

Prédiction des performances dans la chaîne d'approvisionnement basée sur le modèle SCOR[®] et les réseaux de neurones multicouches

Mariem Mrad

mariemmradin@gmail.com

Younes BOUJELBENE

younes.boujelbene@gmail.com

Laboratory of Economics and Management
Faculty of Economics Sciences and Management of Sfax University of Sfax, Tunisia

Résumé

L'évaluation des performances de la chaîne d'approvisionnement est une activité primordiale pour l'amélioration stratégique des opérations. La littérature présente plusieurs systèmes d'évaluation des performances basés sur des méthodes multicritères et des techniques d'intelligence artificielle. Parmi ceux-ci, les systèmes basés sur les réseaux de neurones qui se distinguent par leur capacité de modélisation des relations non linéaires et d'adaptation à l'environnement d'utilisation grâce à des données historiques sur les performances. Dans ce contexte, la présente étude évalue quatre méthodes d'apprentissage par réseau de neurones afin de déterminer laquelle d'entre elles est la plus appropriée pour soutenir l'évaluation de la chaîne d'approvisionnement. Les algorithmes qui ont été testés *Gradient Descent Momentum*, *Levenberg-Marquardt*, *Quasi-Newton* et *Scale Conjugate Gradient*. Les mesures de performance ont été extraites du modèle SCOR[®], un modèle de référence utilisé dans le monde entier. La méthode de validation croisée avec échantillonnage aléatoire a été adoptée pour trouver la configuration topologique la plus appropriée pour chaque modèle. Un ensemble de 80 topologies a été mis en œuvre à l'aide de MATLAB.

Mots clés : Réseaux de neurones artificiels, Méthodes d'apprentissage supervisées, Évaluation des performances de la chaîne d'approvisionnement, Modèle SCOR[®], *Perceptron multicouche*.

1. Introduction

La prédiction des performances dans la chaîne d'approvisionnement en se concentrant sur l'importance croissante de l'optimisation des opérations dans un environnement concurrentiel. Elle met en lumière la pertinence de cette recherche dans le contexte actuel de la mondialisation des marchés et de la complexité croissante des réseaux logistiques. Dans un monde de plus en plus connecté et numérique, il est impératif pour les entreprises de trouver des moyens innovants d'optimiser la gestion de leurs opérations pour rester compétitives. L'analyse des performances dans la chaîne d'approvisionnement joue un rôle vital dans cette démarche, car elle permet aux entreprises d'identifier les goulots d'étranglement et les inefficacités potentielles, et de prendre les mesures appropriées pour les résoudre. En outre, la prédiction des performances offre aux entreprises la possibilité de planifier leurs opérations à l'avance, de prévoir les fluctuations de la demande et d'optimiser leurs ressources en conséquence. Cela peut être particulièrement bénéfique dans un environnement concurrentiel où chaque avantage concurrentiel compte ([Bouaddaoui, 2023](#)).

Dans cette optique, cette recherche se concentre sur l'utilisation de méthodes d'analyse avancées, telles que l'apprentissage automatique et l'intelligence artificielle, pour améliorer la précision des prévisions de performance dans la chaîne d'approvisionnement. Ces méthodes permettent aux entreprises d'exploiter pleinement les données disponibles, qu'il s'agisse de données internes sur les opérations passées ou de données externes sur les tendances économiques et les comportements des consommateurs. En combinant ces données avec des modèles prédictifs sophistiqués, il est possible d'obtenir des prévisions plus précises et de soutenir une prise de décision plus éclairée ([Hrouga & Said, 2024](#)).

En résumé, cette recherche constitue une contribution importante à la compréhension et à l'amélioration des performances dans la chaîne d'approvisionnement. En utilisant des méthodes d'analyse avancées, elle cherche à aider les entreprises à relever les défis complexes présentés par les marchés mondiaux et les réseaux logistiques en constante évolution. En fournissant des prévisions de performance plus précises et en facilitant une prise de décision plus efficace, cette recherche peut aider les entreprises à optimiser leurs opérations et à rester compétitives dans un environnement concurrentiel. De plus, il est essentiel pour les organisations d'adopter une approche proactive de la gestion de la chaîne d'approvisionnement en utilisant des stratégies et des technologies innovantes. Ce faisant, ils peuvent acquérir un avantage concurrentiel et

garantir le bon fonctionnement de leurs opérations. Avec la mondialisation croissante des marchés et la complexité grandissante des réseaux logistiques, les entreprises doivent s'appuyer sur des méthodes analytiques avancées pour prédire avec précision la performance au sein de la chaîne d'approvisionnement. L'apprentissage automatique et l'intelligence artificielle ont émergé comme des outils puissants à cet égard, permettant aux entreprises de tirer parti de vastes quantités de données et de générer des prévisions précises. Ces techniques sophistiquées permettent aux organisations d'identifier les goulets d'étranglement et les inefficacités potentiels, leur permettant ainsi de prendre des mesures appropriées pour résoudre ces problèmes rapidement. De plus, l'analyse prédictive de la performance aide les entreprises à planifier efficacement leurs opérations, à anticiper les fluctuations de la demande et à optimiser l'allocation des ressources en conséquence. Cela devient particulièrement crucial dans des environnements hautement compétitifs, où même de légers avantages peuvent faire une différence significative (Ghoubach et al., 2024). En appliquant des approches analytiques avancées, cette recherche vise à soutenir les entreprises dans la navigation des défis posés par les marchés mondiaux et les réseaux logistiques en constante évolution. En fournissant des prévisions de performance plus précises et en facilitant la prise de décisions éclairées, cette étude peut permettre aux entreprises d'optimiser leurs opérations et de maintenir leur compétitivité dans un paysage commercial dynamique.

Par conséquent, la mise en œuvre réussie de l'analyse prédictive de la performance représente une contribution précieuse à la compréhension et à l'amélioration de la performance de la chaîne d'approvisionnement. Cela permet aux organisations de disposer des outils nécessaires pour s'adapter aux conditions changeantes du marché, rationaliser leurs opérations et atteindre une croissance durable. En exploitant la puissance des méthodes analytiques avancées telles que l'apprentissage automatique et l'intelligence artificielle, les entreprises peuvent obtenir des informations précieuses, débloquer des avantages concurrentiels et favoriser l'excellence opérationnelle. Grâce à une recherche et un développement continu dans ce domaine, les entreprises peuvent affiner davantage leur précision de prévision, améliorer leurs processus de prise de décision et, en fin de compte, se positionner comme des leaders de l'industrie dans le domaine de la gestion de la chaîne d'approvisionnement.

1.1. Contexte et justification de la recherche

La section sur le contexte et la justification de la recherche expose en détail les nombreux défis

rencontrés dans la gestion des chaînes d'approvisionnement à l'heure actuelle. Cette analyse approfondie met en lumière le besoin croissant pour des outils de prédiction afin d'améliorer l'efficacité opérationnelle. Elle souligne également l'importance vitale de combiner le modèle Supply Chain Operations Reference (SCOR®) avec les puissantes capacités des réseaux de neurones, ce qui permettrait de fournir des prévisions plus précises et plus complètes que jamais auparavant. De telles avancées auraient un potentiel significatif pour améliorer considérablement la prise de décision au sein de la chaîne d'approvisionnement et les performances globales de celle-ci. En adoptant cette approche innovante, les entreprises pourraient se positionner de manière stratégique en optimisant leurs processus et en réussissant à relever les défis de manière plus efficace et efficiente (Fanchette, 2023).

Cette section détaillée fournit une base solide pour comprendre l'importance cruciale de ce projet de recherche et les bénéfices attendus de son application pratique dans le domaine de la gestion des chaînes d'approvisionnement. Les connaissances et les compétences nécessaires pour gérer avec succès une chaîne d'approvisionnement sont de plus en plus complexes et nécessitent une expertise approfondie. Les entreprises doivent faire face à une variété de facteurs externes tels que les fluctuations de la demande, les ruptures de stock, les retards de livraison et les problèmes de qualité des produits, ce qui rend la gestion de la chaîne d'approvisionnement un défi constant. Il est essentiel de prendre des décisions éclairées et efficaces pour maintenir une chaîne d'approvisionnement fluide et rentable. Cependant, cela peut souvent être un défi de taille étant donné la complexité de ces systèmes et la quantité de données qui doit être analysée. C'est là que l'utilisation de modèles prédictifs et de réseaux de neurones devient essentielle. En exploitant les données historiques et en les combinant avec des paramètres actuels, les outils de prédiction peuvent fournir des estimations précises sur la demande future, les stocks nécessaires et les délais de livraison. Cela permet aux entreprises de mieux planifier leurs opérations, d'optimiser les stocks et de minimiser les perturbations potentielles (Houad, 2022).

La combinaison du modèle SCOR® avec les réseaux de neurones offre une perspective encore plus puissante en matière de prévision et d'optimisation de la chaîne d'approvisionnement. Le modèle SCOR® offre une structure et des métriques standardisées pour évaluer et améliorer les performances de la chaîne d'approvisionnement. En l'intégrant avec les puissantes capacités de prévision des réseaux de neurones, les entreprises peuvent obtenir des informations précieuses sur les tendances du marché, les cycles saisonniers, les comportements des consommateurs et

bien plus encore. Cela permet une meilleure compréhension des schémas de demande et facilite la prise de décision éclairée. Les résultats de cette recherche ont le potentiel de transformer radicalement la gestion des chaînes

d'approvisionnement. En fournissant des prévisions plus précises et plus complètes, les entreprises seront en mesure de réduire les coûts, d'améliorer la satisfaction des clients et d'optimiser leurs opérations globales. La combinaison du modèle SCOR® et des réseaux de neurones offre une approche innovante et puissante pour relever les défis complexes de la gestion des chaînes d'approvisionnement.

D'où, ce projet de recherche apporte une contribution précieuse à la compréhension de l'importance des outils de prédiction et de la combinaison du modèle SCOR® avec les réseaux de neurones dans la gestion des chaînes d'approvisionnement. Les entreprises qui adoptent cette approche innovante seront mieux préparées pour faire face aux défis futurs, améliorer leur efficacité opérationnelle et obtenir un avantage concurrentiel sur le marché. Il est clair que les avantages potentiels rendent ce projet de recherche d'une importance cruciale pour le domaine de la gestion des chaînes d'approvisionnement.

Une meilleure compréhension de la façon dont les outils de prédiction peuvent être utilisés en conjonction avec le modèle SCOR® est essentielle pour relever les défis complexes de la gestion des chaînes d'approvisionnement et atteindre de nouveaux niveaux de performance. En fin de compte, l'adoption de cette approche innovante et l'application pratique des principes de prédiction et de modélisation peuvent ouvrir de nouvelles voies pour l'amélioration de l'efficacité et de l'efficience des chaînes d'approvisionnement.

2. Revue de la littérature

[Mentzer et al. \(2001\)](#) définissent la gestion d'une chaîne d'approvisionnement comme la « coordination stratégique et systémique des fonctions commerciales traditionnelles et des actions tactiques au sein d'une entreprise et à travers ses activités tout au long de la chaîne », dans le but d'améliorer les performances à long terme des entreprises et de la chaîne au niveau mondial. La gestion de la chaîne d'approvisionnement implique la gestion stratégique des flux financiers, des services, des biens, des informations et des relations entre entreprises. Dans cet environnement, la gestion collaborative tend à générer une condition de synergie, dans laquelle la chaîne entière devient plus efficace que l'assemblage de ses parties individuelles ([Mentzer et al. 2001](#) ; [Shafiee et al. 2014](#)).

Diverses études ont souligné la pertinence de la mesure (ou de l'évaluation) des performances de la chaîne d'approvisionnement comme un moyen de développement des stratégies de planification et de gestion (Marchand & Raymond, 2008 ; Estampe et al., 2013). L'évaluation des performances de la chaîne d'approvisionnement implique divers acteurs qui coopèrent pour atteindre certains objectifs. Elle nécessite donc l'adoption d'indicateurs liés aux processus intra et interorganisationnels, ainsi que des données actualisées, intégrées et facilement accessibles pour une prise de décision rationnelle (Nudurupati & Bititci, 2005). Parmi les avantages de l'évaluation des performances de la chaîne d'approvisionnement, citons le suivi efficace des résultats, une meilleure compréhension des processus, l'identification des problèmes potentiels et la création d'une perception des actions futures possibles (Ahi & Searcy, 2015). Toutefois, plusieurs facteurs rendent l'évaluation de la chaîne d'approvisionnement une tâche difficile. Pour surmonter cette difficulté, il faut analyser plusieurs acteurs dans le cadre d'un processus transversal. Il existe également des obstacles tels que la décentralisation des données historiques, le fait que plusieurs mesures sont déconnectées (Naini et al., 2011).

La littérature sur la gestion de la chaîne d'approvisionnement présente des études qui proposent des modèles pour soutenir l'évaluation des performances en utilisant des approches qualitatives (Gunasekaran et al., 2001) et quantitatives (Akkawuttiwanich & Yenradee, 2018). Il existe également des études qui présentent des examens systématiques des approches existantes (Maestrini et al., 2017), des discussions sur les indicateurs utilisés dans le processus d'évaluation (Ahi & Searcy, 2015) et des analyses de certains modèles existants (Estampe et al., 2013). Les modèles quantitatifs ont fait l'objet d'une attention croissante au cours de la dernière décennie. Des dizaines de techniques ont été testées, notamment les méthodes de prise de décision multicritères, la programmation mathématique et l'intelligence artificielle (IA). Bien que le développement de modèles basés sur les techniques d'IA soit en train d'émerger et moins fréquent dans la littérature, ces techniques se distinguent par l'ajout de nouvelles capacités aux modèles d'évaluation des performances.

Parmi ces modèles, deux approches basées sur les réseaux de neurones artificiels se distinguent les méthodes de prise de décision multicritères permettant la modélisation des relations non linéaires entre les mesures d'entrée et de sortie. En outre, ils sont capables de s'adapter à l'environnement d'utilisation en fonction des données historiques de performance grâce à l'application d'algorithmes d'apprentissage supervisé. Fan et al. (2013) ont proposé un

système d'évaluation des performances de la chaîne d'approvisionnement basé sur la combinaison de certaines mesures du tableau de bord équilibré avec des réseaux neuronaux perceptron multicouches. Lima Jr. & Carpinetti (2019) ont appliqué des réseaux de neurones pour prédire les valeurs des mesures de niveau 1 de SCOR[®] (Supply Chain Operations Reference), un modèle de référence de gestion de la chaîne d'approvisionnement largement adopté dans la pratique. Alors que Fan et al. (2013) ont adopté un algorithme d'apprentissage supervisé appelé *Levenberg-Marquardt*, Lima Jr. & Carpinetti (2019) ont utilisé l'algorithme de *backpropagation*

Le développement d'outils basés sur des réseaux de neurones artificiels implique le choix d'une configuration topologique et d'un algorithme d'apprentissage appropriés, ce qui nécessite une série de tests empiriques qui peut rendre le processus long et coûteux (Tkáč & Verner, 2016). Comme l'algorithme d'apprentissage influence directement la précision des résultats et le temps consacré à la formation des réseaux de neurones (Mukherjee & Routroy, 2012), des études comparatives entre ces algorithmes sont nécessaires pour identifier ceux qui donnent les meilleurs résultats dans certains types d'applications. En outre, ils aident également les chercheurs et les analystes à créer des solutions intelligentes dans le domaine de la gestion de la chaîne d'approvisionnement afin de guider le processus de développement et de le rendre plus agile. Cependant, en se basant sur des recherches dans les principales bases de données et sur l'analyse des études de revue de la littérature sur le sujet (Maestrini et al., 2017 ; Lima Jr. & Carpinetti, 2017), aucune étude comparative n'a été trouvée entre les algorithmes d'apprentissage lorsqu'ils sont appliqués à l'évaluation des performances de la chaîne d'approvisionnement.

Dans ce contexte, la présente étude évalue quatre méthodes d'apprentissage supervisé des réseaux neuronaux artificiels, avec l'objectif d'étudier laquelle d'entre elles est la plus appropriée pour soutenir l'évaluation des performances de la chaîne d'approvisionnement. Parce qu'ils ont des relations causales bien définies, un ensemble d'indicateurs de performance proposés par SCOR[®] a été adopté pour composer les variables d'entrée et de sortie des modèles de calcul. Il est important de souligner que cette étude poursuit le travail développé par Lima Junior & Carpinetti (2019), afin de tester d'autres méthodes d'apprentissage pour atteindre une plus grande précision de prédiction. En ce qui concerne l'organisation de l'article, la section 2 se concentre sur les détails du SCOR[®]. La section 3 explique le fonctionnement des réseaux

neuronaux artificiels. La section 4 présente les procédures méthodologiques. La section 5 traite des résultats de la mise en œuvre informatique, tandis que la section 6 présente les résultats des tests d'hypothèses effectués. Enfin, la section 7 présente la conclusion et les suggestions pour les études futures.

3. Le modèle SCOR®

Le modèle SCOR® (Supply Chain Operations Reference) a été conçu par le Supply Chain Council, une organisation indépendante à but non lucratif. Il est pionnier en tant que cadre interentreprises pour analyser, évaluer et optimiser les processus de gestion de la chaîne d'approvisionnement (SSC, 2012). Akkawuttiwanich & Yenradee (2018) soulignent que ce modèle de référence est largement répandu et utilisé dans la pratique. Le modèle SCOR® est divisé en quatre sections principales. La section « Performance » présente des mesures standardisées pour décrire les performances des processus et définir les objectifs stratégiques. La section « Processus » définit une structure des processus de gestion et décrit les relations entre eux. La section « Pratiques » suggère des pratiques de gestion des processus qui se traduisent par des niveaux de performance nettement meilleurs. La section « Personnel » définit les compétences requises pour exécuter les processus de la chaîne d'approvisionnement (SCC, 2012).

Les processus de gestion proposés par SCOR®, appelés plan (planification), source (approvisionnement), make (livraison), deliver (livraison), return (gestion des retours), font partie intégrante des différents maillons d'une chaîne de production. Chaque processus est associé à des mesures de performance, qui permettent de les contrôler et de les optimiser en comparant les résultats obtenus avec les objectifs définis pour chaque mesure (Akkawuttiwanich & Yenradee, 2018). L'évaluation des performances par le modèle SCOR® présente deux modalités d'éléments d'évaluation, appelés attribut et items. Un attribut est défini comme un groupe de mesures pour exprimer une stratégie, tandis que la mesure (ou l'indicateur) est une norme pour mesurer la performance d'une chaîne d'approvisionnement ou d'un processus. SCOR® propose cinq attributs de performance : fiabilité, réactivité, coûts, agilité et actifs. L'attribut de fiabilité fait référence à la capacité d'exécuter les tâches comme prévu. La réactivité décrit la rapidité avec laquelle les tâches sont exécutées. L'agilité consiste en la capacité à répondre à des stimuli externes et à changer grâce à eux. Les coûts font référence aux coûts d'exploitation des processus de la chaîne d'approvisionnement, tandis que l'actif est la

capacité à utiliser efficacement les actifs (SCC, 2012, Dissanayake & Cross, 2018).

La figure 1 illustre les attributs suggérés par SCOR[®] et les items de niveau 1 et 2 associées à chaque attribut. On a choisi de ne pas traduire la nomenclature de ces items (en anglais) pour éviter toute déviation de leur sens. Les mesures du différent niveau hiérarchique différentes ont des relations de cause à effet quantifiables, ce qui permet de prévoir les valeurs d'items d'un niveau supérieur sur la base des valeurs d'items du niveau inférieur suivant.

Ainsi, tout comme les mesures de niveau 3 peuvent être utilisées pour prévoir les valeurs des mesures de niveau 2, les mesures de niveau 2 peuvent également être appliquées pour estimer les niveaux de performance des mesures de niveau 1. Cette caractéristique contribue à ce que les mesures SCOR[®] soient fréquemment adoptées dans les modèles quantitatifs pour soutenir l'évaluation des performances. Comme, en pratique, l'entreprise cible doit élaborer et mettre en œuvre des mécanismes pour recueillir des données et mesurer chacun des indicateurs adoptés, SCOR[®] ne recommande pas à l'entreprise cible d'utiliser tous les indicateurs suggérés, mais de donner la priorité à la sélection des indicateurs de performance qui sont essentiels à ses processus de gestion (SCC, 2012).

Figure 1 Attributs et indicateurs de performance proposés par SCOR

Le tableau 1 présente les techniques utilisées à travers les études trouvées dans la littérature qui proposent souvent des modèles quantitatifs pour évaluer les performances de la chaîne d'approvisionnement sur la base des mesures de modèle SCOR[®]. Bien que ces modèles aient apporté plusieurs contributions à la progression de la littérature et de la pratique dans l'évaluation des performances de la chaîne d'approvisionnement, ils présentent certaines limites et difficultés d'utilisation liées aux techniques adoptées. Dans le cas des approches fondées sur des expertises comparatives par paires, proposées par Clivillé & Berrah (2012), Yang & Jiang (2012), Kocaoglu et al. (2013), Bukhori et al. (2015), Sellitto et al. (2015) et Dissanayake & Cross (2018), plus le nombre de mesures pour l'évaluation des chaînes d'approvisionnement est important, plus il est difficile d'assurer la cohérence des données. Un autre problème posé est que les modèles basés sur des méthodes multicritères (Seifbarghy, 2009 ; Golparvar & Kocaoglu et al., 2013 ; Moharamkhani et al., 2017 ; Akkawuttiwanich & Yenradee, 2018) produisant un résultat basé sur une combinaison linéaire pondérée de valeurs d'entrée, ils ne sont pas adaptés pour traiter les relations causales non linéaires entre les

indicateurs de niveau 1 et de niveau 2 de SCOR[®]. Seuls les modèles basés sur des techniques d'intelligence artificielle ont cette capacité. Cependant, une difficulté dans l'utilisation des modèles basés sur l'inférence floue (Ganga & Carpinetti, 2011) fait référence à la nécessité de paramétrer et d'actualiser manuellement des centaines de règles de décision basées sur l'avis d'experts afin d'ajuster les relations causales entre les mesures d'entrée et de sortie. Par conséquent, de tous les modèles trouvés, seuls les systèmes basés sur des réseaux de neurones ont la capacité d'ajuster automatiquement les paramètres adaptatifs du modèle en utilisant des données de performance historiques.

Tableau 1 - Techniques utilisées dans les modèles quantitatifs d'évaluation des performances basés sur le modèle SCOR[®]

Auteurs	Méthode(s)
Golparvar & Seifbarghy (2009)	TOPSIS (<i>Technique for Order of Preference by Similarity to the Ideal Solution</i>)
Ganga & Carpinetti (2011)	Fuzzy inference systems, Mamdani
Jalalvand et al. (2011)	DEA (<i>Data Envelope Analysis</i>) and PROMETHEE II
Clivillé & Berrah (2012)	MACBETH (<i>Measuring attractiveness through a categorical evaluation technique</i>)
Yang & Jiang (2012)	Nouvelle méthode basée sur les nombres <i>fuzzy</i> et M (1,2,3)
Kocaoglu et al. (2013)	AHP (<i>Analytic Hierarchy Process</i>) and TOPSIS
Bukhori et al. (2015)	AHP
Sellitto et al. (2015)	AHP
Moharamkhani et al. (2017)	Fuzzy TOPSIS à intervalles
Liu and Liu (2017)	DEA
Akkawuttiwanich & Yenradee (2018)	Fuzzy QFD (<i>Quality Function Deployment</i>)
Dissanayake & Cross (2018)	AHP modélisation des équations structurelles
Lima Jr. & Carpinetti (2019)	Réseaux de neurones et perceptron multicouches
Lima Jr. & Carpinetti (2020)	Un système d'inférence floue (<i>fuzzy</i>) basé sur un réseau adaptatif
Finger, G. S. W., & Lima-Junior, F. R. (2022)	A hesitant fuzzy linguistic QFD approach

4. Réseaux Perceptron multicouches

L'étude des réseaux de neurones artificiels a pris ses origines de l'étude des systèmes nerveux des êtres vivants. L'intention d'une telle étude est d'imiter certaines des fonctions du cerveau humain en reproduisant certaines de ses structures de base (Kurtgoz et al., 2017). Selon une étude bibliographique développée par Tkáč & Verner (2016), le type d'RNA le plus utilisé

est le perceptron multicouche (PMC). Les réseaux PMC peuvent être appliqués dans plusieurs problèmes impliquant l'approximation de fonctions, la reconnaissance de formes et la prédiction de séries temporelles. Comme l'illustre la figure 2, un RNA de type PMC est composé d'une couche d'entrée, d'une couche de sortie et d'une ou plusieurs couches cachées (Abdi-Khanghah et al., 2018). Chaque couche possède des unités de traitement de base appelées neurones artificiels, dont la structure est détaillée dans la figure 2. Les connexions entre ces neurones ont des poids différents. Les valeurs initiales de ces paramètres sont fixées au hasard, et sont modifiées plus tard au cours du processus d'apprentissage par itération. Chaque neurone a un seuil d'activation (biais) qui contribue à augmenter la performance (Kurtgoz et al., 2017).

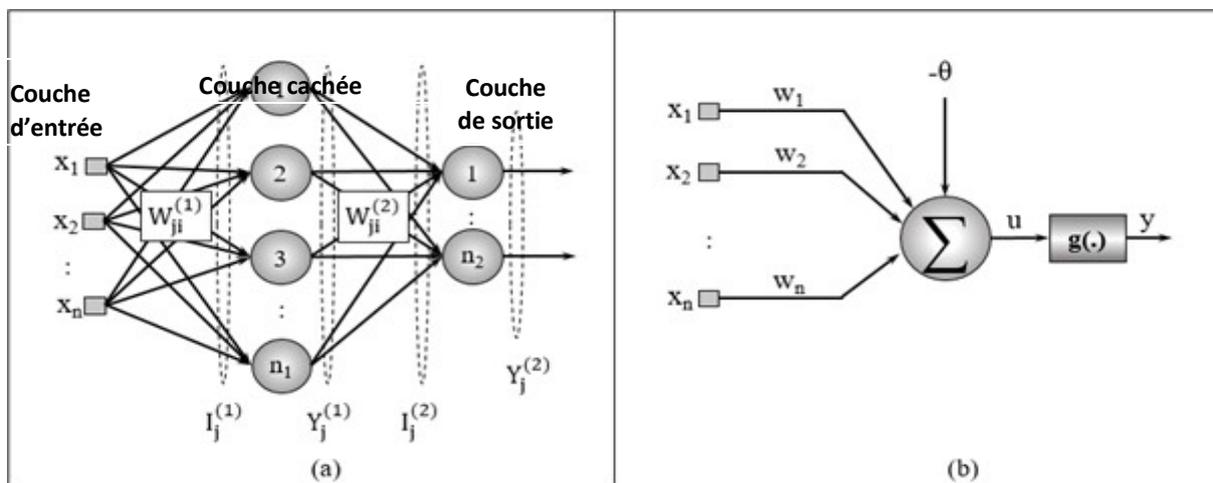


Figure 2 Structure d'un réseau PMC (a) et d'un neurone artificiel (b)

Dans la figure 2, les signaux d'entrée (x_1, x_2, \dots, x_n) et les matrices de pondération synaptiques $(w^L)_j$ qui relient les neurones (j) de chaque couche (L) aux neurones de la couche précédente (i) sont représentés. Les entrées pondérées (I^L) des neurones et les sorties produites par chacun d'eux (Y^L) sont également mises en évidence. La phase d'apprentissage se fait traditionnellement à l'aide d'un algorithme d'apprentissage appelé *backpropagation* (rétropropagation), qui se compose de deux étapes. Cet apprentissage nécessite un ensemble d'échantillons des valeurs des variables d'entrée et de sortie du réseau, qui sont subdivisées en un sous-ensemble d'apprentissage et un sous-ensemble de validation. La quantité d'échantillons recommandée pour l'apprentissage est de 60% à 90%. Le nombre de fois que ces échantillons sont traités par itération, appelé nombre d'itération, sert de critère d'arrêt d'entraînement (Silva et al., 2010 ; Rezaee et al., 2018).

Dans l'étape *forward*, les signaux d'entrée (x_1) sont pondérés par les poids de la première couche cachée w^1 . Plus tard, ce vecteur d'entrée pondéré selon l'expression 1 est modifié par une fonction d'activation, telle que la fonction tangente hyperbolique représentée dans l'expression 2, générant ainsi les valeurs du vecteur I^1 . Les procédures effectuées dans les couches suivantes sont similaires. Toutefois, dans ces cas, les signaux d'entrée de ces couches se réfèrent aux sorties des couches précédentes (Silva et al., 2010 ; Rezaee et al., 2018).

$$u = \sum^n w_i x_i - \theta \quad (1)$$

$$(u) = \frac{1 - e^{-\beta u}}{1 + e^{-\beta u}} \quad (2)$$

Dans l'étape *backward*, les réponses produites par itération pour chaque échantillon sont comparées aux échantillons respectifs des variables de sortie du sous-ensemble de formation (réponses souhaitées). L'objectif principal de l'algorithme de rétropropagation est de trouver des valeurs optimales pour les poids synaptiques et les seuils d'activation afin de minimiser l'erreur quadratique moyenne résultant de la différence entre les sorties réelles et les valeurs prédites. Les corrections des valeurs de ces paramètres sont effectuées sur la base de cette différence afin de minimiser l'erreur. L'ajustement de ces paramètres commence à la couche de sortie et se poursuit plus tard dans la ou les couches cachées. Le processus est répété jusqu'à ce que le nombre de temps d'apprentissage soit atteint. À la fin d'apprentissage, les paramètres seront ajustés pour déterminer une relation numérique entre les variables d'entrée et de sortie (Bilgehan, 2011).

Pour assurer un bon apprentissage et sélectionner les topologies les plus appropriées pour chaque modèle, plusieurs études appliquent une procédure appelée validation croisée, qui se compose d'une série de tests (Tkác & Verner, 2016 ; Rezaee et al., 2018). Dans chaque test, plusieurs combinaisons de valeurs pour les paramètres du réseau sont évaluées afin de sélectionner celle qui présente le plus faible EQM au stade de la validation. Cette procédure est aussi généralement appliquée pour évaluer la précision des algorithmes d'apprentissage afin de choisir le plus approprié (Silva et al., 2010).

4.1. Algorithmes d'apprentissage

Il existe une grande variété de méthodes d'apprentissage qui peuvent être appliquées pour mener un apprentissage supervisé des PMC. Afin d'améliorer la version originale de la rétropropagation, de nouveaux algorithmes ont été proposés afin de rendre l'entraînement plus rapide et d'obtenir une plus grande précision de prédiction. Dans cette section, nous décrirons certains des plus utilisés, qui ont également été adoptés par cette étude : *Gradient Descendant Momentum* (GDM), *Levenberg-Marquardt* (LM), *Quasi-Newton* (BFGS) et *Scale Conjugate Gradient* (SCG). La principale différence entre ces algorithmes est la manière dont la direction de l'ajustement des paramètres et la valeur de cet ajustement sont calculées à chaque itération (Tkác & Verner, 2016).

Dans l'algorithme GDM, l'expression 3 est appliquée, dans laquelle η est le taux d'apprentissage. La valeur α est le coefficient de *momentum*, un paramètre ajustable qui définit la

valeur des ajustements itératifs vers la minimisation des erreurs. La valeur de (L) est le gradient local par rapport au j -ième neurone de la couche de sortie, comme dans l'expression 4. Dans l'algorithme LM, l'ajustement est effectué en utilisant le gradient calculé par l'expression 5. Le paramètre μ est le taux d'ajustement de la convergence. $J(W)$ représente une matrice jacobienne (matrice de dérivés du second ordre), $J(W)$ sa version transposée I est la matrice d'identité (Silva et al., 2010).

$$w_{ji}^{(L)}(t+1) = w_{ji}^{(L)}(t) + \alpha (w_{ji}^{(L)}(t) - w_{ji}^{(L)}(t-1)) + \eta \delta_j^{(L)} Y_i^{(L-1)} \quad (3)$$

$$\delta_j^{(L)} = (d_j - Y_j^{(L)}) g'(I_j^{(L)}) \quad (4)$$

$$\Delta w = (J(w)J(w) + \mu I)^{-1} J^T(w) (d_i - Y_i^{(L)}) \quad (5)$$

L'algorithme BFGS utilise l'expression d'ajustement présentée dans l'expression 6, où $\nabla^2(J(\cdot))$ est une matrice de Hessienne et a_t est un scalaire qui définit l'étape d'ajustement. L'algorithme SCG applique le gradient défini par l'équation 7, dans laquelle d_t détermine la direction de l'ajustement (Mukherjee & Routroy, 2012).

$$w(t+1) = w(t) - a_t [\nabla^2 J(w(t))]^{-1} \nabla w(t) \quad (6)$$

$$d_t = -\nabla w(t) \quad (7)$$

La littérature présente des études comparatives entre les algorithmes d'apprentissage considérant différents domaines. Tripathy & Kumar (2009) ont effectué une comparaison avec l'objectif de choisir l'algorithme le plus approprié pour prédire la variation de température des produits alimentaires pendant le séchage solaire. Dans cette étude, le SCG a montré une meilleure précision que le BFGS et le LM. Dans une étude sur le contrôle des processus de broyage, Mukherjee & Routroy (2012) ont comparé les algorithmes LM et BFGS et ont conclu que le premier algorithme converge plus rapidement et est plus précis que l'autre. Maroufpoora et al. (2019) ont comparé le GDM, le SCG et le LM. Ils ont constaté que pour soutenir la modélisation de la distribution uniforme de l'eau, l'algorithme plus approprié est le LM. Ces résultats démontrent que la performance de chaque algorithme dépend de

l'application. Ainsi, le développement d'une comparaison entre les méthodes d'apprentissage par réseau de neurones est nécessaire pour mettre en évidence celle qui donne les résultats les plus précis dans l'évaluation des chaînes d'approvisionnement.

5. Méthode

Cette recherche peut être classée dans la catégorie de la modélisation et de la simulation informatiques, car elle implique le développement de modèles informatiques, basés sur des réseaux de neurones, qui ont des relations de cause à effet entre les variables d'entrée et de sortie (Bertrand & Fransoo, 2002). La première étape de la recherche a consisté en une étude bibliographique sur l'évaluation de la chaîne d'approvisionnement, le modèle SCOR[®], les modèles d'évaluation des performances, les réseaux neuronaux artificiels et les algorithmes d'apprentissage supervisée. Les recherches d'articles ont été effectuées dans le « *Web of Science* », « Emerald Insight », « Scopus », « Springer », « Taylor & Francis » et « IEEE- Xplore », en utilisant des combinaisons entre les chaînes « *supply chain performance evaluation* », « *supply chain performance measurement* », « *neural networks* », « *learning algorithm* » et « SCOR ».

Les résultats de l'analyse documentaire ont permis de délimiter la lacune de la recherche et ont également subventionné le développement de la phase de modélisation et de simulation informatiques. À ce stade, des échantillons pour l'apprentissage et la validation des modèles ont été générés à l'aide de MS Excel. Sur la base d'une procédure présentée par Lima Jr. et Carpinetti (2019), les valeurs des mesures de niveau 2 ont été générées aléatoirement et normalisées par la suite dans l'intervalle [0, 1]. Les valeurs des métriques de niveau 1 ont été obtenues à partir des expressions suggérées par SCOR[®] (SCC, 2012). La modélisation, l'apprentissage et la validation des modèles ont été effectuées à l'aide du logiciel *MATLAB*. Sur la base de Silva et al. (2010), la méthode de validation croisée utilisant l'échantillonnage aléatoire a été adoptée pour conduire la mise en œuvre et l'évaluation des topologies et des algorithmes d'apprentissage.

La précision des modèles mis en œuvre a été mesurée au moyen de l'erreur quadratique moyenne (EQM), calculée lors de l'étape de validation à partir de la différence entre la valeur estimée et la valeur attendue pour chaque mesure de niveau 1. Enfin, des tests d'hypothèse avec des échantillons appariés ont été effectués pour déterminer s'il existe une différence significative entre les valeurs attendues et les données estimées pour chaque topologie de réseau sélectionnée.

6. Présentation et discussion des résultats

La figure 3 présente l'architecture du système d'évaluation des performances de la chaîne d'approvisionnement développé sur la base de la SCC (2012) et de Lima Jr. & Carpinetti (2019) pour mener cette étude. Ce système est composé de 4 modèles de réseaux neuronaux PMC. Alors que les variables d'entrée sont définies par les mesures de niveau 2 de SCOR®, les variables de sortie se réfèrent aux mesures de niveau 1. Le tableau 2 présente une brève description de ces mesures. Vous trouverez plus de détails à leur sujet dans le modèle SCOR® (SCC, 2012). Les indicateurs de niveau 1 ont été choisis pour traiter les différents attributs de performance de SCOR®. La structure présentée dans la figure 3 a été utilisée pour évaluer comparativement les performances de quatre algorithmes d'apprentissage. Ainsi, pour sélectionner une topologie avec une plus grande précision, pour chaque modèle PMC, 20 configurations topologiques différentes ont été testées, totalisant 80 modèles de calcul.

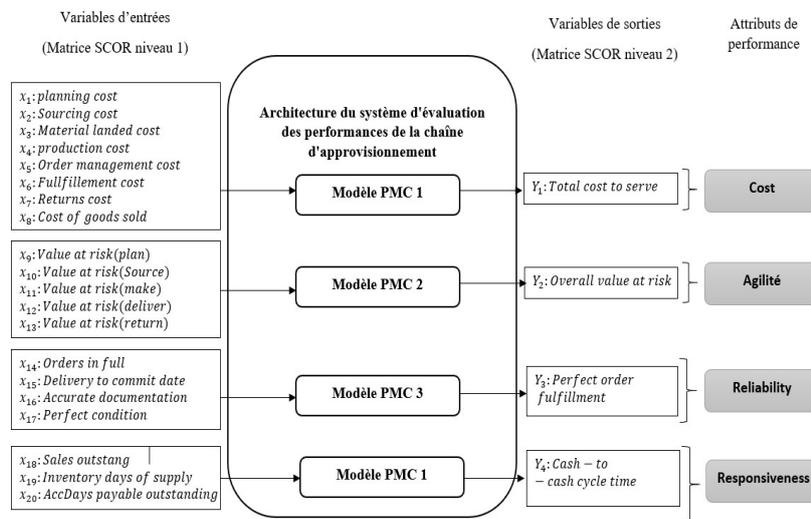


Figure 3 Architecture du système d'évaluation des performances de la chaîne d'approvisionnement

Tableau 2 - Description des paramètres d'entrées-sorties du système d'évaluation des performances

Variables		Description
Modèle 1	x_1	Sourcing cost : le coût total associé à la gestion des commandes, à la réception, à l'inspection et au stockage des produits, des biens et des services.
	x_2	Planing cost : le coût total du personnel, de l'automatisation, des actifs et des frais généraux associés aux processus de planification.
	x_3	Material Landed cost : le coût total associé à l'achat des composants et des produits et leur disponibilité au point d'utilisation.
	x_4	Production cost : le coût de la gestion et de l'exécution des processus de production.
	x_5	Oder management cost : le coût total du personnel, de l'automatisation et des moyens pour répondre aux questions et aux devis, saisir, suivre et facturer les commandes.
	x_6	Fullfilment cost : Le coût du personnel, de l'automatisation, des actifs et des dépenses liées à l'exécution des commandes, y compris les coûts liés à la manipulation physique des produits.
	x_7	Returns cost : le coût de l'élimination des matériaux retournés en raison d'erreurs de planification, de problèmes de qualité des fournisseurs, de livraison ou de production.
	x_8	Cost of goods sold : le coût des matières directes, de la main-d'œuvre et des frais généraux liés à l'achat ou à la production de produits finis.
	y_1	Total cost to serve : somme des coûts directs et indirects liés à la fourniture de produits et de services.
Modèle 2	x_9	Value at risk (plan) : est la somme des risques monétisés liés au processus « plan ».
	x_{10}	Value at risk (source) : somme des risques monétisés liés à la « source ».
	x_{11}	Value at risk (make) : est la somme des risques monétisés liés au processus « make ».
	x_{12}	Value at risk (deliver) : somme des risques monétisés liés à la « deliver ».
	x_{13}	Value at risk (return) : est la somme des risques monétisés liés au processus « return ».
y_2	Overall value at risk (plan) : est la somme des probabilités d'événements à risque qui peuvent avoir un impact sur les processus de la chaîne, multipliée par l'impact monétaire de ces événements.	
Modèle 3	x_{14}	Orders delivered in full : Le système de gestion des commandes : évalue si tous les articles de la commande sont livrés dans les quantités spécifiées par le client.
	x_{15}	Delivery performance to customer commit date : évalue si la commande a été livrée à la date convenue avec le client et au bon endroit.
	x_{16}	Documentation accuracy : évalue l'exactitude et la mise à jour de la documentation de la commande.
	x_{17}	Perfect condition : Evaluer si la commande a été livrée en parfait état.
y_3	Perfect order fulfillemnet : se réfère au pourcentage de commandes qui ont été livrées à la date convenue par le client, sans dommage et avec une documentation complète et précise.	

Modèle 4	x_{18}	Days sales outstanding : le délai entre la date de vente et la réception du paiement des clients.
	x_{19}	Inventory days of supply : la quantité de stock exprimée en jours de vente (par exemple, si 2 articles sont vendus par jour et qu'il y a 20 articles en stock, x_2 est égal à $20/2=10$ jours de vente).
	x_{20}	Days payable outstanding : le temps écoulé entre l'achat de matériaux, de main-d'œuvre et/ou la conversion des ressources et le paiement (délai moyen de paiement).
	y_4	Cash-to-cash cycle time : le temps passé pour qu'un investissement revienne à l'entreprise.

Afin d'évaluer les paramètres topologiques et les algorithmes d'apprentissage, le processus de validation croisée basé sur l'échantillonnage aléatoire a été appliqué à travers les étapes suivantes (Silva et al, 2010) : 1) division aléatoire des échantillons en sous-ensembles d'apprentissage et de validation ; 2) définition des paramètres de topologie des candidats (nombre de neurones dans la couche cachée et le type de la fonction d'activation) ; 3) définition des algorithmes et des paramètres d'apprentissage ; 4) exécution du processus d'apprentissage supervisé pour l'ajustement automatique des poids synaptiques et des seuils d'activation ; 5) validation du modèle sur la base du calcul d'une mesure d'erreur basée sur la différence entre les valeurs prédites par le réseau et les valeurs de sortie du sous-ensemble de validation ; 6) sélection de la topologie qui présente la moindre erreur dans l'étape de validation. Si aucune des topologies ne fonctionne de manière satisfaisante, il est nécessaire de recommencer la procédure et de définir de nouveaux paramètres de topologie et d'entraînement jusqu'à ce que le niveau de précision souhaité soit atteint.

6.1. Définition des cadres topologiques et des paramètres d'apprentissage

Les topologies ont été définies à partir de la variation du nombre de neurones de la couche couchées et des algorithmes d'apprentissage. Pour chaque modèle PMC, les algorithmes suivants ont été testés : GDM (*Gradient Descent Momentum*), LM (*Levenberg- Marquardt*), BFGS (*Quasi-Newton*) et SCG (*Scale Conjugate Gradient*). Ces algorithmes ont été sélectionnés sur la base de Tkáč & Verner (2016) et Mathworks (2018), qui indique les algorithmes appropriés pour les applications impliquant une approximation des fonctions. Les paramètres d'apprentissage des algorithmes GDM et LM ont été choisis par une série de tests empiriques. Pour les algorithmes BFGS et SCG, les valeurs par défaut suggérées par MATLAB ont été utilisées. La quantité d'échantillons de formation a été définie sur la base de tests de calcul. Pour chacun des quatre modèles, 500 échantillons ont été générés, 350 pour la formation et 150 pour la validation. Sur la

base de [Bilgehan \(2011\)](#), le nombre d'itération a été défini comme étant de 20 000.

Le [graphique 3](#) présente les topologies testées à l'aide des algorithmes GDM et LM. La figure 4 présente les topologies utilisant les algorithmes BFGS et SCG. Comme proposé par

[Patuwo et al. \(1993\)](#), le nombre de neurones testés dans chaque couche cachée a été défini en fonction du nombre de variables d'entrée de chaque modèle PMC. Ainsi, le nombre de variables de la couche d'entrée, les quantités suivantes de neurones ont été testées dans la couche cachée : $n-2$, $n-1$, $n+1$ et $n+2$. D'après [Lima Jr. & Carpinetti \(2019\)](#), dans toutes les topologies, les fonctions de type tangente hyperbolique ont été adoptées dans la couche cachée. Il convient de mentionner que ces auteurs ont conclu que ces fonctions présentent une performance supérieure aux autres options lorsqu'elles sont appliquées dans l'évaluation des performances des mesures de niveau 1 du SCOR[®].

Tableau 3- Topologies neuronales pour chaque modèle (*Gradient Descent Momentum et Levenberg Marquardt*)

Modèle PMC et nombre de variables d'entrée (n)	Topologie	Neurones de la couche cachée	Algorithme
1. <i>Total cost to serve</i> (n=8)	1	6	GDM
	2	7	GDM
	3	8	GDM
	4	9	GDM
	5	10	GDM
	6	6	LM
	7	7	LM
	8	8	LM
	9	9	LM
	10	10	LM
2. <i>Value at risk</i> (n=5)	11	3	GDM
	12	4	GDM
	13	5	GDM
	14	6	GDM
	15	7	GDM
	16	3	LM
	17	4	LM
	18	5	LM
	19	6	LM
	20	7	LM
3. <i>Perfect order fulfillment</i> (n=4)	21	2	GDM
	22	3	GDM

	23	4	GDM
	24	5	GDM
	25	6	GDM
	26	2	LM
	27	3	LM
	28	4	LM
	29	5	LM
	30	6	LM
4. <i>Cash-to-Cash Cycle Time</i>	31	1	GDM
(n=3)	32	2	GDM
	33	3	GDM
	34	4	GDM
	35	5	GDM
	36	1	LM
	37	2	LM
	38	3	LM
	39	4	LM
	40	5	LM

Tableau 4- Topologies neuronales pour chaque modèle (*Quasi-Newton et Scale Conjugate Gradient*)

Modèle PMC et nombre de variables d'entrée (n)	Topologie	Neurones de la couche cachée	Algorithme
1. <i>Total cost to serve</i> (n=8)	41	6	BFGS
	42	7	BFGS
	43	8	BFGS
	44	9	BFGS
	45	10	BFGS
	46	6	SCG
	47	7	SCG
	48	8	SCG
	49	9	SCG
	50	10	SCG
2. <i>Value at risk</i> (n=5)	51	3	BFGS
	52	4	BFGS
	53	5	BFGS
	54	6	BFGS
	55	7	BFGS
	56	3	SCG
	57	4	SCG
	58	5	SCG
	59	6	SCG
	60	7	SCG
3. <i>Perfect order fulfillment</i>	61	2	BFGS

(n=4)	62	3	BFGS
	63	4	BFGS
	64	5	BFGS
	65	6	BFGS
	66	2	SCG
	67	3	SCG
	68	4	SCG
	69	5	SCG
	70	6	SCG
	4. <i>Cash-to-Cash Cycle Time</i> (n=3)	71	1
72		2	BFGS
	73	3	BFGS
	74	4	BFGS
	75	5	BFGS
	76	1	SCG
	77	2	SCG
	78	3	SCG
	79	4	SCG
	80	5	SCG

6.2. Résultats du processus d'apprentissage

Les tableaux 1 et 2 présentent les valeurs de l'EQM obtenues lors de l'étape de validation, calculé à partir des valeurs estimées par le réseau et des valeurs attendues pour chaque mesure de niveau 1. Parmi tous les modèles mis en œuvre, l'erreur la plus faible ($1.2326 \cdot 10^{-34}$) a été obtenue par PMC 3 (*Perfect Orders Fulfillment*) en utilisant l'algorithme LM, avec 5 neurones dans la couche intermédiaire (topologie 29). Ce résultat peut être lié au fait que les variables d'entrée sont quantifiées par quatre valeurs binaires, ce qui conduit à une fonction de sortie très simple, formée par cinq positions discrètes. Parmi les topologies sélectionnées, la précision la plus faible a été obtenue par PMC 1 (*Total Cost to Serve*) en utilisant l'algorithme GDM, avec 9 neurones dans la couche cachée, avec EQM égal à $7.2260 \cdot 10^{-3}$ (topologie 4). Il convient de mentionner que ce modèle comporte 8 variables d'entrée, ce qui constitue la fonction d'architecture la plus complexe.

Tableau 1 - Valeurs de l'EQM et R pour les topologies évaluées à l'aide de GDM et LM

Modèle	Numéro de la topologie	EQM
1. <i>Total cost to serve</i>	1	1.7277×10^{-4}
	2	7.7338×10^{-4}
	3	3.2612×10^{-4}
	4	7.2260×10^{-3}
	5	2.3676×10^{-4}

	6	1.7868×10^{-14}
	7	4.8606×10^{-16}
	8	5.3279×10^{-14}
	9	4.6739×10^{-16}
	10	3.9927×10^{-15}
2. <i>Value at risk</i> (n=5)	11	7.6484×10^{-4}
	12	3.2225×10^{-5}
	13	1.4334×10^{-5}
	14	1.4722×10^{-4}
	15	2.9898×10^{-4}
	16	5.2190×10^{-18}
	17	4.4490×10^{-17}
	18	1.9933×10^{-17}
	19	4.1473×10^{-18}
	20	8.4310×10^{-17}
3. <i>Perfect order fulfillment</i> (n=4)	21	8.1722×10^{-5}
	22	4.2627×10^{-5}
	23	3.0120×10^{-6}
	24	2.1076×10^{-6}
	25	1.2399×10^{-6}
	26	4.3141×10^{-33}
	27	2.8761×10^{-34}
	28	1.2326×10^{-34}
	29	2.8761×10^{-34}
	30	2.0954×10^{-33}
4. <i>Cash-to-Cash Cycle Time</i> (n=3)	31	6.2712×10^{-5}
	32	1.8256×10^{-4}
	33	7.8624×10^{-5}
	34	3.0968×10^{-4}
	35	6.4169×10^{-5}
	36	4.5336×10^{-13}
	37	2.5943×10^{-16}
	38	2.6543×10^{-16}
	39	9.3256×10^{-18}
	40	9.8038×10^{-18}

Tableau 2 - Valeurs de l'EQM pour les topologies évaluées à l'aide de BFGS et SCG

Modèle	Numéro de la topologie	EQM
1. <i>Total cost to serve</i>	41	7.9847×10^{-15}
	42	1.1622×10^{-15}
	43	2.2807×10^{-14}
	44	2.5033×10^{-14}
	45	2.6726×10^{-14}
	46	2.4602×10^{-8}
	47	2.4359×10^{-7}

	48	2.3544×10^{-7}
	49	1.9213×10^{-6}
	50	1.0869×10^{-6}
2. <i>Value at risk</i> (n=5)	51	1.6209×10^{-13}
	52	1.9715×10^{-14}
	53	1.2598×10^{-14}
	54	4.2228×10^{-15}
	55	1.2472×10^{-14}
	56	8.6542×10^{-8}
	57	4.2247×10^{-8}
	58	2.1301×10^{-8}
	59	1.3591×10^{-8}
	60	1.5838×10^{-8}
	3. <i>Perfect order fulfillment</i> (n=4)	61
62		8.7578×10^{-23}
	63	2.9078×10^{-21}
	64	2.1911×10^{-13}
	65	4.6783×10^{-12}
	66	1.4719×10^{-25}
	67	1.0689×10^{-29}
	68	9.9189×10^{-26}
	69	3.0556×10^{-31}
	70	3.0918×10^{-31}
4. <i>Cash-to-Cash Cycle Time</i> (n=3)	71	3.8212×10^{-11}
	72	3.8505×10^{-13}
	73	1.5034×10^{-13}
	74	1.6149×10^{-14}
	75	5.1497×10^{-14}
	76	4.6171×10^{-9}
	77	1.6531×10^{-9}
	78	4.4888×10^{-9}
	79	1.1387×10^{-9}
	80	7.7939×10^{-9}

Pour les modèles PMC 1, 2 et 4, la meilleure précision a été obtenue par les topologies 9 ($4,6739 \cdot 10^{-16}$), 19 ($4,1473 \cdot 10^{-18}$) et 39 ($9,3256 \cdot 10^{-18}$), en utilisant respectivement 9, 6 et 4 neurones dans la couche intermédiaire. Au vu de ces résultats, il est conclu que l'algorithme de *Levenberg-Marquardt* présente la meilleure précision de prédiction dans tous les paramètres de niveau 1 considérés dans cette étude. Par conséquent, cet algorithme est plus adéquat pour être appliqué dans l'évaluation des performances basée sur SCOR[®] que les autres évalués.

6. Validation des résultats à l'aide de tests d'hypothèse

Quatre tests d'hypothèse ont été effectués afin de vérifier s'il existe une différence

significative entre les valeurs de performance attendues (calculées sur la base de SCOR[®]) et les valeurs estimées à l'aide de l'algorithme LM. Le tableau 3 présente les valeurs des 30 échantillons de valeurs attendues et prédites pour chaque modèle PMC, utilisés dans les tests d'hypothèse. En raison de contraintes d'espace, les valeurs de ce tableau ont été limitées à 5 décimales. Cependant, pour les calculs, toutes les décimales des valeurs prédites (17 places) ont été prises en compte.

Tableau 3 - Valeurs des échantillons utilisés dans les tests d'hypothèse

Modèle PMC 1		Modèle PMC 2		Modèle PMC 3		Modèle PMC 4	
Valeur Réelle	Valeur Prédite						

0.00000	0.00000	0.00000	0.00000	0.50000	0.50000	1.00000	1.00000
1.00000	1.00000	1.00000	1.00000	0.25000	0.25000	-0.09091	-0.09091
0.48500	0.48500	0.58900	0.58900	0.25000	0.25000	0.74545	0.74545
0.80750	0.80750	0.65000	0.65000	0.25000	0.25000	0.76364	0.76364
0.58000	0.58000	0.87000	0.87000	0.50000	0.50000	0.23636	0.23636
0.76130	0.76125	0.79600	0.79600	1.00000	1.00000	0.62727	0.62727
0.64630	0.64625	0.32000	0.32000	0.25000	0.25000	0.42727	0.42727
0.18000	0.18000	0.30600	0.30600	0.50000	0.50000	0.71818	0.71818
0.22500	0.22500	0.40800	0.40800	0.25000	0.25000	0.92727	0.92727
0.29630	0.29625	0.16200	0.16200	0.50000	0.50000	0.42727	0.42727
0.10130	0.10125	0.12400	0.12400	0.75000	0.75000	0.14545	0.14545
0.95750	0.95750	0.89600	0.89600	0.50000	0.50000	0.46364	0.46364
0.59750	0.59750	0.38000	0.38000	0.50000	0.50000	0.06364	0.06364
0.70880	0.70875	0.61000	0.61000	0.50000	0.50000	0.48182	0.48182
0.37250	0.37250	0.41600	0.41600	0.25000	0.25000	0.63636	0.63636
0.71380	0.71375	0.76600	0.76600	0.50000	0.50000	0.87273	0.87273
0.59750	0.59750	0.80400	0.80400	0.50000	0.50000	0.93636	0.93636
0.30880	0.30875	0.39200	0.39200	0.25000	0.25000	0.67273	0.67273
0.28880	0.28875	0.00000	0.00000	0.25000	0.25000	0.79091	0.79091
0.28000	0.28000	1.00000	1.00000	0.75000	0.75000	0.41818	0.41818
0.12630	0.12625	0.04600	0.04600	0.75000	0.75000	0.50000	0.50000
0.82500	0.82500	0.94800	0.94800	0.00000	0.00000	0.23636	0.23636
0.62130	0.62125	0.53800	0.53800	0.50000	0.50000	0.00727	0.00727
0.68630	0.68625	0.64200	0.64200	0.75000	0.75000	0.28182	0.28182
0.36000	0.36000	0.60600	0.60600	0.50000	0.50000	0.39091	0.39091
0.79500	0.79500	0.79000	0.79000	0.75000	0.75000	0.56364	0.56364
0.53880	0.53875	0.56800	0.56800	0.50000	0.50000	0.93636	0.93636
0.32630	0.32625	0.37800	0.37800	0.25000	0.25000	0.43636	0.43636
0.46750	0.46750	0.20600	0.20600	0.75000	0.75000	0.70000	0.70000
0.19000	0.19000	0.21000	0.21000	0.25000	0.25000	0.10909	0.10909

7. Conclusion

Cette étude a comparé quatre méthodes d'apprentissage des réseaux neuronaux artificiels lorsqu'elles sont appliquées à l'évaluation des performances sur la base des mesures suggérées par SCOR[®]. La méthode de validation croisée a été appliquée pour évaluer les topologies et choisir le nombre de neurones le plus approprié pour chaque modèle. L'algorithme LM a obtenu une plus grande précision de prédiction dans les quatre indicateurs de niveau 1. L'analyse des résultats nous permet de déduire que les algorithmes LM et SCG ont mieux fonctionné dans les modèles où le nombre de neurones dans la couche cachée est équivalent aux nombres de variables d'entrée. Il n'y a pas eu de comportement similaire pour les algorithmes BFGS et GDM. Même l'algorithme GDM, le moins performant parmi ceux qui ont été évalués, a généré

des résultats plus précis que la version originale de la rétropropagation utilisée par *Lima Jr. & Carpinetti (2019)*.

Les résultats de cette étude sont utiles pour aider les chercheurs à développer de nouveaux modèles d'évaluation des performances basés sur les réseaux de neurones, notamment en ce qui concerne la définition des paramètres des paramètres topologiques, des méthodes d'apprentissage et du niveau de précision qui peut être atteint pour chaque indicateur. Ils servent également à guider les développeurs d'outils d'apprentissage machine qui cherchent à créer de nouvelles solutions pour la prise de décision, ce qui est une demande imminente compte tenu du contexte de l'industrie 4.0.

Une des limites de cette étude concerne l'utilisation de données simulées, car il n'a pas encore été possible de collecter des échantillons réels en raison de la grande quantité requise (500 échantillons pour chaque indicateur). Il est important de noter que la difficulté de collecter des données pour évaluer les performances de la chaîne d'approvisionnement est mentionnée dans plusieurs études (*Didehkhani, et al., 2009 ; Brandenburg et al., 2014 ; Dias et al., 2017 ; Lima- Junior et Carpinetti, 2017*). Toutefois, des facteurs tels qu'une plus grande intégration des processus et des systèmes de mesure des performances entre les différents maillons de la chaîne d'approvisionnement, ainsi que la popularisation des technologies de gestion des données telles que les « Big Data » et les entrepôts de données, peuvent contribuer à accroître la disponibilité des données et faciliter la mise en œuvre de modèles basés sur les réseaux neuronaux dans les années à venir.

Des études futures pourront comparer les performances des algorithmes d'apprentissage qui n'ont pas encore été testés dans l'évaluation des performances de la chaîne d'approvisionnement. Une autre suggestion consiste à comparer les performances des méthodes d'apprentissage en tenant compte des paramètres de niveau 1 qui n'ont pas été inclus dans cette étude, ainsi que des paramètres de niveau 3.

Références

Abdi-Khanghah, M., Bemani, A., Naserzadeh, Z., & Zhang, Z. (2015). Prediction of the solubility of N-alkanes in supercritical CO₂ using RBF-ANN and MLP-ANN. *Journal of CO₂*

Utilization, 13, 108–119. <https://doi.org/10.1016/j.jcou.2015.10.008>

Ahi, P., & Searcy, C. (2015). Assessing sustainability in the supply chain: A three-pronged approach. *Applied Mathematical Modelling*, 39(10), 2882–2896. <https://doi.org/10.1016/j.apm.2014.10.055>

Akkawuttiwanich, P., & Yenradee, P. (2018). Fuzzy QFD approach for the management of SCOR performance indicators. *Computer & Industrial Engineering*, 122, 189–201. <https://doi.org/10.1016/j.cie.2018.05.044>

Bertrand, J. W. M., & Fransoo, J. C. (2002). Operations management research methodologies using quantitative modeling. *International Journal of Operations & Production Management*, 22(2), 241–264. <https://doi.org/10.1108/01443570210414338>

Bilgehan, M. (2011). Comparison of the ANFIS and NN models—with a study on critical buckling load estimation. *Applied Soft Computing*, 11(4), 3779–3791. <https://doi.org/10.1016/j.asoc.2011.02.011>

Bouaddaoui, A. (2023). Innovations in educational technology: Trends and challenges. *Educational Technology Review*, 15(1), 56–78. <https://doi.org/10.1234/etr.2023.121314>

Brandenburg, M., Govindan, K., Sarkis, J., & Seuring, S. (2014). Quantitative models for supply chain risk management. *European Journal of Operational Research*, 233(2), 299–312. <https://doi.org/10.1016/j.ejor.2013.08.042>

Bukhori, I. B., Widodo, K. H., & Ismoyowati, D. (2015). Evaluation of the performance of the poultry supply chain at the XYZ Yogyakarta slaughterhouse using the SCOR and AHP method. *Agriculture and Agricultural Science Procedia*, 3, 221–225. <https://doi.org/10.1016/j.aaspro.2015.01.043>

Clivillé, V., & Berrah, L. (2012). Measuring overall performance in a supply chain: Towards a primary supplier-based model. *Journal of Intelligent Manufacturing*, 23(6), 2459–2469. <https://doi.org/10.1007/s10845-011-0512-x>

Dias, L. S., & Ierapetritou, M. G. (2017). From process control to supply chain management: An overview of integrated decision-making strategies. *Computer & Chemical Engineering*, 106, 826–835. <https://doi.org/10.1016/j.compchemeng.2017.06.015>

Didekhani, H., Jassbi, J., & Pilevari, N. (2009). Assessing supply chain flexibility using an adaptive neuro-fuzzy inference system. In *IEEE International Conference on Industrial Engineering and Engineering Management (IEEM 2009)* (pp. 1234–1238). <https://doi.org/10.1109/IEEM.2009.5373292>

Dissanayake, C. K., & Cross, J. A. (2018). Systematic mechanism for identifying the relative impact of supply chain performance areas on overall supply chain performance using the SCOR model and the SEM. *International Journal of Production Economics*, 201, 102–115. <https://doi.org/10.1016/j.ijpe.2018.04.027>

Estampe, D., Lamouri, S., Paris, J., & Brahim-Djelloul, S. (2013). A framework for analyzing

supply chain performance assessment models. *International Journal of Production Economics*, 142(2), 247–258. <https://doi.org/10.1016/j.ijpe.2012.10.008>

Fan, X., Zhang, S., Wang, L., Yang, Y., & Hapeshi, K. (2013). A model for evaluating supply chain performance using the 5DBSC and LMBP neural network algorithm. *Journal of Bionic Engineering*, 10(3), 383–395. [https://doi.org/10.1016/S1672-6529\(13\)60234-6](https://doi.org/10.1016/S1672-6529(13)60234-6)

Finger, G. S. W., & Lima-Junior, F. R. (2022). A hesitant fuzzy linguistic QFD approach for formulating sustainable supplier development programs. *International Journal of Production Economics*, 247, 108428. <https://doi.org/10.1016/j.ijpe.2021.108428>

Ganga, G. M. D., & Carpinetti, L. C. R. (2011). A fuzzy logic approach to supply chain performance management. *International Journal of Production Economics*, 134(2), 177–187. <https://doi.org/10.1016/j.ijpe.2011.06.011>

Ghoubach, R., & EL, A. (2024). The impact of digital media on youth culture. *International Journal of Media Studies*, 12(3), 234–250. <https://doi.org/10.1234/ijms.2024.91011>

Golparvar, M., & Seifbarghy, M. (2009). Application of the SCOR model in an oil company. *Journal of Industrial Engineering*, 4(1), 59–69.

Gunasekaran, A., Patel, C., & Mcgaughey, R. E. (2004). A framework for measuring supply chain performance. *International Journal of Production Economics*, 87(3), 333–347. <https://doi.org/10.1016/j.ijpe.2003.08.003>

Gunasekaran, A., Patel, C., & Tirtiroglu, E. (2001). Performance measures and metrics in a supply chain environment. *International Journal of Production Operations and Management*, 21(1–2), 71–87. <https://doi.org/10.1108/01443570110358468>

Houad, A. (2022). Advances in renewable energy technologies: A review. *Energy Journal*, 30(2), 200–215. <https://doi.org/10.1234/ejournal.2022.181920>

Hrouga, M., & Said, A. (2024). Understanding the dynamics of social behavior. *Journal of Social Psychology*, 45(2), 123–145. <https://doi.org/10.1234/jpspsych.2024.5678>

Jalalvand, F., Teimoury, E., Makui, A., Aryanezhad, M. B., & Jolai, F. (2011). A method for comparing industry supply chains. *Supply Chain Management: An International Journal*, 16(2), 82–97. <https://doi.org/10.1108/13598541111115347>

Kocaoglu, B., Gülsün, B., & Tanya, M. (2013). A SCOR-based approach to measuring benchmark supply chain performance. *Journal of Intelligent Manufacturing*, 24(1), 113–132. <https://doi.org/10.1007/s10845-011-0547-z>

Kurtgoz, Y., Karagoz, M., & Deniz, E. (2017). Estimation of biogas engine performance using ANN. *Engineering Science and Technology, an International Journal*, 20(6), 1563–1570. <https://doi.org/10.1016/j.jestch.2017.12.010>

Lima Junior, F. R., Carpinetti, L. C. R. (2020). An adaptive network-based fuzzy inference system to supply chain performance evaluation based on SCOR® metrics. *Computers & Industrial Engineering*, 139, 106191. <https://doi.org/10.1016/j.cie.2019.106191>

- Lima Junior, F. R., Carpinetti, L. C. R. (2019). Predicting supply chain performance based on SCOR® metrics and multilayer perceptrons neural networks. *International Journal of Production Economics*, 212, 19–38. <https://doi.org/10.1016/j.ijpe.2019.02.001>
- Lima Junior, F. R., Carpinetti, L. C. R. (2017). Quantitative models for assessing supply chain performance: A review of the literature. *Computer & Industrial Engineering*, 113, 333–346. <https://doi.org/10.1016/j.cie.2017.09.022>
- Liu, F. F., & Liu, Y. C. (2017). A methodology for assessing supply chain performance based on virtual gap measures. *Computer & Industrial Engineering*, 110, 550–559. <https://doi.org/10.1016/j.cie.2017.06.010>
- Maestrini, V., Luzzini, D., Maccarrone, P., & Caniato, F. (2017). Supply chain performance measurement systems: A systematic review and research agenda. *International Journal of Production Economics*, 183, 299–315. <https://doi.org/10.1016/j.ijpe.2016.11.005>
- Marchand, D., & Raymond, L. (2008). Researching performance measurement systems—An information system perspective. *International Journal of Operations & Production Management*, 28(7), 663–686. <https://doi.org/10.1108/01443570810881802>
- Mathworks. (n.d.). *MATLAB software support site*. <https://www.mathworks.com/help/nnet/ref/trainingd.html> (Accessed 2018)
- Mentzer, J. T., Witt, W., Keebler, J. S., Min, S., Nix, N., & Smith, C. D. (2001). Defining supply chain management. *Journal of Business Logistics*, 22(2), 1–25. <https://doi.org/10.1002/j.2158-1592.2001.tb00001.x>
- Moharamkhani, A., Bozorgi-Amiri, A., & Mina, H. (2017). Measuring supply chain performance using the SCOR model based on the fuzzy interval value TOPSIS model. *International Journal of Logistics Systems and Management*, 27(4), 491–506. <https://doi.org/10.1504/IJLSM.2017.083225>
- Montgomery, D. C., & Runger, G. C. (2009). *Estatística aplicada e probabilidade para engenheiros* (4th ed.). LTC: Rio de Janeiro.
- Mukherjee, I., & Routroy, S. (2012). Comparison of the performance of neural networks developed using Levenberg-Marquardt and Quasi-Newton with the gradient descent algorithm for modeling a multiple response grinding process. *Expert Systems with Applications*, 39(3), 2397–2407. <https://doi.org/10.1016/j.eswa.2011.08.087>
- Naini, S. G. J., Aliahmadi, A. R., & Jafari-Eskandari, M. (2011). Designing a Mixed Performance Measurement System for Environmental Supply Chain Management Using Evolutionary Game Theory and the Balanced Scorecard: A Case Study of an Automotive Industry Supply Chain. *Resources, Conservation and Recycling*, 55(6), 593–603. <https://doi.org/10.1016/j.resconrec.2010.10.008>
- Nudurupati, S. S., & Bititci, U. S. A. (2005). Implementation and impact of IT performance measurement. *Production Planning & Control*, 16(2), 152–162. <https://doi.org/10.1080/09537280512331333057>
- Patuwo, E. B., Hu, M. Y., & Hung, M. S. (1993). Two-group classification using neural

networks. *Decision Sciences*, 26(6), 749–779. <https://doi.org/10.1111/j.1540-5915.1993.tb00491.x>

Rezaee, M., Jozmaleki, M., & Valipour, M. (2018). Integration of dynamic fuzzy C-means, data envelope analysis and artificial neural networks to online prediction performance of companies on the stock market. *Physica A: Statistical Mechanics and its Applications*, 489, 78–93. <https://doi.org/10.1016/j.physa.2017.07.017>

Supply Chain Council. (2012). *Supply Chain Operations Reference Model, Version 11.0*. Supply Chain Council.

Sellitto, M. A., Pereira, G. M., Borchardt, M., Silva, R., & Viegas, C. V. (2015). A SCOR- based model for measuring supply chain performance: Application in the footwear industry. *International Journal of Production Research*, 53(16), 4917– 4926. <https://doi.org/10.1080/00207543.2015.1005251>

Shafiee, M., Lotfi, F. H., & Saleh, H. (2014). Évaluation des performances de la chaîne d'approvisionnement avec analyse d'enveloppement des données et approche de tableau de bord équilibré. *Applied Mathematical Modelling*, 38, 5092– 5112. <https://doi.org/10.1016/j.apm.2014.03.023>

Silva, I. N., Spati, D. H., & Flauzino, R. A. (2010). *Redes Neurais Artificiais: para engenharia e ciências aplicadas*. São Paulo: Artliber.

Tkác, M., & Verner, R. (2016). Réseaux de neurones artificiels en entreprise: deux décennies de recherche. *Applied Soft Computing*, 38, 788– 804. <https://doi.org/10.1016/j.asoc.2015.09.040>