

Predictive Effectiveness of Machine Learning and Traditional Models in Production and Sales: A Systematic Literature Review

Carol Nicoll Farroñan Soplapuco¹; Manuel Adrián Yalico Fernández²; Universidad Tecnológica del Perú, Sede Chiclayo, Perú, U21205415@utp.edu.pe, Universidad Tecnológica del Perú, Sede Chiclayo, Perú, U21206783@utp.edu.pe

Abstract – *In recent years, the application of Machine Learning (ML) and Deep Learning (DL) techniques in sales forecasting has gained significant relevance as a strategic tool to optimize business processes and decision-making. This Systematic Literature Review (SLR) aims to identify the most widely used models and assess their effectiveness in sales estimation across various commercial settings. Following the PRISMA methodology, fifty-two academic articles published between 2022 and 2025 were analyzed. The results indicate that the most commonly employed models are Random Forest, XGBoost, LSTM, and CNN, all of which outperform traditional methods such as ARIMA and linear regression. It is noteworthy that DL techniques and hybrid models achieve R^2 values above 90% and mean absolute percentage errors (MAPE) below 10%, confirming their effectiveness in multivariable and dynamic contexts.*

Keywords-- *sales prediction, machine learning, deep learning, traditional models, forecasting, business analytics.*

Eficiencia Predictiva en Producción y Ventas: Un análisis de la efectividad de los modelos de aprendizaje automático y tradicionales

Carol Nicoll Farroñan Soplapuco¹; Manuel Adrián Yalico Fernández²; Universidad Tecnológica del Perú, Sede Chiclayo, Perú, U21205415@utp.edu.pe, Universidad Tecnológica del Perú, Sede Chiclayo, Perú, U21206783@utp.edu.pe

Resumen— Recientemente, la aplicación de técnicas de Machine Learning (ML) y Deep Learning (DL) en la predicción de ventas ha cobrado relevancia como herramienta estratégica para optimizar procesos comerciales y de toma de decisiones. Esta revisión sistemática de literatura (RSL) tiene como objetivo identificar los modelos más utilizados y determinar sus niveles de efectividad en la estimación de ventas en distintos entornos comerciales. Siguiendo la metodología PRISMA, se analizaron 52 artículos académicos publicados entre 2022 y 2025. Los resultados indican que los modelos más empleados corresponden a Random Forest, XGBoost, LSTM y CNN, evidenciando un mejor desempeño frente a los métodos tradicionales como ARIMA y regresión lineal. Se destaca que las técnicas de DL y modelos híbridos alcanzan valores de R^2 superiores al 90% y errores porcentuales medios (MAPE) por debajo del 10%, lo cual confirma su efectividad en contextos multivariantes y dinámicos.

Keywords: sales prediction, machine learning, deep learning, traditional models, forecasting, business analytics.

I. INTRODUCTION

En un entorno empresarial cada vez más competitivo y cambiante, la capacidad de anticipar con precisión la producción y las ventas se ha convertido en un factor crítico para la sostenibilidad y el crecimiento de las organizaciones [1]. Las empresas han optado tradicionalmente por métodos estadísticos para realizar pronósticos, sin embargo, estos enfoques presentan limitaciones al enfrentarse a grandes volúmenes de datos o a patrones de comportamiento complejos y no lineales [2]. En este contexto, los modelos de aprendizaje automático se han consolidado como herramientas altamente eficaces para la predicción.

Las organizaciones están recurriendo al intraemprendimiento como una estrategia clave para fomentar la innovación desde dentro, promoviendo que los empleados actúen como emprendedores internos. Por ello, el uso de modelos de ML para la predicción de producción y ventas representa una herramienta estratégica que cataliza esta innovación. La incorporación de algoritmos inteligentes permite anticiparse mejor a la demanda del mercado, optimizar la planificación operativa y reducir los niveles de incertidumbre en la toma de decisiones. Este tipo de enfoque no solo mejora

los procesos internos, sino que también puede generar nuevas oportunidades dentro de la propia organización. Además, esta perspectiva resulta especialmente valiosa para los emprendimientos, ya que la implementación de buenas prácticas de producción y comercialización mediante

técnicas de aprendizaje automático contribuye significativamente a la reducción de costos operativos. Este efecto puede repercutir positivamente en aspectos más amplios como la generación de empleo, el dinamismo económico y el fortalecimiento de los ingresos fiscales, especialmente en el contexto latinoamericano. Así, se reconoce el potencial del aprendizaje automático no solo como herramienta técnica, sino también como motor de desarrollo regional.

Por lo tanto, esta Revisión Sistemática de Literatura (RSL) tiene como objetivo analizar la efectividad de los modelos de aprendizaje automático y tradicionales en la predicción de producción y/o ventas, evaluando su potencial para impulsar el intraemprendimiento y la innovación en los modelos de negocio. A través del análisis de investigaciones recientes, se busca resaltar cómo el uso estratégico de técnicas basadas en ML supera a los enfoques tradicionales en la optimización de procesos, y cómo esta ventaja puede habilitar nuevas formas de crear, entregar y capturar valor dentro de las organizaciones.

II. METODOLOGÍA

La presente investigación se fundamenta en una Revisión Sistemática de Literatura (RSL), una metodología diseñada para recopilar, evaluar y sintetizar de forma rigurosa y completa toda la evidencia disponible sobre una temática específica. Esta estrategia asegura que la revisión sea sistemática y exhaustiva, enfocándose en responder una pregunta de investigación claramente formulada y reduciendo al mínimo el sesgo [3]. Para lo cual se planteó la pregunta principal ¿Qué tan efectiva es la predicción de producción o ventas mediante modelos de machine learning en comparación con métodos tradicionales? Y como preguntas específicas las siguientes, 1 ¿Qué características tiene la predicción de producción y ventas?, 2 ¿Qué métodos de machine learning existen para incrementar la efectividad de la predicción de producción o ventas?, 3 ¿Qué nivel de eficiencia y eficacia tienen los métodos para la

predicción de producción o ventas? En la Tabla I se presentan las preguntas específicas y sus respectivos keywords.

TABLA I
PREGUNTAS ESPECIFICAS

ITEM	Preguntas específicas	Keywords
1	¿Qué características tiene la predicción de producción y ventas?	sales, prediction, forecasting
2	¿Qué métodos de machine learning existen para incrementar la efectividad de la predicción de producción o ventas?	machine, learning, deep, learning
3	¿Qué nivel de eficiencia y eficacia tienen los métodos para la predicción de producción o ventas?	Performance, efficacy, effectiveness, models, traditional, conventional, common, standard, classic

Las bases de datos científicas utilizadas para la búsqueda de información son Scopus y Web of Science.

Para Scopus la cadena de búsqueda fue la siguiente:
(TITLE-ABS-KEY (("sales" AND "prediction") OR ("sales" AND "forecasting") OR ("sales" AND "forecast")) AND TITLE-ABS-KEY (("machine" AND "learning") OR ("deep" AND "learning")) AND TITLE-ABS-KEY ((("effectivity" OR ("efficiency") OR ("performance") OR ("efficacy") OR ("effectiveness")) "models" AND "traditional") OR ("models" AND "conventional") OR ("models" AND "common") OR ("models" AND "standard") OR ("models" AND "classic"))))
Para Web of Science fue la siguiente:
"sales" AND "prediction" OR "sales" AND "forecasting"
"sales" AND "forecast" (All Fields) and "machine" AND "learning" OR "deep" AND "learning" (All Fields) and "effectivity" OR "efficiency" OR "performance" OR "efficacy" OR "effectiveness" "models" AND "traditional" OR "models" AND "conventional" OR "models" AND "common" OR "models" AND "standard" OR "models" AND "classic"

En la tabla II se muestran los filtros que se aplicaron para las bases de datos científicas utilizadas:

TABLA II
FILTROS DE BÚSQUEDA

FILTRO	VALOR
Año de publicación	> 2023, < 2026
Acceso	Open Access
Tipo de documento	Artículo

La cadena de búsqueda para Scopus con los filtros aplicados es la siguiente:

(TITLE-ABS-KEY (("sales" AND "prediction") OR ("sales" AND "forecasting") OR ("sales" AND "forecast")) AND TITLE-ABS-KEY (("machine" AND "learning") OR ("deep" AND "learning")) AND TITLE-ABS-KEY ((("effectivity" OR ("efficiency") OR ("performance") OR ("efficacy") OR ("effectiveness")) "models" AND "traditional") OR ("models" AND "conventional") OR ("models" AND "common") OR ("models" AND "standard") OR ("models" AND "classic"))) AND PUBYEAR > 2021 AND PUBYEAR < 2026 AND (LIMIT-TO (OA , "all"))
La cadena de búsqueda para Web of Science con los filtros aplicados es la siguiente:
"sales" AND "prediction" OR "sales" AND "forecasting"
"sales" AND "forecast" (All Fields) and "machine" AND "learning" OR "deep" AND "learning" (All Fields) and "effectivity" OR "efficiency" OR "performance" OR "efficacy" OR "effectiveness" "models" AND "traditional" OR "models" AND "conventional" OR "models" AND "common" OR "models" AND "standard" OR "models" AND "classic" (All Fields) and Open Access and 2022 (Publication Years)

La búsqueda fue realizada el 28 de abril a las 12:09 pm. Por lo tanto, los resultados pueden cambiar al momento de reutilizar las cadenas de búsqueda.
Entre los criterios de inclusión y exclusión de los documentos, según su contenido se muestran en las Tablas III y Tabla IV.

TABLA III
CRITERIOS DE INCLUSIÓN

ITEM	Criterios
CI1	Uso de métodos de machine learning o métodos estadísticos para predicción de producción y ventas
CI2	Estudios que presenten métricas de eficacia y eficiencia
CI3	Investigaciones con casos reales, simulaciones aplicadas o datos empresariales concretos.

TABLA IV
CRITERIOS DE EXCLUSIÓN

ITEM	Criterios
CE1	Evitar temas relacionados a métodos no aplicados a la predicción de producción y ventas
CE2	Excluir artículos sin resultados empíricos o sin evaluación cuantitativa clara
CE3	Estudios puramente teóricos o sin vínculo claro con aplicaciones reales o empresariales.

Para un análisis riguroso en este estudio se empleó el enfoque PRISMA, cuya finalidad es asegurar la transparencia, integridad y precisión en las revisiones sistemáticas. Este método establece pautas claras para

documentar de forma estructurada los objetivos, los procedimientos y los resultados del análisis [4]. En la figura 1 se muestra que en la fase inicial se obtuvieron 151 artículos, de los cuales 102 de Scopus y 49 de Web of Science, se descartaron 40 artículos duplicados, 30 artículos aplicando los criterios de exclusión, 12 no se lograron descargar a texto completo. Finalmente, luego de haber realizado una lectura de contenido de los artículos a texto completo se descartaron 17 publicaciones aplicando los criterios de exclusión. Como resultado, se seleccionaron 52 artículos que cumplieron con todos los criterios de inclusión y fueron utilizados para la revisión sistemática.




Figura 1 Diagrama de flujo PRISMA

III. RESULTADOS

BIBLIOMETRÍA

La Fig. 2 muestra la evolución en el número de documentos publicados anualmente en el período comprendido entre 2022 y 2025. Se observa que, en 2022, la producción de documentos se inició con 11 publicaciones. Para el año siguiente, 2023, hubo una ligera disminución, registrándose 10 documentos. Sin embargo, el año 2024 representa un punto de inflexión notable, mostrando un incremento, alcanzando el pico de publicaciones con 26 documentos. Este repunte sugiere un período de intensa actividad o un creciente interés en el área de estudio durante ese año. Finalmente, en 2025, se aprecia una marcada

reducción en el número de documentos, con solo 5 publicaciones, lo que podría indicar una fase de desaceleración o la conclusión de un ciclo de investigación intensivo.




Figura 2 Documentos indizados por años

La tabla V presenta una síntesis de los modelos predictivos identificados en los estudios revisados, organizada según el tipo de enfoque aplicado, los algoritmos específicos más utilizados, su frecuencia de aparición en la literatura y las referencias correspondientes. Esta estructura permite observar de manera más clara cuáles son los modelos más empleados y en qué contextos suelen aplicarse. Se observa que los modelos basados en machine learning presentan la mayor frecuencia de uso, destacando algoritmos como Random Forest y XGBoost, ampliamente valorados por su capacidad para manejar datos multivariantes y su buen desempeño en entornos dinámicos. Asimismo, se identificó un uso creciente de modelos de deep learning como LSTM y CNN, especialmente en escenarios donde la naturaleza secuencial de los datos requiere técnicas más complejas.

Por otro lado, los modelos tradicionales, como ARIMA y SARIMA, siguen siendo utilizados en contextos con estructuras simples o datos históricos limitados, aunque su participación es menor en comparación con los enfoques más modernos. También se identificaron estudios que implementan combinaciones de modelos, conocidos como híbridos, con el objetivo de mejorar la precisión de las predicciones mediante la integración de distintos métodos.

En conjunto, la tabla permite identificar con claridad las tendencias metodológicas actuales en predicción de producción y ventas, así como la evolución hacia el uso de técnicas más avanzadas impulsadas por el desarrollo de la inteligencia artificial y el acceso a grandes volúmenes de datos.

TABLA V
REFERENCIAS POR MODELOS UTILIZADOS

Modelo	Modelos	Frecuencia	ID Referencia
--------	---------	------------	---------------

Solo tradicionales	ARIMA, SARIMA	6	[5], [6], [7], [8], [9], [10]
Solo ML	Random Forest, XGBoost, CatBoost, SVM, k-NN, ElasticNet	21	[11], [12], [13], [14], [15], [16], [17], [18], [19], [20], [21], [22], [23], [24], [25], [26], [37], [28], [29], [30], [31]
Solo DL	LSTM, CNN, GRU	8	[32], [33], [34], [35], [36], [37], [38], [39]
ML + DL	CNN-XG, Kernel+Gr ey	2	[40], [41]
ML + DL + Tradicionales	DL con modelos clásicos e híbridos avanzados	15	[42], [43], [44], [45], [46], [47], [48], [49], [50], [51], [52], [53], [54], [55], [56]

En la Tabla VI se puede ver que el tipo de datos más empleado corresponde a series temporales (66%), lo cual evidencia la naturaleza secuencial del fenómeno de predicción tanto en producción como en ventas. Este tipo de datos es especialmente adecuado para técnicas como LSTM o modelos estadísticos como ARIMA y SARIMA. En segundo lugar, se encuentran los datos de clientes (19%), empleados comúnmente para estimaciones en la demanda o comportamiento de compra. Los datos multivariantes (11%) se utilizan en modelos con múltiples variables explicativas, donde se busca capturar relaciones complejas entre distintas dimensiones. Finalmente, un pequeño porcentaje de estudios (4%) utilizó datos sintéticos, generados para pruebas experimentales o para suplir la escasez de datos reales. Esta distribución evidencia una clara preferencia por datos temporales en los modelos predictivos aplicados a contextos empresariales.

TABLA VI
TIPOS DE DATOS EMPLEADOS EN LOS ARTÍCULOS

Tipo de datos	Frecuencia	%
Series temporales	35	66%
Datos de clientes	9	19%
Datos multivariantes	6	11%
Datos sintéticos	2	4%
Total	52	100%

La Tabla VII muestra los principales enfoques utilizados para la predicción de producción y ventas, detallando sus modelos más representativos, el rendimiento alcanzado (R^2 y MAPE) y el volumen de datos necesario para su aplicación. Los modelos tradicionales, como ARIMA, SARIMA y regresión lineal, fueron empleados en contextos con estructuras simples o con disponibilidad limitada de datos históricos. Aunque su implementación es sencilla y ampliamente conocida, su capacidad predictiva es considerablemente baja, con valores de R^2 inferiores a 0.1 y márgenes de error (MAPE) elevados, lo que limita su utilidad en entornos complejos o altamente dinámicos. En cambio, los modelos de Machine Learning y de Deep Learning demostraron un rendimiento superior, particularmente en contextos donde se cuenta con grandes volúmenes de datos y múltiples variables. Los modelos de DL fueron los que alcanzaron mayor precisión, pero requieren mayor poder computacional y preparación técnica. Finalmente, los modelos híbridos, que integran métodos tradicionales con algoritmos de aprendizaje automático, permiten mejorar la precisión, aunque su diseño e implementación son más complejos. Estos hallazgos refuerzan la importancia de elegir el tipo de modelo en función tanto de los objetivos de predicción como de las capacidades analíticas de una organización.

TABLA VII
DESEMPEÑO DE LOS MODELOS

Modelo	Más utilizados	R^2 /MAPE	Volumen de datos
Tradicional	ARIMA, SARIMA, regresión lineal	0.0030.081 / 22.5- 35%	Pocos a moderados
ML	SVM, Random Forest, XGBoos	0.500.87/1030%	Moderados a muchos
DL	LSTM, CNN, GRU	0.90– 0.95/1.11– 9.5%	Moderados a muchos
Híbridos	SARIMA+ML, CNN+GA, Prophet+ LSTM	0.86–0.95/ 1.11– 10.7%	Moderados a muchos

La Tabla VIII presenta la distribución de los modelos utilizados en los 52 estudios seleccionados para la presente revisión sistemática, especificando la frecuencia de uso y las referencias de los artículos donde se aplicaron. Se puede ver que los modelos de Random Forest son los más utilizados, presentes en 8 estudios, confirmando su efectividad como algoritmo de predicción. Le siguen en frecuencia los modelos XGBoost, aplicados en 7 artículos, por su alto rendimiento y capacidad para manejar grandes volúmenes de datos multivariantes. Los modelos tradicionales de series de tiempo, específicamente ARIMA

y SARIMA, aparecen en 6 documentos, mayormente en entornos con disponibilidad de datos históricos limitados o en series estacionales. En cuanto a modelos de Deep Learning, LSTM se destaca con 4 estudios, seguido de CNN en 3 publicaciones y GRU en 2. Además, se identificaron 6 artículos que utilizaron arquitecturas avanzadas como Transformers, SGNN y WaveNet, esto demuestra una tendencia reciente en la aplicación de modelos secuenciales y espaciales para la predicción de ventas. Finalmente, se detectaron combinaciones híbridas (ML + DL) en 2 estudios, y otros algoritmos clásicos de machine learning como SVM, k-NN y ElasticNet en 4 artículos. Esta diversidad de enfoques muestra preferencia por los modelos de machine learning clásicos y deep learning en tareas de predicción de producción y ventas, desplazando progresivamente a los métodos tradicionales.

IV. CONCLUSIONES

A partir de la revisión de los 52 artículos seleccionados, se concluye que la predicción de producción y ventas se ha convertido en un tema de interés creciente en distintos sectores, principalmente en contextos de comercio electrónico, retail físico y ventas de servicios. Se comprobó que los modelos tradicionales, como ARIMA, SARIMA y regresión lineal, continúan utilizándose en algunos escenarios con estructuras de datos simples o series históricas limitadas, aunque su precisión es moderada y presentan dificultades para manejar relaciones no lineales o variables contextuales. Los algoritmos de Machine Learning, particularmente Random Forest y XGBoost, demostraron una mejora notable en los niveles de precisión respecto a los métodos tradicionales, siendo capaces de trabajar con datos multivariantes y proporcionar resultados más ajustados en entornos dinámicos. Los modelos de Deep Learning, como LSTM y CNN, junto a combinaciones híbridas con algoritmos de Machine Learning, alcanzaron las mejores tasas de precisión en los estudios analizados, logrando valores de R^2 superiores al 90% y MAPE por debajo del 10%, lo cual los posiciona como las técnicas más efectivas para la predicción de ventas en entornos complejos y con grandes volúmenes de datos. En cuanto a la procedencia de los estudios, se observó una clara concentración de publicaciones en países asiáticos, especialmente China e India, lo que evidencia una mayor producción académica sobre esta temática en esas regiones, mientras que otras zonas presentan menor representación. Finalmente, se concluye que la efectividad de los modelos predictivos mejora sustancialmente al incorporar variables adicionales como ubicación geográfica, comportamiento digital de los consumidores, factores socioeconómicos y patrones estacionales, por lo que el uso de modelos avanzados y bases de datos completas se vuelve indispensable para obtener proyecciones confiables en mercados competitivos.

AGRADECIMIENTO

Queremos expresar nuestro agradecimiento al comité organizador del 5th LACCEI International Multiconference on

Entrepreneurship, Innovation and Regional Development – LEIRD 2025 por brindarnos la oportunidad de compartir los resultados de nuestra investigación en un espacio de difusión académica internacional. Asimismo, extendemos nuestro reconocimiento a la Universidad Tecnológica del Perú, sede Chiclayo, por el apoyo institucional que hizo posible este trabajo. Finalmente, agradecemos de manera especial al profesor Christian Abraham Dios Castillo, cuyo acompañamiento y orientación fueron fundamentales en el desarrollo de esta investigación.

REFERENCIAS

- [1] “Sales forecasting is an essential process for companies as it allows them to plan and make appropriate decisions about their workforce, cash flow and resources.”
- K. M. Aguirre Méndez, A. L. Moreno Torres & C. Ovalle, “Predictive model based on machine learning for the prevention of overstock in a footwear company,” 21st LACCEI International Multi-Conference, Buenos Aires, 2023. doi: 10.18687/LACCEI2023.1.1.216
- [2] “ML models generally show a superior performance of up to 30 % compared to classical forecasting methods to generate demand forecasts for household appliances.”
- Culcay et al., “Home Appliance Demand Forecasting: A Comparative Approach Using Traditional and Machine Learning Algorithms,” LNNS Intelligent Systems Conference, 2024. doi: 10.1007/978-3-031-47715-7_32
- [3] D. I. L. Alama and C. A. Dios-Castillo, “Effectiveness of Machine Learning Models in Intrusion Detection in Information Systems and Their Applicability in the Context of Entrepreneurship and Innovation: A Systematic Literature Review,” in Proceedings of the LACCEI international Multi-conference for Engineering, Education and Technology, Latin American and Caribbean Consortium of Engineering Institutions, 2024. doi: 10.18687/LEIRD2024.1.1.237.
- [4] Kuziemy C, Lau F. Chapter 8 Methodological Landscape for eHealth Evaluation. In: Lau F, Kuziemy C, editors. Handbook of eHealth Evaluation: An Evidence-based Approach [Internet]. Victoria (BC): University of Victoria; 2017 Feb 27. Available from: <https://www.ncbi.nlm.nih.gov/books/NBK481596/>
- [5] Xin, J. (2023). Linear Regression Predicts Future Sales and Selling Prices. *Advances in Artificial Intelligence, Big Data and Algorithms*
- [6] Elalem, Y. K., Maier, S., & Seifert, R. W. (2023). A machine learningbased framework for forecasting sales of new products with short life cycles using deep neural networks. *International Journal of Forecasting*.
- [7] Moraes, T. C., Yuan, X.-M., & Chew, E. P. (2024). Hybrid convolutional long short-term memory models for sales forecasting in retail. *Wiley*.
- [8] Gururaya, A. M., et al. (2024). Bi-GRU-APSO: Bi-Directional Gated Recurrent Unit with Adaptive Particle Swarm Optimization Algorithm for Sales Forecasting in Multi-Channel Retail. *Telecom*.
- [9] Liu, X., & Wang, W. (2024). Deep Time Series Forecasting Models: A Comprehensive Survey. *Mathematics*.
- [10] Burnap, A., Hauser, J. R., & Timoshenko, A. (2023). Product Aesthetic Design: A Machine Learning Augmentation. *Marketing Science*.
- [11] Ahaggach, H., Abrouk, L., & Lebon, E. (2024). Systematic Mapping Study of Sales Forecasting: Methods, Trends, and Future Directions. *Forecasting*.
- [12] Tang, X., & Zhu, Y. (2024). Enhancing bank marketing strategies with ensemble learning: Empirical analysis. *PLOS ONE*.
- [13] Petropoulos, F., Grushka-Cockayne, Y., Siemsen, E., & Spiliotis, E. (2024). Wielding Occam’s razor: Fast and frugal retail forecasting. *Journal of the Operational Research Society*.
- [14] Zhao, X., & Kelikhevrokhai, P. (2022). Sales Prediction and Product Recommendation Model Through User Behavior Analytics. *Computers, Materials & Continua*.

- [15] Salamai, A. A., Ageeli, A. A., & El-kenawy, E.-S. M. (2022). Forecasting E-commerce Adoption Based on Bidirectional Recurrent Neural Networks. *Computers, Materials & Continua*.
- [16] Li, Q., & Yu, M. (2023). Achieving Sales Forecasting with Higher Accuracy and Efficiency: A New Model Based on Modified Transformer. *Electronics*.
- [17] Liu, R., et al. (2024). Personalized Clothing Prediction Algorithm Based on Multi-modal Feature Fusion. *International Journal of Engineering and Technology Innovation*.
- [18] Tu, R., et al. (2024). Machine learning application in batch scheduling for multi-product pipelines: A review. *Journal of Pipeline Science and Engineering*.
- [19] Zhou, Y., Han, W., & Zhou, F. (2024). A multi-step regularity assessment and joint prediction system for ordering time series based on entropy and deep learning. *Autonomous Intelligent Systems*.
- [20] Steinmeister, L., & Pauly, M. (2024). Human vs. Machines: Who wins in semiconductor market forecasting?. *Expert Systems with Applications*.
- [21] Sobiech-Grabka, K., Stankowska, A., & Jędraszczyk, K. (2022). Determinants of Electric Cars Purchase Intention in Poland: Personal Attitudes v. Economic Arguments. *Energies*.
- [22] Sayyad, J., Attarde, K., & Yilmaz, B. (2024). Improving Machine Learning Predictive Capacity for Supply Chain Optimization through Domain Adversarial Neural Networks. *Big Data and Cognitive Computing*.
- [23] Hwang, S., Lee, Y., Jeon, B.-j., & Oh, S. (2023). Sales Forecasting for New Products Using Homogeneity-Based Clustering and Ensemble Method. *Electronics*.
- [24] Kim, J., et al. (2022). Development of a Deep-Learning-Based Prediction Model for Water Consumption at the Household Level. *Water*.
- [25] Xu, Y., et al. (2023). Deep Intention-Aware Network for Click-Through Rate Prediction in Trigger-Induced Recommendation. *ACM*.
- [26] Syn, C. K., & Abdullah, S. S. (2023). Prediction of Monthly Total Sales for a Company using Deep Learning. *Journal of Advanced Research Design*.
- [27] Netto, C. F. S., Brei, V. A., & Hyndman, R. J. (2023). Forecasting system's accuracy: A framework for the comparison of different structures. *Applied Stochastic Models in Business and Industry*.
- [28] Bo, L., & Xu, J. (2024). Enhancing Supply Chain Efficiency Resilience Using Predictive Analytics and Computational Intelligence Techniques. *IEEE Access*.
- [29] Fourkiotis, K. P., & Isadiz, A. (2024). Applying Machine Learning and Statistical Forecasting Methods for Enhancing Pharmaceutical Sales Predictions. *Forecasting*.
- [30] Peruchini, M., da Silva, G. M., & Teixeira, J. M. (2024). Between artificial intelligence and customer experience: a literature review on the intersection. *Discover Artificial Intelligence*.
- [31] Yue, H. (2023). Feasibility study of deep learning based on data-based ecommerce operations. *Applied Mathematics and Nonlinear Sciences*.
- [32] Giri, C., & Chen, V. (2022). Deep Learning for Demand Forecasting in the Fashion and Apparel Retail Industry. *Forecasting*.
- [33] Emotivwakil, A., Sadiki, A., & Er-Raiy, N. (2024). Predicting groundwater level based on remote sensing and machine learning: a case study in the Rabat-Kénitra region. *Journal of Hydroinformatics*.
- [34] Zhang, X., et al. (2024). Enhancing Time Series Product Demand Forecasting With Hybrid Attention-Based Deep Learning Models. *IEEE Access*.
- [35] Atif, A., Jayaraman, R., Azar, F., & Maalouf, M. (2024). Maximizing supply chain customer backorders while leveraging machine learning to anticipate customer backorders. *Computers & Industrial Engineering*.
- [36] Huang, Z., & Liu, J. (2023). TransTLA: A Transfer Learning Approach with TCN-LSTM-Attention for Household Appliance Sales Forecasting in Small and Big Towns. *Applied Sciences*.
- [37] Poufinas, T., Gogas, P., Papadimitriou, T., & Zaganidis, E. (2023). Machine Learning in Forecasting Motor Insurance Claims. *Risks*.
- [38] Xu, A., & Li, L. (2024). Marketing Decision Model and Consumer Behavior Prediction With Deep Learning. *Journal of Organizational and End User Computing*.
- [39] Chaudhuri, K. D., & Alkan, B. (2022). A hybrid extreme learning machine model with harris hawks optimisation algorithm: an optimised model for product demand forecasting applications. *Springer*.
- [40] Ahmadvov, Y., & Helo, P. (2023). Deep learning-based approach for forecasting intermittent online sales. *Discover Artificial Intelligence*.
- [41] Han, S., et al. (2022). Search well and be wise: A machine learning approach to search for a profitable location. *Elsevier*.
- [42] Alqatawneh, A., Abul-Huda, B., Obeid, N., & Almi'ani, M. (2023). Incorporating Time-Series Forecasting Techniques to Predict Logistics Companies' Staffing Needs and Order Volume. *Computation*.
- [43] Benik, G. Y., Badur, B., & Mamtazian, S. (2022). A New 360° Framework to Predict Customer Lifetime Value for Multi-Category ECommerce Companies Using a Multi-Output Deep Neural Network and Explainable Artificial Intelligence. *Information*.
- [44] Sun, Y., & Li, T. (2024). A transformer-based framework for enterprise sales forecasting. *PeerJ Computer Science*.
- [45] Lange, F., Dreesen, L., & Schlosser, R. (2025). Reinforcement learning versus data-driven dynamic programming: a comparison for finite horizon pricing markets. *Journal of Revenue and Pricing Management*.
- [46] Wen, K. Y., Joseph, M. H., & Sivakumar, V. (2024). Big Mart Sales Prediction using Machine Learning. *EAI Endorsed Transactions on Internet of Things*.
- [47] Suh, Y. (2024). Repurchase Prediction Using Survival Ensembles in CRM Systems for Home Appliance Business. *IEEE Access*.
- [48] Hassan, M. R., Islam, M. R., & Rahman, M. A. (2025). Developing and implementing AI-driven models for demand forecasting in US supply chains. *Edelweiss Applied Science and Technology*.
- [49] Obádovics, C., & Szabados, L. (2025). Methodological research for forecasting electricity consumption with traditional methods and MI application. *Statistikai Szemle*.
- [50] Cao, M., et al. (2022). Short-Term and Medium-Term Electricity Sales Forecasting Method Based on Deep Spatio-Temporal Residual Network. *Energies*.
- [51] Li, J., Tan, L., Wang, X., Sun, J., & Zhou, M. (2024). Product Demand Prediction with Spatial Graph Neural Network. *Applied Sciences*.
- [52] Sayyad, J. K., Attarde, K., & Saadoul, N. (2024). Optimizing eCommerce Supply Chains With Categorical Boosting: A Predictive Modeling Framework. *IEEE Access*.
- [53] Theodorou, E., Spiliotis, E., & Assimakopoulos, V. (2025). Optimizing inventory control through a data-driven and model-independent framework. *EURO Journal on Transportation and Logistics*.
- [54] Nashkinova, I., Kolev, M., & Lazarova, M. (2024). Forecasting Strategies in Retail: Utilizing Advanced Machine Learning Methods while Safeguarding Privacy. *Journal of Physics: Conference Series*.
- [55] Wang, L., et al. (2022). Robust Nonparametric Distribution Forecast with Backtest-based Bootstrap and Adaptive Residual Selection. *arXiv*.
- [56] Kim, B.-H. (2024). Development of Online Fraud Detection and Sales Prediction Model using Supply Chain Dataset. *Journal of System and Management Sciences*.