان چندین ورودی و خروجی مختلف را مدنظر قرار دهد. در محاسبه ریسک، ممکن است نیاز باشد که فاکتورهای مختلفی مانند هزینه‌ها، منابع، زمان و دیگر عوامل ریسک‌زا بررسی شوند. تحلیل پوششی داده‌ها این امکان را فراهم می‌کند که چندین عامل را به‌طور همزمان در نظر بگیریم و کارایی یا ریسک را به‌طور جامع تحلیل کنیم.

۳- تشخیص منابع ناکارآمد یا ریسک‌زا: با استفاده از تحلیل پوششی داده‌ها می‌توان واحدهایی که عملکرد ضعیف دارند و منابع را به‌طور غیر بهینه مصرف می‌کنند شناسایی کرد. این واحدها ممکن است با ریسک‌های بالاتری مواجه شوند، چرا که به‌طور مؤثر و بهینه عمل نمی‌کنند.

۴- فرایند تصمیم‌گیری بهتر: در محاسبه اولویت‌های ریسک، معمولاً هدف یافتن واحدهایی است که در معرض بیشترین ریسک قرار دارند. تحلیل پوششی داده‌ها می‌تواند کمک کند تا واحدهای با کمترین کارایی (که ممکن است با ریسک بیشتری مواجه شوند) شناسایی و اولویت‌بندی شوند.

۵- مدل‌سازی پیچیدگی‌ها: ریسک‌ها معمولاً پیچیدگی‌هایی دارند که نمی‌توان به‌سادگی آنها را با معیارهای یک‌بعدی تحلیل کرد. تحلیل پوششی داده‌ها می‌تواند پیچیدگی‌های مختلفی که در ارزیابی ریسک‌ها وجود دارد را به‌طور مؤثر مدیریت کند و عدد اولویت ریسک را بر اساس تحلیل چندبعدی بدست آورد (۴۳).

مدل تحلیل پوششی داده‌ها به همراه کارایی متقاطع برای محاسبه شاخص‌های ریسک به کار گرفته می‌شود. این مدل امکان ارزیابی کارایی داده‌های مربوط به ریسک‌ها یا واحدهای تصمیم‌گیرنده (DMU) در چارچوب تحلیل پوششی داده‌ها را فراهم می‌سازد. هر شاخص ریسک به‌عنوان یک واحد تصمیم‌گیرنده تلقی می‌شود. این روش امکان مقایسه دقیق‌تر و مدیریت مؤثرتر ریسک‌های شناسایی شده را فراهم می‌کند.

سه عامل اصلی ریسک به‌عنوان ورودی‌های مدل در نظر گرفته می‌شود:

مدل کارایی متقاطع به شرح زیر می‌باشد:

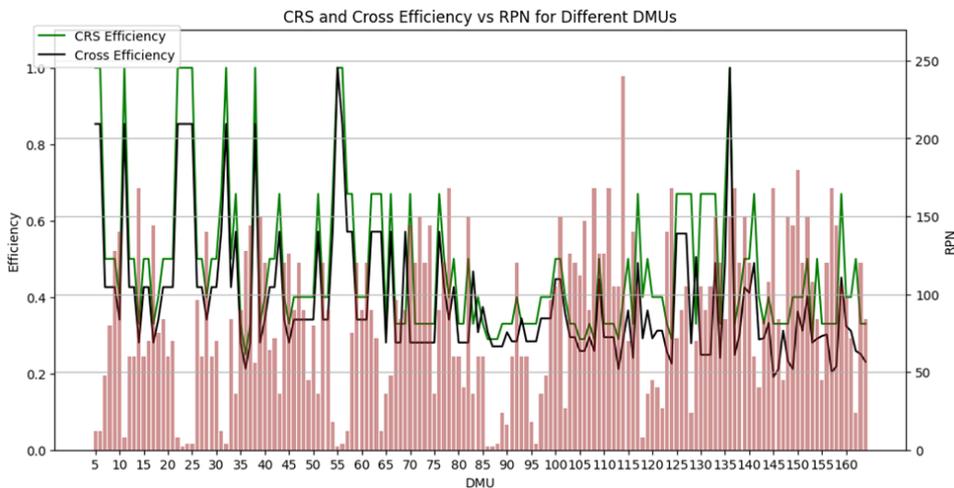
$$CE_j = \frac{1}{N} \sum_{k=1}^N E_{jk}$$

$$= \frac{1}{N} \sum_{k=1}^N \left(\frac{\mu_1 y_{1jk} + \mu_2 y_{2jk} + \dots + \mu_r y_{rjk}}{v_1 x_{1jk} + v_2 x_{2jk} + \dots + v_m x_{mjk}} \right)$$

(۲)

نیاز به k مرتبه حل دارد، هر بار برای یک امتیاز کارایی هدف برای (E_{jk}, DMU_j) ، تا بتواند امتیازات کارایی متقاطع تمامی واحدها را به دست آورد.

مدل کارایی متقاطع توانایی محاسبه دقیق‌تر نمرات کارایی واحدهای تصمیم‌گیرنده را در مقایسه با روش کلاسیک دارد. به طور کلی وقتی روش تحلیل پوششی داده‌ها اعمال می‌شود، یک RPN (عدد اولویت ریسک) پایین معمولاً با نمره کارایی بالاتری همراه است. این به این معنی است که واحدهای تصمیم‌گیرنده‌ای که ریسک پایین‌تری دارند، معمولاً در روش تحلیل پوششی داده‌ها نمره کارایی بالاتری دریافت می‌کنند. با این حال، این رابطه همیشه مستقیم و ثابت نیست؛ همانطور که در شکل زیر دیده می‌شود، نوساناتی در نمودار خطی وجود دارد که نشان می‌دهد نمرات کارایی واحدهای تصمیم‌گیرنده کاملاً به مقدار عددالویت ریسک وابسته نیستند. این نوسانات می‌توانند به دلیل عوامل دیگری باشند که در ارزیابی کارایی توسط روش تحلیل پوششی نقش دارند و نشان‌دهنده پیچیدگی بیشتر در ارزیابی کارایی با این روش هستند.



شکل ۵. مقایسه کارایی‌ها و عددالویت ریسک برای ۱۶۰ واحد تصمیم‌گیری (ریسک‌ها)

بنابراین درمان و پایش ریسک یکی از فرآیندهای اساسی در مدیریت ریسک به شمار می‌آید. اقدامات مرتبط با انتخاب استراتژی‌های مناسب درمان و ارزیابی موفقیت این استراتژی‌ها از جنبه‌های برجسته درمان و پایش ریسک هستند. توسعه روش‌ها و ابزارهای مؤثر برای پیش‌بینی

نتایج بالقوه استراتژی‌های درمان ریسک، اهمیت بسیاری در تقویت فرآیند مدیریت ریسک به سمت رویکردی جامع‌تر و مقاوم‌تر دارد. در ارزیابی ریسک از روش‌های هوشمندی مثل فازی، سیستم‌های خبره، AHP و تحلیل پوششی و شبکه عصبی استفاده می‌شود. بنابراین مطالعه تحقیقات پیشین نشان می‌دهد که شبکه‌های عصبی نقش موثر و مفیدی در یادگیری و آموزش جهت کاهش و مدیریت ریسک داشته است. یکی از چالش‌های مهم در استفاده از تحلیل پوششی داده‌ها زمانی رخ می‌دهد که تغییراتی در واحدهای موجود (ریسک‌های فعلی) به وجود آید یا واحدهای جدیدی (ریسک‌های جدید) به سیستم اضافه شوند. در این شرایط، نیاز به محاسبات مجدد در فرآیند تحلیل پوششی داده‌ها به وجود می‌آید. این محاسبات مجدد به این دلیل ضروری است که مرز کارایی تعریف‌شده توسط تحلیل پوششی داده‌ها ممکن است با ورود داده‌های جدید تغییر کند. تغییر در این مرز می‌تواند منجر به تغییر نمرات کارایی سایر واحدها شود و در نتیجه، دقت تصمیم‌گیری‌های مدیریتی را تحت تأثیر قرار دهد. اگر تنها برخی از واحدهای تصمیم نیاز به محاسبه مجدد داشته باشند تا ارزش جدید کارایی آن‌ها برای نشان دادن سطح جدید ریسک به دست آید، معمولاً مدیران کل فرآیند تحلیل پوششی داده‌ها را دوباره اعمال می‌کنند. که این امر می‌تواند در فرآیند تصمیم‌گیری، به ویژه در نظارت بر ریسک، ایجاد سردرگمی کند. در این شرایط، شبکه‌های عصبی مصنوعی به عنوان راه‌حلی نوین مطرح می‌شوند. استفاده از شبکه‌های عصبی مصنوعی امکان پیش‌بینی سطح جدید کارایی را بدون نیاز به محاسبات مجدد کامل تحلیل پوششی فراهم می‌کند. شبکه‌های عصبی با قابلیت یادگیری از داده‌های گذشته، قادر به پیش‌بینی نمرات کارایی واحدهای جدید (ریسک‌ها) یا تغییر یافته با دقت بالا هستند. این روش علاوه بر صرفه‌جویی در زمان و منابع، به پایداری بیشتر نتایج ارزیابی‌ها کمک می‌کند و از ایجاد نوسانات غیرضروری در نمرات کارایی جلوگیری می‌کند.

بنابراین، ترکیب روش‌های سنتی ارزیابی مانند تحلیل پوششی داده‌ها با تکنیک‌های مدرن یادگیری ماشین نظیر شبکه عصبی، ابزاری قدرتمند برای مدیریت کارایی و ریسک در سازمان‌ها فراهم می‌آورد. این رویکرد ترکیبی به سازمان‌ها امکان می‌دهد تا عملکرد خود را با دقت بیشتری ارزیابی کرده و تصمیمات بهتری در زمینه مدیریت ریسک اتخاذ کنند.

در فرآیند بهینه‌سازی مدل شبکه عصبی، هدف انتخاب ساختار و پارامترهایی بود که بیشترین دقت و کمترین خطا را در شناسایی و پیش‌بینی الگوهای داده تضمین کنند. برای دستیابی به این هدف، فضایی از پارامترها تعریف و ترکیب‌های متنوعی از معماری شبکه و تنظیمات آموزشی مورد ارزیابی قرار گرفتند.

نتایج آزمایش‌ها نشان داد که بهترین عملکرد با پیکربندی زیر حاصل شد:

تابع فعال‌سازی: ReLU

پارامتر تنظیم (α) : 0.001

معماری شبکه: دو لایه مخفی با ۱۰ و ۵ نورون

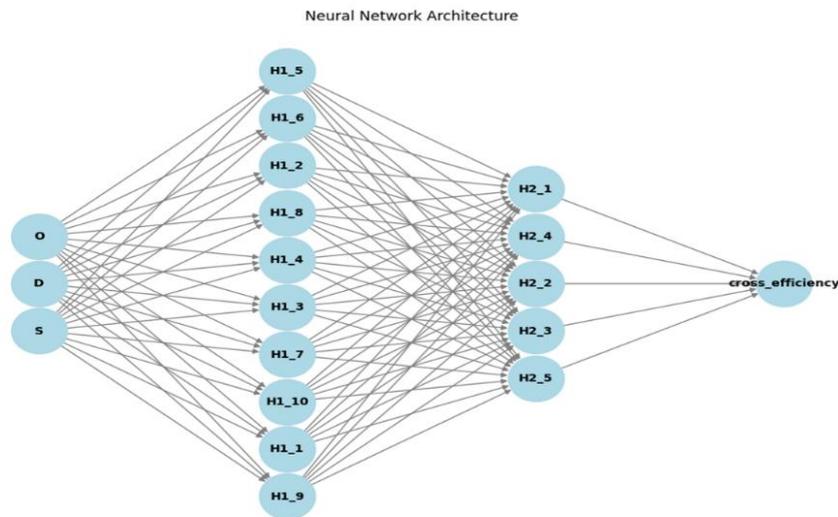
نرخ یادگیری: ثابت (constant)

حل‌کننده: L-BFGS

این ترکیب موجب دستیابی به مدلی شد که علاوه بر دقت بالا، خطای پیش‌بینی اندکی داشته و توانایی بالایی در شناسایی الگوهای پنهان داده‌ها از خود نشان داد. فرآیند بهینه‌سازی تأکید می‌کند که انتخاب هوشمندانه توابع فعال‌سازی، ساختار شبکه و پارامترهای تنظیمی، نقش تعیین‌کننده‌ای در ارتقای عملکرد شبکه‌های عصبی دارد.

شکل (۵) معماری نهایی شبکه عصبی مورد استفاده در مدل را نشان می‌دهد.

این نورون خروجی نهایی مدل را تولید می‌کند که همان مقدار پیش‌بینی‌شده‌ی کارایی متقاطع است.

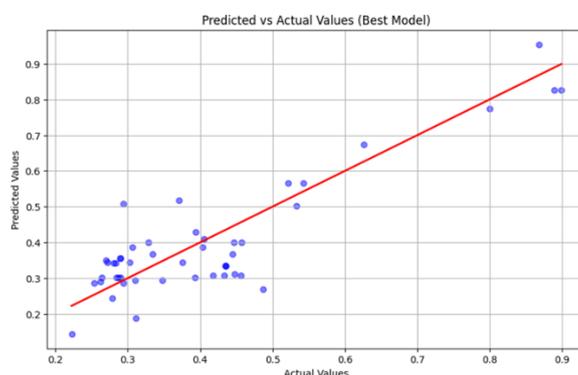


شکل ۶. مدل شبکه عصبی پیشنهادی

تحلیل عملکرد مدل شبکه عصبی نشان می‌دهد که مقدار MSE (Mean Squared Error = ۰.۰۰۶۹۴) و ضریب تعیین R^2 برابر است با ۰.۸۴۲۷، همبستگی بین مقادیر واقعی و پیش‌بینی شده (۰.۸۷۴)، $Relative\ Error = ۱۸.۰۸\%$ است که مقدار کم MSE و همبستگی بالا، نشان‌دهنده پیش‌بینی‌های دقیق و قابل اعتماد مدل است.

مقدار نشان می‌دهد که مدل قادر است بخش عمده‌ای از واریانس داده‌ها را توضیح دهد، هرچند هنوز مقداری از واریانس باقی مانده است. خطای نسبی پایین، دقت عملیاتی مدل را تأیید می‌کند. بنابراین می‌توان نتیجه گرفت که مدل شبکه عصبی با تنظیمات بهینه عملکردی دقیق و قابل اعتماد ارائه داده است.

شکل (۷) مقادیر پیش‌بینی شده را در مقابل مقادیر واقعی برای داده‌های آزمون نمایش می‌دهد و با خط ۴۵ درجه مقایسه شده است. این شکل تأیید می‌کند که اکثر پیش‌بینی‌ها نزدیک به مقادیر واقعی قرار دارند و مدل توانسته عملکرد قابل توجهی در پیش‌بینی داده‌ها ارائه دهد.

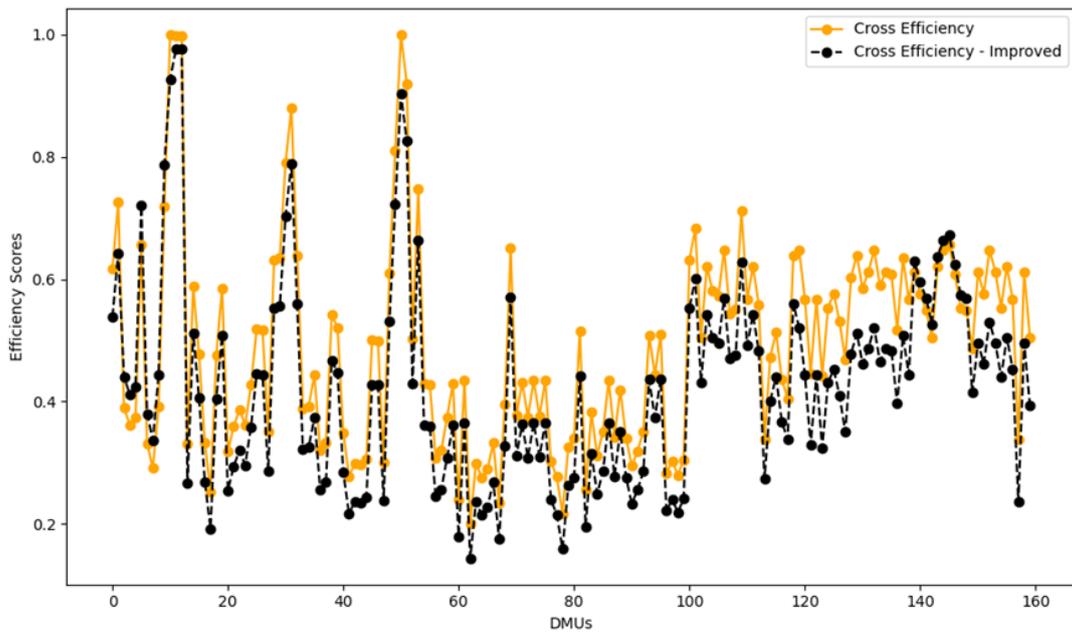


شکل ۷. مقایسه مقادیر پیش‌بینی شده و واقعی

هدف اصلی این پژوهش توسعه روش‌هایی برای پیش‌بینی تغییرات در مقادیر ریسک با اجرای استراتژی‌های کاهش ریسک است. برای این منظور، یک سناریوی ایده‌آل از بهبود کاهش ریسک ارائه می‌شود. این سناریو بر مبنای نتایج رویکرد بهره‌وری متقاطع تحلیل پوششی داده‌ها طراحی شده است.

این سناریو فرض می‌کند که ریسک‌های مرتبط می‌توانند در آینده با اعمال قوانین منعطف‌تر و قوی‌تر کاهش احتمال وقوع کمتری باشند یابند. به عبارت دیگر از مجموعه ۱۶۰ ریسک ارزیابی شده در بخش قبل احتمال وقوع ۶ مورد از ریسک‌های موجود در روش تامین دیجیتال که مقادیر عدد ریسک بالایی دارند را با توجه به نظر کارشناسان کاهش می‌دهیم چرا که با بهبود تکنولوژی در حوزه زنجیره تامین دیجیتال احتمال وقوع چنین ریسک‌هایی قابل کاهش است. لازم به ذکر است که این سناریوی بهبود روی سایر شاخص‌های ریسک یعنی قابلیت تشخیص و شدت وقوع نیز قابل اجراست. در این سناریو، ۶ واحد تصمیم‌گیری بهبود یافته شناسایی شده‌اند که در شکل زیراطلاعات مربوط به قبل و بعد از بهبود قابل مشاهده است.

مقادیر قبل و بعد از بهبود را برای تمامی واحدها به روش کارایی متقاطع نمایش می‌دهد که تغییر در مقادیر اکثر واحدها (چه بهبود یافته و چه بهبود نیافته) کاملاً از روی شکل قابل تشخیص است و این تأیید می‌کند که روش ترکیبی یادگیری ماشین-کارایی متقاطع عملکرد بسیار قوی تری نسبت به روش کارایی متقاطع (به تنهایی) دارد.



شکل ۸. مقادیر قبل و بعد از بهبود برای تمامی واحدها به روش کارایی متقاطع

بحث و نتیجه‌گیری

هدف اصلی پژوهش حاضر طراحی و آزمون یک مدل ترکیبی مبتنی بر تحلیل پوششی داده‌ها و شبکه عصبی مصنوعی برای پیش‌بینی و بهینه‌سازی مدیریت ریسک در زنجیره تأمین دیجیتال صنعت فولاد بود. نتایج نشان داد که رویکرد ترکیبی DEA-ANN قادر است ریسک‌های شناسایی شده را نه تنها به صورت دقیق ارزیابی و اولویت‌بندی کند، بلکه با اتکا به یادگیری داده‌محور، تغییرات آتی سطح ریسک و کارایی متقاطع آن‌ها را نیز با دقت قابل‌قبولی پیش‌بینی نماید. این یافته حاکی از آن است که گذار از روش‌های ایستا و قضاوت‌محور به مدل‌های هوشمند و پیش‌بینی‌گر می‌تواند کیفیت تصمیم‌گیری در محیط‌های پیچیده دیجیتال را به‌طور معناداری ارتقا دهد؛ امری که در ادبیات مدیریت ریسک زنجیره تأمین دیجیتال به‌عنوان یک نیاز راهبردی مطرح شده است (Porter, 2021; Song et al., 2024).

در مرحله نخست، شناسایی ۱۶۰ ریسک در پنج بعد اصلی زنجیره تأمین دیجیتال (تأمین منابع، تولید، لجستیک، توزیع و فروش دیجیتال) نشان داد که ریسک‌های فناورانه، سایبری و سیستمی سهم غالبی در آسیب‌پذیری زنجیره تأمین فولاد دارند. این نتیجه با مطالعاتی که بر ماهیت شبکه‌ای و وابستگی متقابل ریسک‌ها در زنجیره‌های دیجیتال تأکید کرده‌اند همسو است (DuHadway et al., 2019; Rao & Goldsby, 2009). به‌ویژه، برجستگی ریسک‌های مرتبط با زیرساخت‌های فناوری، امنیت داده و ناهماهنگی سیستم‌ها تأیید می‌کند که دیجیتالی‌شدن، در کنار فرصت‌های بهره‌وری، سطح جدیدی از عدم قطعیت را وارد سیستم کرده است (Brintrup et al., 2024; Creazza et al., 2022).

یافته‌های مربوط به محاسبه عدد اولویت ریسک نشان داد که استفاده صرف از RPN، اگرچه تصویری اولیه از شدت و احتمال ریسک‌ها ارائه می‌دهد، اما قادر به انعکاس پیچیدگی روابط بین شاخص‌ها و تفاوت کارایی ریسک‌ها در سطح سیستم نیست. این محدودیت پیش‌تر نیز در پژوهش‌های مرتبط با روش‌های سنتی ارزیابی ریسک گزارش شده است (Araz et al., 2020; Dias et al., 2020). در این پژوهش، به‌کارگیری تحلیل پوششی داده‌ها با رویکرد کارایی متقاطع، امکان تعدیل وزن‌ها و مقایسه دقیق‌تر ریسک‌ها را فراهم ساخت و نشان داد که برخی ریسک‌ها با وجود RPN مشابه، از منظر کارایی سیستمی اثرگذاری متفاوتی دارند. این نتیجه با یافته‌های Emrouznejad و Yang مبنی بر توان DEA در تحلیل چندبعدی و پوشش نواقص شاخص‌های تک‌عددی همخوان است (Emrouznejad & Yang, 2018).

نتایج مرحله مدل‌سازی شبکه عصبی مصنوعی نشان داد که ANN آموزش‌دیده با خروجی‌های DEA، توانایی بالایی در پیش‌بینی نمرات کارایی متقاطع دارد. مقادیر پایین خطای میانگین مربعات، ضریب تعیین بالا و همبستگی قوی بین مقادیر واقعی و پیش‌بینی‌شده، بیانگر دقت و پایداری مدل است. این یافته با مطالعاتی که ANN را ابزاری کارآمد برای پیش‌بینی ریسک در محیط‌های دیجیتال معرفی کرده‌اند، هم‌راستا است (Dijie, 2022; Fu et al., 2022; Rezki & Mansouri, 2023). افزون بر این، نتایج با مرورهای اخیر که بر مزیت شبکه‌های عصبی در یادگیری الگوهای غیرخطی زنجیره تأمین تأکید دارند، تطابق دارد (Soori et al., 2023; Zogaan et al., 2025). از منظر نظری، نتایج پژوهش حاضر مؤید دیدگاه قابلیت‌های پویا در مدیریت زنجیره تأمین دیجیتال است. بر اساس این دیدگاه، سازمان‌ها تنها با در اختیار داشتن فناوری‌های دیجیتال به تاب‌آوری دست نمی‌یابند، بلکه نیازمند سازوکارهایی برای یادگیری، پیش‌بینی و تطبیق مستمر با عدم قطعیت‌ها هستند (Haicao et al., 2024; Nasiri et al., 2020). مدل DEA-ANN ارائه‌شده، با ترکیب ارزیابی کارایی و یادگیری ماشینی، دقیقاً چنین سازوکاری را فراهم می‌کند و نشان می‌دهد که چگونه می‌توان از داده‌های گذشته برای پیش‌بینی سناریوهای آینده و بهبود تصمیمات مدیریت ریسک بهره گرفت.

از منظر کاربردی، نتایج نشان داد که سناریوهای بهبود ریسک (کاهش احتمال وقوع برخی ریسک‌های کلیدی) نه تنها موجب افزایش کارایی همان ریسک‌ها می‌شود، بلکه بر نمرات کارایی سایر ریسک‌ها نیز اثرگذار است. این اثر سرریز، بیانگر ماهیت شبکه‌ای ریسک‌ها در زنجیره تأمین دیجیتال است؛ موضوعی که در مطالعات تاب‌آوری زنجیره تأمین نیز گزارش شده است (Gupta, 2022; Ivanov et al., 2019). به‌عبارت دیگر، مدیریت هدفمند چند ریسک کلیدی می‌تواند به بهبود کلی عملکرد سیستم منجر شود، که این امر برای مدیران صنعت فولاد از اهمیت راهبردی برخوردار است.

یافته‌های پژوهش همچنین با مطالعات انجام‌شده در صنایع دیگر همخوانی دارد. برای مثال، نتایج با پژوهش Nazari-Shirkouhi و همکاران در استفاده از مدل‌های ترکیبی DEA-ANN برای انتخاب تأمین‌کننده تاب‌آور همسو است و نشان می‌دهد که این رویکرد در

محیط‌های مختلف صنعتی قابلیت تعمیم دارد (Nazari-Shirkouhi et al., 2023). همچنین، شباهت نتایج با مطالعات Pan و Miao در ارزیابی ریسک زنجیره‌های بسته و دیجیتال، بر کارایی شبکه‌های عصبی در مدل‌سازی پویایی‌های ریسک تأکید می‌کند (Pan & Miao, 2023).

در نهایت، هم‌راستایی نتایج این پژوهش با ادبیات مدیریت ریسک دیجیتال نشان می‌دهد که حرکت به سوی مدل‌های هوشمند ترکیبی، نه یک انتخاب اختیاری، بلکه ضرورتی اجتناب‌ناپذیر برای صنایع راهبردی است. مطالعات پیشین بارها بر ناکارآمدی رویکردهای صرفاً توصیفی و ایستا در مواجهه با ریسک‌های دیجیتال تأکید کرده‌اند (Alok et al., 2020; Schlüter & Henke, 2017). پژوهش حاضر با ارائه شواهد تجربی از صنعت فولاد، این ادعا را تقویت می‌کند که ترکیب روش‌های تصمیم‌گیری چندمعیاره با یادگیری ماشین می‌تواند مسیر جدیدی برای مدیریت ریسک زنجیره تأمین دیجیتال فراهم آورد (Ghadge et al., 2020; Lee et al., 2022).

یکی از محدودیت‌های اصلی این پژوهش، تمرکز آن بر صنعت فولاد است که ممکن است تعمیم‌پذیری کامل نتایج به سایر صنایع را با احتیاط همراه سازد. همچنین، بخشی از داده‌های مورد استفاده مبتنی بر قضاوت خبرگان بوده و هرچند تلاش شد با روش‌های کمی این سوگیری کاهش یابد، اما احتمال تأثیر ذهنیت پاسخ‌دهندگان همچنان وجود دارد. محدودیت دیگر، دسترسی محدود به داده‌های تاریخی بلندمدت و استاندارد در حوزه ریسک‌های دیجیتال بود که می‌توانست دقت آموزش مدل شبکه عصبی را بیش از پیش افزایش دهد. پژوهش‌های آینده می‌توانند مدل پیشنهادی را در صنایع دیگر نظیر پتروشیمی، خودروسازی یا لجستیک بین‌المللی آزمون و مقایسه کنند. همچنین، ترکیب DEA-ANN با رویکردهای پیشرفته‌تر یادگیری عمیق یا مدل‌های پویا مبتنی بر زمان می‌تواند به درک بهتر رفتار ریسک‌ها در افق‌های بلندمدت کمک کند. بررسی نقش متغیرهای کلان اقتصادی، سیاسی و ژئوپلیتیکی به‌عنوان ورودی‌های تکمیلی نیز می‌تواند مسیر پژوهش‌های آتی را غنی‌تر سازد.

به مدیران زنجیره تأمین صنعت فولاد توصیه می‌شود از مدل‌های هوشمند ترکیبی برای پایش مستمر ریسک‌ها استفاده کنند و تصمیمات خود را از سطح واکنشی به سطح پیش‌نگر ارتقا دهند. استقرار سیستم‌های داده‌محور و سرمایه‌گذاری در زیرساخت‌های تحلیلی می‌تواند زمینه بهره‌گیری عملی از مدل DEA-ANN را فراهم سازد. همچنین، تمرکز بر مدیریت چند ریسک کلیدی با اثر سرریز بالا می‌تواند راهبردی مؤثر برای افزایش تاب‌آوری و کاهش هزینه‌های ناشی از اختلالات دیجیتال باشد.

مشارکت نویسندگان

در نگارش این مقاله تمامی نویسندگان نقش یکسانی ایفا کردند.

تعارض منافع

در انجام مطالعه حاضر، هیچ گونه تضاد منافی وجود ندارد.

موازین اخلاقی

در تمامی مراحل پژوهش حاضر اصول اخلاقی مرتبط با نشر و انجام پژوهش رعایت گردیده است.

تشکر و قدردانی

از تمامی کسانی که در انجام این پژوهش ما را همراهی کردند تشکر و قدردانی به عمل می آید.

Extended Abstract

Introduction

Digital transformation has fundamentally reshaped supply chain structures by integrating advanced technologies such as artificial intelligence, big data analytics, the Internet of Things, blockchain, and cyber-physical systems into operational and strategic processes. These developments have led to the emergence of the digital supply chain, characterized by real-time data exchange, increased transparency, automation, and enhanced responsiveness to environmental uncertainty. While digital supply chains offer significant opportunities for efficiency, agility, and performance improvement, they simultaneously introduce new forms of risk that are more complex, interconnected, and difficult to predict than those in traditional supply chains (Pellicelli, 2023; Porter, 2021).

The literature on supply chain risk management has evolved from focusing on physical disruptions and logistical delays toward addressing systemic, cyber, and data-driven risks embedded in digitally enabled networks (DuHadway et al., 2019; Rao & Goldsby, 2009). Recent studies emphasize that digital technologies may act as a double-edged sword: while they can strengthen resilience and coordination, they also amplify vulnerability through technological dependency, cyber exposure, and cascading failures across interconnected systems (Fosso Wamba & Queiroz, 2022; Gupta, 2022). These risks are particularly salient in capital-intensive and strategically critical industries such as steel, where disruptions can lead to substantial economic losses and operational shutdowns (Ghadge et al., 2020; Mehrmanesh & Mirmahalleh, 2020).

Existing approaches to supply chain risk assessment largely rely on traditional multi-criteria decision-making techniques such as FMEA, AHP, TOPSIS, and related variants. Although these methods provide structured frameworks for risk identification and prioritization, they are often static, expert-dependent, and limited in their ability to capture nonlinear relationships and dynamic interactions among risk factors (Abdel-Basset & Mohamed, 2020; Araz et al., 2020; Dias et al., 2020). As digital supply chains generate large volumes of heterogeneous and rapidly changing data, these limitations become increasingly problematic.

In response, scholars have increasingly advocated the use of data-driven and intelligent techniques for supply chain risk management. Artificial neural networks have been widely applied for risk prediction due to their capacity to learn complex nonlinear patterns and generalize from historical data (Dijie, 2022; Fu et al., 2022; Rezki & Mansouri, 2023). Systematic reviews further confirm the effectiveness of ANN-based models in improving predictive accuracy in supply chain contexts (Soori et al., 2023; Zogaan et al., 2025). However, a persistent challenge in ANN-based approaches lies in the lack of transparent and theoretically grounded mechanisms for weighting risk indicators and benchmarking relative risk efficiency.

Data Envelopment Analysis (DEA) has emerged as a powerful nonparametric technique for evaluating relative efficiency across decision-making units by simultaneously considering multiple inputs and outputs without requiring predefined weights (Emrouznejad & Yang, 2018). Recent studies suggest that DEA can complement traditional risk metrics by providing a multidimensional efficiency perspective (Lee et al., 2022). Nevertheless, DEA alone remains primarily descriptive and requires recalculation when new data or scenarios arise.

To address these gaps, recent research has proposed hybrid DEA-ANN models that integrate the benchmarking strength of DEA with the predictive capabilities of neural networks (Nazari-Shirkouhi et al., 2023; Singh et al., 2019). Such hybrid approaches are particularly promising for digital supply chains, where risk dynamics are highly interconnected and continuously evolving (Brintrup et al., 2024; Radanliev & et al., 2020). Despite their potential, empirical applications of DEA-ANN models in the context of digital supply chain risk management—especially in heavy industries such as steel—remain limited. This study seeks to address this gap by developing and empirically testing a hybrid DEA-ANN framework for predicting and optimizing risk management in the digital supply chain of the steel industry.

Methods and Materials

This research adopted an applied mixed-method design combining qualitative and quantitative approaches. Initially, a systematic review of the literature and semi-structured expert interviews were conducted to identify key risk factors associated with digital supply chains in the steel industry. As a result, 160 distinct risks were identified and classified across five main stages of the digital supply chain: digital sourcing, digital production, digital logistics, digital distribution, and digital sales.

A structured questionnaire was then developed to quantify each risk based on three standard dimensions: probability of occurrence, severity of impact, and detectability. Experts scored each dimension on a ten-point scale. Risk Priority Numbers were calculated by combining these dimensions to provide an initial quantitative representation of risk criticality.

To overcome the limitations of simple risk aggregation, Data Envelopment Analysis with cross-efficiency evaluation was employed to assess the relative efficiency of each identified risk as a decision-making unit. The resulting cross-efficiency scores were subsequently used as target outputs for training an Artificial Neural Network.

The neural network architecture was optimized through systematic experimentation with different configurations, including the number of hidden layers, neurons, activation functions, learning rates, and solvers. The final model consisted of two hidden layers and was trained using supervised learning techniques. Model performance was evaluated using standard statistical metrics, including mean squared error, coefficient of determination, correlation coefficients, and relative prediction error.

Findings

The analysis revealed that risks related to technological infrastructure, cybersecurity, data integrity, and system integration exhibited the highest criticality across the digital supply chain stages. Digital logistics and digital sales stages were particularly vulnerable, reflecting their dependence on real-time data exchange and platform reliability.

DEA cross-efficiency analysis demonstrated that several risks with similar Risk Priority Numbers differed substantially in terms of relative efficiency, highlighting the added value of efficiency-based evaluation. This result confirmed that traditional risk ranking alone is insufficient for capturing systemic risk behavior in digital supply chains.

The trained neural network achieved strong predictive performance, with low mean squared error and a high coefficient of determination, indicating that the model successfully learned the underlying patterns linking risk attributes to efficiency outcomes. The correlation between actual and predicted cross-efficiency scores was high, confirming the robustness and stability of the hybrid DEA–ANN framework.

Scenario-based analysis further showed that reducing the probability of a limited number of high-impact risks led to measurable improvements in overall system efficiency, illustrating the interconnected and cascading nature of digital supply chain risks.

Discussion and Conclusion

The findings demonstrate that the proposed hybrid DEA–ANN model provides a robust and effective tool for managing risk in digital supply chains. By integrating efficiency benchmarking with predictive learning, the model moves beyond static risk assessment toward a dynamic and forward-looking approach.

The results highlight that digital supply chain risks are inherently networked, meaning that targeted mitigation of key risks can generate positive spillover effects across the entire system. This insight is particularly relevant for the steel industry, where complex interdependencies amplify the consequences of disruption.

From a theoretical perspective, the study supports the argument that effective digital supply chain risk management requires adaptive and intelligent mechanisms capable of learning from data and anticipating future conditions. The hybrid DEA–ANN framework contributes to the literature by demonstrating how traditional efficiency analysis can be successfully combined with machine learning to address the limitations of each approach in isolation.

Practically, the model offers decision-makers a data-driven basis for prioritizing risk mitigation strategies and allocating resources more effectively. Rather than reacting to disruptions after they occur, managers can use predictive insights to enhance resilience and operational continuity.

In conclusion, this study shows that hybrid intelligent models represent a promising direction for advancing digital supply chain risk management. The DEA-ANN framework developed here provides both analytical rigor and practical relevance, offering a scalable solution that can be adapted to other industries facing similar digital transformation challenges.

References

- Abdel-Basset, M., & Mohamed, R. (2020). A novel plithogenic TOPSIS-CRITIC model for sustainable supply chain risk management. *Journal of Cleaner Production*(247), 119586. <https://doi.org/10.1016/j.jclepro.2019.119586>
- Ali, A. (2022). The role of industry 4.0 technologies in mitigating supply chain disruption: empirical evidence from the Australian food processing industry. *Ieee Transactions on Engineering Management*. <https://www.semanticscholar.org/paper/The-Role-of-Industry-4.0-Technologies-in-Mitigating-Ali-Arslan/144b29c7f4146cc09269e040db556f5f6dd4c3db>
- Alok, K., Garg, R., & Garg, D. (2020). Development of a Structural Model of Risk Issues Involved in E-Supply Chain Adoption in Indian Mechanical Industries. *International Journal of Supply and Operations Management*. <https://sid.ir/paper/667262/fa>
- Araz, O. M., Choi, T. M., Olson, D., & Salman, F. S. (2020). Data analytics for operational risk management. *Decision Sciences*(6), 1316-1319. <https://doi.org/10.1111/dec.12443>
- Brintrup, A., Kosasih, E., Schaffer, P., Zheng, G., Demirel, G., & MacCarthy, B. L. (2024). Digital supply chain surveillance using artificial intelligence: definitions, opportunities and risks. *International Journal of Production Research*. <https://doi.org/10.1080/00207543.2023.2270719>
- Creazza, A., Colicchia, C., Spiezia, S., & Dallari, F. (2022). Who cares? Supply chain managers' perceptions regarding cyber supply chain risk management in the digital transformation era. *Supply chain management*(1), 30-53. <https://doi.org/10.1108/SCM-02-2020-0073>
- Dias, G. C., Hernandez, C. T., & Oliveira, U. R. D. (2020). Supply chain risk management and risk ranking in the automotive industry. *Gestão & Produção*(1), 1--. <https://doi.org/10.1590/0104-530x3800-20>
- Dijie, Y. (2022). Evaluation of Enterprise Financial Risk Level under Digital Transformation with Artificial Neural Network. *Discrete Dynamics in Nature and Society*. <https://doi.org/10.1155/2022/1882100>
- DuHadway, S., Carnovale, S., & Hazen, B. (2019). Understanding risk management for intentional supply chain disruptions: Risk detection, risk mitigation, and risk recovery. *Annals of Operations Research*, 179-198. <https://doi.org/10.1007/s10479-017-2452-0>
- Emrouznejad, A., & Yang, Z. (2018). A survey and analysis of the first 40 years of DEA research. *Socio-Economic Planning Sciences*(4), 4-8. <https://doi.org/10.1016/j.seps.2017.01.008>
- Fosso Wamba, S., & Queiroz, M. M. (2022). A Framework Based on Blockchain, Artificial Intelligence, and Big Data Analytics to Leverage Supply Chain Resilience considering the COVID-19.
- Fu, W., Zhang, H., & Huang, F. (2022). Internet-based supply chain financing-oriented risk assessment using BP neural network and SVM. *PLoS One*. <https://doi.org/10.1371/journal.pone.0262222>
- Ghadge, A., Jena, S. K., Kamble, S., Misra, D., & Tiwari, M. K. (2020). Impact of financial risk on supplychains: a manufacturer-supplier relational perspective. *International Journal of Production Research*, 1-16. <https://dSPACE.lib.cranfield.ac.uk/bitstreams/6ad38947-d110-41e9-9b51-c951b032b962/download>
- Gupta, S. (2022). Examining the influence of big data analytics and additive manufacturing on supply chain risk control and resilience: an empirical study. *Computers & Industrial Engineering*. <https://doi.org/10.1016/j.cie.2022.108629>
- Haicao, S., Rui, C., Heshan, C., Pan, L., & Dongwei, Y. (2024). The impact of manufacturing digital supply chain on supply chain disruption risks under uncertain environment—Based on dynamic capability perspective. *Advanced Engineering Informatics*. <https://doi.org/10.1016/j.aei.2024.102385>
- Hosseinzadeh, M., Mehregan, M. R., & Ghomi, M. (2019). Identifying and Analyzing Supply Chain Risks of Saipa Automobile Company using the COSO Model and Social Network Analysis (SNA). *Research in Production and Operations Management*. https://jpom.ui.ac.ir/article_23625.html?lang=en
- Ivanov, D., Dolgui, A., Sokolov, B., & Ivanova, M. (2019). Disruption tails and revival policies: A simulation study on supply chain resilience in the COVID-19 pandemic context. *International Journal of Production Research*, 3361-3380. <https://blog.hwr-berlin.de/ivanov/publications-readmore/>
- Karimzadegan, H., & Kianous, A. (2021). The Effect of Strategic Management on Minimizing the Pollution of Oil Refinery. *Journal of environmental science and technology*, 41-56. <https://sanad.iau.ir/Journal/jest/Article/838481>

- Lee, K. L., Najiha Azmi, N. A., Hanayshaa, J. R., Alshurideh, H. M., & Alshurideh, M. T. (2022). The effect of digital supply chain on organizational performance: An empirical study in Malaysia manufacturing industry. *Uncertain Supply Chain Management*. <https://doi.org/10.5267/j.uscm.2021.12.002>
- Mehrmanesh, S. R. S., & Mirmahalleh, H. (2020). A model for risk management in the supply chain of Iran's gas industry. *Iranian journal of management sciences*(57). http://journal.iams.ir/article_326_en.html
- Mitra, S., Taheri, S. M., & Farzadi, S. (2022). Identification and Ranking of Supply Chain Risks in Digital Libraries of State Universities of Tehran Based on ISO 31000 Standard. *Iranian Journal of Information Processing and Management*, 749-780. <https://ensani.ir/fa/article/501893/>
- Moktadir, M. A., Dwivedi, A., Khan, N. S., Paul, S. K., Khan, S. A., Ahmed, S., & Sultana, R. (2021). Analysis of risk factors in sustainable supply chain management in an emerging economy of leather industry. *Journal of Cleaner Production*. <https://doi.org/10.1016/j.jclepro.2020.124641>
- Nasiri, M., Ukko, J., Saunila, M., & Rantala, T. (2020). *Managing the digital supply chain: The role of smart technologies*. LUT University. <https://doi.org/10.1016/j.technovation.2020.102121>
- Nazari-Shirkouhi, S., Tavakoli, M., Govindan, K., & Mousakhani, S. (2023). A hybrid approach using Z-number DEA model and Artificial Neural Network for Resilient supplier Selection. *Expert Systems with Applications*(222), 119746. <https://doi.org/10.1016/j.eswa.2023.119746>
- Özkanlısoy, O., & Akkartal, E. (2020). Risk Assessment in Digital Supply Chains. *Ekonomi ve Sosyal Araştırmalar Dergisi*. https://www.duvarayinlari.com/Webkontrol/IcerikYonetimi/Dosyalar/implementation-of-disruptive-technologies-in-supply-chain-management_icerik_g4056_NHSHCivw.pdf
- Pan, W., & Miao, L. (2023). Dynamics and risk assessment of a remanufacturing closed-loop supply chain system using the internet of things and neural network approach. *The Journal of Supercomputing*. <https://doi.org/10.1007/s11227-022-04727-6>
- Pellicelli, M. (2023). The Digital Transformation of Supply Chain Management-2023: Department of Economics and Management. In *The Digital Transformation of Supply Chain Management-2023*. <https://doi.org/10.1016/B978-0-323-85532-7.00002-5>
- Porter, M. (2021). Digital Transformation and Industrial Risk Management. *Harvard business review*. <https://www.hbs.edu/faculty/Pages/profile.aspx?facId=6532>
- Pourjamshidi, H., Mehdizadeh, H., & Motamedinia, Z. (2021). Investigating the factors affecting the consumption of green products among the citizens of Khorramabad with SEM. *Journal of environmental science and technology*, 147-161. <https://www.sid.ir/paper/402595/en>
- Radanliev, P., & et al. (2020). Cyber risk at the edge: current and future trends on cyber risk analytics and artificial intelligence in the industrial internet of things and industry 4.0 supply chains.
- Rao, S., & Goldsby, T. J. (2009). Supply chain risks: A review and typology. *International Journal of Logistics Management*(1), 97-123. <https://doi.org/10.1108/09574090910954864>
- Rasi, R. E., Abbasi, R., & Hatami, D. (2019). The Effect of Supply Chain Agility Based on Supplier Innovation and Environmental Uncertainty. *International Journal of Supply and Operations Management*(2), 94-109. <https://www.mdpi.com/2071-1050/14/14/8928>
- Rezki, N., & Mansouri, M. (2023). Improving supply chain risk assessment with artificial neural network predictions. *International Scientific Journal about Logistics*(4), 645-658. <https://doi.org/10.22306/al.v10i4.444>
- Sadeghi Moghaddam, M. R., Karimi, T., & Bandesi, S. (2018). Service Supply Chain Risk Assessment Applying Rough Set Theory Approach: Case of Payment Service Providers. *Management Research in Iran*(1), 69-94. <https://sid.ir/paper/372796/fa>
- Schlüter, F., & Henke, M. (2017). Smart supply chain risk management - a conceptual framework. In. HICL Proceedings. <https://www.econstor.eu/bitstream/10419/209317/1/hicl-2017-23-361.pdf>
- Singh, P., Dwivedi, P., & Kant, V. (2019). A hybrid method based on neural network and improved environmental adaptation method using Controlled Gaussian Mutation with real parameter for short-term load forecasting. *Energy*, 460-477. <https://doi.org/10.1016/j.energy.2019.02.141>
- Smolarski, J., Verick, H., Foxen, S., & Kut, C. (2005). Risk management in Indian venture capital and private equity firms: A comparative study. *Thunderbird International Business Review*(4), 469-488. <https://doi.org/10.1002/tie.20063>
- Song, H., Chen, S., & Xu, Y. (2024). Risk management in digital supply chains: Interplay of digital technologies and uncertainty. *Journal of Business Research*. <https://www.sciencedirect.com/science/article/abs/pii/S1474034624000338>
- Soori, M., Behroz, A., & Dastres, R. (2023). Artificial Neural Networks in Supply Chain Management, A Review. *Journal of Economy and Technology*(11). <https://doi.org/10.1016/j.ject.2023.11.002>
- Zogaan, W. A., Ajabnoor, N., & Salamai, A. A. (2025). Leveraging deep learning for risk prediction and resilience in supply chains: insights from critical industries. *Journal of Big Data*. <https://doi.org/10.1186/s40537-025-01143-4>