

عنوان الدراسة:

"تحليل أثر تقنيات الذكاء الاصطناعي وتحليل البيانات الضخمة على كفاءة التنبؤ
بالطلب وتحسين إدارة المخزون وأداء المستودعات"

الاسم: أحمد بشير عنبرخان

قسم: ادارة الاعمال

الرقم الجامعي: 232002485

Table of Contents

3.....	الفصل الثاني (الدراسات السابقة)
5.....	المراجع

الفصل الثاني (الدراسات السابقة)

1. Demand Forecasting Model using Deep Learning Methods for Supply Chain Management 4.0 (Terrada et al., 2022)

في هذه الدراسة التي أجراها *الويني الطرادة* وزملاؤها في المغرب، تم تطوير نموذج تنبؤ بالطلب في سياق سلاسل الإمداد الذكية (إدارة سلسلة الإمداد 4.0) باستخدام طرائق التعلم العميق. اعتمدت الدراسة على بيانات معاملات تاريخية لشركة، وقارنت نموذجين: نموذج إحصائي تقليدي (ARIMA) ونموذج شبكة عصبية ذاكرة طويلة قصيرة الأجل (LSTM). أظهرت النتائج أن نموذج الـ LSTM أعطى تنبؤات أقرب إلى الواقع من نموذج ARIMA، بسبب قدرته على المحافظة على معلومات الطلب عبر الزمن. فوائد الدراسة تكمن في تحسين دقة التنبؤ بالطلب مما يوازن بين العرض والطلب ويعزز الأداء اللوجستي. أما عوائقها فتربط باستخدام مجموعة بيانات محدودة (من Kaggle) واقتصار المقارنة على نموذجين فقط، ما قد يقيد تعميم النتائج.

2. Machine Learning Demand Forecasting and Supply Chain Performance (Feizabadi, 2022)

درس الباحث *جواد فيضي أبادي* في جامعة مانيتوبا (قبلاً معهد ماليزيا لسلسلة الإمداد) أثر طرائق التنبؤ المتقدمة على أداء سلسلة الإمداد. طور فيضي أبادي نموذجاً هجيناً للتنبؤ بالطلب يجمع بين ARIMAX وشبكة عصبية، يشمل بيانات زمنية وعوامل تفسيرية. طبق النموذج في سياق منتج صناعي في شركة فولاذ (منتج وظيفي)، ووجد فروقاً معنوية في أداء سلسلة الإمداد بين التنبؤات التقليدية (إحصائية) وتلك المستندة إلى التعلم الآلي. خلاصات الدراسة تشير إلى أن التنبؤات المعتمدة على التعلم الآلي حسنت أداء سلسلة الإمداد الفعلية وتقليل أثر ظاهرة سوط المخزون (Bullwhip) مقارنة بالطرائق التقليدية. فوائدها تشمل تقديم دليل تجريبي على كفاءة طرق التعلم الآلي في تحسين نتائج سلسلة الإمداد (خدمات عملاء أفضل وكلفة مخزون أقل)، في حين أن حدودها تكمن في كونها دراسة حالة محدودة لشركة واحدة (الحديد) لذا فقد تحتاج الدراسات المستقبلية إلى تطبيقها على صناعات وشركات مختلفة للتحقق من عمومية النتائج.

3. Big Data Analytics and Demand Forecasting in Supply Chains: A Conceptual Analysis (Hofmann & Rutschmann, 2018)

في دراسة مفاهيمية قام بها *إريك هوفمان* و*إيمانويل رتشممن* من سويسرا، تم بناء إطار نظري يربط بين تحليلات البيانات الضخمة وعمليات التنبؤ بالطلب في سلاسل الإمداد. ركز الباحثان على كيفية استغلال مصادر بيانات إضافية

وتعليمها إلى نماذج التنبؤ بهدف تحسين دقة التنبؤات. أبرز ما خلاصا إليه هو أن دمج مصادر بيانات متنوعة في التنبؤ يمكن ويعزز فعاليته، لكن هذا يتطلب بنية تقنية ملائمة واستعانة بمختصين (علماء بيانات). تقدم الدراسة إطاراً توجيهياً لبدء مبادرات تحليلات بيانات ضخمة في سلسلة الإمداد، إذ وصفت الخطوات والمبادئ النظرية المطلوبة. من ناحية الفوائد، قدمت هذه الدراسة رؤية شاملة لموضوع التحليلات الضخمة والتنبؤ، وهي الأولى التي تجمع بينهما في إطار واحد. أما القيود فهي كونها إطاراً نظرياً غير تجريبي، فقدّم رؤى عامة دون تطبيق عملي يمكن قياسه.

4. Artificial Intelligence in Logistics Optimization with

Sustainable Criteria: A Review (Chen et al., 2024)

قدم ويوان تشن وزملاؤه في إسبانيا مراجعة شاملة حول استخدام الذكاء الاصطناعي في تحسين العمليات اللوجستية تحت معايير الاستدامة. شملت الدراسة نماذج ذكاء اصطناعي متعددة (تعلم آلي، خوارزميات استدلال) تطبيقاً على قضايا مثل التنبؤ بالطلب وإدارة المخزون والمسارات اللوجستية. النتائج الرئيسية أوضحت أن الذكاء الاصطناعي يمكن الشركات من التنبؤ بالطلب بدقة أكبر، وتحسين توزيع المخزون والطرق النقلية مما يقلل الهدر والتكاليف البيئية. كما ناقشت الدراسة تحديات التكامل مع أهداف الاستدامة (مثل تقليل الانبعاثات)، وأضافت اتجاهات مستقبلية مثل دور البيانات اللحظية والبلوك تشين في اللوجستيات. فوائد المراجعة أنها جمعت أحدث التطبيقات والتوجهات البحثية في المجال، لكنها تظل عامة وشمولية كمرجعية، وتفتقر إلى دراسة حالة تطبيقية واحدة تقيس التأثير في شركة محددة.

5. Artificial Intelligence Driving Intelligent Logistics: Benefits,

Challenges, and Drawbacks (Gonçalves & Domingues, 2025)

ناقش رودريجو غونزاليس ولويسا دومينغيش في هذه الدراسة (من مؤتمر Procedia) الدور التحويلي للذكاء الاصطناعي في اللوجستيات الذكية. استندت الدراسة إلى مراجعة أدبية شاملة (متعددة المصادر)، وحددت الفوائد الرئيسية لـ AI في اللوجستيات مثل زيادة الكفاءة التشغيلية، وخفض التكاليف، وتحسين خدمة العملاء. في المقابل، أشارت إلى تحديات كبيرة ترافق استخدامه، مثل المخاطر القانونية وأمن المعلومات المعتمدة على البيانات التاريخية واعتماد النظم على قوة الحوسبة الكبيرة. نتائجها توفر تصوراً متوازناً حول دمج الذكاء الاصطناعي: فهو يمتلك القدرة على تحسين أداء المخازن والإدارة اللوجستية، ولكنه لا يخلو من جوانب سلبية كاختراقات أمنية وخوف من تأثيره على القوى العاملة. تكمن فائدة هذه الدراسة في تقديم نظرة عامة متوازنة تجذب انتباه الممارسين لوضع استراتيجية متكاملة، أما حدودها فهي طابعها الاستعراضي العام (لا تقدم تجارب حقيقية) واعتمادها على مصادر مفتوحة (قد تغفل بعض التطبيقات الخاصة).

ماذا ستضيف دراستنا؟

على ضوء ما سبق، ستملأ دراستنا فراغات مهمة في الأدبيات الحالية. فأغلب الدراسات السابقة كانت نظرية أو على حالات محدودة وغير عربية. دراستنا ستركز على تطبيق عملي بياناتي في شركات لوجستية فعلية (ومنطقة معينة إن أمكن) مستخدمة أحدث تقنيات الذكاء الاصطناعي وتحليلات البيانات الضخمة لتحسين التنبؤ بالطلب وإدارة المخزون وأداء المستودعات. سنجمع بيانات حقيقية من الشركات (على عكس بعض الدراسات التي استخدمت مجموعات بيانات عامة)، كما سندمج مؤشرات أداء جديدة لقياس أثر التحسين في الكفاءة اللوجستية. بهذا، ستميز دراستنا المساهمة العملية للذكاء الاصطناعي في سياق واقعي، مع تصويب الفروق أو العيوب التي ظهرت في الدراسات السابقة وتحقيق نتائج يمكن تكرارها وتعميمها على شركات لوجستية مماثلة.

المراجع

- عبدالرؤوف، ش. ع. ن.، ياسين، ع. م. ي.، & محروس، ر. ع. ر. (2024). دور الذكاء الاصطناعي في تحليل البيانات الضخمة. *مجلة الدراسات التجارية المعاصرة*. 10(17), 1907–1949.
- حلمي، ك. م. ع. (2024). أثر تحليلات البيانات الضخمة باستخدام تقنيات الذكاء الاصطناعي على تحسين جودة التقارير المالية (دراسة تطبيقية). *المجلة العلمية للدراسات والبحوث المالية والتجارية*, 5(2), 451–492.
- Terrada, L., El Khaili, M., & Ouajji, H. (2022). *Demand Forecasting Model using Deep Learning Methods for Supply Chain Management 4.0*. *International Journal of Advanced Computer Science and Applications*, 13(5), 704–711.
- Feizabadi, J. (2022). *Machine learning demand forecasting and supply chain performance*. *International Journal of Logistics Research and Applications*, 25(2), 119–142.
- Hofmann, E., & Rutschmann, E. (2018). *Big data analytics and demand forecasting in supply chains: a conceptual analysis*. *International Journal of Logistics Management*, 29(2), 739–766.

- Chen, W., Men, Y., Fuster, N., Osorio, C., & Juan, Á. A. (2024). *Artificial Intelligence in logistics optimization with sustainable criteria: A review*. Sustainability, 16(21), 9145.
<https://doi.org/10.3390/su16219145> •
- Gonçalves, R., & Domingues, L. (2025). *Artificial Intelligence driving intelligent logistics: Benefits, challenges, and drawbacks*. Procedia Computer Science, 256, 665–672. •
- Enhancing inventory management and customer satisfaction. World *Journal of Advanced Research and Reviews*, 23(02), 708–719. •
<https://doi.org/10.30574/wjarr.2024.23.2.2394>
- Nweje, U., & Taiwo, M. (2025). *Leveraging artificial intelligence for predictive supply chain management: Focus on demand forecasting and inventory optimization*. Unpublished manuscript. •
- Kagalwala, H. (2025). *The role of AI and machine learning in demand forecasting*. ACR Journal. •
- Ma, Z. (2024). *Research on inventory forecasting and management strategies in logistics and warehousing automation based on artificial intelligence models*. Journal of Combinatorial Press. •
- Es-satty, A., & Naimi, M. (2025). *The impacts of big data analytics and artificial intelligence on supply chain strategic performance*. Operations and Supply Chain Management, 18(2), 201–213. •
- Daios, A. (2025). *AI applications in supply chain management: A survey*. Applied Sciences. •
- Angammana, J. S. K. (2022). *Influence of artificial intelligence on warehouse performance*. Biblioteka Nauki. •
- Fatima, A., & Salam, M. A. (2026). *A data-driven predictive framework for inventory optimization using context-augmented machine learning models*. arXiv. •