

الجمهورية الجزائرية الديمقراطية الشعبية
People's Democratic Republic of Algeria
وزارة التعليم العالي والبحث العلمي
Ministry of Higher Education and Scientific Research
المدرسة العليا للإعلام الآلي 8 ماي 1945 - سيدي بلعباس
Higher School of Computer Science
8 Mai 1945 - Sidi Bel Abbès



Master's Thesis

To obtain the diploma of Master's Degree
Field of Study: Computer Science
Specialization: SIW

Time Series-Based Demand Forecasting in Supply Chain Systems Using Machine Learning and Deep Learning Models

Presented by
Belkorche Widad

Defended on: **July, 2026**
Before the jury composed of

Ms. Elouali Nadia

Mr. Sidi Mohammed BENSLIMANE

Ms. Bousba Fadia Nouna

Mr. Kechar Mohamed

Ms. Abdelhak Soumia

President of the Jury

Thesis Supervisor

Examiner

Incubator Representative

Guest

Academic Year: 2025/2026

Abstract

Accurate demand forecasting is essential for optimizing inventory and reducing costs in modern supply chains. However, increasing data volatility and non-linearity expose the limitations of traditional statistical methods. This thesis critically examines the application of machine learning (ML) and deep learning (DL) approaches for time-series demand forecasting, while comparing them with classical forecasting methods.

Through a systematic review of recent empirical literature, this study evaluates the predictive performance and practical applicability of these forecasting paradigms. The findings reveal that while classical methods remain effective for stable demand patterns, ML models—particularly tree-based approaches such as XGBoost and Random Forest—provide a strong balance between accuracy, interpretability, and scalability. In contrast, DL architectures, including LSTM and GRU, demonstrate superior capabilities in capturing complex temporal dependencies and nonlinear patterns, although they generally require larger datasets and greater computational resources.

Furthermore, the research identifies critical challenges affecting real-world adoption, including data quality issues, temporal data leakage, cold-start scenarios, and model interpretability limitations. It emphasizes that forecasting models should be assessed not only through statistical accuracy metrics but also through their impact on operational and financial Key Performance Indicators (KPIs). Ultimately, this thesis provides a structured framework for selecting appropriate forecasting approaches and highlights future directions such as adaptive forecasting, explainable AI, and lightweight models for practical deployment.

Keywords: Supply Chain Management, Demand Forecasting, Time Series Forecasting, Machine Learning, Deep Learning.

الملخص

يُعدّ التنبؤ الدقيق بالطلب أمراً حتمياً لتحسين المخزون وتقليل التكاليف في سلاسل التوريد الحديثة. ومع ذلك، فإن تزايد تقلب البيانات وطبيعتها غير الخطية يكشفان عن قيود الطرق الإحصائية التقليدية. تفحص هذه الرسالة بشكل نقدي تطبيق أساليب التعلم الآلي والتعلم العميق في التنبؤ بالطلب اعتماداً على السلاسل الزمنية، مع مقارنتها بطرق التنبؤ التقليدية.

من خلال مراجعة منهجية للأدبيات التجريبية الحديثة، تقيم هذه الدراسة الأداء التنبؤي والقابلية للتطبيق العملي لهذه النماذج. وتكشف النتائج أنه بينما تبقى الطرق الكلاسيكية فعالة لأنماط الطلب المستقرة، فإن نماذج التعلم الآلي، وخاصة الأساليب القائمة على الأشجار مثل XGBoost و Random-Forest توفر توازناً قوياً بين الدقة وقابلية التفسير وقابلية التوسع. وفي المقابل، تُظهر معماريات التعلم العميق، بما في ذلك LSTM و GRU قدرات متفوقة في التقاط التبعيات الزمنية المعقدة والأنماط غير الخطية، رغم أنها تتطلب عموماً مجموعات بيانات أكبر وموارد حوسبة أكثر.

علاوة على ذلك، يحدد البحث التحديات الحرجة التي تؤثر على التنبؤ في الواقع العملي، بما في ذلك مشكلات جودة البيانات، وتسرب البيانات الزمنية، وسيناريوهات البداية الباردة، وقيود قابلية تفسير النماذج. ويؤكد أن نماذج التنبؤ ينبغي أن تُقيم ليس فقط من خلال مقاييس الدقة الإحصائية، بل أيضاً من خلال تأثيرها على مؤشرات الأداء الرئيسية التشغيلية والمالية. وفي النهاية، تقدم هذه الرسالة إطار عمل منظماً لاختيار أساليب التنبؤ المناسبة، وتبرز الاتجاهات المستقبلية مثل التنبؤ التكيفي، والذكاء الاصطناعي القابل للتفسير، والنماذج الخفيفة للنشر العملي. الكلمات المفتاحية: إدارة سلاسل التوريد، التنبؤ بالطلب، التنبؤ بالسلاسل الزمنية، التعلم الآلي، التعلم العميق.

Résumé

Une prévision précise de la demande est essentielle pour optimiser les stocks et réduire les coûts dans les chaînes d’approvisionnement modernes. Cependant, l’augmentation de la volatilité des données et de la non-linéarité expose les limitations des méthodes statistiques traditionnelles. Cette thèse examine de manière critique l’application des approches d’apprentissage automatique et d’apprentissage profond pour la prévision des séries temporelles de demande, en les comparant aux méthodes de prévision classiques.

Par le biais d’un examen systématique de la littérature empirique récente, cette étude évalue la performance prédictive et l’applicabilité pratique de ces paradigmes de prévision. Les résultats révèlent que si les méthodes classiques restent efficaces pour les modèles de demande stables, les modèles d’apprentissage automatique—en particulier les approches basées sur les arbres décisionnels tels que XGBoost et Random Forest—offrent un équilibre solide entre la précision, l’interprétabilité et l’évolutivité. En revanche, les architectures d’apprentissage profond, notamment LSTM et GRU, démontrent des capacités supérieures pour capturer les dépendances temporelles complexes et les modèles non linéaires, bien qu’elles nécessitent généralement des ensembles de données plus importants et davantage de ressources informatiques.

De plus, la recherche identifie les défis critiques affectant l’adoption dans le monde réel, notamment les problèmes de qualité des données, la fuite de données temporelles, les scénarios de démarrage à froid et les limitations d’interprétabilité des modèles. Elle souligne que les modèles de prévision doivent être évalués non seulement sur la base de métriques de précision statistique, mais aussi sur leur impact sur les indicateurs clés de performance (KPI) opérationnels et financiers. Finalement, cette thèse fournit un cadre structuré pour sélectionner les approches de prévision appropriées et met en évidence les orientations futures telles que la prévision adaptative, l’intelligence artificielle explicable et les modèles légers pour un déploiement pratique.

Mots-clés : Gestion de la chaîne d’approvisionnement, Prévision de la demande, Prévision des séries temporelles, Apprentissage automatique, Apprentissage profond.