

Tendances actuelles dans l'utilisation de l'Intelligence Artificielle pour la prévision de la demande : Une revue de la littérature

BALAR Khalid¹, ADIL Kaoutar², EL ALAMI Amina³

¹ PHD, Faculté des sciences Juridiques, Economiques et Sociales de Aïn Chock, Casablanca, Maroc

² PHD Student, Faculté des sciences Juridiques, Economiques et Sociales de Aïn Chock, Casablanca, Maroc

³ PHD Student, Faculté des sciences Juridiques, Economiques et Sociales de Aïn Chock, Casablanca, Maroc

Résumé : La prévision de la demande est une composante cruciale de la gestion efficace des stocks et de la planification des opérations commerciales dans les entreprises. Cependant, les défis posés par la volatilité des marchés et les changements imprévisibles dans le comportement des consommateurs ont longtemps entravé les efforts visant à produire des prévisions précises. Cette revue de littérature examine les tendances actuelles dans l'utilisation de l'Intelligence Artificielle (IA) pour la prévision de la demande. L'étude offre une analyse approfondie des récentes avancées, des méthodologies et des études de cas dans ce domaine en constante évolution. L'intégration de techniques d'apprentissage automatique se positionne comme une approche essentielle en prévision de la demande. Elle permet de surmonter le défi de la variabilité des données, conduisant à une précision accrue des prévisions. De plus, l'incorporation de Réseaux de Neurones et d'Apprentissage Profond a démontré des résultats prometteurs dans la prédiction de la demande. Des études de cas pratiques, mettant en avant l'applicabilité et l'adaptabilité des méthodologies pilotées par l'IA, viennent renforcer ces avancées. En conclusion, cette revue met en lumière l'évolution rapide des techniques d'IA dans la prévision de la demande, offrant une vue d'ensemble complète des dernières tendances. Ces avancées promettent d'améliorer considérablement la précision et l'efficacité des prévisions de demande.

Mots-clés : Intelligence Artificielle, Prévision de la Demande, Apprentissage Automatique, Réseaux de Neurones, Apprentissage Profond.

1. Introduction

La prévision de la demande représente le domaine de l'analyse prédictive qui se focalise sur la compréhension des besoins des consommateurs en biens ou en services. Cette appréhension est cruciale pour anticiper et planifier les niveaux de demande et de ventes. Du fait de sa complexité, la prévision de la demande doit être d'une précision extrême. Avoir une vision claire des demandes futures permet aux entreprises une gestion précise des matières premières et des emballages, une planification de production ainsi qu'une réduction globale des coûts. Si la demande est sous-évaluée, cela peut entraîner une perte de ventes en raison de la pénurie de produits. En cas de surestimation de la demande, une partie considérable des ressources peut se trouver immobilisée.

Toute entreprise qui commercialise des produits doit inévitablement établir des prévisions de la demande, car elles représentent un pilier essentiel pour de nombreux autres processus opérationnels. Cela englobe la planification de la production, la gestion des approvisionnements en matières premières et en emballages, la gestion des niveaux de stock, la mise en œuvre d'activités publicitaires et

promotionnelles, ainsi que le lancement de nouveaux produits. De surcroît, la fiabilité de ces données est cruciale pour chaque maillon de la chaîne d'approvisionnement : les fabricants doivent déterminer les quantités à produire, les distributeurs doivent savoir quelles quantités commander et stocker, tandis que les détaillants doivent anticiper les quantités à vendre.

Bien que les méthodes de prévision traditionnelles aient longtemps été suffisantes pour répondre aux besoins du marché, la compétition croissante exige désormais une approche plus intégrée. Cela implique la combinaison de plusieurs facteurs géographiques, démographiques, historiques, comportementaux et microéconomiques pour saisir les moteurs de la demande. Une telle compréhension permet des décisions proactives et une planification stratégique, essentielles pour rester compétitif dans un marché dynamique et exigeant.

C'est ici qu'intervient l'intelligence artificielle (IA) qui a révolutionné de nombreux aspects de la vie moderne, et son application dans la prévision de la demande constitue l'un des domaines les plus dynamiques et prometteurs. À mesure que les technologies de l'IA continuent de se développer, elles offrent des opportunités considérables pour améliorer la précision des prévisions de la demande dans diverses industries.

Cette étude vise à fournir une revue approfondie des tendances actuelles dans l'utilisation de l'IA pour la prévision de la demande, en s'appuyant sur un corpus diversifié de recherches éminentes. L'accent est mis sur les méthodologies innovantes, les approches technologiques avancées, ainsi que les études de cas pratiques illustrant l'efficacité et l'applicabilité de ces techniques.

Ce parcours à travers les tendances actuelles de l'utilisation de l'Intelligence Artificielle (IA) dans la prévision de la demande se concentrera sur divers aspects cruciaux pour les professionnels de la planification et de la gestion des ressources. Tout d'abord, nous approfondirons l'examen des méthodes classiques de prévision de la demande à savoir les méthodes qualitatives et les méthodes quantitatives. Par la suite, nous plongerons dans les méthodes émergentes, telles que l'intégration des Réseaux de Neurones et de l'Apprentissage Profond, ainsi que les pratiques modernes qui redéfinissent la manière dont nous appréhendons la prévision de la demande. En outre, à travers l'analyse de cas concrets, nous mettrons en lumière des exemples tangibles où l'IA a été déployée avec succès.

Ce parcours à travers les tendances actuelles de l'utilisation de l'Intelligence Artificielle pour la prévision de la demande offre un panorama complet des avancées les plus récentes dans ce domaine en constante évolution. Chaque section apportera des éclairages spécifiques, tirant parti des recherches et des études empiriques les plus pertinentes pour guider les professionnels vers des pratiques de prévision de pointe.

2. Méthodes classiques de Prévision de la Demande

Dans toute industrie, la précision des prévisions de la demande est cruciale pour garantir un approvisionnement optimal en produits et maintenir des niveaux de stock adéquats. Les méthodes de prévision traditionnelles ont longtemps été le pilier de ces processus, reposant souvent sur des techniques statistiques telles que les modèles de séries chronologiques, les méthodes de lissage exponentiel, et les régressions. Ces approches ont fait leurs preuves en fournissant des prévisions relativement fiables dans des environnements stables et prévisibles.

Différentes approches sont employées pour anticiper la demande, souvent catégorisées en méthodes quantitatives et qualitatives. Les méthodes qualitatives se basent sur des évaluations subjectives et ne requièrent pas de traitement de données, tandis que les méthodes quantitatives reposent sur des procédures standardisées et produisent des résultats objectifs, excluant ainsi tout jugement.

2.1. Méthodes qualitatives

Les méthodes qualitatives de prévision de la demande, également appelées « méthodes basées sur le jugement », s'appuient sur le jugement, le discernement et l'expérience de décideurs experts (Petropoulos et coll., 2018). Ces approches s'avèrent pertinentes pour esquisser des perspectives à venir lorsqu'il existe une pénurie de données disponibles (Seifert et al., 2015), quand la fiabilité est limitée, ou encore pour estimer des paramètres associés à des produits ou processus innovants ou perturbateurs (Arvan et al., 2019).

2.1.1. Jugement des experts :

Une des approches qualitatives pour anticiper la demande repose sur l'évaluation des experts, exploitant l'opinion et l'expérience d'individus spécialisés pour générer des prévisions de la demande (Arvan et al., 2019). Ces experts émettent des prévisions de manière individuelle, qui sont ensuite agrégées pour former une estimation globale. Ces prévisions ont une portée à long terme et revêtent une importance particulière dans la stratégie de planification de l'entreprise.

L'ajustement du jugement personnel se traduit par l'intégration des données anticipées par les experts dans des modèles mathématiques, transformant les jugements subjectifs en informations structurées. Pour cela, les informations utilisées par ces experts pour anticiper la demande sont d'abord identifiées, puis ces spécialistes élaborent des prévisions pour divers scénarios, réels ou hypothétiques (Arvan et al., 2019). Les données résultantes sont ensuite formulées en un modèle qui effectue une régression sur la base de l'ensemble des prévisions collectées (Seifert et al., 2015).

2.1.2. Delphi

La méthode Delphi repose sur l'envoi d'un questionnaire à un groupe d'experts, dont les réponses sont analysées, résumées, puis renvoyées de manière anonyme aux participants (Nikolopoulos et al., 2015). Généralement, cette équipe comprend entre cinq et 20 experts. De manière confidentielle, ces spécialistes répondent à des questionnaires où ils expriment et justifient leurs prévisions. Le processus se répète jusqu'à ce que les prédictions entre les tours montrent peu de changements significatifs (von Briel, 2018). En général, deux ou trois tours suffisent, et la médiane ou le mode des prédictions finales des experts détermine le résultat de la prédiction (Arvan et al., 2019).

Selon Kudlak et al. (2018), la méthode Delphi est souvent appliquée pour étudier des phénomènes complexes et peu explorés dans les domaines de la prévision scientifique et technologique, de la prévision commerciale et de la formulation de politiques participatives.

2.1.3. Méthode d'analogie structurée

La méthode de l'analogie structurée s'appuie sur les événements passés comme référence pour anticiper le déroulement d'une nouvelle situation, en utilisant des analogies. Selon Jun et al. (2017), elle représente un effort conscient et réfléchi pour tirer parti de l'expérience historique, impliquant une comparaison systématique entre ce qu'il faut prédire et des éléments passés considérés comme similaires à bien des égards, voire dans la plupart des cas.

Dans cette méthode, un gestionnaire élabore une description de la situation objective et sélectionne des experts ayant une expérience dans des situations similaires, de préférence ceux possédant une expérience directe (Jun et al., 2017). Ces experts identifient et décrivent des situations analogues, évaluant leur similitude avec la situation cible et établissant des parallèles entre les résultats de ces analogies et les résultats probables de la situation cible. Ainsi, l'administrateur crée une analogie pour

chaque expert, en se basant sur celui qui présente le plus de similitudes avec les autres experts, obtenant ainsi une prédiction analogue par expert.

2.1.4. Recherche d'intention et d'opinion

Les sondages d'intention et d'opinion sont déployés afin d'évaluer les intentions d'achat ou les schémas de comportement vis-à-vis de certaines conditions spécifiques. Cette méthode requiert la prise en compte d'enquêtes présentant une signification statistique pour permettre des généralisations (Armstrong & Green, 2005). Cependant, parfois, des groupes ciblés sont utilisés à cette fin, mais dans ces cas, ils ne représentent pas un échantillon significatif de la population. L'analyse conjointe est également incluse dans cette catégorie lorsque la recherche vise à comprendre les attributs qui influenceraient un choix d'achat ou un schéma de comportement (Jun et al., 2017).

2.2. Méthodes quantitatives

Les approches quantitatives de prévision de la demande, souvent désignées sous le nom de "méthodes mathématiques", reposent sur l'utilisation de modèles mathématiques pour générer des valeurs prévisionnelles. Ces méthodes offrent la possibilité de contrôler les erreurs et se segmentent en méthodes causales et en séries chronologiques.

2.2.1. Méthodes causales

Dans les modèles causaux, les demandes de produits finis ou de services associés, désignées comme des "variables dépendantes", entretiennent une relation de cause à effet avec des variables antérieures, qualifiées de "variables indépendantes". Ces modèles cherchent à prédire la demande pour un produit en utilisant une fonction incluant des variables telles que le prix, le pays d'origine, et d'autres (Katsikopoulos et al., 2018). La méthode causale relie étroitement la prévision de la demande à certains facteurs environnementaux, tels que des indicateurs économiques nationaux ou les taux d'intérêt. Ces modèles mettent en lumière des tendances dans les données au fil du temps et révèlent des relations identifiables entre les données que l'on souhaite prédire et d'autres facteurs (Arvan et al., 2019)

Un modèle de régression est une relation entre ce qui est censé être prédit, appelé la « variable dépendante » (Y), et les facteurs qui déterminent la valeur de Y, appelées « variables indépendantes » (xi) Le modèle de régression simple analyse la relation entre deux variables, où les données appropriées pour cette méthode sont constituées d'observations, chacune avec deux mesures différentes. La régression est significative lorsque la variable dépendante est significativement liée aux variables indépendantes (Fang & Lahdelma, 2016). La régression simple peut être représentée par l'équation (1), c'est-à-dire Y est une fonction de X:

$$Y=f(X) \quad (1)$$

Le modèle de régression multiple peut être exprimé par la fonction présentée dans l'équation (2).

$$Y=f(X_1, X_2, X_3, \dots, X_n) \quad (2)$$

sur quoi:

X_1, X_2, \dots, X_n =ensemble de n variables indépendantes.

2.2.2. Les séries chronologiques

L'étude des séries temporelles se concentre principalement sur l'évolution temporelle d'un phénomène sans l'intégration d'autres facteurs explicatifs externes. Elle repose sur l'analyse de données organisées chronologiquement (Boroojeni et al., 2017). Cette approche vise à comprendre comment un phénomène s'est comporté dans le passé pour prédire son évolution future (Villani et al., 2017). Pour ce faire, elle se

base sur les valeurs passées et le comportement de la variable étudiée, comme la demande par exemple. Les données sont considérées comme un processus aléatoire où si la variance reste constante au fil du temps, le processus est dit "stationnaire", sinon il est qualifié de "non stationnaire" (Fortsch & Khapalova, 2016). Ces méthodes sont utilisées pour prédire à court terme lorsque les observations suivent un schéma identifiable dans le temps (Zhu et al., 2015).

- **La Moyenne Mobile (moving average)**

Ce modèle représente l'une des approches les plus simples, consistant à estimer simplement la demande future en calculant la moyenne des n dernières demandes. Il s'adapte spécialement aux produits avec une demande stable et une faible variabilité. Son efficacité réside dans sa capacité à lisser les fluctuations aléatoires susceptibles de perturber les séries, surtout pour des produits de base et essentiels. La formule mathématique de cette moyenne est définie comme suit :

$$p_t = \frac{\sum_{k=1}^n d_{t-k}}{n}$$

P_t est la prévision pour la période t , d_t est la demande réelle pour la période t , et n , le nombre de périodes prises en compte.

Une variante de ce modèle est la moyenne mobile pondérée, où les demandes des périodes passées reçoivent des poids différents.

$$p_t = 2 \cdot \frac{nd_{t-1} + (n-1)d_{t-2} + (n-2)d_{t-3} + \dots + 2d_{t-(n+2)} + d_{t-(n+1)}}{n(n+1)}$$

P_t est la prévision pour la période t , d_t est la demande réelle pour la période t , et n , le nombre de périodes prises en compte.

- **Lissage exponentiel**

Le lissage exponentiel est une méthode spécifique de traitement des données passées qui utilise une approche de pondération exponentielle. Cette technique attribue des poids décroissants aux données antérieures en fonction de leur éloignement dans le temps. Le coefficient de pondération détermine la vitesse à laquelle les données passées impactent la prévision, allant d'une réactivité élevée avec un coefficient proche de 1 ($\alpha \approx 1$) à une pondération uniforme avec un coefficient proche de 0 ($\alpha \approx 0$). Un coefficient proche de 1 favorise les données récentes, tandis qu'un coefficient proche de 0 traite toutes les valeurs de manière équivalente. Ce modèle repose sur le principe bien accepté selon lequel les informations récentes sont plus pertinentes que les informations plus anciennes.

$$P_t = P_{t-1} + \alpha (d_t - P_{t-1})$$

$$P_t = \alpha \cdot d_t + (1 - \alpha)P_{t-1}$$

P_t est la prévision pour la période t , d_t est la demande pour la période t , et α le coefficient de lissage avec $\alpha \in [0; 1]$.

Ce modèle est principalement appliqué lorsque les événements récents sont de meilleurs indicateurs du futur par rapport à des événements plus anciens. (Tyagi 2002) recommande son utilisation dans les situations saisonnières sans tendance ou fortement influencées par les conditions météorologiques, en particulier pour des prévisions à court terme (comme sur une base quotidienne ou hebdomadaire). Cette approche permet au modèle de réagir promptement aux valeurs les plus récentes et d'ajuster la prévision en fonction des observations les plus récentes.

• **Les lissages exponentiels doubles et triples: méthodes de Brown, de Holt et de Winters**

Le lissage exponentiel double offre la capacité de modéliser des séries temporelles comportant des tendances, contrairement au lissage exponentiel simple qui exige des données stationnaires.

On identifie trois variantes principales du lissage exponentiel simple : le modèle de Brown (lissage exponentiel double avec un paramètre simple), le modèle de Holt (lissage exponentiel double avec des paramètres doubles) et le modèle de Winters ou Holt/Winters (lissage exponentiel triple). Les modèles de Brown et de Holt sont parmi les premières approches permettant de modéliser des séries temporelles comportant une tendance mais sans saisonnalité. En revanche, le modèle de Winters, plus récent, intègre à la fois la tendance et la saisonnalité. Ces modèles sont largement utilisés dans les logiciels de prévision actuels. Cependant, la recherche sur ces modèles reste active, comme le montre la modification du modèle Holt/Winters, comme démontré dans les travaux de Bermúdez et al. en 2006.

En ce qui concerne le modèle de Brown (lissage double avec un paramètre simple), la prévision pour la période $t + h$ est formulée comme suit :

$$p_{t+h} = a_{0t} + a_{1t} \cdot h$$

P_{t+h} correspond à la prévision pour la période $t+h$. où h représente l'horizon de cette prévision. A_{0t} est le coefficient de la moyenne de la demande et a_{1t} celui de la tendance. Ces coefficients sont déterminés comme suit:

$$\begin{cases} a_{0t} = 2S_t - SS_t \\ a_{1t} = \frac{\alpha}{1-\alpha} (S_t - SS_t) \end{cases}$$

Avec S_t et SS_t (représentant les termes de lissage) définis de la façon suivante :

$$\begin{aligned} S_t &= \alpha \cdot d_t + (1-\alpha)S_{t-1} \\ SS_t &= \alpha \cdot S_t + (1-\alpha)SS_{t-1} \end{aligned}$$

d_t est la demande réelle à la période t .

Et α le coefficient de lissage avec $\alpha \in [0; 1]$.

Le modèle de Holt (lissage double à paramètre double) : La prévision est donnée par :

$$p_{t+h} = a_{0t} + a_{1t} \cdot h$$

P_{t+h} correspond à la prévision pour la période $t+h$. où h représente l'horizon de cette prévision, d_t représente la demande réelle à la période t . a_{0t} désigne la moyenne lissée de la série à la période t et a_{1t} représente la pente de la tendance estimée à la période t . Ces coefficients sont évalués de la façon suivante :

$$\begin{cases} a_{0t} = \alpha \cdot d_t + (1-\alpha)(a_{0t-1} + a_{1t-1}) \\ a_{1t} = \beta(a_{0t} - a_{0t-1}) + (1-\beta)a_{1t-1} \end{cases}$$

α représente le coefficient de lissage de la moyenne ($\alpha \in [0; 1]$), β est le coefficient de lissage de la tendance ($\beta \in [0; 1]$).

Pour initialiser, $a_{0t} = x_1$ et $a_{1t} = 0$.

Le modèle de Holt-Winters (lissage triple) requiert la définition de la périodicité des données: $p = 12$ pour des données mensuelles, $p = 4$ pour des données trimestrielles dans un contexte annuel.

La prévision pour la période $t + h$ est ensuite calculée par :

$$\begin{aligned} p_{t+h} &= (a_{0t} + a_{1t} \cdot h) \cdot S_{t-p+h} & \text{si } 1 \leq h \leq p \\ p_{t+h} &= (a_{0t} + a_{1t} \cdot h) \cdot S_{t-p+2h} & \text{si } p + 1 \leq h \leq 2p \end{aligned}$$

P_{t+h} correspond à la prévision pour la période $t+h$. où h représente l'horizon de cette prévision, d_t représente la demande réelle à la période t . a_{0t} désigne la moyenne lissée de la série à la période t et a_{1t} représente la pente de la tendance estimée à la période t . S_t représente le coefficient saisonnier à la période t . Ces coefficients sont évalués selon la méthode suivante :

$$\begin{cases} a_{0t} = \alpha \cdot (d_t / S_{t-p}) + (1 - \alpha)(a_{0t-1} + a_{1t-1}) \\ a_{1t} = \beta(a_{0t} - a_{0t-1}) + (1 - \beta)a_{1t-1} \\ S_t = \gamma \cdot (d_t / a_{0t}) + (1 - \gamma)S_{t-p} \end{cases}$$

α représente le coefficient de lissage de la moyenne ($\alpha \in [0; 1]$), β est le coefficient de lissage de la tendance ($\beta \in [0; 1]$) et γ le coefficient de lissage de la saisonnalité ($\gamma \in [0; 1]$).

Pour initialiser, $a_{0p} = d$, $a_{1p} = 0$ et $S_t = d_t/d$ où d représente la moyenne des p premières observations de la demande.

Les détails concernant la mise en œuvre du modèle de Winters sont exposés en profondeur par (Lai et al. 2006).

Il est important de noter que pour les trois exemples de lissages précédents, les paramètres α , β , γ sont spécifiés par l'utilisateur au début de la simulation. Ces paramètres sont ensuite ajustés en comparant ultérieurement les prévisions passées avec les valeurs réelles de la demande.

- **Modèle de Croston**

Pour les articles à rotation très lente, souvent appelés "slow moving items", l'historique des ventes est fréquemment caractérisé par des valeurs très faibles voire nulles pour certaines périodes, ce qui induit une demande erratique.

Dans de tels cas, l'application de modèles de lissage s'avère inappropriée. En effet, pour ces types de produits, la réception d'une commande suggère davantage l'absence de commande pour la période suivante. Dans des secteurs tels que l'industrie aéronautique, pour plus de 80% des pièces de rechange, la demande est inférieure à cinq unités par an, entraînant ainsi de nombreuses périodes avec une demande nulle (Ghobbar & Friend, 2003), (Regattieri et al., 2005).

Une méthode adaptée à ces produits est celle proposée par Croston en 1972, reposant sur deux paramètres clés : la fréquence des commandes (nombre de périodes séparant deux commandes) et la commande moyenne (nombre moyen d'articles commandés lorsqu'une commande est passée). Étant donné l'existence de nombreuses périodes caractérisées par une demande nulle, cette approche novatrice consiste à utiliser la formule du lissage exponentiel pour prédire séparément :

- Toutes les valeurs positives de l'historique, c'est-à-dire toutes les sorties de stock (non zero demand) d_t ;
- L'intervalle moyen entre chaque sortie (le nombre de périodes durant lesquelles aucune vente n'a eu lieu) i_t .

Étant donné la nature aléatoire et probabiliste de la demande, les valeurs sont représentées par une distribution normale avec une moyenne μ et un écart type σ : $N(\mu, \sigma^2)$. Les demandes non nulles se produisent selon un processus de Bernoulli avec une probabilité $1/p$.

Si la demande actuelle à la période t est nulle ($d_t = 0$), alors $P_t = P_{t-1}$ (où P_t est la prévision de demande pour la période t) et $i_t = i_{t-1}$ (où i_t est l'estimation de l'intervalle entre deux demandes non nulles successives, temps d'inter-arrivées). Les prévisions ne sont pas mises à jour en l'absence de demande à la période t . En revanche, si la demande actuelle à la période t est non nulle ($d_t \neq 0$), alors $P_t = P_{t-1} + \alpha (d_t - P_{t-1})$ et $i_t = i_{t-1} + \alpha(q - i_{t-1})$, où α est le coefficient de lissage et q une variable mesurant le temps écoulé depuis la dernière demande non nulle observée. Ainsi, la prévision de la demande pour chaque période au temps t est exprimée comme suit :

$$CR_t = P_t/i_t$$

Cette méthode a prouvé sa fiabilité et sa précision (Willemain et al. 1994) par rapport au lissage exponentiel et a été incorporée dans nombreux progiciels de prévision.

3. Méthodes Émergentes dans la Prévision de la Demande

L'évolution rapide du paysage commercial, marquée par des facteurs tels que la mondialisation, la technologie de l'information et l'expansion du commerce électronique, a conduit à une complexification des dynamiques de demande. Dans ce contexte, les entreprises se tournent de plus en plus vers des méthodes de prévision plus avancées, notamment celles basées sur l'Intelligence Artificielle (IA).

L'Intelligence Artificielle propose un éventail de techniques puissantes qui transcendent les limitations des modèles statistiques traditionnels. Ces modèles, fondés sur l'intelligence artificielle, présentent la remarquable capacité de détecter des relations qui peuvent être à la fois non linéaires et interactives. Dans le domaine de la prévision de la demande, l'usage de ces méthodes basées sur l'intelligence artificielle s'est avéré extrêmement bénéfique. Elles sont également employées en amont du processus, pour prétraiter les données et en extraire des informations pertinentes, facilitant ainsi la compréhension des liens entre des fonctions de grande complexité (Wang et al., 2018).

3.1. Intégration des Réseaux de Neurones et de l'Apprentissage Profond

Ces dix dernières années, les chercheurs ont fortement focalisé leur attention sur les réseaux de neurones artificiels, les considérant comme un outil informatique d'une grande puissance pour résoudre des problèmes complexes. Ces réseaux ont été spécifiquement conçus pour saisir des schémas non linéaires à partir de séries temporelles étendues (Fiot & Dinuzzo, 2016). Ils ont récemment été exploités avec succès dans divers domaines tels que la biomédecine, l'aérospatiale, l'industrie automobile, l'électronique, ainsi que dans le secteur financier, pour la prévision de la demande et des ventes (Raza et Khosravi, 2015).

Les réseaux de neurones artificiels sont des techniques de modélisation similaires au fonctionnement du cerveau humain. Le réseau de neurones artificiellement interconnectés explore plusieurs hypothèses concurrentes grâce à un traitement simultané (Qiu et coll., 2017). Dans le cerveau humain, il y a unités de traitement – neurones – qui agissent en parallèle pour traiter et collecter des données. Les neurones sont connectés à des poids synaptiques et il a été découvert que ces connexions ou « poids » sont capables de stocker un certain type d'informations qui peuvent être récupérées ultérieurement (Deb et coll., 2017).

Le réseau neuronal est constitué d'un ensemble de neurones interconnectés, chacun avec des coefficients de connectivité distincts qui déterminent la force des liaisons entre eux (Ren et al., 2016). L'apprentissage se produit par l'ajustement de ces coefficients afin de regrouper les neurones en couches. Il peut être de type monocouche ou multicouche, avec ce dernier présentant une ou plusieurs couches intermédiaires entre les couches d'entrée et de sortie, ce qui lui confère une meilleure capacité

d'apprentissage et des performances supérieures par rapport au réseau monocouche (Chae et al., 2016; Raza et Khosravi, 2015)

Dans le cadre mathématique du réseau neuronal, l'objectif principal est d'identifier les poids entraînant le modèle avec des ensembles de données historiques, généralement composés d'entrées et de sorties appariées (Deb et al., 2017). En utilisant le processus d'entraînement du réseau, celui-ci parvient à extraire les relations non linéaires entre les variables (Ke et al., 2017). Ainsi, le réseau est en mesure d'apprendre le comportement de la demande en fonction de différents paramètres grâce à la réorganisation des modèles. Cependant, il est important de noter que ces modèles de sortie sont acquis en appliquant les données d'entraînement initiales pour former le réseau (Aizenberg et al., 2016).

Les Long Short-Term Memory (LSTM) sont des outils clés du deep learning spécialement adaptés à l'analyse de séries temporelles. Ils sont largement employés pour prédire les évolutions financières ou pour traduire des langues. Fondamentalement, les LSTM étendent les réseaux neuronaux récurrents (RNN) en prolongeant la conservation et l'utilisation des informations sur différentes échelles temporelles. Contrairement aux RNN traditionnels avec des neurones, les LSTM comportent des blocs de mémoire connectés par des couches. Ces blocs intègrent trois portes non linéaires : une porte d'entrée qui sélectionne les informations à intégrer pour mettre à jour la mémoire, une porte d'oubli pour filtrer les données à exclure, et une porte de sortie pour déterminer la sortie en fonction des informations actuelles et de la mémoire. Les poids des différentes portes sont ajustés lors de l'apprentissage du modèle, réalisé via la rétropropagation. (Sezer, Gudelek et Ozbayoglu, 2020).

3.2. Pratiques modernes des Méthodes de Prévision Actuelles

Diverses solutions de prévision sont disponibles sur le marché, mais la plupart des entreprises se contentent d'utiliser des méthodes simples à une seule variable (Fildes et al., 2018 ; McCarthy et al., 2006). Les logiciels actuels, tels que SAP ou SAS, offrent une gamme étendue de solutions comprenant des méthodes simples à une seule variable, des méthodes multivariées et même des solutions avancées reposant sur l'apprentissage automatique. Dans un contexte de variables volatiles telles que les performances économiques passées, les conditions économiques mondiales, les changements environnementaux, sectoriels et organisationnels, les taux d'inflation, les efforts de marketing, la demande saisonnière, ainsi que les risques de pénurie de stocks, de demandes non satisfaites et de retard de produits (Krishna et al., 2019), il devient essentiel pour les dirigeants de développer des modèles de prévision solides et précis.

Depuis la fin des années 2000, de nombreuses entreprises comme Amazon, Netflix et Facebook ont déjà intégré des modèles quantitatifs avancés d'IA pour exploiter leurs données et générer une valeur tangible pour leurs activités (Harris, 2010). À l'ère du big data, les algorithmes de prévision de l'apprentissage automatique détectent automatiquement des schémas, incluant une multitude de facteurs dans les calculs, et établissent des liens dans d'énormes ensembles de données qui seraient impossibles, voire trop longs, à reconnaître pour les humains. Une approche de l'apprentissage automatique pour la prévision de la demande peut surperformer les modèles classiques de séries temporelles et linéaires pour les produits fonctionnels étudiés. Des études montrent qu'en moyenne, l'exactitude des prévisions de la demande s'améliore d'environ 6,4 % lorsqu'on utilise la technologie d'apprentissage automatique (Feizabadi & Shrivastava, 2018).

Exemple de Amazon forecast :

En 2018, Amazon a dévoilé Amazon Forecast, un service avancé d'apprentissage profond dédié à la prévision des séries temporelles. Cette solution d'apprentissage automatique exploite des données

historiques tout en étant capable de gérer efficacement de vastes ensembles de données présentant des tendances non régulières. Par exemple, elle rassemble des ensembles de données incluant les prix, les rabais et le trafic web, en y ajoutant des variables pertinentes telles que les caractéristiques des produits, les promotions et la localisation des magasins. L'outil examine automatiquement ces données, identifie les liens essentiels, et sélectionne l'algorithme le plus adapté à la prévision. En se basant sur les caractéristiques identifiées, Amazon Forecast entraîne le modèle et génère des prévisions personnalisées accessibles sur sa plateforme, via l'API Amazon Forecast pour une intégration dans des applications externes, ou disponibles en téléchargement au format CSV (Poccia, 2019 ; Schmidt, 2022).

Cas d'Étude Réels

Ren, Chan et Siqin (2019) proposent une étude de cas réelle sur la prévision de la demande pour les produits de mode dans le secteur de la vente au détail. Ils explorent différentes méthodologies et soulignent l'importance de l'adaptabilité des modèles aux tendances de l'industrie. Leur étude met en lumière l'impact significatif du big data sur la prévision des ventes dans l'industrie de la mode. Elle révèle une transformation majeure, où la prévision de la demande passe d'une approche basée sur la collecte de données externes à une nécessité de filtrer et d'exploiter efficacement le volume massif et changeant de données. De plus, le rôle des clients dans la définition des tendances de la mode évolue, passant d'une direction imposée par l'industrie à une influence ascendante de leurs besoins. Les méthodes de prévision traditionnelles montrent leurs limites, nécessitant une adaptation rapide à l'évolution du marché et une utilisation plus efficace des données générées par les utilisateurs pour une meilleure précision dans la prévision de la demande. En somme, l'étude souligne le besoin impératif pour l'industrie de la mode d'adopter des approches plus agiles, basées sur les avancées technologiques et l'exploitation intelligente du big data pour répondre aux attentes changeantes des consommateurs.

Bandara, Shi, Bergmeir, Hewamalage, Tran et Seaman (2019) ont évalué leur cadre de prévision en utilisant deux ensembles de données de ventes pour le commerce électronique provenant de Walmart.com. Les chercheurs ont comparé les performances de différents modèles de prévision, y compris des techniques basées sur les réseaux LSTM, pour prédire les ventes de divers produits dans des catégories spécifiques et des sous-groupes. Les résultats ont montré que les modèles LSTM, en particulier ceux utilisant des stratégies de regroupement de produits, ont présenté des prévisions compétitives, même pour des articles avec des ventes saisonnières limitées. Globalement, cette étude a démontré que les modèles LSTM sont efficaces pour prédire la demande dans le commerce en ligne, soulignant l'importance des stratégies de regroupement de produits pour améliorer la précision des prévisions.

Alzubaidi (2020) explore dans son étude les méthodes de prévision de la demande dans l'industrie des biens de consommation courante (FMCG) en comparant les performances des modèles de séries temporelles statistiques et d'apprentissage automatique. En utilisant des données de transactions de trois ans provenant d'une entreprise FMCG, l'étude vise à prédire la demande des produits finis sur trois mois dans les marchés du Golfe. Les méthodes statistiques telles que SARIMA et ETS ont montré une meilleure précision que les techniques d'apprentissage automatique comme le KNN, bien que le modèle LSTM se soit rapproché de SARIMA en termes de précision. La conclusion suggère l'utilisation de SARIMA pour les prévisions à court terme et de LSTM pour les prévisions à plus long terme.

Ubaid, Hussain et Saqib (2021) examine dans leur étude la prévision de la demande de livraisons de conteneurs dans l'industrie maritime australienne. Trois modèles de prévision, SARIMA, Holt-Winters et Prophet de Facebook, ont été comparés pour prédire la demande à court et long terme. Les résultats

ont montré que Prophet surpassait les autres modèles en offrant des prévisions plus précises, avec une flexibilité pour intégrer des jours fériés personnalisés. L'analyse des données a révélé des tendances de demande hebdomadaires et mensuelles. Les modèles ont été évalués en utilisant des mesures telles que l'erreur MAPE et RMSE, montrant la supériorité de Prophet. Cette étude souligne le besoin d'une meilleure visibilité dans la chaîne d'approvisionnement du transport maritime et suggère des pistes pour des recherches futures, telles que l'expansion des prévisions à d'autres routes commerciales et l'utilisation de modèles plus complexes.

Chong, Ch'ng, Liu et Li (2015) explore dans leur étude l'influence des promotions marketing en ligne et des avis en ligne sur la prédiction de la demande des consommateurs pour des produits électroniques. À partir des données électroniques d'Amazon.com, les chercheurs ont examiné comment des variables telles que le volume et la tonalité des avis en ligne, ainsi que les stratégies de promotion comme les réductions, peuvent influencer la demande de produits électroniques sur cette plateforme. En utilisant une architecture Big Data et des réseaux neuronaux, ils ont constaté que les variables des avis en ligne, comme les avis positifs et négatifs, étaient des prédicteurs importants, tout comme le volume de questions répondues. Ces résultats suggèrent que les avis en ligne ont un impact significatif sur les ventes, avec une interconnexion entre le volume d'avis et les réductions. Les réductions associées à des volumes élevés d'avis semblent augmenter les ventes de produits électroniques. Cette étude offre des perspectives sur l'utilisation des Big Data pour prédire la demande des produits en ligne, soulignant l'importance des avis en ligne dans les décisions d'achat des consommateurs.

L'étude menée par Torres, Hadjout, Sebaa, Martínez-Álvarez et Troncoso (2020) examine l'utilisation des techniques de deep learning pour la prédiction des séries temporelles, en mettant en lumière leur efficacité dans la résolution de problèmes complexes associés aux vastes ensembles de données. Elle présente en détail les architectures les plus couramment employées dans ce domaine, telles que les réseaux neuronaux récurrents (Elman, mémoire à court et long terme, unités récurrentes contrôlées) et les réseaux neuronaux convolutifs. L'accent est mis sur des aspects pratiques tels que la sélection des hyperparamètres et le choix des Framework pour l'application réussie du deep learning aux séries temporelles. En outre, cette étude explore les performances de ces architectures dans divers domaines d'application, identifiant les lacunes de recherche et offrant ainsi des orientations pour de futures études visant à explorer des architectures moins testées dans certains domaines spécifiques.

4. Conclusion

La prévision de la demande demeure un pilier essentiel pour assurer une gestion optimale des ressources et des niveaux de stock adéquats dans toute industrie. Cet article a exploré en profondeur les méthodes traditionnelles et émergentes de prévision de la demande, mettant en lumière l'évolution constante de ce domaine crucial.

Les méthodes classiques, qu'elles soient qualitatives ou quantitatives, ont longtemps été utilisées pour anticiper la demande, reposant sur des techniques statistiques telles que les séries chronologiques, le lissage exponentiel et les méthodes causales. Celles-ci ont apporté des prévisions relativement fiables dans des contextes stables, mais leur efficacité peut être limitée face à des environnements changeants et complexes.

L'avènement de l'intelligence artificielle (IA) a ouvert de nouvelles perspectives dans la prévision de la demande. Les méthodes basées sur l'IA, notamment les réseaux de neurones et l'apprentissage profond, ont révolutionné ce domaine en offrant la capacité de détecter des relations non linéaires, d'explorer des schémas complexes, et d'améliorer la précision des prévisions. Ces avancées sont particulièrement

remarquables dans des secteurs tels que le commerce électronique, l'industrie des biens de consommation courante, et même l'industrie maritime.

Les études de cas présentées dans cet article fournissent des exemples concrets de l'efficacité de ces approches avancées. Qu'il s'agisse de prédire la demande pour des produits de mode, des articles en ligne, ou même des livraisons de conteneurs, les modèles basés sur l'IA ont montré une précision accrue par rapport aux méthodes traditionnelles.

En somme, cet article offre une perspective holistique sur l'évolution des méthodes de prévision de la demande, soulignant le passage d'approches statistiques classiques à des méthodes plus sophistiquées basées sur l'IA. Ces avancées représentent un potentiel significatif pour les entreprises, leur offrant des outils puissants pour anticiper les tendances du marché, optimiser la gestion des stocks, et répondre de manière proactive aux exigences changeantes des consommateurs. À mesure que ces méthodes continuent de se développer, elles promettent de redéfinir la manière dont nous appréhendons et gérons la demande, offrant ainsi un avantage concurrentiel crucial dans un paysage commercial en constante évolution.

REFERENCES

- [1] Aichner, T., & Santa, V. (2023). Demand Forecasting Methods and the Potential of Machine Learning in the FMCG Retail Industry. In *Serving the Customer: The Role of Selling and Sales* pp. 215-252. Wiesbaden: Springer Fachmedien Wiesbaden.
- [2] Aizenberg, I., Sheremetov, L., Villa-Vargas, L. and Martinez-Muñoz, J., (2016). Multilayer neural network with multi-valued neurons in time series forecasting of oil production. *Neurocomputing*, 175, pp.980-989.
- [3] Alzubaidi, Z.Y., (2020). A Comparative Study on Statistical and Machine Learning Forecasting Methods for an FMCG Company.
- [4] Armstrong, J.S. and Green, K.C., (2005). Demand forecasting: evidence-based methods (No. 24/05). Monash University, Department of Econometrics and Business Statistics.
- [5] Arvan, M., Fahimnia, B., Reisi, M. and Siemsen, E., (2019). Integrating human judgement into quantitative forecasting methods: A review. *Omega*, 86, pp.237-252. <https://doi.org/10.1016/j.omega.2018.07.012>
- [6] Bandara, K., Shi, P., Bergmeir, C., Hewamalage, H., Tran, Q., & Seaman, B. (2019). Sales demand forecast in E-commerce using a long short-term memory neural network methodology. <https://arxiv.org/pdf/1901.04028.pdf>.
- [7] Bermúdez, J.D., Segura, J.V. and Vercher, E., (2006). A decision support system methodology for forecasting of time series based on soft computing. *Computational statistics & data analysis*, 51(1), pp.177-191.
- [8] Boroojeni, K.G., Amini, M.H., Bahrami, S., Iyengar, S.S., Sarwat, A.I. and Karabasoglu, O., (2017). A novel multi-time-scale modeling for electric power demand forecasting: From short-term to medium-term horizon. *Electric Power Systems Research*, 142, pp.58-73.
- [9] Chae, Y.T., Horesh, R., Hwang, Y. and Lee, Y.M., (2016). Artificial neural network model for forecasting sub-hourly electricity usage in commercial buildings. *Energy and Buildings*, 111, pp.184-194.
- [10] Chong, A. Y. L., Ch'ng, E., Liu, M. J., & Li, B. (2015). Predicting consumer product demands via Big Data: the roles of online promotional marketing and online reviews. *International Journal of Production Research*, 55(17), 5142–5156.
- [11] Croston, J.D., (1972). Forecasting and stock control for intermittent demands. *Journal of the Operational Research Society*, 23(3), pp.289-303.
- [12] Deb, C., Zhang, F., Yang, J., Lee, S.E. and Shah, K.W., (2017). A review on time series forecasting techniques for building energy consumption. *Renewable and Sustainable Energy Reviews*, 74, pp.902-924.
- [13] Fang, T. and Lahdelma, R., (2016). Evaluation of a multiple linear regression model and SARIMA model in forecasting heat demand for district heating system. *Applied energy*, 179, pp.544-552.
- [14] Feizabadi, J. and Shrivastava, A., (2018). Does AI-enabled demand forecasting improve supply chain efficiency. *Supply Chain Manag. Rev.*, 22, pp.8-10. https://www.scmr.com/article/does_artificial_intelligence_ai_enabled_demand_forecasting_improve_supply_c

- [15] Fildes, R., Ma, S. and Kolassa, S., (2022). Retail forecasting: Research and practice. *International Journal of Forecasting*, 38(4), pp.1283-1318.
- [16] Fiot, J.B. and Dinuzzo, F., (2016). Electricity demand forecasting by multi-task learning. *IEEE Transactions on Smart Grid*, 9(2), pp.544-551.
- [17] Fortsch, S.M. and Khapalova, E.A., (2016). Reducing uncertainty in demand for blood. *Operations Research for Health Care*, 9, pp.16-28.
- [18] Ghobbar, A.A. and Friend, C.H., (2003). Evaluation of forecasting methods for intermittent parts demand in the field of aviation: a predictive model. *Computers & operations research*, 30(14), pp.2097-2114.
- [19] Harris, J.G., (2010). How to turn data into a strategic asset. *Outlook Journal*, Accenture.
- [20] Jun, S.P., Sung, T.E. and Park, H.W., (2017). Forecasting by analogy using the web search traffic. *Technological Forecasting and Social Change*, 115, pp.37-51.
- [21] Katsikopoulos, K. V., Durbach, I. N., & Stewart, T. J. (2017). When should we use simple decision models? A synthesis of various research strands. *Omega*. doi:10.1016/j.omega.2017.09.005
- [22] Ke, J., Zheng, H., Yang, H. and Chen, X.M., (2017). Short-term forecasting of passenger demand under on-demand ride services: A spatio-temporal deep learning approach. *Transportation research part C: Emerging technologies*, 85, pp.591-608.
- [23] Krishna, A., V. A., Aich, A., & Hegde, C. (2018). Sales-forecasting of Retail Stores using Machine Learning Techniques. 2018 3rd International Conference on Computational Systems and Information Technology for Sustainable Solutions (CSITSS). doi:10.1109/csitss.2018.8768765
- [24] Kudłak, R., Szócs, I., Krumay, B., & Martinuzzi, A., (2018). The future of CSR - Selected findings from a Europe-wide Delphi study. *Journal of Cleaner Production*, 183, pp.282–291.
- [25] Lai, F., Zhao, X. and Lee, T.S., (2006). Selecting forecasting model parameters in Material Requirement Planning systems. *International Journal of Internet and Enterprise Management*, 4(4), pp.331-354.
- [26] Ma, S., Fildes, R., & Huang, T. (2016). Demand forecasting with high dimensional data: The case of SKU retail sales forecasting with intra- and inter-category promotional information. *European Journal of Operational Research*, 249(1), 245–257.
- [27] McCarthy, T.M., Davis, D.F., Golicic, S.L. and Mentzer, J.T., (2006). The evolution of sales forecasting management: A 20-year longitudinal study of forecasting practices. *Journal of Forecasting*, 25(5), pp.303-324.
- [28] Nikolopoulos, K., Litsa, A., Petropoulos, F., Bougioukos, V. and Khammash, M., (2015). Relative performance of methods for forecasting special events. *Journal of Business Research*, 68(8), pp.1785-1791.
- [29] Petropoulos, F., Kourentzes, N., Nikolopoulos, K., & Siemsen, E. (2018). Judgmental selection of forecasting models. *Journal of Operations Management*, 60, pp.34–46. <https://doi.org/10.1016/j.jom.2018.05.005>
- [30] Poccia, D. (2019). Amazon forecast—Time series forecasting made easy|AWS News Blog. <https://aws.amazon.com/fr/blogs/aws/amazon-forecast-time-series-forecasting-made-easy/>
- [31] Qiu, X., Ren, Y., Suganthan, P.N. and Amaratunga, G.A., (2017). Empirical mode decomposition based ensemble deep learning for load demand time series forecasting. *Applied soft computing*, 54, pp.246-255.
- [32] Raza, M.Q. and Khosravi, A., (2015). A review on artificial intelligence based load demand forecasting techniques for smart grid and buildings. *Renewable and Sustainable Energy Reviews*, 50, pp.1352-1372.
- [33] Regattieri, A., Gamberi, M., Gamberini, R. and Manzini, R., (2005). Managing lumpy demand for aircraft spare parts. *Journal of Air Transport Management*, 11(6), pp.426-431.
- [34] Ren, S., Chan, H.-L., & Siqin, T. (2019). Demand forecasting in retail operations for fashionable products: Methods, practices, and real case study. *Annals of Operations Research*.
- [35] Ren, Y., Suganthan, P.N., Srikanth, N. and Amaratunga, G., (2016). Random vector functional link network for short-term electricity load demand forecasting. *Information Sciences*, 367, pp.1078-1093.
- [36] Schmidt, D. (2022). Getting Started with the Industrial Data Platform on AWS. <https://aws.amazon.com/fr/blogs/industries/getting-started-with-the-industrial-data-platform-on-aws/>
- [37] Schaer, O., Kourentzes, N., & Fildes, R. (2019). Demand forecasting with user-generated online information. *International Journal of Forecasting*, 35(1), 197–212.

- [38] Seifert, M., Siemsen, E., Hadida, A.L. and Eisingerich, A.B., (2015). Effective judgmental forecasting in the context of fashion products. *Journal of Operations Management*, 36, pp.33-45.
- [39] Sezer, O.B., Gudelek, M.U. and Ozbayoglu, A.M., (2020). Financial time series forecasting with deep learning: A systematic literature review: 2005–2019. *Applied soft computing*, 90, p.106181.
- [40] Shashi, M. (2022). Artificial Intelligence Digital Enablers in Facilitating Demand Forecasting of Biopharmaceutical Supply Chains.
- [41] Torres, J. F., Hadjout, D., Sebaa, A., Martínez-Álvarez, F., and Troncoso, A. (2020). Deep Learning for Time Series Forecasting: A Survey. *Big Data*.
- [42] Tyagi, R., (2002). How to evaluate a demand planning & forecasting package. *SUPPLY CHAIN MANAGEMENT REVIEW*, V. 6, NO. 5 (SEPT./OCT. 2002), P. 48-56: ILL.
- [43] Ubaid, A., Hussain, F., & Saqib, M. (2021). Container shipment demand forecasting in the Australian shipping industry: A case study of Asia-oceania trade lane. *Journal of Marine Science and Engineering*, 9(9), 968.
- [44] Villani, M., Earnest, A., Nanayakkara, N., Smith, K., De Courten, B. and Zoungas, S., (2017). Time series modelling to forecast prehospital EMS demand for diabetic emergencies. *BMC health services research*, 17, pp.1-9.
- [45] Von Briel, F., (2018). The future of omnichannel retail: A four-stage Delphi study. *Technological Forecasting and Social Change*, 132, pp.217-229.
- [46] Wang, Q., Li, S. and Li, R., (2018). Forecasting energy demand in China and India: Using single-linear, hybrid-linear, and non-linear time series forecast techniques. *Energy*, 161, pp.821-831.
- [47] Willemain, T.R., Smart, C.N., Shockor, J.H. and DeSautels, P.A., (1994). Forecasting intermittent demand in manufacturing: a comparative evaluation of Croston's method. *International Journal of forecasting*, 10(4), pp.529-538.
- [48] Zhang, G. (1998). Forecasting with Artificial Neural Networks: The State of the Art. *International Journal of Forecasting*.
- [49] Zhu, T., Luo, L., Zhang, X., Shi, Y. and Shen, W., (2015). Time-series approaches for forecasting the number of hospital daily discharged inpatients. *IEEE journal of biomedical and health informatics*, 21(2), pp.515-526.