

الجمهورية الجزائرية الديمقراطية الشعبية
وزارة التعليم العالي والبحث العلمي
جامعة 8 ماي 1945 قالمة



الكلية: العلوم الاقتصادية والتجارية وعلوم التسيير
القسم: علوم التسيير
مخبر التنمية الذاتية والحكم الراشد

أطروحة

لنيل شهادة الدكتوراه في الطور الثالث

الميدان: علوم اقتصادية، والتسيير وعلوم تجارية

الشعبة: علوم التسيير

التخصص: إدارة مالية

من إعداد:

بلجهم مفيدة

بعنوان

دور التنبؤ بتقلبات أسعار الأسهم في إدارة المخاطر المالية بالاعتماد على الشبكات العصبية
الاصطناعية دراسة حالة سوق إسطنبول للأوراق المالية.

أمام لجنة المناقشة المكونة من:

بتاريخ: 2025/12/02

الاسم واللقب	الرتبة	بجامعة 8 ماي 1945 قالمة	رئيسا
السيدة مریمت عديلة	أستاذ	بجامعة 8 ماي 1945 قالمة	رئيسا
السيدة عمر عبدة سامية	أستاذ	بجامعة 8 ماي 1945 قالمة	مشرفا
السيد فركوس شكري	أستاذ محاضر ب	بجامعة 8 ماي 1945 قالمة	مشرفا مساعدا
السيد دوش عبد القادر	أستاذ	بجامعة 8 ماي 1945 قالمة	ممتحنا
السيدة شعابنة رزيقة	أستاذ محاضر أ	بجامعة 8 ماي 1945 قالمة	ممتحنا
السيد شعباني مجيد	أستاذ	بجامعة محمد بوقرة بومرداس	ممتحنا
السيد قدام جمال	أستاذ	بجامعة محمد الصديق بن يحي جيجل	ممتحنا

السنة الجامعية: 2026/2025



﴿يَرْفَعُ اللَّهُ الَّذِينَ آمَنُوا مِنْكُمْ وَالَّذِينَ أُوتُوا

الْعِلْمَ دَرَجَاتٍ ۚ وَاللَّهُ بِمَا تَعْمَلُونَ خَبِيرٌ﴾ (11)

سورة المجادلة الآية: 11

ملخص

تهدف الدراسة إلى بناء نموذج مطور من الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار الأسهم ومعرفة دوره في إدارة المخاطر المالية، مع التركيز على قياس المخاطر باستخدام مقياس القيمة المعرضة للخطر المشروطة، واستخدام تقنيات متقدمة لمعالجة البيانات كالاستيفاء الخطي لمعالجة القيم المفقودة، وحساب العوائد اللوغاريتمية، بالإضافة إلى تنعيم السلاسل الزمنية باستخدام تحويل الموجات Wavelet Transform، وتطبيع الميزات عبر أداة RobustScaler لضمان استقرار توزيع البيانات. تم تطوير نموذج تنبؤي قائم على بنية شبكة المحول Transformer مستفيد من دمج آليات الانتباه متعدد الرؤوس مع الشبكات العصبية العميقة، واعتماد دالة الخسارة Huber Loss وخوارزمية التحسين AdamW لتحقيق التوازن بين الدقة ومقاومة القيم الشاذة.

استخدمت الدراسة بيانات يومية للفترة الممتدة من 2001/01/03 إلى 2024/12/31، حيث قسمت إلى مجموعات هي مجموعة للتدريب ومجموعة للتحقق ومجموعة للاختبار، مع استبعاد بيانات شهر ديسمبر واعتبارها كعينة مستقلة للتنبؤ بسعر إغلاق اليوم التالي لمؤشر BIST100 هذا من جهة، ومن جهة أخرى تم اعتماد نوعين من البيانات كمدخلات للنموذج قسمت إلى ميزات ذاتية التي تمثل البيانات التاريخية لعشرين يوم السابقة للسعر الحالي لمؤشر BIST100، وميزات خارجية تتمثل في أسعار إغلاق أسهم أهم المؤشرات الرئيسية في البورصة العالمية وهي: مؤشر S&P 500، مؤشر Dow Jones، مؤشر Nasdaq، مؤشر Small Cap 2000، وأسعار الذهب باعتباره عامل مهم في السوق المالي، بالإضافة إلى مؤشرات التداول اليومية لأسهم مؤشر BIST100 وهي: سعر الافتتاح، أعلى سعر، وأدنى سعر، هذا بمجموع كامل 321789 مشاهدة، وذلك بالاستعانة بلغة البرمجة Python على برنامج Anaconda Navigator.

اعتمدت الدراسة على مقاييس الأداء المتمثلة في متوسط مربع الخطأ (Mean Squared Error (MSE)، متوسط الخطأ المطلق (Mean Absolute Error (MAE)، معامل التحديد R^2 Coefficient of Determination، قدرة التنبؤ بالاتجاه (Predictive Capability Direction (PCD لتقييم أداء الشبكة العصبية الاصطناعية، حيث أظهرت نتائج الدراسة دقة تنبؤية عالية، كما أن نتائج حساب CVAR للعوائد الحقيقية والمتنبئ بها أظهرت تقارباً واضحاً حيث بلغت نسبة الخطأ في تقدير المخاطر حوالي 9.37%، والتي نستنتج من خلالها أن استخدام نماذج الشبكات العصبية الاصطناعية كنموذج المحول في التنبؤ بتقلبات أسعار الأسهم يساهم بفعالية في تحسين قياس وإدارة المخاطر المالية، مما يؤكد أهمية هذه النماذج كأدوات داعمة لاتخاذ القرارات الاستثمارية في الأسواق المالية ذات الطبيعة المتقلبة والمخاطر المرتفعة، خاصة في الأسواق الناشئة كسوق إسطنبول للأوراق المالية والمعبر عنه بمؤشر BIST100 والتي تندمج بأنماطها المعقدة وتقلباتها العالية.

الكلمات المفتاحية: تنبؤ بتقلبات أسعار الأسهم، إدارة المخاطر المالية، قيمة معرضة للخطر المشروطة، شبكات عصبية اصطناعية، نموذج المحول.

Abstract

The study aims to develop an advanced model based on artificial neural networks to predict stock price fluctuations and explore its role in financial risk management, with a focus on measuring risk using the conditional value at risk (CVAR) metric, and the use of advanced data processing techniques such as linear interpolation to process lost values, and calculate logarithmic returns, in addition to smoothing time series using Wavelet Transform, and normalizing features via the RobustScaler tool. To ensure the stability of data distribution. A predictive model based on the Transformer network architecture has been developed that takes advantage of the integration of multi-head attention mechanisms with deep neural networks, the adoption of the Huber Loss function and the AdamW optimization algorithm to balance accuracy and resistance to anomalous values.

The study used daily data for the period from 03/01/2001 to 31/12/2024, where it was divided into groups that are a training group, a validation group and a test group, excluding December data and considering it as an independent sample to predict the closing price of the day after this BIST100 index on the one hand, and on the other hand, two types of data were adopted as inputs to the model divided into subjective features. Which represents the historical data for the twenty days preceding the current price of the BIST100 index, and external features represented in the closing prices of the shares of the most important major indices on the global stock exchange, namely: the S&P 500 index, the Dow Jones index, the Nasdaq index, the Small Cap 2000 index, and gold prices as an important factor in the financial market, In addition to the daily trading indicators for the shares of the BIST100 index , namely: the opening price, the high, and the lowest, this is a complete sum of 321789 viewed, using the Python programming language on the Anaconda Navigator program.

The study relied on performance measures represented in Mean Square Error (MSE), Mean Absolute Error (MAE), Coefficient of Determination R^2 , Predictive Capability Direction (PCD) to evaluate the performance of the artificial neural network, where the results of the study showed high predictive accuracy, and the results of calculating CVAR The real and predicted returns showed a clear convergence, as the error rate in estimating risks was about 9.37%, through which we conclude that the use of artificial neural network models as the transformer model in predicting stock price fluctuations contributes effectively to improving the measurement and management of

financial risks, which confirms the importance of these models as supporting tools for making investment decisions in volatile and high-risk financial markets., especially in emerging markets such as the Istanbul Stock Exchange, expressed by the BIST100 index, which is characterized by complex patterns and high volatility.

Keywords: Stock price prediction, financial risk management, conditional value at risk, artificial neural networks, transformer model.

Résumé

L'étude a pour objectif de développer un modèle avancé basé sur les réseaux neuronaux artificiels pour prédire les fluctuations du prix des actions et explorer son rôle dans la gestion des risques financiers, en mettant l'accent sur la mesure du risque à l'aide de la métrique de la valeur à risque conditionnelle (CVAR), et l'utilisation de techniques de traitement de données avancées telles que l'interpolation linéaire pour traiter les valeurs perdues et calculer les rendements logarithmiques. En plus de lisser les séries chronologiques à l'aide de la transformée en ondelettes (Wavelet Transform) et de normaliser les entités à l'aide de l'outil RobustScaler. Pour assurer la stabilité de la distribution des données. Un modèle prédictif basé sur l'architecture du réseau Transformer a été développé qui tire parti de l'intégration de mécanismes d'attention multi-têtes avec des réseaux de neurones profonds, de l'adoption de la fonction de perte de Huber et de l'algorithme d'optimisation AdamW pour équilibrer la précision et la résistance aux valeurs anormales.

L'étude a utilisé des données quotidiennes pour la période du 03/01/2001 au 31/12/2024, où elle a été divisée en groupes qui sont un groupe de formation, un groupe de validation et un groupe test, en excluant les données de décembre et en les considérant comme un échantillon indépendant pour prédire le prix de clôture du lendemain de cet indice BIST100 d'une part, Et d'autre part, deux types de données ont été adoptés comme entrées du modèle divisé en caractéristiques subjectives. Qui représente les données historiques des vingt jours précédant le prix actuel de l'indice BIST100, et les caractéristiques externes représentées dans les prix de clôture des actions des principaux indices les plus importants de la bourse mondiale, à savoir : l'indice S&P 500 , l'indice Dow Jones , l'indice Nasdaq , le Small Cap 2000 et les prix de l'or en tant que facteur important sur le marché financier, En plus des indicateurs de trading quotidiens pour les actions de l'indice BIST100 , à savoir : le prix d'ouverture, le plus haut et le plus bas, il s'agit d'une somme complète des 321789 consultés, en utilisant le langage de programmation Python sur le programme Anaconda Navigator.

L'étude s'est appuyée sur des mesures de performance représentées par l'erreur quadratique moyenne (MSE), l'erreur absolue moyenne (MAE), le coefficient de détermination R^2 , la direction de capacité prédictive (PCD) pour évaluer la performance du réseau neuronal artificiel, où les résultats de l'étude ont montré une grande précision prédictive, et les résultats du calcul de CVAR

Les rendements réels et prédits ont montré Une convergence claire, puisque le taux d'erreur dans l'estimation des risques était d'environ 9,37 %, grâce à laquelle nous concluons que l'utilisation de modèles de réseaux neuronaux artificiels comme modèle transformer dans la prédiction des fluctuations des prix des actions contribue efficacement à améliorer la mesure et la gestion des risques financiers, ce qui confirme l'importance de ces modèles en tant qu'outils de soutien pour la prise de décisions d'investissement dans les marchés boursiers volatils et à haut risque. Marchés financiers., en particulier dans les marchés émergents tels que la Bourse d'Istanbul, exprimé par l'indice BIST100, qui se caractérise par des modèles complexes et une forte volatilité.

Mots-clés : Prédiction des prix des actions, gestion des risques financiers, réseaux de neurones artificiels, valeur conditionnelle à risque, modèle Transformer.

الدعاء

الحمد لله الذي بنعمته تتم الصالحات وبفضله أهدى ثمرة جهدي هذا:

إلى روح والدي الطاهرة الذي رحل قبل أن أراه لكنه بقي حيا في وجداني دافعا لي بصمته وسيرته، أسأل الله أن يرحمه رحمة واسعة ويسكنه فسيح جنانه.

إلى أُمي الحبيبة أطال الله في عمرها وأحاطها بعنايته وبارك لي فيها كانت نبع الحنان وسند الدعاء وملجأ القوة في كل ضعف.

إلى إخوتي وأخواتي وكل العائلة الكريمة وأبنائهم وبناتهم كل باسمهم، الذين كانوا لي خير سند ودعم في كل مراحل هذا المشوار.

إلى أصدقائي رفقاء الدرب والذكرى الذين زادوا الطريق نورا ودفئا وكانوا لي عوناً بالكلمة والشجع.

وإلى كل من مد لي يد العون أو دعاء صادق، أو كلمة طيبة، أو لحظة اهتمام في إنجاز هذا العمل، من قريب أو بعيد.

إليكم جميعا، أهدى هذا الجهد

شكر وتقدير

﴿وَقَالَ رَبِّ أَوْزِعْنِي أَنْ أَشْكُرَ نِعْمَتَكَ الَّتِي أَنْعَمْتَ عَلَيَّ وَعَلَى وَالِدَيَّ وَأَنْ أَعْمَلَ صَالِحًا تَرْضَاهُ وَأَدْخِلْنِي بِرَحْمَتِكَ فِي عِبَادِكَ الصَّالِحِينَ﴾ ١٩

سورة النمل الآية: 19

اللهم إني أسألك علماً نافعا ورزقا طيبا وعملا متقبلا وتوفيقا في الدارين، وأعوذ بك من علم لا ينفع ومن قلب لا يخشع ومن دعاء لا يسمع.

الحمد لله جدا كثيرا طيبا مباركا فيه كما ينبغي لجلال وجهه وعظيم سلطانه والصلاة والسلام على سيدنا محمد خير من علم وتعلم وعلى آله وصحبه أجمعين.

أقدم بخالص الشكر وعظيم الامثان إلى أسناذتي المشرفة الفاضلة عمى عبدة سامية، والأسناذ المساعد المشرف فركوس شكري، على ما بذلوه من جهد وتوجيهات قيمة، وملاحظات بناءة، كان لها بالغ الأثر في إنفاذ هذه الأطروحة، فلهما مني كل التقدير والعرفان.

كما أخص بالشكر كل من ساهم في إنجاز هذا العمل من قريب أو بعيد، بكلمة، أو دعم، أو توجيه، أو حتى دعاء في ظهر الغيب.

أرفع أسمى عبارات الشكر والامثان إلى أساتذة جامعة قلمة عموماً، وإلى كلية علوم النسيير خصوصاً، على ما قدموه من دعم ومساندة طيلة سنوات الدراسة.

ولا يفوتني أن أعبر عن امثاني العميق لكل الأسناذة والمعلمين الذين وأكبوني منذ خطواتي الأولى في هذا المسار العلمي، فكانوا لي شعلة نور أستير لها في كل مرحلة.

كما أقدم بخزير الشكر والتقدير إلى أعضاء لجنة المناقشة، لفضلهم بقبول مناقشة هذه الأطروحة، ومنحي شرف الاستماع إلى آرائهم العلمية وتوجيهاتهم السديدة.

جزى الله الجميع خير الجزاء، وبارك لهم في علمهم وأعمالهم.

فہرست المحتویات

فهرس المحتويات

الصفحة	العنوان
	البسملة
	الملخص
	الإهداء
	شكر وتقدير
	فهرس المحتويات
VII	قائمة الأشكال
X	قائمة الجداول
XII	قائمة الاختصارات والرموز
أ-ز	مقدمة
الفصل الأول: الإطار النظري للتنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية	
2	تمهيد
3	المبحث الأول: أساسيات حول تقلبات أسعار الأسهم
3	المطلب الأول: مدخل لتقلبات أسعار الأسهم
3	أولاً: ماهية السهم
7	ثانياً: أنواع الأسهم
8	ثالثاً: تقلبات أسعار الأسهم والعوامل المؤثرة فيها
30	المطلب الثاني: النظريات المفسرة لتقلبات أسعار الأسهم
32	المبحث الثاني: التنبؤ بتقلبات أسعار الأسهم
32	المطلب الأول: مدخل للتنبؤ بالتقلبات
32	أولاً: تعريف التنبؤ المالي
33	ثانياً: العوامل المؤثرة في عملية التنبؤ
35	المطلب الثاني: نماذج التنبؤ بتقلبات أسعار الأسهم

40	المبحث الثالث: إدارة المخاطر المالية
40	المطلب الأول: مدخل لإدارة المخاطر المالية
40	أولاً: تعريف المخاطر المالية
41	ثانياً: أنواع المخاطر المالية
43	ثالثاً: الاستراتيجيات المتبعة في إدارة المخاطر المالية
46	المطلب الثاني: أساليب قياس المخاطر المالية
46	أولاً: الأدوات الإحصائية
48	ثانياً: نموذج تسعير الأصول المالية
49	ثالثاً: نماذج القيمة المعرضة للخطر
55	خلاصة الفصل الأول
	الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية
57	تمهيد
58	المبحث الأول: مدخل عام للذكاء الاصطناعي
58	المطلب الأول: ماهية الذكاء الاصطناعي
58	أولاً: تعريف الذكاء الاصطناعي
60	ثانياً: الذكاء الاصطناعي والبيانات الضخمة
61	المطلب الثاني: نماذج التعلم في تطبيقات الذكاء الاصطناعي
67	المبحث الثاني: الشبكات العصبية الاصطناعية
67	المطلب الأول: ماهية الشبكات العصبية الاصطناعية
67	أولاً: أوجه التشابه بين الخلية العصبية البيولوجية والعصبونات الاصطناعية
70	ثانياً: تعريف الشبكات العصبية الاصطناعية
71	ثالثاً: مراحل تطور الشبكات العصبية الاصطناعية
74	المطلب الثاني: هيكلية الشبكات العصبية الاصطناعية
74	أولاً: مكونات الشبكات العصبية الاصطناعية
93	ثانياً: أنواع الشبكات العصبية الخاصة بالتنبؤ

102	المبحث الثالث: الشبكات العصبية الاصطناعية والتنبؤ بتقلبات أسعار الأسهم في إدارة المخاطر المالية
102	المطلب الأول: تطبيق الشبكات العصبية الاصطناعية في التنبؤ بالتقلبات وإدارة المخاطر المالية
102	أولا: استخدامات الشبكات العصبية الاصطناعية في التنبؤ بالتقلبات وإدارة المخاطر
104	ثانيا: مميزات استخدام الشبكات العصبية الاصطناعية للتنبؤ بالتقلبات المالية
106	المطلب الثاني: خطوات بناء نموذج لشبكة عصبية اصطناعية للتنبؤ بتقلبات أسعار الأسهم وقياس المخاطر المالية
110	خلاصة الفصل الثاني
	الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم مؤشر BIST100 ودوره في قياس القيمة المعرضة للخطر المشروطة CVAR
112	تمهيد
113	المبحث الأول: تعريف البيانات والمتغيرات المستخدمة في النموذج
113	المطلب الأول: التعريف بسوق إسطنبول للأوراق المالية ومؤشر BIST100
113	أولا: سوق إسطنبول للأوراق المالية
116	ثانيا: مؤشر BIST100
118	المطلب الثاني: وصف وتحليل بيانات ومتغيرات الدراسة
119	أولا: تعريف متغيرات الدراسة
120	ثانيا: تعريف البيانات المستخدمة في النموذج
127	ثالثا: وصف وتحليل بيانات الدراسة
135	المبحث الثاني: بناء الشبكة العصبية الاصطناعية
135	المطلب الأول: التجهيز المسبق للبيانات
135	أولا: معالجة البيانات
139	ثانيا: تقسيم البيانات
140	المطلب الثاني: بناء الشبكة العصبية الاصطناعية وتدريبها
141	أولا: الهيكل العام للشبكة العصبية الاصطناعية
144	ثانيا: تدريب الشبكة العصبية الاصطناعية والتحقق من أدائها

فهرس المحتويات

147	المبحث الثالث: اختبار النموذج وتطبيقه في عملية التنبؤ وقياس القيمة المعرضة للخطر المشروطة
147	المطلب الأول: اختبار وتقييم النموذج
151	المطلب الثاني: التنبؤ بالقيم المستقبلية لأسعار مؤشر Bist100 وحساب CVAR
151	أولا: التنبؤ بالقيم المستقبلية لأسعار مؤشر BIST100
156	ثانيا: حساب القيمة المعرضة للخطر المشروطة للقيم المتوقعة والقيم الحقيقية
160	خلاصة الفصل الثالث
163	خاتمة
171	قائمة المراجع

قائمة الاسئلة

قائمة الأشكال

الرقم	عنوان الشكل	الصفحة
(1-1)	أنواع الأسهم	8
(2-1)	آلية تحديد قيمة السهم	15
(3-1)	شكل مستقيم الانحدار الخطي لعائد السهم والسوق	27
(4-1)	نموذج تسعير الأصول الرأسمالية	49
(5-1)	التمثيل البياني للقيمة المعرضة للخطر	51
(6-1)	منحنى بياني يوضح كل من VAR and CVAR	54
(1-2)	الذكاء الاصطناعي، التعلم الآلي، والتعلم العميق	60
(2-2)	نماذج التعلم في الذكاء الاصطناعي	62
(3-2)	العصب البيولوجي	68
(4-2)	العصب الاصطناعي	69
(5-2)	العلاقة بين الشبكة والطبقات، وظيفة الخسارة، وخوارزميات التحسين	75
(6-2)	رسم تخطيطي لعملية تهيئة الوزن	76
(7-2)	الرسم البياني لدالة التنشيط الثنائية	79
(8-2)	الرسم البياني لدالة التنشيط الخطية	80
(9-2)	رسم تخطيطي لدالة التنشيط السينية	81
(10-2)	رسم تخطيطي يوضح دالة التنشيط الظل الزائدي	81
(11-2)	رسم تخطيطي لدالة التنشيط ReLU	82
(12-2)	رسم تخطيطي لدالة التنشيط LeakyReLU	83
(13-2)	رسم تخطيطي لدالة التنشيط PReLU	84
(14-2)	رسم تخطيطي لدالة التنشيط SWISH	85
(15-2)	خوارزمية نزول التدرج	88
(16-2)	رسم بياني لدالة SGD	90
(17-2)	مقارنة خوارزمية SGD مع الزخم وبدونه	91

قائمة الأشكال

94	هيكلية الشبكة العصبية متعددة الطبقات MLP	(18-2)
95	هيكلية الشبكة ذات الأساس الإشعاعي RBFN	(19-2)
96	هيكلية الشبكة العصبية المتكررة RNNs	(20-2)
97	البنية الهيكلية لشبكة الذاكرة الطويلة LSTM	(21-2)
98	معمارية شبكة GRNN	(22-2)
99	بنية الشبكة العصبية العميقة DNN	(23-2)
100	بنية شبكة NARX	(24-2)
101	بنية نموذج المحول Transformer	(25-2)
124	التقلبات الشرطية باستخدام نموذج التقلبات العشوائية	(1-3)
128	منحنى تطور أسعار أسهم مؤشر BIST100 خلال فترة الدراسة	(2-3)
129	منحنى تطور عوائد أسهم مؤشر BIST100 خلال فترة الدراسة	(3-3)
145	منحنى خسارة النموذج أثناء عمليتي التدريب والتحقق	(4-3)
153	مقارنة بين الأسعار الفعلية والمتنبئ بها لمؤشر BIST100 خلال ديسمبر 2024	(5-3)

قائمة الجداول

قائمة الجداول

الرقم	عنوان الجدول	الصفحة
(1-3)	عدد الشركات المدرجة في سوق إسطنبول للأوراق المتداولة حسب القطاعات لسنة 2025	117
(2-3)	الوصف الإحصائي لأسعار التداول لمؤشر BIST100	131
(3-3)	قيم الارتباط للمؤشرات المالية اليومية بسعر إغلاق أسهم مؤشر BIST100	133
(4-3)	تقسيم بيانات الدراسة	139
(5-3)	مكونات هيكلية الشبكة العصبية الاصطناعية المستخدمة	142
(6-3)	نتائج تقييم النموذج المستخدم في الدراسة على بيانات الاختبار	150
(7-3)	نتائج تقييم النموذج المستخدم في التنبؤ بقيمة مؤشر BIST100 خلال شهر ديسمبر 2024	155
(8-3)	تحليل القيمة المعرضة للخطر المشروطة ونسبة الخطأ فيها	158

قائمة الاختصارات والرموز

قائمة الاختصارات والرموز

الرمز	الدلالة
β_i	معامل بيتا (معامل المخاطرة)
λ	معلمة محددة مسبقا في النطاق (0، 1)
σ	الانحراف المعياري
$v = \sigma^2$	معامل الاختلاف أو التباين
ε_i^2	مربع الخطأ العشوائي
α	معامل تنعيم
ξ	معامل الشكل Shape Parameter
μ	متوسط الأسعار خلال النافذة الزمنية المختارة
θ_{new}	الوضع التالي
θ_{old}	الوضع الحالي
$\propto$	مستوى الثقة أو المعنوية
η	معدل التعلم أو حجم الخطوة
$\Delta_{\theta} J(\theta)$	اتجاه الزيادة الأسرع
$\nabla J(W)$	يمثل التدرج لوظيفة التكلفة بالنسبة للأوزان
A	
AD	التوزيعات المعلن عنها
AVS	القيمة المحاسبية للسهم
ARIMA	نماذج المتوسط المتحرك التكاملي ذاتي الانحدار البسيط
ARCH	نماذج الانحدار الذاتي ذو التباين الشرطي غير المتجانس
ANN	الشبكات العصبية الاصطناعية
AdaGrad	الهبوط التدريجي التكيفي
AdaDelta	دلتا التكيفية
Adam	تقدير اللحظة التكيفية
AdamW	دالة تقدير اللحظة التكيفية مع تحليل الأوزان المنفصل

قائمة الاختصارات والرموز

الذكاء الاصطناعي	AI
B	
عائد السهم الأساسي	Basic EPS
القيمة الدفترية للأموال الخاصة	BVPf
مقدار التحيز Bias	Bi
نزول التدرج الكتلي	BGD
C	
الأموال الخاصة	CP
التبيان المشترك لعائد السهم ولعائد السوق	$COV(R_i, R_M)$
نموذج تسعير الأصول المالية	CAPM
القيمة المعرضة للخطر المشروطة	CVAR
بورصة شيكاغو للخيارات	CBOE
D	
الأرباح الصافية الموزعة خلال الفترة t	D_t
الطلب	d
عائد السهم المخفف	Diluted EPS
تعديلات للأوراق المالية المخففة	DSA
الربح الموزع للسهم	DPS
معدل التوزيع	DPR
مردودية السهم	DY
الديون المالية	D
أشجار القرار	DT
التعلم العميق	DL
خوارزمية تدرج السياسة الحتمية العميقة	DDPG
الشبكة العصبية العميقة	DNN

قائمة الاختصارات والرموز

الشبكات العصبية العميقة	DNNs
E	
الأمل الرياضي	$E(R_i)$
معدل التضخم المتوقع	$E(I)$
ربحية السهم	EPS
نموذج GARCH الآسي	EGARCH
العائد المتوقع على محفظة سوق الأوراق المالية	$E(R_m)$
التوقع الشرطي للخسائر التي تتجاوز القيمة المعرضة للخطر	$E[L L \geq VAR_{\alpha}(L)]$
العجز المتوقع	ES
المتوسط المتحرك الآسي لسبعة أيام سابقة	EMA7
المتوسط المتحرك الآسي لأربعة عشر يوم سابقة	EMA14
القيم المتطرفة أو الشاذة	EVS
F	
الرفع المالي	FL
شبكة التغذية الأمامية	FFN
شبكات التغذية الخلفية	FBN
G	
نموذج ARCH المعمم	GARCH
نزول المتدرج	GD
الشبكة العصبية للانحدار العام	GRNN
I	
معدل الفائدة	i
الفرق بين الربع الأول والربع الثالث	IQR
K	
خوارزمية k الجيران الأقرب	KNN

قائمة الاختصارات والرموز

عدد الفئات الممكنة (وحدة معالجة)	K
L	
الخسارة العشوائية	L
الانحدار الخطي	LR
شبكة الذاكرة طويلة المدى	LSTM
M	
التعلم الآلي	ML
متوسط الخطأ التربيعي	MSE
الخطأ المطلق المتوسط	MAE
متوسط النسبة المئوية للخطأ المطلق	$MAPE$
نزول التدرج مصغر الدفعات	MBGD
شبكة الإدراك الحسي متعددة الطبقات	MLP
N	
عدد الفترات (يوم، سنة)	n
صافي الدخل المتاح للمساهمين العاديين	NIACS
صافي الربح بعد الضريبة	NPAT
عدد الأسهم العادية المسجلة في الشركة	NOSRC
الربح الصافي المتاح لحملة الأسهم العادية	NPACS
الربح الصافي	NR
شبكة الانحدار الذاتي غير الخطية ذات المدخلات الخارجية	NARX
بورصة نيويورك	NYSE
القيم المفقودة	NaN
P	
احتمالية حدوث العائد	P_i
السعر في اللحظة الزمنية الحالية t	P_t

قائمة الاختصارات والرموز

السعري في اللحظة الزمنية السابقة t-1	P_{t-1}
توزيعات الأسهم الممتازة	PSD
مضاعف سعر السهم	PER
مضاعف القيمة الدفترية	PBR
الخسائر المحتملة	$P(L)$
تحليل المكونات الرئيسية	PCA
قدرة التنبؤ بالاتجاه	PCD
دالة ReLU البارامترية	PRelu
Q	
مستوى الطلب	Q
R	
معدل العائد المتوقع	$\bar{R}_i$
العائد الفعلي	R_i
معدل العائد الخالي من المخاطرة	R_f
معدل العائد الاسمي	R_n
معدل العائد على الأصول	ROA
النتيجة قبل الفوائد والضريبة	RbIT
معدل العائد على حقوق الملكية	ROE
معدل العائد على الاستثمار	ROI
المردودية المالية	RF
المردودية الاقتصادية	RE
مردودية السوق	R_m
المردودية المتوسطة للسوق	$\bar{R}_m$
دالة الوحدة الخطية المصححة أو المعدلة	ReLU
جذر متوسط الخطأ التربيعي	RMSE

قائمة الاختصارات والرموز

جذر متوسط مربع الانتشار	RMSProp
الشبكة ذات الأساس الإشعاعي	RBFN
الشبكات العصبية المتكررة	RNNS
معامل التحديد	R^2
S	
العرض	s
الرسملة البورصية	SMC
معدل دوران السهم	ST
نموذج التقلبات العشوائية	SV
آلية ناقلات الدعم	SVM
نزول التدرج العشوائي	SGD
الانحراف المعياري لسبعة أيام سابقة	Std7
الانحراف المعياري لأربعة عشر يوم سابقة	Std14
T	
مجموع الأصول	TAS
مجموع حقوق الملكية	TE
معدل الضريبة	t
خوارزمية تضمين الجار العشوائي الموزع	T-SNE
دالة الظل الزائدي	Tanh
V	
تباين عائد السوق	$V(R_m)$
القيمة المعرضة للخطر	VAR
سوق العقود الآجلة والخيارات التركي	VIOP
W	
المتوسط المرجح لعدد الأسهم العادية القائمة أو المتداولة	WANCSO

قائمة الاختصارات والرموز

المتوسط المرجح لعدد الأسهم المصدرة من الأوراق المالية المخفضة	WANSIDS
تمثل الوزن الذي يربط وحدة المعالجة k بالوحدة j الموجودة في الطبقة السابقة	W_{kj}
X	
القيمة المدخلة القادمة من الوحدة j والداخلية إلى الوحدة k	X_j
مؤشر BIST100	XU100
القيمة الأصلية	X
الميزات الذاتية التاريخية	X_{ar}
الميزات الخارجية	X_{exog}
Y	
ناتج عملية الجمع لكل وحدة معالجة k	Y_k
القيمة الحقيقية أو الخرج المطلوب للنقطة i	y_i
القيمة المتوقعة للنموذج للنقطة i	$\hat{y}_i$
المتوسط الحسابي للقيم الحقيقية	$\bar{y}$
Z	
قيمة المدخل للفئة i	z_i

مقدمة

تعتبر الأسواق المالية جزء مهم من الاقتصاد الحديث ومن الركائز الأساسية التي يقوم عليها، إذ تلعب دورا حيويا في تعبئة المدخرات وتوجيهها نحو الأنشطة الإنتاجية، كما تشكل هذه الأسواق حلقة وصل فعالة بين المدخرين والمستثمرين من خلال توفير أدوات مالية متنوعة وقنوات تمويل فعالة وآليات مرنة تمكن الشركات من الحصول على رأس المال اللازم لتوسيع أنشطتها ومشاريعها، إلى جانب كونها وجهة رئيسية للمستثمرين الساعين إلى تحقيق عوائد مجزية، ومن بين الأدوات الاستثمارية المتاحة يبرز الاستثمار في الأسهم باعتباره أحد أكثر الأشكال شيوعا وانتشارا لما يقدمه من فرص لتحقيق أرباح معتبرة، خاصة للمستثمرين الذين يتمتعون برؤية تحليلية وفهم جيد لتوجهات السوق، وتزداد فعالية هذا النوع من الاستثمار عندما يتم وفق منهجيات علمية مدروسة توازن بين معدل العائد الذي يمكن تحقيقه من وراء هذا الاستثمار باعتباره المحدد الرئيسي لجاذبية السهم وبين المخاطرة المصاحبة له والتي لا يمكن فصلها عنه، مما يجعل من الضروري تقييم العلاقة بين العائد والمخاطرة ضمن إطار من التحليل الكمي.

إن هذا النوع من الاستثمار لا يخلو من التحديات إذ تتسم أسعار الأسهم بطبيعتها غير المستقرة والتقلبات المتكررة والمستمرة نتيجة لاستجابتها بشكل سريع للظروف والأحداث وتأثرها بعدة عوامل، منها ما هو اقتصادي أو مالي ومنها ما يرتبط بسلوكيات المستثمرين والأحداث الجيوسياسية، وتمثل هذه التقلبات في الأسعار انعكاسا لمستوى المخاطر الكامنة في الأسواق، وقد تكون حادة ومفاجئة أحيانا ما يؤدي إلى خسائر كبيرة للمستثمرين، مما يجعل من الضروري امتلاك أدوات تحليل قادرة على فهم الأنماط السائدة واستشراف التحركات المستقبلية للأسعار بدقة وموضوعية، والقدرة على فهم وقياس التقلبات يعد أمرا حيويا ليس فقط لاتخاذ قرارات استثمارية أكثر وعيا ولكن لتحليل السيناريوهات المحتملة واتخاذ تدابير وقائية وتحليل العوامل واستخلاص الاتجاهات المستقبلية الذي يتطلب أدوات دقيقة قادرة على استيعاب التعقيد العالي للبيانات.

وفي هذا الإطار يعد التنبؤ بتقلبات أسعار الأسهم من الموضوعات التي حظيت باهتمام متزايد من قبل الباحثين والممارسين في المجال المالي، نظرا لما يوفره من إمكانيات لتحسين القرارات الاستثمارية والحد من عنصر المفاجأة، فالتنبؤ الدقيق يمكن المستثمرين من اتخاذ قرارات مدروسة مبنية على توقعات دقيقة تساعد على تكوين رؤية استباقية للاتجاهات المستقبلية، ومع ذلك فإن التنبؤ بتقلبات أسعار الأسهم يظل تحديا كبيرا نظرا للطبيعة الديناميكية للأسواق المالية والتأثير العشوائي لبعض المتغيرات غير القابلة للقياس بسهولة، ولذلك قد جرى استحداث العديد من الأدوات والنماذج التي تهدف للوصول إلى أكبر دقة في التنبؤ تراوحت هذه الطرق بين البسيطة التي تعتمد على التقديرات الشخصية والأساليب التقليدية كالنماذج الإحصائية والرياضية وصولا إلى التقنيات الحديثة التي تعتمد على الذكاء الاصطناعي ومع تطور هذه التقنيات ظهرت ما تعرف بالشبكات

العصبية الاصطناعية والتي تعد واحدة من أبرز الأدوات المعتمدة في التنبؤ المالي، لما لها من قدرة عالية على معالجة البيانات المعقدة والتعرف على الأنماط غير الخطية التي يصعب على النماذج التقليدية رصدها.

ومع ذلك فإن التنبؤ وحده لا يكفي ما لم يكن مصحوبا بفهم عميق لكيفية إدارة المخاطر المالية الناتجة عن تلك التقلبات، ففي ظل التطورات المتسارعة التي يشهدها العالم المالي والتكنولوجي وفي بيئة مالية تتسم بعدم اليقين أصبحت إدارة المخاطر عنصرا محوريا في الحفاظ على الاستقرار المالي على مستوى المستثمرين سواء كانوا أفراد أو شركات، وهنا تبرز أهمية استخدام أدوات متقدمة في تقدير الخسائر المحتملة ضمن أفق زمني محدد كالقيمة المعرضة للخطر VAR والقيمة المعرضة للخطر المشروطة CVAR، ورغم فعالية وقدرة هذه الأدوات في قياس المخاطر المالية إلا أن النتائج تعتمد بشكل كبير على دقة التنبؤ بالتقلبات، ومن هذا المنطلق تسعى هذه الدراسة إلى الربط بين التنبؤ بتقلبات أسعار الأسهم باستخدام الشبكات العصبية الاصطناعية وتقدير المخاطر المالية من خلال نماذج القيمة المعرضة للخطر بهدف المساهمة في تطوير أدوات فعالة لاتخاذ قرارات استثمارية أكثر أمانا وكفاءة.

أولا: إشكالية الدراسة

إن الدمج بين التنبؤ بتقلبات أسعار الأسهم وقياس المخاطر باستخدام القيمة المعرضة للخطر المشروطة CVAR يقدم منظورا حديثا ومتقدما لإدارة المخاطر، فمن خلال استخدام النماذج التنبؤية يمكن تحديد المدى المتوقع لتقلب الأسعار ومن ثم الاعتماد على هذه المعلومات لحساب تأثيرها على المخاطر المالية باستخدام CVAR إذ الغرض الوصول لإطار تنبؤي تحليلي متكامل يعزز من كفاءة إدارة المخاطر المالية ويساهم في تحقيق استقرار مالي سواء قصير أو طويل الأجل.

ومن هنا نطرح الإشكالية الرئيسية التالية:

ما مدى دقة التنبؤ بتقلبات أسعار أسهم مؤشر BIST100 باستخدام الشبكات العصبية الاصطناعية في إدارة المخاطر المالية بسوق إسطنبول للأوراق المالية؟

وانطلاقا من الإشكالية الرئيسية نطرح التساؤلات التالية:

- ماهي طرق التنبؤ بتقلبات أسعار الأسهم؟
- ماهي أهم الأدوات والأساليب المستخدمة في قياس وإدارة المخاطر المالية؟
- ما مدى دقة نماذج الشبكات العصبية الاصطناعية في التنبؤ بتقلبات أسعار أسهم مؤشر BIST100؟

- كيف يمكن استغلال هذه التنبؤات في قياس القيمة المعرضة للخطر المشروطة CVAR وإدارة المخاطر المرتبطة بالاستثمار في الأسهم ببورصة إسطنبول للأوراق المالية؟

ثانيا: فرضيات الدراسة

وفقا لما جاء في إشكالية الدراسة من تساؤلات وتحقيقا لأهدافها يمكن وضع الفرضيات التالية:

- 1- الفرضية الفرعية الأولى: ظهرت العديد من الطرق الحديثة للتنبؤ بتقلبات أسعار الأسهم التي تتميز بقدرتها على استيعاب الأنماط الزمنية المعقدة للسلاسل الزمنية والتعامل مع العلاقات غير الخطية.
- 2- الفرضية الفرعية الثانية: تعتبر القيمة المعرضة للخطر VAR والقيمة المعرضة للخطر المشروطة CVAR أهم الأدوات الحديثة والمتقدمة التي تستخدم في قياس وإدارة المخاطر المالية.
- 3- الفرضية الفرعية الثالثة: تقدم الشبكات العصبية الاصطناعية دقة عالية في التنبؤ بتقلبات أسعار أسهم مؤشر BIST100.
- 4- الفرضية الفرعية الرابعة: يمكن استغلال التنبؤات بالقيم المستقبلية لمؤشر BIST100 الناتجة عن نماذج الشبكات العصبية الاصطناعية في تحسين قرارات إدارة المخاطر المالية.

ثالثا: أهمية الدراسة

إن إدراك وفهم العلاقة بين التنبؤ بتقلبات أسعار الأسهم واستخدام هذه التنبؤات في إدارة المخاطر المالية عن طريق قياس القيمة المعرضة للخطر المشروطة CVAR يمثل اضافة علمية مهمة واسهاما فعالا في مجال الإدارة المالية، فهذا البحث من جهة يوفر فهما أعمق لتقلبات الأسواق والمخاطر المالية المرتبطة بها، ومن جهة أخرى، فإنه يقدم أداة عملية تساعد في تحسين التخطيط الاستثماري وتقليل المخاطر، وما يميز هذه الدراسة هو الدمج بين الجوانب النظرية والمفاهيم التقليدية في علم المالية والتقنيات الحديثة كالشبكات العصبية الاصطناعية، مما يعزز القدرة على معالجة البيانات بكفاءة وقياس المخاطر المالية وتقديم حلول دقيقة للتحديات الراهنة في الأسواق المالية.

رابعا: أهداف الدراسة

تهدف هذه الدراسة إلى معرفة دور التنبؤ بتقلبات أسعار الأسهم في إدارة المخاطر المالية باستخدام الشبكات العصبية الاصطناعية، وذلك من خلال:

- تطوير نموذج تكاملي يجمع بين التحليل الكمي باستخدام الأدوات الإحصائية والشبكات العصبية الاصطناعية لتقديم رؤية شاملة حول ديناميكيات الأسواق وأدوات قياس المخاطر.
- تطوير نموذج تنبؤي يعتمد على نماذج الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم مؤشر BIST100 بشكل دقيق وفعال.
- توظيف نتائج النموذج العصبي للتنبؤ بأسعار الأسهم كمدخل لحساب القيمة المعرضة للخطر المشروطة CVAR مما يخلق إطارا متكاملًا وهيكليًا شاملاً لتحليل وإدارة المخاطر المالية.
- تقييم دور البيانات التاريخية في تقديم توقعات موثوقة عن الأداء المستقبلي للأسهم وتوظيف هذه البيانات في إدارة المخاطر المالية.
- تصميم نموذج يقدم قيمة مضافة للممارسين في الأسواق المالية وتقديم إطار عملي يمكن تطبيقه لتوقع التغيرات المفاجئة في الأسواق المالية والتعامل مع الأحداث المالية النادرة بفعالية، وبذلك مساعدتهم في اتخاذ قرارات استثمارية أكثر وعياً وتقليل التعرض للمخاطر المالية.

خامساً: منهج وحدود الدراسة

تم استخدام المنهج الوصفي التحليلي وذلك لعرض معلومات حول التنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية ونماذج الذكاء الاصطناعي خاصة الشبكات العصبية الاصطناعية المستخدمة في الدراسة، بالإضافة إلى الأساليب الإحصائية المستخدمة لوصف تطور الأسعار والعوائد، وتم بناء وتنفيذ نموذج الشبكات العصبية الاصطناعية على منصة Anaconda Navigator باستخدام لغة البرمجة Python بالاعتماد على مجموعة من المكتبات التابعة لها أهمها: Keras، Tensorflow، Pandas، Numpy، Scikit-learn.

تمثل مجتمع الدراسة في سوق إسطنبول للأوراق المالية، أما عينة الدراسة فركزت على أسعار أسهم مؤشر BIST100 باعتباره المؤشر الرئيسي والأهم في بورصة إسطنبول، تركيا، تم الحصول على بيانات الدراسة من موقع Investing، والتي تمثلت في أسعار الإغلاق والعوائد اليومية للفترة من 3 جانفي 2001 إلى غاية 30 نوفمبر 2024 بمجموع 8765 صف و37 عمود تمثل ميزات الإدخال والإخراج للشبكة العصبية الاصطناعية، إذ قسمت البيانات إلى مجموعات كعينة تدريب، وعينة تحقق، وعينة اختبار، والتنبؤ بفترة 30 يوم التالية لفترة الدراسة أي من 2 إلى 31 ديسمبر 2024.

سادسا: الدراسات السابقة

يتم التركيز في هذا القسم على أهم الدراسات السابقة المتعلقة بموضوع الدراسة الحالية:

1. الدراسات العربية

1. دراسة (مروان جمعة درويش، 2019) مقال منشور بعنوان فعالية التنبؤ بمؤشر بورصة فلسطين باستخدام نموذج الشبكات العصبية الاصطناعية مقارنة بنموذج الانحدار الذاتي:

هدفت الدراسة بشكل أساسي إلى إيجاد النموذج الأكثر نجاعة في التنبؤ بمؤشر القدس للبورصة الفلسطينية من خلال المقارنة بين نموذج الانحدار الذاتي والشبكات العصبية، تمثل مجتمع الدراسة بسوق فلسطين للأوراق المالية فيما اقتصر العينة على أسعار الإغلاق اليومية لمؤشر القدس للفترة من 2010/1/3 إلى 2018/2/28 إذ بلغت 1986 مشاهدة، تبنت الدراسة المنهج الوصفي التحليلي بهدف دراسة المتغيرات التي تؤثر بمؤشر سوق فلسطين للأوراق المالية، وقد استخدمت الدراسة أسلوب الانحدار الذاتي والشبكات العصبية في عملية التنبؤ، وقد جرى تنفيذ الدراسة التطبيقية بواسطة برنامج SPSS، EvIEWS9 و Alyuda و Neurointelligence، وكمعيار لتقييم الخطأ في الشبكة العصبية الاصطناعية تم استخدام مجموع مربعات الأخطاء MSE، نتائج الدراسة المتوصل إليها أثبتت تفوق الشبكات العصبية على أسلوب الانحدار الذاتي في التنبؤ بمؤشر سوق فلسطين إذ كانت نتائج الشبكات العصبية مقارنة بأسلوب الانحدار الذاتي أكثر دقة وبمعدل خطأ أقل.

2. دراسة (أهم محمود الحميد، 2020) أطروحة مقدمة لنيل درجة الدكتوراه بعنوان الكفاءة السعرية والتنبؤ بمؤشر السوق المالي باستخدام النماذج القياسية والشبكات العصبونية الاصطناعية (دراسة مقارنة بين سوق دمشق للأوراق المالية وبعض أسواق المال العربية):

هدفت الدراسة إلى إيجاد نموذج للتنبؤ بمؤشر سوق دمشق للأوراق المالية ومؤشرات الأسواق العربية لتقييم الكفاءة السعرية لهذه الأسواق من خلال المقارنة بين عدة أساليب، هي النماذج القياسية والنماذج الهجينة والشبكات العصبية الاصطناعية، يتمثل مجتمع الدراسة بالأسواق المالية العربية أما عينة الدراسة فتمثلت بأسعار الإغلاق لسبعة أسواق عربية بالإضافة لسوق دمشق للأوراق المالية وهي كل من سوق مسقط، بورصة بيروت، بورصة الأوراق المالية التونسية، بورصة عمان، سوق دبي، بورصة البحرين، سوق الأسهم السعودي، للفترة من 2015/1/1 إلى 2020/1/1 بواقع 1250 مشاهدة، استخدمت الدراسة في تحليل كفاءة أسواق المال وجمع البيانات على المنهج الوصفي التحليلي، أما في الدراسة التطبيقية فاعتمدت على النماذج

القياسية ARIMA، GARCH، الشبكات العصبية الاصطناعية، وقد تم استخدام برنامج Matlab و Eviews9 لتنفيذ الدراسة التي توصلت إلى أن النموذج الهجين (GARCH-ARIMA-ANN) هو الأفضل في التنبؤ بمؤشرات جميع الأسواق المدروسة بالمقارنة مع نتائج النماذج بشكل منفرد، واستنتجت الدراسة تفوق الشبكات العصبية على النماذج القياسية في قدرتها على التنبؤ.

3. دراسة (حاووط، 2020) مقال منشور بعنوان استخدام المؤشرات الفنية والشبكات العصبونية للتنبؤ بحركة أسعار الأسهم دراسة تطبيقية على بورصة عمان:

هدفت الدراسة لمحاولة بناء نموذج شبكة عصبية قادر على اكتشاف الأنماط المخفية في البيانات التاريخية للأسعار والتنبؤ بالقيم المستقبلية لها بغرض الاستفادة من ذلك في دعم قرارات الاستثمار في الأسواق المالية، اعتمدت الدراسة على المنهج التحليلي، حيث استخدمت نموذج الشبكات العصبية من نوع MLP باستعمال أداة WEKA، وتمثل مجتمع الدراسة بجميع الشركات المدرجة في سوق عمان للأوراق المالية أما عينة الدراسة تتمثل في مجموعة البيانات التاريخية الخاصة بالبنك الأردني الإسلامي للفترة من 2017 إلى 2018، وقد تم اختبار دقة النموذج من خلال بعض المقاييس الإحصائية وهي كل من Kappa و ROC Area، الدراسة استنتجت أن نموذج الشبكات العصبية كفى وفعال في توقع أسعار الأسهم ونتيجة لذلك يمكن الاعتماد على تلك النتائج في دعم وتعزيز مختلف القرارات الاستثمارية.

4. دراسة (ليث حليم مالك الحجيمي، 2022) رسالة مقدمة لنيل درجة الماجستير بعنوان التنبؤ بأسعار الأسهم باستخدام الشبكات العصبية الاصطناعية: دراسة لعينة من الشركات المدرجة في سوق العراق للأوراق المالية:

ركزت الدراسة على التنبؤ بأسعار الأسهم متمثلةً بأسعار الإغلاق اليومية باستخدام نموذج مطور من الشبكات العصبية الاصطناعية يتمثل في نموذج شبكة الذاكرة الطويلة لمساعدة المستثمرين في اتخاذ قرار الاستثمار بالأسهم، تمثل مجتمع الدراسة بشركات القطاعين المصرفي والصناعي المدرجة في سوق العراق للأوراق المالية، فيما اقتضت عينة الدراسة على 8 شركات توزعت بين 4 مصارف و 4 شركات صناعية لمدة سنتين وثلاثة أشهر من 2020/1/2 إلى 2022/3/31 بشكل يومي بواقع أربع مشاهدات أسبوعياً، انتهجت الدراسة أسلوباً تحليلياً للمقارنة بين نموذجين لشبكة الذاكرة الطويلة، الأول أحادي المتغير يعتمد على سلسلة أسعار الإغلاق السابقة، والثاني متعدد المتغيرات يعتمد على مجموعة من مؤشرات التداول اليومية للأسهم عينة الدراسة، تتمثل مقاييس الأداء التي اعتمدت عليها الدراسة في كل من متوسط الخطأ التربيعي Mean Squared Error (MSE) ومعامل الارتباط (R) Correlation Coefficient وجذر متوسط الخطأ التربيعي Root Mean Squared Error

Error (RMSE) للمفاضلة بين النموذجين وترشيح الأمثل بينهما، أهم النتائج التي توصلت إليها الدراسة فاعلية نماذج شبكة الذاكرة الطويلة كافة، كما أن النموذج أحادي المتغير مقارنة بالنموذج متعدد المتغيرات أكثر دقة للتنبؤ بأسعار الإغلاق للأسهم عينة الدراسة.

II. الدراسات الأجنبية

1. دراسة (Vijh et al., 2020) مقال منشور بعنوان Stock Closing Price Prediction using Machine Learning Techniques:

هدف الدراسة يتلخص في محاولة إيجاد النموذج الأمثل للتنبؤ بأسعار الإغلاق في اليوم التالي للأسهم خمس شركات تنتمي لقطاعات تشغيل مختلفة من خلال المقارنة بين إثنين من تقنيات التعلم الآلي، يتمثل مجتمع الدراسة بالقطاع الصناعي الأمريكي فيما تتمثل عينة الدراسة بخمس شركات في قطاعات صناعية مختلفة إذ كانت البيانات التاريخية للعينة من 2009/5/4 إلى 2019/5/4 بواقع عشر سنوات وبمعدل يومي، استخدمت الدراسة تقنية الشبكات العصبية وتقنية الغابات العشوائية للتنبؤ بسعر الإغلاق لليوم التالي، وبعض البيانات المالية كأسعار الافتتاح والارتفاع والانخفاض والإغلاق للأسهم وحجم التداول تستخدم كمدخلات للنموذج، وللمقارنة بين التقنيتين اعتمدت على الأسلوب التحليلي، وتم تقييم النماذج عن طريق حساب المؤشرات القياسية MAPE و RMSE، الدراسة أثبتت أن كلا النموذجين فعال في التنبؤ بأسعار الإغلاق وببدا أن نتائج المقارنة أوضحت تفوق نموذج الشبكات العصبية الاصطناعية على نموذج الغابات العشوائية.

2. دراسة (Arian et al., 2020) مقال منشور بعنوان Encoded Value-at-Risk: A Predictive Machine for Financial Risk Management:

هدفت هذه الدراسة لتقديم نهج جديد متقدم لقياس مخاطر السوق أطلق عليه اسم القيمة المشفرة المعرضة للخطر Encoded VAR، التي استخدمت فيها نوع من الشبكات العصبية الاصطناعية تسمى أجهزة التشفير التلقائي المتغيرة VAEs والتي تعتبر آلة تنبؤية لإدارة المخاطر المالية، عينة الدراسة تتكون من ثلاث محافظ مالية لثلاثة أسواق مختلفة، المحفظة الأولى تتكون من 346 سهما مدرجا في مؤشر S&P500 من 11 ديسمبر 1998 إلى 27 مارس 2018 بواقع 4853 مشاهدة، والثانية تتكون من 191 سهما من بورصة لندن LSE من 27 جويلية 2000 إلى 5 ديسمبر 2019 بواقع 4754 مشاهدة، والثالثة 82 سهما من بورصة فرانكفورت FSE من 2 جانفي 2001 إلى 29 أكتوبر 2019، النتائج المتحصل عليها تمت مقارنتها مع نتائج إحدى عشرة طريقة أخرى وتوصلت إلى أن القيمة المشفرة المعرضة للخطر قادرة على المنافسة مع العديد من الخوارزميات الأخرى.

3. دراسة (Chandrika & Srinivasan, 2021) مقال منشور بعنوان Predicting Stock Market Movements Using Artificial Neural Networks

تسعى هذه الدراسة إلى تطبيق واستخدام تقنيات التعلم العميق للشبكة العصبية الاصطناعية في مجال التنبؤ بمؤشرات الأسواق المالية، إذ تتكون عينة الدراسة من أسعار الافتتاح، أسعار الإغلاق، أعلى سعر، أدنى سعر، والحجم لمجموعة من مؤشرات الأسواق المالية العالمية والتي تضمنت S&P500، NIFTY50، NYSE، Dow Jones Index، Korean Stock Index، و Shanghai Stock Index بواقع 1324 مشاهدة للفترة من جانفي 2015 إلى ماي 2020، اعتمدت الدراسة المنهج التحليلي وجرى استخدام تقنيات التعلم العميق للشبكات العصبية حيث تبنت نوعين من الشبكات العصبية هما ANN و RNN ولتقييم أداء الشبكات العصبية استعملت أربع مقاييس هي Accuracy، F1 Score، Recall، Precision، توصلت نتائج الدراسة إلى أن الشبكات العصبية الاصطناعية قادرة على التعامل مع الأحداث والعوامل غير المتوقعة في البيانات على المدى القصير لا سيما وأن الدراسة أجريت في ظل جائحة كورونا المستجد.

4. دراسة (Fatouros et al., 2023) مقال منشور بعنوان DeepVaR: A Framework for Portfolio Risk Assessment Leveraging Probabilistic Deep Neural Networks

تم تقديم في هذه الدراسة نهجا احتماليا للتعلم العميق مع الاستفادة من تقنيات التنبؤ بالسلاسل الزمنية ذات الإمكانات العالية لرصد مخاطر محفظة معينة بطريقة فعالة للغاية، سمي هذا النهج DeepVaR والذي يستفيد من الشبكات العميقة، تم اختيار أربعة أدوات فوركس FX هي AUDUSD، GBPUSD، USDJPY، EURUSD ذات السيولة الأعلى بين الأسواق ذات الصلة كعينة أساسية للتحليل، وتتراوح الفترة الزمنية من 2007/1/1 إلى 2020/12/18، تمت مقارنة نتائج الشبكة العصبية العميقة الاحتمالية مع النماذج الأساسية وهي النماذج البارامترية وشبه البارامترية وغير البارامترية لتقدير القيمة المعرضة للخطر، إذ توصلت الدراسة إلى أن النموذج المقترح أكثر فعالية من غيره ويوفر نتائج أفضل من حيث مقاييس التقييم المستخدمة.

5. دراسة (Buczynski & Chlebus, 2024) مقال منشور بعنوان GARCHNet: Value-at-Risk Forecasting with GARCH Models Based on Neural Networks

تم تقديم نهج جديد غير الخطي للتباين الشرطي يجمع بين طريقة التقدير بأقصى الاحتمالات في نموذج التقلبات الذاتية المشروطة المعمم GARCH مع بنية الشبكة العصبية ذات الذاكرة طويلة المدى LSTM، وذلك للتنبؤ بالقيمة المعرضة للخطر VAR، استخدمت العوائد اللوغاريتمية للمؤشرات التالية: S&P500، WIG20،

FTSE100، عبر أربع فترات زمنية مختلفة من عام 2005 إلى 2021 مع مستويات مختلفة من التقلبات المرصودة والمسجلة، توصلت الدراسة بعد مقارنة نتائج النموذج المقترح مع نتائج نموذج GARCH الأصلي إلى أن النموذج GARCHNet نموذج متميز قادر على توليد تنبؤات ذات جودة أو أفضل من نموذج GARCH الأصلي.

من خلال عرض الدراسات السابقة يعتقد أن الدراسة الحالية تميزت كونها أول الدراسات على مستوى سوق إسطنبول للأوراق المالية في استخدام الشبكات العصبية الاصطناعية للتنبؤ بأسعار أسهم مؤشر BIST100، إذ تم التركيز على هذا المؤشر وعلى قدرة النموذج المستخدم على التكيف مع الأسواق الناشئة والتي غالبا ما تظهر خصائص فريدة مقارنة بالأسواق الناضجة، بالإضافة إلى أن هذه الدراسة تقدم مساهمة جديدة من خلال دمج التحليلات التنبؤية مع إدارة المخاطر المالية لإنشاء إطار قوي لإدارة المخاطر وعدم اليقين المالي، أيضا غطت الدراسة فترة طويلة جدا امتدت لما يقارب 24 سنة من 2001/01/03 إلى 2024/11/30 مشاهدات يومية، وتنبأت بأسعار الأسهم لثلاثين 30 يوم التالية وهذا بشكل لم تقدمه من قبل، كما أن الدراسة طبقت نوعا من الشبكات العصبية لم يتم تطبيقه في الدراسات السابقة، وأيضا قدمت الدراسة تطبيقا عمليا يمكن تحويله إلى برنامج على الحاسوب أو الهاتف المحمول يخدم المستثمرين والمحللين الماليين بصورة سريعة ومباشرة ويقلل من الجهد المبذول والتكلفة المطلوبة للتنبؤ بأسعار الأسهم وإدارة مخاطرها المالية.

سابعاً: هيكل الدراسة

للإجابة على الإشكالية المطروحة وما انبثق منها من أسئلة فرعية واختبار صحة الفرضيات وتحقيقاً للأهداف المسطرة تم تقسيم الدراسة إلى ثلاث فصول، فصلين نظريين وفصل تطبيقي تسبقهم مقدمة عن الموضوع، إذ يستعرض الفصل الأول أساسيات حول التنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية تمثل في تقديم مفاهيم أساسية حول الأسهم وتقلباتها وأهم العوامل المؤثرة فيها بالإضافة إلى النظريات المفسرة لها وأيضا النماذج المختلفة التي يتم استخدامها في التنبؤ بتقلبات أسعار الأسهم بعد تقديم مدخل بسيط لعملية التنبؤ بهذه التقلبات، ليتم اختتام هذا الفصل بماهية إدارة المخاطر المالية وأهم أساليب قياس مخاطر الاستثمار في الأسهم، أما الفصل الثاني خصص للشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار الأسهم تناول هذا الفصل التعرف على مختلف الأدبيات المتعلقة بالذكاء الاصطناعي وفهم شامل للشبكات العصبية الاصطناعية ودورها في التنبؤ المالي، وتقديم تفاصيل على نماذج الشبكات العصبية موضحاً أنواعها وآلية عملها، ويختتم الفصل بأهمية تطبيق الشبكات العصبية الاصطناعية في التنبؤ المالي مستعرضاً مزاياها وتحدياتها بالإضافة إلى خطوات تطبيقها، أما الفصل الثالث فقد خصص للدراسة التطبيقية لبناء الشبكة العصبية الاصطناعية للتنبؤ بتقلبات أسعار الأسهم واستعمال نتائج التنبؤ كمدخل لقياس المخاطر

المالية وقبل ذلك تقديم عام حول المنهجية المتبعة والبيانات المستخدمة ومدخلات الشبكة العصبية الاصطناعية، بالإضافة إلى خطوات تنفيذ عملية تدريب واختبار الشبكة وتقديم بنية النموذج المستخدم، ليتم اختتام الفصل بنتائج التنبؤ وقياس المخاطر المالية بالاعتماد على نموذج CVAR وتقديم أهم النتائج المتوصل لها، ليتم اختتام هذه الدراسة بخاتمة قدمت ملخص للنتائج النظرية والتطبيقية وتقديم توصيات وأفاق الدراسة.

الفصل الأول: الإطار النظري للتنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية.

المبحث الأول: أساسيات حول تقلبات أسعار الأسهم.

المبحث الثاني: التنبؤ بتقلبات أسعار الأسهم.

المبحث الثالث: إدارة المخاطر المالية.

تمهيد

نظرا لأن الأسهم أحد أقدم وأهم وسائل الاستثمار في الأسواق المالية، فأسعارها تمثل مؤشرا ماليا أساسيا يعكس أداء الشركات وتوقعات المستثمرين تجاه مستقبلها، ومع مرور الزمن أخذ الاستثمار في الأسهم يحتل قسما مهما في السوق المالي، فأصبح المستثمر يركز بشكل أساسي على معدل العائد الذي يتقاضاه مقابل تحمله لمستويات مقبولة من المخاطر، وبالتالي فإنه يحتاج لترشيد قراراته الاستثمارية وإلى إدارة فعالة لتقييم عوائد الأسهم وإدارة المخاطر المرتبطة بها، هذا من جهة، ومن جهة أخرى فإن أسعار الأسهم في الأسواق المالية ليست ثابتة بل معروفة بتقلبات مستمرة نتيجة تفاعل مجموعة من العوامل، مما يجعل دراسة وتحليل هذه التقلبات موضوعا محوريا في الأبحاث المالية، حيث سعى العديد من الباحثين إلى التعمق في طرق تحليل هذه التقلبات ومحاولة تطوير نماذج تنبؤية تستند إلى أساليب إحصائية ونماذج رياضية تسعى لتفسير وتحليل هذه التقلبات بهدف تحسين وزيادة دقة التنبؤات لاتخاذ قرارات استثمارية رشيدة وتقديم أدوات فعالة لإدارة المخاطر المالية المرتبطة بها، ومن هنا أصبح التنبؤ بتقلبات أسعار الأسهم ليس مجرد أداة لزيادة العوائد بل وسيلة فعالة لتقليل المخاطر المصاحبة للاستثمار في بيئة سوقية متغيرة وأحداث نادرة، مما يساهم في تحسين القدرة على فهم التغيرات السوقية واتخاذ القرار الاستثماري المناسب وبالتالي تعزيز أدوات إدارة المخاطر المالية لمواجهة التقلبات غير المتوقعة.

من هنا يستعرض هذا الفصل الأساسيات المرتبطة بالتنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية حيث المبحث الأول يقدم ماهية تقلبات أسعار الأسهم وأهم العوامل المؤثرة فيها بالإضافة إلى النظريات المفسرة لها، يناقش المبحث الثاني النماذج المختلفة التي يتم استخدامها في التنبؤ بتقلبات أسعار الأسهم بعد تقديم مدخل بسيط لعملية التنبؤ بهذه التقلبات، ليتم تناول ماهية إدارة المخاطر المالية وأهم أساليب قياس مخاطر الاستثمار في الأسهم كمبحث ثالث.

المبحث الأول: أساسيات حول تقلبات أسعار الأسهم

تعد تقلبات أسعار الأسهم واحدة من أبرز الظواهر التي تعكس ديناميكية الأسواق المالية وتعقيدها، فهي تعبر عن التغيرات المستمرة في أسعار الأسهم نتيجة العديد من العوامل خاصة مع الأحداث النادرة والأزمات المتزايدة مؤخرًا مما يجعل فهم هذه التقلبات ضرورة ملحة لكل من المستثمرين والباحثين في مجال الأسواق المالية.

المطلب الأول: مدخل لتقلبات أسعار الأسهم

يركز هذا القسم على تقديم مدخل لتقلبات أسعار الأسهم من تعريف ومختلف العوامل المؤثرة فيه ولكن قبل ذلك سيتم توضيح ماهية السهم أولاً كما يلي:

أولاً: ماهية السهم

مصطلح السهم مشتق في الأساس من المصدر مساهمة إذ يشير لغويا إلى الحصة أو النصيب، ويعني ذلك الاشتراك في ملكية شيء ما، وقد ارتبطت المساهمة منذ القدم بالأعمال التجارية إذ لا يمكن أن نحدد تاريخ ظهور المساهمة بدقة بالنظر لتوغلها في الممارسات البشرية تاريخياً، فقد وجد الانسان منذ زمن بعيد أنه بحاجة إلى مشاركة الآخرين في التجارة والأعمال نتيجة لقلة رأس المال واشتداد المنافسة والرغبة في التطوير، إلا أن الأسهم بشكلها الحديث ظهرت بظهور شركات المساهمة العامة إذ يذكر الباحثون أنه في القرن الثالث عشر وتحديدًا في عام 1250م في مدينة تولوز الفرنسية حصلت أولى عمليات تبادل الحصص لشركة تدعى (Societe de Moulins de Bazacle) وتختص هذه الشركة بطحن الحبوب، إذ قامت بطرح حصص من رأس المال وعرضها على المستثمرين مقابل مستند يثبت ملكيتهم ليحصل كل مستثمر في نهاية كل سنة على نصيبه من الأرباح. (بشارات بهاء محمد سعد، 2021، ص 6-7)

1- تعريف السهم

الأسهم تعد أهم الأوراق المالية في شركات المساهمة لما تمثله من حق في رأس المال تلك الشركات وتعطي للمستثمر مختلف الامتيازات وتفرض عليه بعضاً من الالتزامات، وأصبح تداول الأسهم في الشركات ذات الاكتتاب العام لا يتم إلا وفق آلية وضعت وحددت قواعدها بواسطة نظام السوق المالي ولوائح التنفيذية، وعلى هذا الأساس فقد عرفت الأسهم بعدة تعاريف تختلف فيما بينها بحسب الخصائص والأنواع المختلفة من الأسهم وتبعاً للزاوية التي يراها الباحثون، نوجز بعضها كالتالي: (الجريش عبد الله سليمان، 2018، ص 43)

يعرف: "باسم أسهم الملكية كونها تمثل حصص ملكية في الشركة، ويمنح كل سهم من الأسهم لمالكه الحق في التصويت على أي قرار يتعلق بالشركة". (Bodie Zvi et al., 2014, p 41-42)

الفصل الأول: الإطار النظري للتنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

ويعرف أيضا بأنه: "صك يمثل حصة شائعة في رأس مال الشركة المساهمة ويمنح صاحبه حقوقا قانونية في المشاركة في الأرباح والتصويت في الجمعيات العمومية، ويعتبر حملة الأسهم العادية المالكين الحقيقيين للشركة ويشار إليهم باسم الملاك المتبقين". (Gitman Lawrence J & Zutter Chad J, 2012, p 268)

كما يعرف السهم بأنه: "ورقة مالية تمثل جزء من رأس مال الشركة تطرح للاكتتاب العام ولحاملها الحق في امتلاك جزء من الشركة يتناسب مع قيمة الأسهم التي يمتلكها". (Bradley & Descamps, 2005, p 12-13)

من خلال التعاريف السابقة يمكن القول إن السهم عبارة عن ورقة مالية تطرحها الشركات ويتم تداولها في السوق المالي، لغرض الحصول على تمويل طويل الأجل، وهو مستند ملكية يضمن لحامله وهو المساهم مجموعة من الحقوق كحق التصويت، الحق في الأرباح إذا ما تقرر توزيعها، وحق الأولوية في الاكتتاب.

2- عائد السهم

من غير الممكن التحدث عن الأسهم بدون الحديث عن عائد السهم رغم الاختلاف الكبير لوجهات النظر حول هذا المصطلح، فالبعض يرى أن عائد السهم نفسه ربحية السهم وهناك من يرى أن العائد يختلف تماما عن الربحية، ولذا سيتم التطرق في هذا العنصر لعائد السهم باعتباره مختلف عن الربحية.

فالعائد يعتبر: "مؤشر أساسي للاستثمار بالأسهم ومقياس لترتيبها والمفاضلة بينها، وهناك مفاهيم مختلفة للعائد فهناك العائد الذي يحصل عليه المستثمر طيلة فترة احتفاظه بالسهم، والبعض يفضل العائد اللاحق والذي يحصل عليه في نهاية مدة الاحتفاظ بالسهم والذي يتوقع منه تحقيق أرباح". (فليح حسن خلف, 2006, ص 212-217)

ويعرف العائد على أنه: "مبلغ أو نسبة الأرباح المحققة من الاستثمار أو المكافأة التي ينتظرها كل مستثمر، ويعبر عن قدرة الموجودات على تحقيق دخل معبر عنه كنسبة عائد، وهذه النسبة تكشف ربحية الشركة في عملياتها التشغيلية وغير التشغيلية أو الربح أو الخسارة المترتبة على الاستثمار خلال مدة زمنية معينة". (V. Gangadhar & Ramesh G. Babu, 2006, p 28)

ومما سبق فإن العائد عبارة عن التدفق النقدي الصافي الذي ينتج عن العملية الاستثمارية خلال فترة زمنية معينة لأن فترة تحقيق التدفق لها أهمية كبيرة في المشاريع الاستثمارية، حيث تساعد على تحديد درجة التأثير بمخاطر انخفاض القيمة الزمنية للنقود مما يمكن الاختيار بين البدائل الاستثمارية المتاحة، ويقصد به كذلك ما يحصل عليه المستثمر من أمواله في وقت لاحق مقابل تضحيته بالاحتفاظ بأمواله في الوقت الحاضر وذلك من خلال استثماره لهذه الأموال لفترة زمنية معينة، وهناك عدة تقسيمات للعائد نذكر أهمها:

أ- العائد المتوقع

هو معدل العائد الدوري الذي يتوقع الحصول عليه من كل دينار مستثمر، وهو يدل على أن القرارات المالية للمؤسسة سليمة ونتائجها مربحة، وعليه يعبر عن معدل العائد على الاستثمار الذي يتوقع المستثمر

الفصل الأول: الإطار النظري للتنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

الحصول عليه خلال العملية الاستثمارية، حيث يقوم على الاحتمال وليس التأكد من تحقيقه ويتم حساب نسبة احتمال تحقق العائد حسب تكرار العوائد التاريخية خلال فترة زمنية معينة ويقاس العائد المتوقع في حالة العوائد التاريخية من خلال حساب الوسط الحسابي للعوائد المحققة خلال فترة زمنية معينة ويعبر عنه بالمعادلة التالية: (حماد طارق عبد العال, 2006, ص 86)

$$\bar{R}_i = \sum_{i=1}^n R_i / n$$

$\bar{R}_i$: معدل العائد المتوقع،

R_i : العائد السنوي الفعلي على الاستثمار،

n : عدد سنوات العوائد.

هناك غالبا عدم التأكد من قدرة الاستثمارات على تحقيق العوائد المتوقعة منها، إذ عندما يتوقع المستثمر أن يحقق استثماره معدل عائد قدره 10 % فإن هذه العملية لا تتعدى كونها تخمين أو محاولة للتنبؤ بالمستقبل ولكن يمكن للمستثمر أن يقوم بالتنبؤ أن عوائده لا تكون أقل من نسبة معينة ولن تزيد عن نسبة معينة، وكلما زاد هذا المدى بين أقل عائد وأكبر عائد ممكن تحقيقه كان الاستثمار أشد خطورة، ولذلك يلجأ المستثمرون إلى صياغة توزيع احتمالي لمعدلات العائد المحتملة، ويمكن أن يكون التوزيع الاحتمالي إما ذاتي بناء على خبرة المستثمر أو موضوعي عن طريق قياس البيانات التاريخية وتخصيص احتمالات لكل معدل عائد متوقع، ويمكن تحديد الاحتمالات لكل حالة عن طريق التوزيع التكراري للعوائد التي حققتها الورقة المالية في الماضي، ومعادلة العائد المتوقع في هذه الحالة تأخذ الشكل التالي: (Frank K. Reilly & Keith C. Brown, 2012, p 9-11)

$$E(R_i) = \sum_{i=1}^n (P_i)(R_i)$$

حيث أن:

$E(R_i)$: معدل الأمل الرياضي (العائد المتوقع)،

P_i : احتمالية حدوث العائد،

R_i : معدل العائد المتوقع حدوثه وفق كل احتمالية.

ب- العائد الفعلي أو المحقق

ويعرف أيضا بالعائد على فترة الاحتفاظ، يتمثل في معدل العائد على الاستثمار الذي يحصل عليه من كل دينار مستثمر فعليا ويعتبر أحد مؤشرات الربحية ومقياس الأداة التشغيلية للشركات أي العائد الصافي الذي نحصل عليه من الأموال المستثمرة، بمعنى العائد الذي يحصل عليه المستثمر الذي يقوم بشراء الورقة المالية

الفصل الأول: الإطار النظري للتنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

بسعر معين ثم يقوم بالاحتفاظ بتلك الورقة لفترة معينة، بعدها يقوم ببيعها في سوق الأوراق المالية. (نظير رياض محمد الشحات, 2007, ص 59-60)

والمعادلة التالية توضح كيفية حساب معدل العائد المحقق: (أمين السيد أحمد لطفي, 2006, ص 11)

$$R_i = \frac{D_t + (P_t - P_{t-1})}{P_{t-1}}$$

R_i : معدل العائد على فترة الاحتفاظ،

D_t : الأرباح الصافية الموزعة خلال الفترة t ،

P_t : سعر الأصل في نهاية الفترة t (سعر البيع)،

P_{t-1} : سعر الأصل في نهاية الفترة $t-1$ (سعر الشراء).

ت- العائد المطلوب

يعتبر أدنى معدل عائد للاستثمار يطلبه المستثمرون لتعويضهم عن تحمل المخاطرة، أي أن المستثمر يتحفز لشراء سهم معين إذا ما اقتنع أن معدل العائد المطلوب بموجب ما يعكسه السوق ومجموعة الخيارات البديلة أقل من أو يساوي العائد المتوقع من السهم، بينما يتحفز لبيع هذا السهم إذا كان معدل العائد المطلوب أعلى من معدل العائد المتوقع، كما يعتمد هذا المعدل على درجة المخاطرة التي تصاحب ذلك العائد ويرتكز في الغالب على المخاطر النظامية ويتم تقديره من خلال الاعتماد على معادلة نموذج تسعير الأصل الرأسمالية وفق المعادلة التالية: (Bodie Zvi et al., 2014, p 415)

$$R_i = R_f + \beta_i(R_m - R_f)$$

حيث:

R_i : معدل العائد المطلوب للاستثمار في سهم معين،

R_f : معدل العائد الخالي من المخاطرة،

β_i : معامل بيتا (معامل المخاطرة)،


R_m : معدل عائد السوق،

$(R_m - R_f)$: علاوة مخاطر السوق.

ثانياً: أنواع الأسهم

- يمكن تصنيف الأسهم وفق معايير متعددة يمكن تلخيصها في الشكل (1-1)، والذي يوضح أربع معايير:
- أولها من حيث الشكل فيظهر هذا المعيار الاختلافات بين الأسهم التي تصدر بأسماء ملاك محددين (الأسهم الاسمية)، والأسهم التي يمكن تداولها بحرية دون تسجيل اسم المالك (أسهم لحاملها) بالإضافة إلى الأسهم الإذنية التي تتطلب إجراءات معينة للتحويل. (Coyle Brian, 2002, p 18)
 - ثاني معيار من حيث نوع الحصة المدفوعة فيتناول هذا التصنيف كيفية تقديم قيمة السهم سواء بأصول مادية أو بشكل نقدي أو مجانية. (محمد عبد الله شاهين محمد, 2018, ص 44)
 - المعيار الثالث من حيث استهلاك رأس المال الذي يوضح الفرق بين الأسهم التي تسترد قيمتها بعد فترة محددة (أسهم التمتع) وتلك التي تمثل جزء دائماً من رأس مال الشركة (أسهم رأس المال). (Ferran Eilís & Look Chan Ho, 2014, p 136-137)
 - أما المعيار الأخير أو الرابع التصنيف وفق الحقوق الذي يشمل الأسهم العادية التي تمنح حقوق ملكية أساسية والأسهم الممتازة التي تمنح أصحابها حقوقاً إضافية كأولوية في توزيع الأرباح. (خالد بن عبد العزيز السهلاوي & عبد القادر محمد أحمد عبد الله, 2007, ص 28)

الشكل (1-1): أنواع الأسهم.



المصدر: من إعداد الطالبة.

ثالثاً: تقلبات أسعار الأسهم والعوامل المؤثرة فيها

تعكس تقلبات أسعار الأسهم مستوى عدم الاستقرار والاختلاف في أسعار الأسهم بمرور الوقت، والتي تمثل بمثابة المخاطر التي يواجهها المستثمرون في الأسواق المالية، وبالتالي فهم طبيعة هذه التقلبات والعوامل المؤثرة فيها يعد أمراً حيوياً لتطوير استراتيجيات استثمار فعالة وإدارة المخاطر المرتبطة بها، لذلك خصص هذا القسم لاستعراض تعريف تقلبات أسعار الأسهم والعوامل المؤثرة فيها.

1- تعريف تقلبات أسعار الأسهم

تعتبر تقلبات أسعار الأسهم من الظواهر المميزة للأسواق المالية إذ تمثل مقياساً لعدم الاستقرار في هذا النوع من الاستثمارات والذي يعرف بارتفاع درجة المخاطرة والتي بدورها تؤثر على قرارات المستثمرين وتوقعاتهم المستقبلية، ومن التعاريف المقدمة لها نذكر ما يلي:

التقلب في العلوم المالية هو: "مقياس لتغير سعر الورقة المالية عبر الزمن ومنه يمكن تعريف تقلبات سعر السهم بأنه تشتت الأسعار اليومية إذ أن أسعار الأسهم تتذبذب هبوطاً وصعوداً، وعلى نحو عام فإن إحدى الطرق المستخدمة لقياس مخاطر السهم تتم من خلال تذبذب سعره، لأن تذبذب سعر السهم قد يبين مدى عدم اليقين لعوائد السهم وبالتالي يمثل التذبذب جميع المخاطر لأنه يعكس حركات سعر السهم في جميع الأوقات وليس فقط تلك المرافقة لحركات سوق الأسهم". (Bhowmik & Wang, 2020, p 2)

التقلب هو: "ميل الأسعار إلى التغير بشكل غير متوقع إذ كلما كانت حركة السعر أكبر وأكثر تكراراً كلما زادت التقلبات، والتقلب في الأسواق المالية له تأثير مباشر على الاستقرار الاقتصادي الكلي والمالي، ومن الناحية الإحصائية التقلب هو الانحراف المعياري لعوائد الأسهم خلال فترة زمنية معينة، وفي معظم الأحيان كلما زاد التقلب زادت الخطورة". (John C. Hull, 2022, p 342-343)

ومن المميزات الخاصة لتقلبات الأسهم أنها لا يمكن ملاحظتها بشكل مباشر، وتتكون من تقلبات داخل اليوم والتقلبات بين عشية وضحاها أي بين أيام التداول، ورغم هذا فإن تقلبات الأسهم تتميز ببعض الخصائص منها: (Tsay, 2005, p 98-99)

- أولاً توجد مجموعة من التقلبات أي أن أسعار الأسهم قد تكون مرتفعة لفترات زمنية معينة ومنخفضة لفترات أخرى،
- ثانياً تتطور التقلبات بمرور الوقت بطريقة مستمرة أي أن قفزات التقلبات نادرة،
- ثالثاً لا تتباعد التقلبات إلى ما لا نهاية أي أن التقلبات تتنوع ضمن نطاق ثابت، إحصائياً هذا يعني أن التقلبات غالباً ما تكون ثابتة،
- رابعاً يبدو أن التقلبات تتفاعل بشكل مختلف مع الزيادة الكبيرة في الأسعار أو الانخفاض الكبير والذي يشار إليه بتأثير الرافعة المالية، هذه الخصائص تلعب دوراً مهماً في تطوير نماذج تحليل التقلبات والتنبؤ بها.

وكتبسيط لتعريف التقلب فهو انعكاس لدرجة تحرك السعر فيعتبر السهم الذي يتقلب سعره بشكل كبير ويصل إلى ارتفاعات وأدنى مستويات جديدة أو يتحرك بشكل غير منتظم متقلباً للغاية، أما السهم الذي يحافظ على سعر مستقر نسبياً لديه تقلبات منخفضة، لذلك فإن السهم شديد التقلب هو الأكثر خطورة بطبيعته وفي

الفصل الأول: الإطار النظري للتنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

نفس الوقت تزداد فرصة الحصول على عوائد أكبر بقدر مخاطر الخسارة، وتنعكس تقلبات الأسواق المالية بشكل رئيسي في انحراف القيمة المستقبلية المتوقعة للأصول لذلك يقوم العديد من المستثمرين ذوي القدرة على تحمل المخاطر إلى استخدام مقاييس متعددة لقياس وتحليل هذه التقلبات لتقييم التغيرات السابقة في الأسعار للتنبؤ بتحركاتها المستقبلية، للمساعدة في توجيه استراتيجياتهم الاستثمارية.

2- العوامل المؤثرة في تقلبات أسعار الأسهم

عند التعرض للعوامل المؤثرة أو المحددة لسعر السهم فإنه يتم التركيز على القيمة السوقية للسهم العادي، لأنها القيمة التي يتم بها تداول السهم في السوق المالي أي يباع ويشترى بها ولذلك سيركز على هذه القيمة بالتحديد في هذه الدراسة، وباعتبارها مؤشر هام على كل من قيمة الشركة ووضعيتها المالية كما يمكن أن يكون أداة رقابية على أداء المسير المالي فإن المستثمرون يهتمون بالتغيرات التي تصيب أسعار الأسهم في السوق المالي، فالملاحظ أن العديد من الباحثين حاولوا وصف وتحديد العوامل التي تقف وراء التغير في هذه الأسعار ومحاولة دراستها وتفسيرها بغرض الاستفادة منها، حيث توجد عدة عوامل يمكنها التأثير على سعر السهم في السوق وهي متفاوتة من حيث قوتها وتأثيرها من عامل لآخر، ومن بين أهم هذه العوامل تلك المرتبطة بالبيئة الاقتصادية، وكذلك التي تحكم إليها ميكانيزمات وآليات السوق المالي، وأيضا إلى العوامل المرتبطة بالسهم بحذ ذاته، دون أن ننسى تلك العوامل غير المتوقعة أو النادرة والتي تحدث فجأة وهي الأزمات أو ما يطلق عليها بالبجعات السوداء:

أ- العوامل المرتبطة بالبيئة الاقتصادية

إن هذه العوامل غير مرتبطة مباشرة بقيمة السهم لأن تأثيرها يكون على إجمالي المتعاملين الاقتصاديين ومختلف القطاعات، وباعتبار أن السهم عملة للشركة فإنه يتأثر بها بطريقة أو بأخرى، ومن أبرز هذه العوامل معدل النمو الاقتصادي، ومعدلات التضخم والفائدة، أسعار صرف العملات، بالإضافة إلى السياسة النقدية والضريبية المتبعة من طرف الدولة، وسيتم توضيحها فيما يلي:

- **الأوضاع الاقتصادية:** أي الحالة الاقتصادية العامة للدولة وتتأثر بمتغيرات من داخل الدولة ذاتها، والتي يعبر عنها بدرجة النمو الاقتصادي، حيث يعزى التوسع والانتعاش الاقتصادي الذي يصاحب النمو الاقتصادي والذي يؤدي بدوره إلى زيادة الطلب على السهم العادي وتزداد قيمته في السوق نتيجة لذلك وهذا راجع لزيادة الطلب على السلع والخدمات التي تقدمها الشركات مما يزيد من صافي التدفقات النقدية التي تحققها الشركة، في حين أن الركود والانكماش الاقتصادي يتضمن تقليص النشاطات الاقتصادية والذي يقود إلى انخفاض الطلب على السهم العادي وتنخفض قيمته في السوق بسبب ذلك، لذلك يتوجب معرفة الاتجاه المحتمل لأثر الزيادة في معدل النمو الاقتصادي، للإعلان عن زيادة غير متوقعة في النشاط الاقتصادي الحقيقي يزيد من التفاؤل بشأن المستقبل مما يزيد من حركة التعامل بالأسهم

الفصل الأول: الإطار النظري للتنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

وبذلك يؤدي إلى ارتفاع أسعارها، وعلى العكس من ذلك فإن المعلومات عن زيادة غير متوقعة في الناتج الوطني قد تلقى بظلال من التشاؤم بشأن المستقبل ويحدث هذا إذا ما ساد الاعتقاد بأن تلك الزيادة من شأنها أن تؤدي إلى زيادة النمو في المعروض النقدي وبالتالي الزيادة في التضخم. (منير إبراهيم هندي، 2006، ص 215-216)

● **معدل التضخم:** يقصد بمعدل التضخم الارتفاع المستمر في المستوى العام للأسعار، الذي يؤدي إلى تراجع القوى الشرائية للمدخرات أو الثروة وبذلك فهي عدم التأكد بشأن القوى الشرائية المستقبلية للأموال، حيث يرى البعض إلى أن الأسهم محمية من التضخم أحياناً غير أن هذا ليس صحيح بوجه عام، والأصح أن الأسهم مقارنة بالاستثمارات ذات الدخل الثابت تعاني بدرجة أقل من مخاطر انخفاض القوى الشرائية. (محمد محمود الخطيب، 2010، ص 88)

وهناك دراسات اقتصادية تعتمد على اتجاهين أساسيين لتحليل العلاقة بين التضخم وعوائد الأسهم هما: (فاخر عبد الستار حيدر، 2002، ص 69)

الأول: فرضية "Fischer" التي تفترض أن معدلات العوائد الاسمية للأسهم تساوي معدلات العوائد الحقيقية مضاف إليها معدل التضخم المتوقع:

$$R_n = R_i + E(I)$$

حيث:

R_n : معدل العائد الاسمي،

R_i : معدل العائد الحقيقي،

$E(I)$: معدل التضخم المتوقع.

تفترض هذه الصيغة الرياضية أن معدل التضخم المتوقع يكون مساوياً للواحد الصحيح، أي أن العوائد الاسمية للأسهم تزداد بمعدل يساوي معدل التضخم المتوقع، لذلك فإن توزيعات الأسهم في أوقات التضخم سترتفع بنسبة تكافئ انخفاض القوة الشرائية بسبب هذا التضخم، ما يعني أن فرضية "Fischer" تتجه إلى أن الأسهم وسيلة تحوط تجاه التضخم، إلا أن هذه الفرضية لم تكن بمعدل العائد المطلوب من قبل حاملي الأسهم، وهو العامل الأكثر أهمية بالنسبة إلى المستثمرين، فعندما يرتفع معدل التضخم فإن المستثمرين ولتحقيق معدل العائد الحقيقي ذاته سوف يقومون بطلب معدل عائد على الأسهم أعلى بالمقدار نفسه.

الثاني: فرضية "Fama" والتي تفترض وجود علاقة عكسية بين عوائد الأسهم والتضخم، فالعلاقة بين المتغيرات الاقتصادية الحقيقية مثل الناتج المحلي، والإنفاق الاستثماري، ومعدل العائد الحقيقي على رأس المال،

الفصل الأول: الإطار النظري للتنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

وبين عوائد الأسهم علاقة طردية، كما أن العلاقة بين هذه المتغيرات والتضخم علاقة عكسية، لذلك فالعلاقة بين التضخم وعوائد الأسهم هي علاقة عكسية.

لكن هناك بعض الأنواع من الأسهم يمكن أن تلائم البيئة التضخمية فالمؤسسات التي تمتلك كميات كبيرة من الموارد المادية ولأن قيمة أصولها تزيد مع الزيادة العامة للأسعار فإنها تزدهر في فترات التضخم. (طارق عبد العال حماد، 2008، ص 56)

- السياسة الضريبية والنقدية: السياسة الضريبية تقوم على الإجراءات التي تتبعها الدولة لتمويل نفقاتها فإذا ما لجأت الدولة إلى تخفيض معدل الضريبة على الأرباح التجارية والصناعية للشركات هذا يساعد على زيادة دخل المستهلكين والشركات مما يؤدي إلى زيادة الطلب الإجمالي، هذا من شأنه أن يترك أثراً إيجابياً على أرباحها الصافية وهو ما يترتب عليه انتعاش التعامل بالبورصة ما يعني ارتفاع أسعار الأسهم (بصفة عامة). محمد عبده & محمد مصطفى، 1998، ص (45-47)

أما السياسة النقدية فيقصد بها مدى السيطرة على المعروض النقدي التي تمارسها الدولة، في المفهوم الضيق لعرض النقود يتمثل في رصيد الودائع الجارية بالعملة المحلية لدى البنوك التجارية إضافة إلى النقدية المحتفظ بها لدى الجمهور، أما المفهوم الواسع لعرض النقود يتم إضافة لما سبق الودائع لأجل بالعملة المحلية والودائع الجارية بالعملة الأجنبية، وبما أن نشاط الأسهم في الأسواق المالية يعتبر جزءاً مهماً من النشاط الاقتصادي فإن أي تغيير في عرض النقد سيكون له تأثير في هذه الأسواق إما مشجعاً أو مثبطاً للمستثمرين على شراء أو بيع الأسهم وبذلك يتأثر سعره، فإذا كان لزيادة المعروض النقدي يتبعها تحسن في مستوى النشاط الاقتصادي ذلك على أساس أن هذه الزيادة وبفرض أن المطلوب منها ثابت من شأنه أن يؤدي إلى انخفاض أسعار الفائدة الأمر الذي يشجع على الاستثمار ويؤدي بالتبعية إلى زيادة الإنتاج، وبذلك تأثر على أرباح الشركات والتي بدورها تؤثر إيجاباً على أسعار الأسهم، ومن ناحية أخرى قد يكون للزيادة في المعروض النقدي تأثير سلبي، فهذه الزيادة تزيد من احتمال حدوث التضخم وهو ما يؤدي إلى زيادة في الحد الأدنى للعائد الذي يطلبه المستثمرون، وبما أن القيمة السوقية للمنشأة وبالتالي القيمة السوقية للسهم الذي تصدره تتحدد على ضوء القيمة الحالية للتدفقات النقدية المتوقعة، فإن مخاطر التضخم يسبب ارتفاع معدل العائد المطلوب على الاستثمار ما يتوقع أن يترتب عليه انخفاض في أسعار الأسهم. (منير إبراهيم هندي، 2008، ص 126-127)

- أسعار الفائدة: تتحرك أسعار الأسهم في اتجاه معاكس لأسعار الفائدة السوقية حيث يؤثر هذا الارتفاع والانخفاض في معدل العائد الذي يحققه المستثمر، ففي حالة ارتفاع أسعار الفائدة السوقية سيتوجه المستثمرون للتعامل بالسندات على حساب تعاملهم بالأسهم وربما إلى بيع هذه الأسهم وبالتالي زيادة

الفصل الأول: الإطار النظري للتنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

المعروض من الأسهم مما يعظم مخاطرها وذلك لانخفاض أسعارها في السوق الأمر الذي قد يحقق خسائر جراء ذلك أو يقلص معدل العائد الذي يحصل عليه المستثمر. (مقابلة سهيل & عيسى محمد، 2013، ص 27-28)

عند حدوث انخفاض في أسعار الفائدة على القروض فإن من شأن ذلك أن يؤدي إلى انخفاض تكلفة الأموال المقترضة التي تقوم الشركات المقيمة في البورصة باقتراضها مما يعني انخفاض تكاليف القروض وبالتالي زيادة الأرباح التي تحققها هذه الشركات ومن ثمة زيادة الأرباح الموزعة على المساهمين والتي تؤدي إلى زيادة الطلب على الاستثمار في الأسهم، وعند حدوث انخفاض في سعر الفائدة على الودائع فإن ذلك من شأنه أن يزيد من الكفاية الحدية للاستثمار ناتج عن انخفاض تكلفة الفرصة البديلة والخالية من المخاطر بما يعني زيادة الطلب على الاستثمار في الأسهم. (بودريوة & عبدالحكيم، 2019، ص 314-315)

- **أسعار صرف العملة:** يؤثر سعر صرف العملة المحلية في أسعار الأسهم بطريقتين: (احمد حسن الهيتي & فخر الدين أيوب اوس، 2012، ص 23-24)
- الأولى:** يفضل المستثمرون الأجانب عندما تكون العملة المحلية منخفضة الاستثمار في الأسهم المحلية بينما يبيعون استثماراتهم عندما تصل قيمة العملة المحلية إلى ذروتها أي أن الطلب الأجنبي على الأسهم المحلية يزيد عندما يتوقع أن تتحسن العملة المحلية على افتراض بقاء العوامل الأخرى على حالها.
- الثانية:** يؤدي تخفيض سعر صرف العملة المحلية اتجاه العملات الأخرى إلى زيادة الاستثمارات في الأسهم لأن تخفيض سعر الصرف يؤدي إلى زيادة الطلب على منتجات الشركات الوطنية وبالتالي تحسين أرقام مبيعاتها بالعملية المحلية ومن ثمة زيادة أرباحها المتوقعة مما يؤدي إلى زيادة العائد المتوقع من الاستثمار في الأسهم فيزداد الطلب المحلي على شراء الأسهم هذا ما يؤدي إلى ارتفاع أسعارها السوقية، بينما يؤدي رفع سعر صرف العملة المحلية تجاه العملات الأخرى إلى انخفاض الاستثمار في الأسهم نظرا لأن رفع سعر الصرف يؤدي إلى انخفاض الطلب الخارجي على منتجات الشركات الوطنية ومن ثم انخفاض أرباحها المتوقعة مما يؤدي إلى انخفاض أسعارها السوقية، هذا إذا كانت الشركة المحلية مصدرة بالأساس، أما إن كانت الشركة المحلية مستوردة فإن تخفيض سعر صرف العملة المحلية سيرفع من قيمة مستورداتها وبالتالي يخفض من تدفقاتها النقدية وأسعار أسهمها، ولا تحدث هذه الآثار على سوق الأوراق المالية إلا بتوفر عدد من الشروط من أهمها: مرونة الجهاز الإنتاجي، مرونة الطلب على الواردات، مرونة عرض الصادرات المحلية، مرونة الطلب الخارجي على الصادرات، وضرورة توافر جهاز مصرفي ذو كفاءة عالية.

ب- العوامل المرتبطة بالسوق


تعتبر العوامل المرتبطة بالسوق من أهم المحددات الخارجية لسعر السهم لاعتبارها حلقة وصل بين الشركات المدرجة والمتدخلين في السوق المالي بحيث أن أداء أي سهم يكون مرتبطا بعوامل السوق والمتعاملين فيه ومستقلا عن إرادة الشركات.

- **آلية العرض والطلب:** السهم أصل مالي تتحدد قيمته بناء على قوى العرض والطلب في السوق والمرتبطة بدورها بمجموعة من العوامل والتي يمكن أن تؤدي إلى زيادة الطلب على العرض وتزداد القيمة السوقية للسهم العادي، ويحصل العكس عندما تتحقق زيادة في عرض السهم على الطلب عليه فإن قيمته السوقية تنخفض فعند لحظة زمنية معينة يعد عرض الأسهم لشركة ما ثابتا يمكن التعبير عنه بمنحنى ذو مرونة صفرية حيث تكون الاستجابة النسبية للكمية المعروضة من الأسهم في هذا الفاصل الزمني صفرا للتغيرات النسبية في السعر، وبذلك يأخذ شكل خط مستقيم عمودي على المحور السيني، أما الطلب على الأسهم فيستجيب للتغيرات في السعر عكسيا فعند ارتفاع سعر السهم يتوجه المستثمرون المتفائلون للشراء على الرغم من أنهم قلة كما يلاحظ عند السعر المنخفض للسهم مثل p_1 فإن الطلب يزداد ويصل إلى Q_3 أما عند السعر p_3 حيث يكون الطلب بمستوى Q_1 ، ويمكن توضيح آلية تحديد السعر التوازني من خلال التقاء تيار العرض S وتيار الطلب d عند السعر p_2 حيث تتعادل الكمية المطلوبة مع المعروضة. (محمود محمد الداغر، 2005، ص 162-163)

والشكل التالي يوضح ذلك:

الفصل الأول: الإطار النظري للتنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

الشكل (2-1): آلية تحديد قيمة السهم.



المصدر: محمود محمد الداغر، الأسواق المالية؛ مؤسسات - أوراق - بورصات، الطبعة العربية الأولى، الإصدار الأول، دار الشروق للنشر والتوزيع، عمان، الأردن، 2005، ص 163.

- **كفاءة السوق:** من ميزات السوق الكفاء أن تعكس الأسعار وبسرعة المعلومات التي من شأنها أن تؤثر على القيمة السوقية للأوراق المالية المتداولة فيه، أي أن معلومة ما تكون مفيدة وذات قيمة للمتعاملين في السوق المالي فقط إذا ما أدت إلى حدوث استجابة لها على أسعار الأسهم وحينئذ تصبح لهذه المعلومات قيمة أو محتوى إعلامي، والسوق يتسم بالصيغ التالية للكفاءة: (Michèle Mollet & Georges Langlois, 2011, p 76)
- **فرضية الصيغة الضعيفة:** تقضي أن المعلومات التي تعكسها أسعار الأسهم في السوق هي المعلومات التاريخية بشأن ما طرأ من تغيرات على سعر السهم وعلى حجم التعاملات التي جرت عليه في الماضي وهو ما يعني أن أي محاولة للتنبؤ بما سيكون عليه سعر السهم في المستقبل من خلال دراسة التغيرات التي طرأت على سعره في الأيام أو الشهور أو السنوات الماضية هي مسألة عديمة الجدوى.
- **فرضية الصيغة متوسطة القوة:** تقضي هذه الصيغة أن أسعار الأسهم في لحظة معينة لا تعكس فقط التغيرات السابقة في أسعار تلك الأسهم بل تعكس كذلك كافة المعلومات المتاحة للجمهور أو التنبؤات التي تقوم على تلك المعلومات سواء تمثلت تلك المعلومات في ذلك التقارير المالية وغيرها من التقارير والتحليلات التي تتاح للجمهور.

الفصل الأول: الإطار النظري للتنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

- فرضية الصيغة القوية: تقضي بأن المعلومات التي يعكسها سعر السهم في السوق هي جميع المعلومات المتاحة للعامة والخاصة إضافة إلى تلك المعلومات التي قد تكون متاحة لفئة معينة منه كإدارة الشركة المصدرة للسهم وكبار العاملين فيها وتلك التي يمكن أن يصل إليها المحللين الأساسيين من خلال ما يملكونه من أدوات تحليل تدعمها خبرة ومهارة عاليتين، باختصار تعكس الأسعار كل ما يمكن معرفته وفي ظل هذه الظروف يستحيل على أي مستثمر أن يحقق أرباحاً غير عادية على حساب مستثمرين آخرين حتى لو استعان بخبرة أفضل مستشاري الاستثمار في السوق.
- اتجاه السوق: يقصد باتجاه السوق حركة جميع الأسهم المتداولة في السوق بحيث لا تكون محصورة في سهم معين أو فئة معينة من الأسهم ويأخذ أحد الأشكال التالية: (Edward Bassetti, 2007, p 17-18)
 - السوق الصاعد: كمرحلة أولى للسوق الصاعد يلاحظ المضاربون أن الجمهور أصبح متشائماً من مناخ الأعمال السائد نظراً لكثرة التقلبات في الأسعار فيقومون بعملية تجميع الأسهم التي يقوم بشرائها من المستثمرين المتخوفين من حركة السوق، وتكون نتيجة هذه العملية أن المعروض من الأسهم أصبح أقل من ذي قبل فيقوم المضاربون كمرحلة ثانية لهذه العملية بطرح الأسهم تدريجياً بعد ذلك يبدأ العامة بملاحظة أن فكرة الربح الرأسمالي بدأت تخطف الأنظار فيزداد السوق نشاطاً وتستمر الأسعار في الصعود لدرجة أن المستثمر يصبح محتاراً أي سهم يشتري وأي سهم يبيع.
 - السوق النازل: عندما يبلغ السوق ذروته تبدأ المرحلة الأولى من السوق النازل حيث يلاحظ فيها فئة المستثمرون أن غالبية الأسعار بلغت مستوى يطرح العديد من التساؤلات ويزداد ارتياهم نحو المستقبل فيقومون بعرض الأسهم بوتيرة تدفع الأسعار نحو الانخفاض بشكل تدريجي، لتبدأ المرحلة الثانية التي تمتاز بأن جميع المتعاملين في السوق يريدون البيع لكن دون وجود أطراف ترغب في الشراء، أما في المرحلة الثالثة والأخيرة تصبح الأسعار في أدنى مستوياتها ويكون الجميع متخوفاً من سوق الأسهم، ولعل أهم ما يميز هذه المرحلة أنها مماثلة للمرحلة الأولى من السوق الصاعد وهذا ينطبق على أهم مبدأ للتحليل الفني الذي يفترض أن التاريخ يعيد نفسه.
- التحكم في الأسعار: التحكم في الأسعار على عكس حركة السوق التي تلعب فيها نفسية المتعاملين دوراً أساسياً فهو نشاط يقوم به فرد أو مجموعة من الأفراد للسيطرة والتأثير على الأسعار بوسائل مصطنعة لجعل السعر السائد في السوق أعلى أو أقل من السعر الطبيعي، أي جعل السعر مغايراً لذلك السعر الذي كان في حالة غياب تلك العوامل المصطنعة ويكون ذلك بتجميع الأسهم أو بالبيع الصوري، وكذلك عن طريق الاستفادة من المعلومات التي لم تعرض على الجمهور، والهدف من التحكم في الأسعار هو تحقيق الأغراض التالية: (محمد صالح جابر، 2005، ص 55)

الفصل الأول: الإطار النظري للتنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

- رفع السعر: ويقصد به إحداث اتجاه صعودي في الأسعار ودفع جمهور المتعاملين إلى الشراء ثم يقوم المتحكمين بالبيع وتفريغ حملتهم من الأسهم وهذا التصرف هو أكثر أنواع التلاعب شيوعا.
- تثبيت الأسعار: الغرض منه محاولة بيع السهم بسعر أفضل من السعر الذي كان متوقعا أن يسود طبيعيا لو لم يحدث التدخل من جانب المتلاعبين في السوق، ويحدث هذا التدخل عادة بواسطة الجهة صاحبة المصلحة في رفع أو مساندة السعر لترويج أسهم جديدة.
- خفض الأسعار: يكون بإحداث اتجاه نزولي ومصطنع في الأسعار لدفع الجمهور لبيع أسهمهم ثم يقوم المتآمرون بالحصول على هذه الأوراق بأسعار منخفضة ولا يتجه إلى هذه العملية إلا المضاربون على النزول الذين توسعوا في البيع الأجل توقعوا لانخفاض الأسعار فإذا ما باءت توقعاتهم بالفشل فإنهم يقومون بهذه الأعمال لإجبار الأسعار على الانخفاض.

ت- العوامل المرتبطة بالسهم

تعتبر مؤشرات السهم من أهم العوامل المحددة لقيمته السوقية بحيث تسمح للمحللين بالدراسة الكمية للسهم على عكس العوامل الأخرى التي تعتبر شكلية لحد كبير، ومن بين أهم المؤشرات المستخدمة من قبل المتعاملين في سوق الأسهم هي المؤشرات المالية وغير المالية والتي غالبا ما يتم استخراجها من التقارير والمعلومات المالية التي تصرح بها الشركة صاحبة السهم، أو تلك المؤشرات المتعلقة بالسوق بصفة عامة بالإضافة إلى حساسية السهم.

- **المؤشرات المالية:** تعتبر العوامل المالية والتي تتمثل في مؤشرات التقارير المالية والمعلومات المحاسبية ومؤشرات السوق المالي عاملا أساسيا في تحديد قيمة السهم سواء كان التأثير مباشر أو غير مباشر، وبغض النظر عن طبيعة الشركة إذا أراد أحد معرفة الوضع المالي فإن القوائم المالية تعتبر من أفضل الطرق الموجودة للحصول على هذه المعلومات، ومن الأمور الضرورية التي على لجان مراقبة أعمال البورصة توفيرها للجمهور وتسمح بالاطلاع على جميع المعلومات ذات الطبيعة السوقية أو المالية للسهم، ومن أهم هذه المؤشرات نذكر ما يلي:

- **ربحية السهم EPS:** تعتبر من أهم مؤشرات الربحية لأنه يسهل مقارنة الربحية للسهم من خلال السنوات السابقة أو مقارنته بربحية السهم لشركات أخرى، لذا يجد المستثمرين في هذا المؤشر وسيلة جيدة لترشيد قراراتهم الاستثمارية وبالتالي يؤثر على الطلب على تلك الأسهم، ويطلق البعض على هذا المؤشر بحصة السهم العادي من الأرباح ونظرا لأهميته تلتزم الشركات المتداولة في البورصة بالإفصاح، ولأن الأرباح الصافية المتوقعة تعتبر أساس القيمة الحالية فهذا يعني أن الزيادة في الأرباح الصافية المحققة من الشركة في الفترات المقبلة تؤدي بالضرورة لإحداث أثر ايجابي على القيمة السوقية لأسهمها وهذا جراء

الفصل الأول: الإطار النظري للتنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

زيادة الطلب عليها، ويفسر الأمر بوجود علاقة خطية بين المتغيرين السابقين زيادة على كفاءة الإدارة وعملها على تحقيق الاستقرار في صافي الأرباح مما قد يمكنها من مواجهة المخاطر المؤثرة على قيمة أسهمها، حيث يأمل المستثمر من خلال شراءه للسهم الحصول على عائد إما من التوزيعات النقدية أو الزيادة في قيمة السهم في المستقبل لذا فهناك ارتباط قوي بين الإفصاح عن الربح المتوقع تحقيقه وبين التغير في السهم فالارتفاع في الربح المتوقع يصاحبه تعديل في سعر الأسهم، ومع هذا قد يتضح في الأجل القصير عدم وجود ارتباط بين أسعار الأسهم والربح فقد تتجه الأسعار في اتجاه عكسي للربح أو قد تتزايد بنسبة صغيرة بالمقارنة بنسبة الزيادة في الربح، ويمكن تفسير هذه التحركات من خلال نظرية الثقة حيث يتضح أن سعر السهم يتوقف على درجة ثقة التاجر أو المستثمر في الأوراق المالية أكثر من الاعتماد على الربح، أي أن درجة الثقة أو عدم الثقة في السهم تدفع السعر إلى الزيادة أو الانخفاض بصرف النظر عن الربح. (سالم صلال راهي الحسناوي, 2019, ص 252)

ويتم حسابه عادة وفق طبيعة هيكل رأس المال المستثمر في الشركة فإذا كان هيكل رأس المال المستثمر بسيطاً أي خال من الأدوات القابلة للتحويل إلى أسهم عادية يحسب وفق العلاقة التالية والذي يطلق عليه في هذه الحالة عائد السهم الأساسي Basic EPS (James M Wahlen et al., 2018, p 192-193)

$$\text{Basic EPS} = \text{NIACS} \div \text{WANCSO}$$

حيث:

Basic EPS: عائد السهم الأساسي (هيكل رأس المال البسيط)،

NIACS: صافي الدخل المتاح للمساهمين العاديين،

WANCSO: المتوسط المرجح لعدد الأسهم العادية القائمة أو المتداولة.

ويحسب صافي الدخل المتاح للمساهمين العاديين بالمعادلة التالية:

$$\text{NIACS} = \text{NPAT} - \text{PSD}$$

حيث:

NPAT: صافي الربح بعد الضريبة،

PSD: توزيعات الأسهم الممتازة.

أما إذا كان هيكل رأس المال المستثمر مركباً باحتوائه عدداً من الأدوات المالية التي يحتمل تحويلها إلى أسهم عادية والمتمثلة في السندات والأسهم الممتازة القابلة للتحويل للأسهم العادية بالإضافة إلى الخيارات وصكوك شراء الأسهم فحينئذ يتم حساب عائد السهم المخفض Diluted EPS، بالعلاقة التالية: (James M Wahlen et al., 2018, p 193-194)

$$\text{Diluted EPS} = (\text{NIACS} \div \text{WANCSO}) + (\text{DSA} \div \text{WANSIDS})$$

حيث:

Diluted EPS: عائد السهم المخفف (هيكل رأس المال المعقد)،

DSA: تعديلات للأوراق المالية المخففة،

WANSIDS: المتوسط المرجح لعدد الأسهم المصدرة من الأوراق المالية المخففة.

وتشير إلى الانخفاض الذي يطرأ على عائد السهم الأساسي نظراً لإضافة الأوراق المالية سالفة الذكر، ويعتبر

إجبارياً على الشركات التي تعتمد هيكلًا ماليًا مركبًا نشر كلا القيمتين أي الأساسية والمخفضة.

- **الربح الموزع للسهم DPS:** يقيس ما سوف يحصل عليه المساهم من أرباح موزعة وبذلك فهو يمثل التدفق النقدي الذي يحصل عليه المساهمون، فإن ارتفع دفع توزيعات الأرباح ينظر لها بصورة إيجابية وتكشف معلومات إيجابية حول الأرباح المستقبلية للشركة ويزيد سعر السهم، والعكس صحيح، حيث تحدد هذه الحصة بعد تسديد حصة الأسهم الممتازة من الأرباح المعلن عن توزيعها من طرف الإدارة وتحسب بطرح توزيعات الأسهم الممتازة من المبلغ الإجمالي للتوزيعات ثم قسمتها على عدد الأسهم المسجلة في دفاتر الشركة قبل تاريخ نهاية الحق في توزيعات الأرباح ويمكن التعبير عنها بالعلاقة التالية: (محمد مطر، 2015، ص 268)

$$DPS = (AD - PSD) \div NOSRC$$

حيث:

AD: التوزيعات المعلن عنها،

NOSRC: عدد الأسهم العادية المسجلة في الشركة.

- **معدل التوزيع DPR:** معدل التوزيع هو مقدار يقيس حجم الربح الموزع من نتيجة السنة المالية المقفلة، كما قد يكون بالاقتطاع من أرباح السنوات السابقة المتمثلة في الاحتياطات أو المرحل من جديد، ويتم حساب معدل توزيع الأرباح بقسمة التوزيعات المعلن عنها على الربح الصافي للشركة كما توضح العلاقة التالية: (أسامة عبد الخالق الأنصاري، 2006، ص 218-219)

$$DPR = AD \div NPACS$$

حيث:

NPACS: الربح الصافي المتاح لحملة الأسهم العادية.

- وبعبارة أخرى يشير إلى العلاقة بين نصيب السهم من الربح الموزع على المساهمين ونصيبه من حقوق المساهمين أو ربحية السهم ويتم حسابه بقسمة الربح الموزع للسهم على عائد السهم كالتالي: (أسامة عبد الخالق الأنصاري، 2006، ص 219-220)

$$DPR = DPS \div EPS$$

الفصل الأول: الإطار النظري للتنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

إذا ما كان معدل التوزيع يفوق 100% فإن الشركة تضيف إلى رصيد التوزيعات الاحتياطات المجمعة من أرباح السنوات السابقة، أما إذا كان معدل التوزيع 0% فمعناه أن الشركة قد أعادت استثمار إجمالي أرباحها لغرض التمويل الذاتي.

- **مردودية السهم DY:** يعرف أيضا بناتج مقسوم الأرباح أو بمعدل الربح السنوي المتحقق للمستثمر كونه يمثل مصدر مهم للعائد، يعكس هذا المؤشر تكلفة الفرصة البديلة بين الاستمرار في الاحتفاظ بالسهم أو بيعه والتحول إلى استثمارات أخرى، كما يرتبط بقدرة السوق على إدراك النمو المتوقع للشركة، فانخفاض هذا المؤشر يشير إلى ارتفاع النمو المتوقع ما يؤدي إلى ارتفاع سعر السهم في السوق، ويحسب بقسمة آخر ربح موزع للسهم على سعره الجاري وهو كالتالي: (عدنان تايه النعيمي & أرشد فؤاد التميمي, 2007, ص 101)

$$DY = DPS \div P_0$$

ولمعرفة إن كان هذا المؤشر مرتفع أو منخفض يجب مقارنته مع المعيار التاريخي أو معدل الصناعة أو المستهدف.

- **مضاعف سعر السهم PER:** يعرف مضاعف السعر على العائد أيضا باسم معامل رسملة الأرباح أو مضاعف عائد السهم أو بمضاعف أو مكرر الربحية، ويعتبر من المفاهيم البورصية الأكثر شهرة وأوسعها استعمالا لاختيار السهم في التداول، يقيس هذا المعدل العلاقة الموجودة بين السعر P وربحيته EPS ويعبر مدلوله عن عدد المرات اللازمة لاسترجاع تكلفة شراء السهم مقارنة مع الأرباح التي يذرها سواء أكان هذا الربح موزعا جزئيا أو على شكل كوبون أو محتجز على شكل احتياطات أو أرباح محتجزة، ويعتبر مؤشر مالي قوي يعكس القيمة الحالية للشركة فكلما انخفض سعر السهم للعائد كلما كان حافزا لشراء الأسهم من قبل المستثمرين أملا في تحقيق الأرباح نتيجة ارتفاع سعر السهم مستقبلا، ويحسب كالتالي: (Simon Parienté, 2009, p 115)

$$PER = P_0 \div EPS$$

- **معدل العائد على الأصول ROA:** يعرف أيضا بتسمية المردودية الاقتصادية ويستخدم كأداة لقياس قدرة الشركة على خلق الأرباح من خلال نشاطها الاستغلالي، أي مدى فاعلية الإدارة في استخدام الموارد المتاحة من مختلف المصادر التمويلية بغض النظر عن الطريقة التي تم بها هذا التمويل وبالتالي يعكس أثر الأنشطة التشغيلية والتمويلية في الشركة، ويحسب بقسمة النتيجة العملياتية على قيمة الأصل الاقتصادي كما يلي: (Eugene F. Brigham & Houston F. Joel, 2016, p 112-113)

$$ROA = R_{BIT} \div TAS$$

حيث:

RbIT: النتيجة قبل الفوائد والضريبة،

TAS: مجموع الأصول.

- **معدل العائد على حقوق الملكية ROE**: تستعمل نسبة العائد على حقوق الملكية أو المردودية المالية كمقياس للثروة التي حققها المساهمون خلال السنة، ويمكن هذا المؤشر معرفة العائد الذي يحققه المساهمون نظير مساهمتهم في الشركة، وحقوق الملكية تشمل رأس المال المدفوع وعلاوات الإصدار والأرباح المحتجزة والاحتياطات، وتحسب كالتالي: (Herbert B. Mayo, 2021, p 292)

$$ROE = NR \div TE$$

حيث:

NR: الربح الصافي،

TE: مجموع حقوق الملكية.

فإذا كانت النسبة مرتفعة فذلك يدل على كفاءة قرارات الاستثمار والتشغيل مما يؤثر إيجاباً على سعر السهم في السوق.

- **معدل العائد على الاستثمار ROI**: يشير هذا المؤشر إلى مدى الكفاءة التشغيلية للشركة ويستخدم للمقارنة بين الشركات في نفس القطاع، كما يشير إلى مدى قوة الشركة على المدى الطويل ومدى استغلال وإدارة كافة الأموال المتاحة لديها من المساهمين والأموال المقترضة، ويحسب من خلال قسمة صافي الربح على موجودات الشركة كما توضحه المعادلة التالية: (أمين السيد أحمد لطفي, 2006, ص 374-375)

$$ROI = NR \div TAS$$

فإذا كان معدل العائد على الاستثمار للشركة أقل بكثير من المعدل العائد المتوسط السائد في السوق أو القطاع فإنه مؤشر على انخفاض الأرباح نتيجة زيادة التكاليف أو إلى زيادة إجمالي الأصول نتيجة شراء أصول وممتلكات جديدة قد تكون أكثر من اللازم، الشيء الذي يؤثر على أسعار أسهم الشركة بالانخفاض.

- **الرفع المالي FL**: وتمثل هذه النسبة مقدار مساهمة الديون في تركيبة الهيكل المالي للشركة حيث ينطلق مبدأ تحليل الملاءة المالية للشركة من تحليل خصومها وعلى وجه الخصوص ديونها المالية، فكلما زاد اعتماد الشركات على الديون تزداد معها حدة المخاطر، ومضمونها أن القيمة السوقية لموجودات الشركة غير كافية للوفاء بالتزاماتها المالية، وبعبارة أخرى تزيد الرافعة المالية من تقلب الأرباح إذا انخفضت الربحية الاقتصادية، أي أن المديونية تضخم تأثير الانخفاض على الربحية المالية أو على ربحية السهم عند مستوى مديونية مرتفع، ويتم حسابها بقسمة الديون المالية على إجمالي الأصول كالتالي: (Alain Rivet, 2003, p 121)

$$FL = D \div TAS$$

الفصل الأول: الإطار النظري للتنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

حيث:

D: الديون المالية.

وبقراءة معمقة يمكن القول إن الرفع المالي يتلخص في العلاقة بين المردودية المالية والمردودية الاقتصادية

عند مستوى مديونية معين، وتقاس في هذه الحالة بالعلاقة التالية: (Alain Rivet, 2003, p 121)

$$RF = \left[RE + \frac{D}{CP} (RE - i) \right] (1 - t)$$

إذن المردودية المالية تساوي المردودية الاقتصادية مضافا إليها المقدار $\frac{D}{CP} (RE - i)$ والذي يعبر عن

أثر الرفع المالي، حيث:

RF: المردودية المالية،

RE: المردودية الاقتصادية،

D: الديون،

CP: الأموال الخاصة،

i: معدل الفائدة،

t: معدل الضريبة.

- مضاعف القيمة الدفترية **PBR**: يقيس هذا المعامل العلاقة بين القيمة السوقية والقيمة المحاسبية

للأموال الخاصة ويمكن حسابه بقيمة الرسملة السوقية على إجمالي الأموال الخاصة أو السعر السوقي

للسهم على القيمة المحاسبية له، فإذا كان المعدل أكبر من الواحد الصحيح معناه أن القيمة السوقية

أكبر من القيمة الدفترية للأموال الخاصة أي أن الشركة نجحت في خلق قيمة لحملة الأسهم، والعكس

إذا كان المعدل أصغر من الواحد معناه أن القيمة الدفترية أكبر من القيمة السوقية وأن الشركة لم تنجح

في خلق قيمة لحملة الأسهم، وبحسب وفق العلاقة التالية: (Aswath Damodaran, 2012, p 490-491)

$$PBR = SMC \div BVPf$$

حيث:

SMC: الرسملة البورصية،

BVPf: القيمة الدفترية للأموال الخاصة.

أو العلاقة التالية:

$$PBR = P_0 \div AVS$$

حيث:

AVS: القيمة المحاسبية للسهم.

- **العوامل غير المالية:** بالإضافة إلى العوامل المالية التي تؤثر على أسعار الأسهم فقد تتداخل عدة عوامل غير مالية فيما بينها وتؤثر هي الأخرى بأسعار الأسهم سواء بشكل مباشر أو غير مباشر ولعل أهم هذه العوامل ما يلي:

- **سمعة الشركة وحوكمتها:** تتمثل سمعة الشركة في نوعية منتجاتها وخدماتها وثقة المستهلكين بها ومدى مساهمتها بخدمة المجتمع من خلال تبني برامج المسؤولية الاجتماعية وخلق الشركة من منازعات أو فضائح قانونية أو إدارية، وتعتمد سمعة الشركة على حكم الجمهور الذي توصل إليه من خلال معلوماته عنها وتقييمه لها باستخدام التقارير النظيفية التي نشرها مدقق الحسابات، لذلك فإن الأسواق بحاجة إلى أن تكون شفافة حتى يتمكن المستثمرون من اتخاذ قرارات مستنيرة، فإذا تمكنت الشركات من تضليل الجمهور بشأن مستقبلها فقد يحدث أزمات كثيرة، واستجابة لسلسلة فضائح أخلاق الشركات أصدر قانون Sarbanes-Oxley لتشديد قواعد حوكمة الشركات. (Zvi Bodie et al., 2013, p 8-9)

- **حجم الشركة:** يعتبر حجم الشركة المحرك الأساسي لأي مشروع ويهدف لزيادة الإنتاجية وإعادة تجديد رأس المال هذا وغالبا ما يؤثر حجم الشركة على عوائد الأسهم، ويقصد به تصنيف الشركات إلى صغيرة الحجم أو كبيرة حيث يعتمد هذا التصنيف على اللوغاريتم الطبيعي للقيمة الاجمالية للأصول، وأكدت دراسات Jerry O. Peters أن الشركات الصغيرة أكثر خطورة بشكل عام وبالتالي تتطلب معدل عائد أعلى، وهذا راجع للاعتبارات العملية التي يتبعها المستثمرون عند اتخاذ قرارات البيع والشراء لسبب واحد أن الشركات الأكثر نجاحا تصبح تدريجيا أكبر الشركات وفي أغلب الحالات تصبح الشركات الرائدة في صناعاتها الخاصة، وبذلك فإن نجاحها الكبير وحجمها اللاحق هو دليل كاف للمستثمر على أن هذه الشركات لديها القدرة على النمو وما يترتب عن ذلك من ارتفاع الأرباح بها. (James R. Hitchner, 2011, p 162)

- **الشائعات:** تشكل الشائعات خطرا كبيرا سواء على سوق الأوراق المالية بشكل عام أو على الأسهم بشكل خاص وغالبا ما يروج لهذه الشائعات إما كبار المستثمرين أو المؤسسات المالية المستثمرة في السوق حتى يوجهوا صغار المستثمرين باتجاه معين إما بيعا أو شراء، ومن جانب آخر نلاحظ أن الشائعات تصدر من قبل أصحاب الشركات لنفس الغرض الذي يقوم به كبار المستثمرين فقد يكون هدف ملاك الشركات زيادة حصتهم من الأسهم ولكن أسعار الأسهم مرتفعة فيقوموا بترويج اشاعات حتى يقوم حاملي الأسهم ببيعها فتتخفف أسعارها ليشتروها بأسعار منخفضة، وتنتشر هذه الظاهرة في ظل الأسواق المالية للدول النامية بكثرة حيث ينتشر ما يعرف باحتكار المعلومات، وفي ظل غياب كل من القوانين والأنظمة واللوائح المنظمة للسوق من ناحية، والوعي الاستثماري لدى المستثمرين من ناحية أخرى وعدم وجود منافسة

الفصل الأول: الإطار النظري للتنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

كاملة في السوق المالي وكثرة حدوث حركات مفاجئة غير مبررة في أسعار الأوراق المالية. (Clyde P. Stickney, 1998, p 52-62)

- اشتقاق الأسهم: قد تلجأ المؤسسة إلى ما يطلق عليه باشتقاق الأسهم أو تقسيم السهم أو أحيانا تفتيت السهم وهو تخفيض القيمة الاسمية للسهم مما يضاعف عدد الأسهم التي يتكون منها رأس المال، وتختلف هذه السياسة مع سابقتها في أنها تهدف في النهاية إلى تخفيض القيمة السوقية بما يسمح بزيادة الطلب عليه، وبالتالي يترك أثره الإيجابي على مستوى سيولته ذلك أن زيادة عدد الأسهم نتيجة الاشتقاق لا يؤدي في حد ذاته إلى زيادة أرباح المؤسسة، وعليه يتوقع أن يؤدي تقسيم السهم إلى انخفاض نصيب السهم من الأرباح والتوزيعات، وهو أمر يؤدي في النهاية إلى انخفاض القيمة السوقية للسهم مما يحقق سيولة أفضل. (إبراهيم الكراسنة, 2010, ص 16)

• مؤشرات أداء السهم في سوق الأوراق المالية: وتختلف هذه المؤشرات عن سابقتها، فإذا كانت العوامل المالية وغير المالية مستخرجة من القوائم المالية والمعلومات المحاسبية المتعلقة بالشركة فإن مؤشرات أداء السهم تستخرج من داخل سوق الأوراق المالية وكافة المعلومات البورصية التي على لجان البورصة الإفصاح عنها لكافة الأسهم المتداولة داخلها، ويمكن تلخيصها على سبيل المثال لا الحصر فيما يلي:

- المؤشر العام للسوق: مؤشر البورصة هو مؤشر قياس أسعار الأسهم في السوق بشكل عام على أساس يومي، ويعتبر بمثابة مقياس الحرارة بالنسبة للسوق ويظهر إن كان مستوى السوق قد ارتفع أو انخفض كون المؤشرات في أسواق الأوراق المالية تقيس مستوى الأسعار حيث تقوم على عينة من أسهم الشركات التي يتم تداولها في السوق المالية ويتم اختيار العينة بطريقة تتيح للمؤشر أن يعكس حالة السوق التي يهدف المؤشر إلى قياسها، وهناك من بعض المؤشرات التي تقيس حالة السوق بصفة عامة كمؤشر داوجونز لمتوسط الصناعة ومؤشر ستاندرد أن بورز 500، في حين هناك مؤشرات قطاعية والتي تقيس حالة السوق بالنسبة إلى قطاع أو صناعة معينة مثل مؤشر داوجونز لقطاع النقل، ومؤشر ستاندرد أن بورز لقطاع الخامات، ولعل أهمية المؤشرات تنبع بعلاقتها بالحالة الاقتصادية فهي مرآة للحالة الاقتصادية، وفضلا عن ذلك تتنبأ بالحالة الاقتصادية المستقبلية قبل حدوث أي تغير على الأسهم بفترة زمنية. (نزار كاظم الخيكاني & حيدر يونس الموسوي, 2018, ص 135)

- مؤشر السيولة Liquidity: يعبر عن السيولة بمدى القدرة على تحويل الأصول إلى نقدية وتكون العلاقة الرابطة بين القيمة الحالية للسهم والسيولة علاقة طردية، فمع كل تزايد في السيولة تشهد القيمة الحالية للسهم ارتفاعا، لأن المستثمرون يفضلون الأسهم التي تتسم بدرجة سيولة عالية ويدفعون لها أسعار تفوق قيمتها الحقيقية، لهذا فإن الكثير من المراجع تعطي لسيولة السوق دورا مؤثرا بشكل مباشر

الفصل الأول: الإطار النظري للتنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

في الأوراق المالية بشكل عام والأسهم بشكل خاص، ويتمتع السهم بالسيولة إذا كانت عملية شراء وبيع عدد معتبر من الأسهم لن يؤثر على اتجاه السهم في البورصة، وتحدد سيولة السوق من خلال ثلاث سمات وهي عمق السوق، اتساع السوق، وسرعة استجابة السوق، كالتالي: (مصطفى يوسف كافي، 2014، ص 58-59)

عمق السوق Market Depth: إذا تم بيع وشراء الأسهم بأسعار تزيد أو تنخفض عن القيمة الجارية للسهم في السوق في هذه الحالة يكون السوق عميق، وإذا لم يتحقق هذا يمكن القول إن السوق هي سوق ضحلة Shadow.

سعة السوق Market Breadth: تكون السوق ذات سعة إذا تمت أوامر بيع وشراء الأسهم بكميات، وهي ترتبط بعمق السوق، والسوق التي لا تتضمن أوامر بيع وشراء بكميات تسمى سوق محدودة.

سرعة استجابة السوق Market Resiliency: إذا استجابت الأوامر الجديدة بشكل مباشر للتغيرات في الأسعار الناتجة عن الأوامر المتقلبة فنقول إن السوق ذات سرعة في الاستجابة، ولذلك فإن حدوث أي خلل متوقع في العرض والطلب يمكن معالجته بسرعة مما يقلل من الخسائر التي تتعرض لها الأوراق المالية.

- **حجم التداول Volume:** يعد حجم تداول الأسهم عاملاً مهماً جداً من العوامل التي تؤثر في سعر السهم وبالتالي التي يبني عليها القرار الاستثماري وكذلك يعتبر من أهم عوامل التحليل الفني، وهي عدد الأسهم التي تم تداولها في السوق لفترة زمنية معينة، أو بمعنى آخر عدد الأسهم التي تم بيعها وشراءها. (Pierre Vernimmen et al., 2022, p 542)

يعتبر حجم التداول القوة الدافعة خلف حركة الأسعار لأنه مرآة لمدى إقبال المتعاملين في الشراء أو البيع فمن البديهي أن يعود سبب أي ارتفاع للأسعار إلى زيادة الطلب على العرض وهو ما يترجم عملياً وفي الواقع إلى زيادة في طلبات الشراء وبأسعار مرتفعة نسبياً لجذب البائعين، وهذا ما يزيد من حجم التداول والعكس صحيح أيضاً فكمما أن أي انخفاض في الأسعار يكون نتيجة زيادة العرض على الطلب وهو ما يترجم واقعياً بتلبية طلبات الشراء حتى ولو كانت الأسعار متدنية نسبياً. (أزهري الطيب الفكي أحمد، 2017، ص 148)

- **معدل دوران السهم ST:** إن معدل دوران الأسهم يعتبر إحدى مقاييس حجم التداول إذ يستهدف بشكل أساسي قياس درجة عرض النقد لسهم ما دون آخر، وبمعنى أدق يقيس هذا المؤشر مدى الإقبال على السهم في السوق المالي معبرا عنه بكمية الأسهم المتداولة في الصفقات المالية التي تحدث على السهم، ويحسب معدل دوران السهم بطريقتين الأولى تركز على قيمة الأسهم المتداولة لشركة ما خلال فترة زمنية ما منسوبة إلى إجمالي القيمة السوقية لأسهم ذات الشركة خلال نفس الفترة، أما الطريقة الأخرى تركز على عدد الأسهم المتداولة لشركة ما خلال فترة زمنية ما منسوبة إلى إجمالي عدد الأسهم المكتتب فيها والمصدرة من جانب الشركة نفسها خلال نفس الفترة الزمنية. (طلال كداوي، 2008، ص 89)

الفصل الأول: الإطار النظري للتنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

- تقرير التداول: يتمثل في مختلف الأسعار التي تعلن عليها البورصة بشكل يومي فإن وقوف المستثمر على هذا التقرير وهذه الأسعار ومعرفة كيفية تحليلها وأخذ متوسط الأسعار وحساب الاتجاه العام لتطورها يساعده على اتخاذ قراره الاستثماري بشكل سليم مما قد يؤثر بدوره على أسعار الأسهم في البورصة، ومن بين أهم الأسعار التي يتم الإعلان عنها نذكر: (شعبان محمد إسلام البرواري، 2002، ص 77)

- سعر الفتح وهو أول سعر يحدد للسهم بعد افتتاح البورصة،
- أعلى سعر للسهم،
- أدنى سعر للسهم،
- سعر الإغلاق وهو آخر سعر في جلسة البورصة يسجل للسهم.

- حساسية السهم: يقصد بها حساسية السهم تجاه حركة معدلات عائد السوق، حيث يقيس المعامل β المخاطر النظامية التي يتعرض لها المساهمون ويمثل إجمالي الخطر الذي يترتب عن الاستثمار في أسهم شركة ما مقابل إجمالي خطر السوق الذي يكون مساوياً للواحد الصحيح، ويأخذ هذا المعامل قيم عديدة تختلف من شركة لأخرى ومن سوق لآخر بحيث يكون لكل شركة معامل خاص بها، حيث يشير السهم الذي يحتوي على بيتا أكبر من 1 إلى تقلبات أكبر في معدلات عائده مقارنة بالسوق وبذلك نقول على هذا السهم ذو حساسية مرتفعة لأي تغير يحدث في السوق، أما السهم الذي يحتوي على بيتا أقل من 1 فيشير إلى تقلبات أقل في معدلات عائده مقارنة بالسوق، وبذلك حساسية السهم تجاه عوائد السوق منخفضة. (James R. Hitchner, 2011, p 223)

يمكن تقدير القيمة التاريخية ل β سهم ما باستخدام ما يعرف بنموذج السوق والمتمثل في العلاقة التالية: (Frank K. Crundwell, 2008, p 355)


$$R_i = \alpha + \beta_i R_M$$

يكون تحديد قيمة المعاملات α و β من خلال مستقيم الانحدار الخطي لعائد السهم R_i وعائد السوق R_M

الممثلة بيانيا في الشكل التالي:

الفصل الأول: الإطار النظري للتنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

الشكل (3-1): شكل مستقيم الانحدار الخطي لعائد السهم والسوق.



Source: Stephen A. Ross, Randolph W. Westerfield and Bradford D. Jordan, Fundamentals of Corporate Finance, 10th Edition, McGraw-Hill Irwin Edition, New York, 2011, p435.

حيث يوضح الشكل العلاقة الخطية بين عائد السهم وعائد السوق، حيث يعبر ميل خط الانحدار عن معامل بيتا β الذي يقيس مدى حساسية عائد السهم تجاه تغيرات عائد السوق، فإذا كانت $\beta = 1.0$ فإن السهم يتحرك في نفس اتجاه السوق وبنفس درجة التقلب، مما يعكس تحمله لمستوى المخاطر النظامية نفسها التي يتحملها السوق، وتمثل نقطة تقاطع خط الانحدار مع المحور العمودي معامل ألفا α والذي يعبر عن الجزء من عائد السهم غير المفسر بحركة السوق عندما يكون عائد السوق صفراً.

ولتحديد قيمة β حسابياً فيكفي حساب التباين المشترك الموجود بين مردودية السهم R_i ومردودية السوق

R_M وقسمته على التباين في مردودية السوق كالتالي: (Annaïck Guyvarc'h et al., 2012, p 43)

$$\beta_i = \frac{COV(R_i, R_M)}{V(R_M)}$$

حيث:

$$COV(R_i, R_M) = \frac{1}{n-1} \sum_{t=1}^n (R_{it} - \bar{R}_{it})(R_{Mt} - \bar{R}_{Mt})$$

$$V(R_M) = \frac{1}{n-1} \sum_{t=1}^n (R_{Mt} - \bar{R}_{Mt})^2 \quad \text{و:}$$

حيث أن:

R_{it} : مردودية السهم i في التاريخ t ،

$\bar{R}_{it}$: المردودية المتوسطة للسهم i في الفترة t ،

R_{mt} : مردودية السوق في التاريخ t ،

$\bar{R}_{mt}$: المردودية المتوسطة للسوق خلال الفترة t ،

n : عدد الفترات المستعملة في حساب المردودية.

ث- الأزمات المالية العالمية

تعتبر الأزمات المالية العالمية بمثابة العوامل النادرة والمفاجئة والتي تتسبب في انخفاضات وتقلبات في سوق الأسهم، والتي يطلق عليها باسم البجعات السوداء، أو الفقاعات المالية، ومن بين أهم هذه الأزمات التي ضربت الأسواق المالية ما يلي: (investing, 2023)

- انهيار 29 (1929): عند الحديث عن البجعة السوداء الأولى فإننا نتحدث عن انهيار بورصة وول ستريت يوم الثلاثاء 29 أكتوبر 1929 والمسمى بالثلاثاء الأسود بعد انهيار سابق لها قبل 5 أيام، وهو أعمق هبوط عانى منه السوق واستمر 33 شهرا، وكانت المستويات العالية من مديونية تجار التجزئة والتقييمات المرتفعة بشكل مبالغ فيه وسهولة الائتمان، من العوامل التي تسببت في مبيعات ضخمة، أدى هذا السيناريو في غضون أسبوع إلى تحول آلاف العائلات إلى الفقر والاستعانة بالتسهيلات الائتمانية، كما أدى إلى إفلاس عددا كبيرا من الشركات التي لم تستطع تلبية احتياجات رأس المال العامل، وحدث أكبر انخفاض لمؤشر داو جونز في جلسة يوم الثلاثاء 29 أكتوبر 1929 مع انخفاض بنسبة 12.8%.
- الاثنين الأسود (1987): حدد موقع البجعة السوداء في 19 أكتوبر 1987 التي تسببت في واحدة من أكبر الانخفاضات في الأسواق المالية خلال القرن الماضي، بدأ الانهيار في هونغ كونغ وانتشر غربا إلى أوروبا ضاربا الولايات المتحدة بعد أن هبطت أسعار الأسواق الأخرى بهامش كبير، حيث انخفض مؤشر داو جونز بأمريكا الشمالية بنسبة 22.6% في جلسة واحدة، مما أدى إلى تقلب ما يقرب من ربع رأسماله السوقي، ويرجع السبب إلى المبالغة في تقييم الأصول والتضخم المرتفع وارتفاع النفط مما أدى لمبيعات ضخمة من قبل المستثمرين الأفراد والشركات.
- أزمة الدوت كوم (2000): رأى العديد من المستثمرين فرصة استثمارية كبيرة مع ظهور شبكة الويب العالمية وظهرت الشركات في بعض الحالات التقليدية والتي قدمت مع صعود الانترنت والتجارة الإلكترونية نماذج أعمال تستخدم الانترنت كأساس، وقد بدأ مؤشر ناسداك في ذروة الفقاعة يعاني من انخفاض بعض القيم مما أدى إلى نشر الخوف بين المستثمرين وبالتالي بدأ ما يسمى بتأثير 2000 من الدوت كوم أو

الفصل الأول: الإطار النظري للتنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

فقاعة تكنولوجيا المعلومات، وفي غضون عامين سجل السوق خسائر كبيرة ولا ميس مؤشر ناسداك القاع في أكتوبر.

- **هجمات 11 سبتمبر (2001):** كان هناك أيضا بجعة سوداء أخرى تسببت في تأثير قوي على أسواق الأسهم ولكنها ذات أصل بعيد عن المجال الاقتصادي البحث، وهذا ما حدث مع هجمات 11 سبتمبر الإرهابية في نيويورك والتي تسببت أيضا في تحول الأسواق إلى اللون الأحمر، حيث انخفض السوق في ذلك اليوم بنسبة 7.1%، وقد تسبب تأثير العدوى في فتح قيم المؤشرات الأوروبية الرئيسية أيضا على انخفاض.

- **الأزمة المالية (2008):** انتشرت هذه الأزمة على مستوى العالم على الرغم من أن أصلها في سوق الرهن العقاري الأمريكي لهذا تعرف باسم أزمة الرهن العقاري، حيث كان الاقتصاد العالمي ينمو بوتيرة جيدة في عام 2008 ولم يكن هناك ما ينذر بانخفاض سوق الأسهم، لكن قبل اندلاع الأزمة عرضت البنوك تسهيلات ائتمانية كبيرة لتمويل شراء الرهون العقارية للأشخاص الذين ليس لديهم موارد، هذا جنبا إلى جنب مع عملية إلغاء الضوابط المالية التي نفذت في الولايات المتحدة في السنوات السابقة، جعل من الممكن تسويق هذه الرهون العقارية بجودة ائتمانية منخفضة موهمة، وأدى إلى أزمة سيولة أدت إلى ركود عميق وذعر في سوق الأسهم.

- **خروج بريطانيا من الاتحاد الأوروبي (2016):** النتيجة غير المتوقعة للاستفتاء الذي روجت له الحكومة البريطانية للتصويت على خروج محتمل للبلاد من الاتحاد الأوروبي تسببت في حدوث زلزال حقيقي على المستوى السياسي والاجتماعي والاقتصادي، كما ولد الدعم لمغادرة الاتحاد الأوروبي رد فعل أوليا في أسواق الأسهم والعملات أدى إلى انخفاض سوق الأوراق المالية في لندن بأكثر من 7% في الجلسة اللاحقة.

- **أزمة كوفيد-19 (2020):** وأكبر مثال على البجعات السوداء الحالية الوباء العالمي الناجم عن أزمة كوفيد-19 الذي ضرب العالم بأسره عام 2020، مما تسبب في عمليات إغلاق عالمية، وكانت عواقبه مدمرة سواء في الخسائر البشرية أو الاقتصادية، كما كانت له آثار واسعة النطاق وشديدة في الأسواق المالية ففي غضون شهرين فقط تراجعت الأسواق المالية بنسبة 40%، فكانت عواقب هذه الأزمة هي الأكثر أهمية منذ الحرب العالمية الثانية.

- **الحرب الأوكرانية (2022):** على الرغم من التوترات السياسية وعملية ضم منطقة القرم التي تمت قبل بضع سنوات لم يكن من المتوقع حدوث غزو عسكري واسع النطاق من قبل روسيا، ولم يكن تأثير اندلاع حرب في منتصف القرن الحادي والعشرين في قلب أوروبا على سوق الأوراق المالية بنفس حدة تأثيرها على المستوى الجيوسياسي، على الرغم من أن التراجع في الأسواق في الأشهر السبعة التالية لبداية الحرب بلغ

الفصل الأول: الإطار النظري للتنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

18%، وبلغ التراجع نفس اليوم من الغزو بنسبة 3.7% في مؤشر ستوكس في أوروبا، ومع ذلك فقد شهدنا أكبر تأثير مباشر في ارتفاع تكاليف الوقود والطاقة بسبب طبيعة تصدير روسيا للمواد الخام.

المطلب الثاني: النظريات المفسرة لتقلبات أسعار الأسهم

سعى الاقتصاديون والمحللون الماليون إلى فهم الديناميكيات التي تؤثر على تقلبات الأسواق فتلورت العديد من النظريات المفسرة لتقلبات أسعار الأسهم والتي ظهرت على مدى فترات مختلفة، ومن بين أهم هذه النظريات ما يلي:

1. نظرية البجعة السوداء

طورها عالم الرياضيات اللبناني نسيم نيكولاس طالب، في إشارة إلى اكتشاف البجعات السوداء في أستراليا في القرن السابع عشر، بالضبط سنة 2007 عندما صدر له كتاب بعنوان البجعة السوداء، وهي نوع غير معروف في الدول الغربية، والنظرة تشير إلى أن الأحداث النادرة للغاية والتي لا يمكن التنبؤ بها يمكن أن يكون لها تأثير غير متناسب على عالمنا. تقوم هذه النظرية على الفكرة السائدة بأن البجع كله أبيض أما وجود البجع الأسود فهو نادر ومفاجئ، ويشير هذا المفهوم، المطبق على القطاع المالي، إلى حقيقة أن الأحداث غير المتوقعة ذات الطبيعة الاقتصادية أو الاجتماعية أو الجيوسياسية، والتي يستحيل التنبؤ بها، يمكن أن تؤدي إلى حدوث هبوط مفاجئ في الأسواق، ما يؤول إلى تقلبات مفاجئة وغير متوقعة في أسعار الأسهم. (investing, 2023)

2. نظرية كفاءة الأسواق المالية

قدمها Eugene Fama سنة 1960 وتفترض هذه النظرية أن الأسواق المالية فعالة، بمعنى أن أسعار الأسهم في أي وقت من الأوقات تعكس بشكل كامل جميع المعلومات المتاحة، وبناء على هذه الفرضية لا يمكن للمستثمرين العاديين أو حتى الخبراء تحقيق أرباح غير عادية باستخدام المعلومات المتاحة لأن الأسعار تعكس تلك المعلومات بالفعل، وهناك ثلاث مستويات لكفاءة السوق: الكفاءة الضعيفة، الكفاءة شبه القوية، والكفاءة القوية، وكل مستوى يعكس درجة مختلفة من دقة انعكاس المعلومات في الأسعار، وبحسب هذه النظرية فإن تقلبات أسعار الأسهم ناتجة عن رد فعل السوق الفوري لأي معلومة جديدة نظرا لأن الأسواق تعكس دائما المعلومات المتاحة فإن الأسعار تتغير فقط عندما تظهر معلومات جديدة غير متوقعة. (Fama, 1970, p 413-414)

3. النظرية السلوكية

تطورت في التسعينيات من قبل عدة باحثين أبرزهم Daniel Kahneman و Robert Shiller اللذان قدما سلسلة من المؤتمرات حول التمويل السلوكي في عام 1991، حيث ظهرت هذه النظرية استجابة للنقد الموجه للنظريات التقليدية كفرضية كفاءة السوق، حيث سعت إلى تفسير كيف تؤثر العواطف والانحيازات النفسية على قرارات المستثمرين، إذ تفترض أن المستثمرين لا يتصرفون دائما بطريقة عقلانية فالعواطف والتحفيزات

الفصل الأول: الإطار النظري للتنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

النفسية والانحيازات المعرفية تلعب دورا كبيرا في اتخاذ القرارات المالية مما يؤدي إلى سلوك غير عقلاني يؤثر على السوق وعلى تقلبات أسعار الأسهم، وتم توضيح تقدم التمويل السلوكي بمثالين بارزين من الأبحاث هما نماذج التغذية الراجعة، والعقبات أمام المال الذكي. (Shiller, 2003, p 90-92)

4. نظرية المشي العشوائي

طور هذه النظرية العالم Paul Cootner عام 1964 في كتابه بعنوان The Random Character of Stock Market Prices، وانتشر المصطلح من خلال كتاب Burton Malkiel عام 1973 بعنوان A Random Walk Down Wall Street، تستند النظرية إلى فكرة مفادها أن تحركات أسعار الأسهم غير قابلة للتنبؤ وتحدث بشكل عشوائي مما يعني أن السعر الحالي للسهم يعكس كل المعلومات المتاحة وتتكيف بسرعة مع المعلومات الجديدة، ولا يمكن التنبؤ بحركته المستقبلية بناء على المعلومات السابقة، وهذا ما يتوافق مع فرضية الكفاءة شبه القوية، بمعنى آخر تشير النظرية إلى أن أسعار الأسهم تتبع مسارا عشوائيا وغير منتظم مما يجعل التنبؤ الدقيق لتقلباتها أمرا شبه مستحيل، أي أن محاولة تحديد توقيت السوق أو التغلب عليه، أو استخدام التحليل الأساسي أو الفني للتنبؤ بتقلبات أسعار الأسهم على أساس البيانات السابقة، يعد مضيعة للوقت. (Burton G Malkiel, 2014, p 16-17)

5. نظرية الفقاعات

صاحب هذه النظرية هو Olivier Blanchard و Stanley Fischer وظهرت في أوائل الثمانينيات، حيث تفترض أن تقلبات أسعار الأسهم يمكن أن تتجاوز القيم الحقيقية للأصول بسبب المضاربة المفرطة حتى في سوق يتمتع بكفاءة، يمكن أن تستمر هذه الفقاعات بسبب توقعات المستثمرين باستمرار ارتفاع الأسعار ما يؤدي إلى انفجار الفقاعة عند نقطة معينة، بمعنى آخر تفسر هذه النظرية التقلبات في الأسعار على أنها ناتجة عن تشكل فقاعات أسعار غير مستدامة نتيجة للمضاربة عند انفجار الفقاعة يحدث تصحيح كبير في الأسعار. (Blanchard & Watson, 1982, p 4-5)

المبحث الثاني: التنبؤ بتقلبات أسعار الأسهم

استقطب موضوع التنبؤ بتقلبات أسعار الأسهم في الأسواق المالية الكثير من الاهتمام نظرا للإقبال الكبير من المستثمرين على هذا النوع من الاستثمار خاصة مع الأحداث العالمية الأخيرة والتي أثرت على حركة الأسواق المالية في العالم، فظهرت الحاجة إلى إيجاد نظم داعمة لقرار المستثمرين تساعد على اتخاذ القرار الأكثر صوابا من أجل تحقيق العائد الأعلى، لذا ركز هذا القسم على ماهية عملية التنبؤ بالتقلبات والعوامل المؤثرة فيه، وأهم الطرق التقليدية والحديثة المستخدمة في التنبؤ بتقلبات أسعار الأسهم.

المطلب الأول: مدخل للتنبؤ بالتقلبات

يتوقف اتخاذ القرارات ووضع السياسات وإعداد الدراسات المستقبلية على تقدير القيمة المستقبلية لعدة متغيرات، إذ يعد التنبؤ الدقيق في المجالات المالية أساسها، وهو يمثل توقع أحداث المستقبل بالاعتماد على دراسات إحصائية وكمية للفترة الماضية، وكذلك دراسة الاتجاهات في المستقبل وعلى أساس هذه الدراسات نتوصل إلى وضع افتراضات للفترة المستقبلية والتي من شأنها أن تساعد في اتخاذ القرار حيث يصور له ما يمكن أن يكون عليه الحال في المستقبل، وبالتالي فإن التنبؤ كان من أكثر القضايا أهمية للكثير من الأبحاث.

أولا: تعريف التنبؤ المالي

رغم تعدد التعريفات المقدمة لعملية التنبؤ المالي إلا أنه سيتم التركيز على التعريفات التالية:

التنبؤ المالي هو: "عملية استخدام البيانات المالية التاريخية والنماذج الرياضية والاحصائية للتنبؤ باتجاهات المستقبل في الأسواق المالية، ويتم ذلك من خلال تحليل الاتجاهات السابقة وتحديد الأنماط المحتملة لتقلبات الأسعار، بمعنى آخر هي عبارة عن بيانات حول المستقبل يتم توليدها من خلال مجموعة من الأساليب المعتمدة على التقنيات الإحصائية المعقدة واستخدام الأساليب القياسية الاقتصادية وتطبيقات الذكاء الاصطناعي، إضافة إلى الأساليب غير التقنية والتي يتم فيها التركيز على خبرة المستثمر والمحلل المالي، ومع ذلك لا يلتزم المتنبئون المحترفون بطريقة واحدة للتنبؤ". (Gunnar Bardsen et al., 2005, p 245-246)

التنبؤ المالي يشير إلى: "تقدير التقلبات المستقبلية في الأسواق المالية باستخدام النماذج الإحصائية والاقتصادية مع مراعاة العوامل الاقتصادية الأساسية والتحليلات الفنية للسوق، والتنبؤ المالي لا يقتصر دوره على تقديم توقعات رقمية فحسب بل يتجاوز ذلك ليكون بمثابة إطار استراتيجي شامل يساعد المستثمرين في بلورة رؤيتهم المالية وتحديد أهدافهم الاستثمارية المستقبلية بشكل أكثر وضوحا، ومن خلال هذا التنبؤ يستطيع المستثمرون مواءمة استراتيجياتهم الاستثمارية مع مستويات المخاطر المالية المتوقعة المرتبطة بالعوائد المرجوة، ما يمكنهم من اتخاذ قرارات مبنية على مزيج متوازن من العائد والمخاطرة". (Campbell, 2017, p 33)

الفصل الأول: الإطار النظري للتنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

إحصائياً يهدف إلى: "معرفة وتوقع القيم المستقبلية لسلسلة زمنية وذلك بالاعتماد على بيانات جمعت وسجلت خلال فترة زمنية سابقة ومنتالية، عن طريق تطبيق التقنيات الإحصائية والرياضية والتقنيات الحسابية كالشبكات العصبية والنماذج الإحصائية لتقدير وتحليل سلوك الأصول المالية في المستقبل بما في ذلك التقلبات في أسعار الأسهم". (David Ruppert & David S. Matteson, 2015, p 342-343)

ومنه يمكن القول إن التنبؤ هو عملية عرض حالي لمعلومات مستقبلية باستخدام معلومات تاريخية بعد دراسة سلوكها في الماضي، أي أنها العملية التي يتم من خلالها العمل على توقع الأسعار في المستقبل بالاعتماد على البيانات المتوفرة على طول الفترة الزمنية السابقة، بمعنى آخر عملية التنبؤ طريقة من الطرق العلمية لمعرفة تقلبات أسعار الأسهم في الأسواق المالية بعد فترة محددة وذلك بالاعتماد على تحليل قيم الأسعار المسجلة عبر الزمن أي السلاسل الزمنية باستخدام تقنيات ونماذج مختلفة.

ثانياً: العوامل المؤثرة في عملية التنبؤ

عندما نريد التنبؤ بتقلبات أسعار الأسهم فإن صعوبة التنبؤ تتجلى بعوامل عديدة والتي من شأنها أن تعقد عملية التنبؤ، وهناك عوامل غير واضحة تتطلب خبرة واسعة لكشفها، والتنبؤ بسلوك الأسهم يتطلب تحليل المئات من المؤشرات حتى تتمكن من صياغة القرار، وهذه المؤشرات عبارة عن توابع إحصائية بعضها يمتلك طبيعة متشابهة، والمحللون لابد من أن يختاروا المؤشرات المفيدة لهم من خلال طرق دقيقة وهذا يتطلب الوقت وقد يكون له تكاليف مالية غير مرغوبة، ومن بين العوامل المؤثرة في عملية التنبؤ بالتقلبات المالية ما يلي: (Malkiel Burton Gordon, 2011, p 300-315)

1. توفر البيانات

إن توفر البيانات يعد من ضروريات التنبؤ وأحد أهم العوامل الحاسمة في اختيار الأسلوب الأنسب لهذه العملية، إذ تستلزم عملية التنبؤ اختيار الأسلوب الملائم لنمط البيانات المستهدفة، وبالتالي فإن أسلوب التنبؤ في حالة الأسهم الجديدة التي لا تحتوي على بيانات تاريخية يختلف عن أسلوب التنبؤ في حالة الأسهم المتداولة، وعلى أساس ذلك هناك أساليب حديثة يمكنها التعامل مع مختلف أنواع البيانات بغض النظر عن طبيعتها أو درجة التعقيد التي تتسم بها، إذ تختلف عن الأساليب التقليدية بعدم وجوب تحقيق الفروض المبدئية لاستقرار السلاسل الزمنية.

2. المدى الزمني

يعد تحديد المدى الزمني من العوامل المهمة في عملية التنبؤ بأسعار الأسهم، إذ تتميز أسعار الأسهم بالتذبذب السريع واختلاف قيمتها من وقت إلى آخر، ومن المعروف إن دقة التنبؤ تنخفض كلما كان المدى الزمني طويلاً نسبياً، إلا أن التنبؤ طويل الأجل -وإن كان أقل دقة- فإنه يعطي صورة مبدئية عن سلوك الأسعار في

الفصل الأول: الإطار النظري للتنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

المستقبل، ولأجل ذلك تتميز الأساليب الحديثة بإمكانية التنبؤ قصير الأجل وطويل الأجل على حد سواء الأمر الذي يجعلها مناسبة جدا لحاجة المستثمرين في اتخاذ قراراتهم الاستثمارية.

3. سرعة التنبؤ

اختيار أسلوب حديث يتميز بقدرة فائقة على معالجة جميع أنواع البيانات علاوة على سرعتها في ذلك مقارنة بالأساليب الأخرى أمرا ضروريا في عملية التنبؤ، إذ يعد عامل السرعة مهما في التداول بالأسهم مما يجعل الأسلوب المستخدم في عملية التنبؤ أكثر فاعلية في أداء هذه المهمة.

4. كلفة التنبؤ

لا شك في أن كلفة التنبؤ من العوامل المهمة في اختيار الأسلوب المناسب للتنبؤ بأسعار الأسهم، وتتمثل كلفة التنبؤ بكلفة الحصول على البيانات وإعدادها، كلفة الأسلوب المتبع وما يحتاجه من تجهيزات لوجستية وتقنية، كلفة المحللين الماليين أو الفنيين القائمين بعملية التنبؤ، بالإضافة إلى كلفة الفرصة البديلة لاستخدام الأساليب الأخرى، ومن ذلك يكشف أن الأساليب الحديثة تختصر كثيرا في تكاليف التنبؤ عند مقارنتها بمتطلبات الأساليب الأخرى.

5. دقة التنبؤ

الدور الفعال لعملية التنبؤ تنبع من دقة نتائج التنبؤ التي تستند بالأساس على عملية البناء الصحيح للنموذج المولد لهذه النتائج، وبالتالي فإن دقة التنبؤ تعد العامل الأكثر أهمية في عملية التنبؤ بأسعار الأسهم وأما حاسما في المفاضلة بين أساليب التنبؤ، فقد يضطر المستثمر إلى تكبد تكلفة عالية في سبيل الحصول على توقعات دقيقة، إلا أن الأساليب الحديثة أثبتت في العديد من الدراسات السابقة أنها علاوة على كلفتها المنخفضة فإنها أكثر دقة من الأساليب التقليدية الأخرى.

6. تأثير الأحداث العشوائية

تعرف الأحداث العشوائية أيضا بالأحداث غير المتوقعة أو الصدمات العشوائية وهي أحداث خارجية تحدث بشكل مفاجئ ولا يمكن التنبؤ بها بدقة مسبقا في الأسواق المالية، وتشمل في الغالب الأزمات الاقتصادية، الكوارث الطبيعية، الأزمات الصحية وغيرها، وتلعب هذه الأحداث دورا حيويا في تحفيز تقلبات أسعار الأسهم حيث تؤثر على ثقة المستثمرين وتوقعاتهم المستقبلية، مما يجعل من الضروري تضمين تأثيرها في نماذج التنبؤ المالي، باستخدام نماذج متقدمة كنماذج التقلبات العشوائية، نماذج GARCH المتقدمة، ونماذج الذكاء الاصطناعي، وذلك من أجل تحسين دقة التنبؤات وتقليل المخاطر المرتبطة بها.

الفصل الأول: الإطار النظري للتنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

المطلب الثاني: نماذج التنبؤ بتقلبات أسعار الأسهم

يهتم المستثمر في الأوراق المالية خاصة في الأسهم العادية بالحصول على عوائد جراء هذا الاستثمار وتكون هذه العوائد إما من الأرباح السنوية التي تحققها الشركات أو مكاسب رأسمالية الناتجة عن الفرق الإيجابي لأسعار تلك الأسهم عند بيعها، ولذلك فعملية التنبؤ بالأسعار مهمة جدا لمساعدة المستثمر لاتخاذ القرار الاستثماري الأفضل إما بشراء أو بيع السهم، ومن أجل هذا الهدف تم استخدام العديد من الطرق والمؤشرات والتقنيات الإحصائية المختلفة بالإضافة إلى مؤشرات التحليل الأساسي والتقني، لكن مع ذلك لم يتم التوصل إلى نموذج ناجح ذو دقة عالية بحيث يمكننا القول أنه تم هزم السوق، لذلك توجه المستثمرون ومختلف المهتمين بهذا المجال إلى استخدام نماذج للتنبؤ متعددة ومتنوعة منها التقليدية والحديثة، والتي تطورت معظمها خاصة بعد الفترة الصحية التي ضربت العالم ككل متأملين إلى إيجاد نموذج جيد ودقيق بشكل كافٍ من أجل فك أسرار السوق المالي، ومن بين النماذج الأكثر شيوعا في التنبؤ بالأسعار في الأسواق المالية هي التحليل الأساسي والتحليل التقني، ونماذج السلاسل الزمنية بالإضافة إلى تقنيات الذكاء الاصطناعي، والتي يتم ايجازها فيما يلي:

أولاً: التحليل الأساسي Fundamental Analysis

هو أداة من أدوات التحليل المالي يجري فيه التركيز على الجوانب المالية والاقتصادية والإدارية، حيث يفترض أن الشركات التي تحقق نتائج جيدة من خلال الأداء الفعال والكفؤ سوف تحقق أرباحا عالية وبالتالي ستضمن نتائج جيدة في سوق الأسهم، حيث أن هذا الأخير يعكس قيمة الشركة التي يمثلها والتي يمكن ربطها بخصائصها المالية، آفاق نموها، وهيكل المخاطر المرتبطة بها، والتدفقات النقدية، وأي انحراف عن هذه القيمة هو علامة على أن الأسهم مقدرة بأقل من قيمتها الحقيقية أو بأكثر منها، بالنسبة للعاملين بالتحليل الأساسي فهم بالحاجة إلى معرفة السوق بشكل خاص وعن قرب، أما بالنسبة لأسواق الأسهم فهذا التحليل يعني تحليل القوائم المالية للشركات ومحاولة تقييم الأسهم في السوق بناء على وضعها وأرباحها المستقبلية، آخذين بعين الاعتبار وضع القطاع التي تعمل به الشركة والاقتصاد الذي يحويها بشكل عام. عند الخوض في التحليل الأساسي للأسهم نجد أنه يتكون من دراسات كمية تقوم على تحليل رقمي ومعدلات إحصائية تأخذ من القوائم المالية للشركات حيث يعتمد على بيانات تاريخية وحالية وأيضا التوقعات المستقبلية، وأخرى نوعية التي تركز على الأمور غير الملموسة في الشركة كنزاهتها وسمعتها وما إلى ذلك، وللإشارة فإنه يوجد العديد من المؤشرات التي تستخدم في التحليل الأساسي ولكنها صعبة التحقيق ولا تدخل ضمن إطار هذه الدراسة لذلك لن يتم التطرق لها، هذا لا يمنع أنها قد تكون محط تركيز في الدراسات اللاحقة. (Aswath Damodaran, 2012, p 23)

ثانيا: التحليل التقني Technical Analysis

أصبح التحليل التقني شائعا جدا من عام 1970، وهو عملية تستند إلى تقنيات إحصائية عامة من أجل تحديد الأسعار المحتملة في المستقبل عن طريق محاولة تحليل تقلبات الأسعار القديمة، كما يتناول هذا النوع من التحليل حجم التداول للأسهم خلال فترات زمنية معينة للمساعدة في التوقع، ووفقا للمحللين التقنيين فإن الكثير من الأوراق المالية تتبع أنماطا مختلفة من النمو تتغير مع الزمن، والمفتاح الأساسي لتحقيق الربح هو التنبؤ بالنقاط التي يتغير عندها ميل سعر السهم إما نحو الارتفاع أو نحو الانخفاض وذلك عن طريق معرفة ماضي أسعار السهم التي تساعد في فهم سلوك المستثمرين وتحديد مستويات الأسعار التي تشجعهم على الشراء أو البيع ولهذا فإن الكثيرين يربطون التحليل التقني بدراسة سلوك الجماعة في سوق الأسهم، وفيه يتم الاعتماد على المخططات والرسوم البيانية لدرجة أن المحللين التقنيين وصل بهم المطاف إلى أن يعرفوا بأصحاب الرسوم البيانية وبمرادفات أخرى، يمكن القول أن التحليل التقني هو فن تمييز تغير الاتجاهات قبل أو في أقرب وقت لحدوثه والتمشي مع هذا الاتجاه إلى أن تظهر علامات وأدلة تشير إلى أن هذا الاتجاه سيتغير مرة أخرى، وكما يعتمد هذا التحليل على مبادئ مالية تتمحور حول أسعار الأسهم حيث يعتبر أن السعر يمثل صور حقيقية حول السوق المالية، كما أن معظم التقنيين يؤمنون بفكرة انتظام حركة الأسعار وبذلك هناك إمكانية لتحديد الاتجاهات والقنوات للمتاجرة وتحقيق الأرباح دون أي مشكلة وبمصدقية عالية. (Pring Martin J, 2002, p 2-3)

إن فهم المبادئ الأساسية التي تقوم عليها تحركات الأسعار في الأسواق المالية والنظرة المتوازنة للموقف التقني العام يوفران إطارا أفضل للعمل على التنبؤ بالأسعار المستقبلية، لكن قد نجد أحيانا بعض التضارب في الاتجاهات بسبب اختلاف نوع التحليل التقني المستخدم زمنيا، ومنه فإن المحلل التقني مهمته معرفة اتجاه السعر مستقبلا بالتركيز على السعر بشكل مباشر دون معرفة أسباب التغيرات التي طرأت عليه لذا يهتم بشيئين هما: سعر السهم وكيفية تحرك السعر سابقا، مع الحذر من الإفراط في الثقة حيث كتب العالم Charles H. Dow المعروف بأبو التحليل التقني أن "التمسك بالرأي تسبب في سقوط عدد من الرجال في وول ستريت أكثر من كل الآراء مجتمعة"، لأن اتجاهات الأسعار في السوق قد تنحرف بشكل غير متوقع عن مسارها لذلك يجب على المستثمرين تعديل مواقفهم مع ظهور تغييرات في الوضع التقني. (Pring Martin J, 2002, p 3-6)

ثالثا: السلاسل الزمنية

هي مجموعة القياسات المسجلة لمتغير واحد أو أكثر مرتبة حسب زمن وقوعها، أما رياضيا فإن كل قيمة في الزمن t يقابلها قيمة للمتغير y فإن الدالة y دالة في الزمن t أي: $y = f(t)$ ، وتعتبر السلاسل الزمنية أهم وسائل التنبؤ حول المستقبل من خلال وقائع الأمس واليوم، والتغير الذي يحدث في قيم متغير السلسلة الزمنية

الفصل الأول: الإطار النظري للتنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

يعتبر دالة في الزمن، وفي الأصل قام كل من Brown عام 1962 و Holt et al عام 1963 بتقديم أول وصف للتنبؤ قصير المدى، ويمكن توضيح مكونات السلاسل الزمنية كما يلي: (George E.P. Box et al., 2016, p 2-3)

- **الاتجاه العام:** الاتجاه الذي تأخذه السلسلة الزمنية للظاهرة محل الدراسة خلال فترة زمنية سواء في إطار متزايد (اتجاه موجب) أو متناقص (اتجاه سالب)، وفي كل الحالات لا يكون التغير مفاجئاً بل بالتدرج وهو ميزة للاتجاه العام الذي يعتبر من أهم عناصر السلسلة الزمنية، لأنه يبين الحركة المنتظمة لحالات التزايد (النمو) والتناقص (الركود) لفترات زمنية طويلة.
- **التغيرات الموسمية:** هي فترات خاصة كالأعياد أو بداية العام الدراسي، حيث يكثر بيع سلعة معينة وتعد هذه الفترات مجالا جيدا للدراسة، وقد يلعب الطقس والتقاليد والاحتفالات الدينية والوطنية دورا بالتأثير على التغير الموسمي الذي لا يزيد طول فترته عن السنة، فقد يكون أسبوعيا أو يوميا أو كل أربعة أشهر.
- **التغيرات الدورية:** هي التغيرات التي تطرأ على الدورات الاقتصادية من ارتفاع وهبوط بمدة تتجاوز السنة وتضم عدة مراحل في الدورة الكاملة هي: الارتفاع الأولي – التراجع – الركود – الانتعاش – الارتفاع النهائي، وقد تمتد طول الفترة (الدورة الكاملة) من ثماني سنوات إلى عشر سنوات وترجع لعوامل كثيرة مثل سياسة الحكومة والعلاقات الدولية وغيرها ويقاس طول الدورة بطول الفترة الزمنية بين مرحلتين ازدهار متتاليتين أو ركود متتاليتين.
- **التغيرات العشوائية:** تشير هذه التغيرات وهي غير منتظمة لتحركات السلسلة الزمنية للأعلى وللأسفل بعد استبعاد التغيرات الأخرى والاتجاه العام، وتنشأ هذه التغيرات عن عوامل لا يمكن التحكم بها كالزلازل والبراكين والفيضانات والحروب وإفلاس بنك وما شابه ذلك، ومن الواضح بأنه لا يمكن التنبؤ بها لعدم انتظامها من جهة وللفترة الزمنية الصغيرة التي تحدث فيها، ويهمل تأثيرها عند دراسة العناصر الأخرى للسلسلة الزمنية وغالبا يشار إليها بالتغيرات المتبقية Residual Variations لكونها تضم ما تبقى من العوامل التي لم يشر إليها في عناصر السلسلة الثلاثة السابق ذكرها وبالطبع هذا العنصر عشوائي لأنه يقع فجأة أو بالصدفة.

لذلك وجب قبل التنبؤ بالسلاسل الزمنية معرفة مكوناتها بدقة واختيار النموذج الملائم، ومن بين نماذج السلاسل الزمنية المستخدمة في التنبؤ ما يلي:

1- نماذج Box Jenkins

قام كل من الباحثان Box و Jenkins سنة 1962 بتقديم منهجية لدراسة السلاسل الزمنية من خلال تحديد المتنبئ متعدد الحدود المناسبة للظاهرة المدروسة قصد التنبؤ بمتغيراتها، عن طريق تحديد نمط البيانات وتقديم تنبؤات دقيقة بناء على هذا النمط، وذلك مرورا بمراحل تحليلية تشمل اختبارات جذر الوحدة ودراسة استقرارية

الفصل الأول: الإطار النظري للتنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

السلسلة وأخيرا تحديد النموذج الأنسب للتنبؤ وفقا لمعايير إحصائية معينة، وهي صيغة مثيرة للاهتمام يمكن استخدامها للتنبؤ بالسلاسل الزمنية غير الثابتة. (Terence C. Mills, 2011, p 313)

2- نماذج المتوسط المتحرك التكاملية ذاتي الانحدار البسيط AutoRegressive Integrated Moving

Average (ARIMA)

هي فئة من نماذج السلاسل الزمنية التي تستخدم لتمثيل البيانات غير المستقرة وتحويلها إلى بيانات مستقرة من خلال التفاضل، وتتضمن هذه النماذج مكونات المتوسط المتحرك MA، الانحدار الذاتي AR، والتكامل I، ظهرت في السبعينيات حين قام George E. P. Box وGwilym Jenkins بترويج هذه النماذج لأول مرة في كتاب صدر عام 1970، كامتداد لنموذج بوكس-جينكز الذي وصف هذه النماذج على أنها مفيدة وجيدة في التنبؤ بالسلاسل الزمنية، وذلك لتوفير أدوات أكثر مرونة لتحليل السلاسل الزمنية المختلفة، كما استخدمت لتحليل والتنبؤ بتقلبات أسعار الأسهم من خلال نمذجة العلاقات الزمنية بين البيانات السابقة والحالية مما يساعد في فهم الاتجاهات والتذبذبات المحتملة. (Robert J. Shiller, 2019, p 295)

3- نماذج الانحدار الذاتي ذو التباين الشرطي غير المتجانس Autoregressive Conditional

Heteroskedasticity (ARCH)

تم تقديم النموذج الأولي ARCH في أوائل الثمانينيات (عام 1982) بواسطة Robert Engle والتي حصل بها على جائزة نوبل في الاقتصاد عام 2003، وقد تم تطويره والحصول على نماذج أكثر كفاءة من النموذج الأولي كنموذج ARCH المعمم GARCH للعالم Bollerslev عام 1986، ونموذج GARCH الأسّي EGARCH للعالم Nelson عام 1991 وغيرها من النماذج المتطورة، تستخدم لنمذجة التقلبات الزمنية في السلاسل الزمنية المالية، حيث تفترض هذه النماذج أن التباين الشرطي للتغيرات في الأسعار يعتمد على القيم السابقة للتباين والتغيرات السابقة في الأسعار وغير مترابطة بشكل تسلسلي، والتي تتيح فهم كيفية تغير التقلبات المالية مع مرور الوقت حيث يمكن أن تتزايد أو تتناقص التقلبات بناء على الأحداث السابقة مما يعكس طبيعة التقلبات المالية المتغيرة، والتي توفر نهجا جيدا للتنبؤ بهذه التقلبات بشكل دقيق. (Tsay, 2005, p 102-105)

4- نموذج التقلبات العشوائية Stochastic Volatility Models (SVM)

تعتبر من الأدوات المتقدمة في مجال التنبؤ بتقلبات أسعار الأسهم، فمنذ أواخر التسعينيات أصبحت نماذج التقلبات العشوائية تحتل مكانة مركزية في التحليل الاقتصادي للتنبؤ بالتقلبات باستخدام البيانات عالية التردد المستندة إلى تقلبات محققة، يعود السبب في ذلك إلى أن التحليل الاقتصادي للتقلبات المحققة يعتمد على عمليات الزمن المستمر، تهدف إلى تحسين فهم وتحليل سلوك التقلبات في الأسواق المالية من خلال اعتبار التقلبات نفسها كعمليات عشوائية تتغير بمرور الوقت، هذا يسمح بمرونة أكبر في تمثيل سلوك التقلبات خاصة

الفصل الأول: الإطار النظري للتنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

في الحالات التي تظهر فيها التقلبات خصائص غير خطية أو غير مستقرة عبر الزمن، قدم كل من Robert Engle و Norbert Fischer اسهامات بارزة في تطوير هذه النماذج، وقد توسعت هذه التطورات من تطبيقات نماذج التقلبات العشوائية لتشمل مجالات هامة لإدارة المخاطر. (Neil Shephard, 2005, p 248-257)

رابعاً: تطبيقات الذكاء الاصطناعي

بدأ استخدام تقنيات الذكاء الاصطناعي في المالية في التسعينيات مع التطور في الحوسبة وتوفير كميات كبيرة من البيانات المالية، وتشمل مجموعة من الأساليب المتقدمة كالشبكات العصبية الاصطناعية والتعلم العميق والتعلم الآلي وغيرها من التقنيات، والتي تستخدم لتحليل البيانات المالية المعقدة والتنبؤ بتقلبات الأسعار، تتميز هذه التقنيات بقدرتها على التعامل مع كميات كبيرة من البيانات واستخراج الأنماط المعقدة التي قد تكون غير مرئية للنماذج التقليدية، وتركز هذه التقنيات على تحسين دقة التنبؤات من خلال التكيف مع التغيرات في السوق وتحديث نماذجها بشكل مستمر بناء على البيانات الجديدة، وسيتم التعمق في هذا الجزء في الفصل الموالي.

المبحث الثالث: إدارة المخاطر المالية

تعد إدارة المخاطر المالية من الركائز الأساسية في عالم الاقتصاد الحديث، إذ تشكل المخاطر المالية هاجسا بالنسبة للمتعاملين في الأسواق المالية، حيث سعى المستثمرون سواء أفراد أو شركات إلى تحصين أنفسهم ضد التقلبات المالية غير المتوقعة، ومع التطور الكبير في الأسواق المالية وتعقيد الأدوات الاستثمارية أصبح من الضروري وجود استراتيجيات محكمة لإدارة المخاطر التي قد تؤثر سلبا على القرارات الاستثمارية ومنه على العوائد والأرباح، لذلك إدارة المخاطر تتضمن عملية مستمرة من التعرف على المخاطر المحتملة، قياسها، ووضع استراتيجيات للتعامل معها واختيار طرق ونماذج قياس وإدارة المخاطر المالية، حيث تلعب النماذج الإحصائية والتحليل الكمي دورا محوريا في هذه العملية فهي تسمح بتحليل البيانات التاريخية والمتغيرات المؤثرة على الأسواق لتوقع المخاطر المستقبلية. من أجل توضيح ذلك يتناول هذا القسم مدخل لإدارة المخاطر المالية كمطلب أول، وطرق ونماذج قياس وإدارة المخاطر المالية كمطلب ثاني.

المطلب الأول: مدخل لإدارة المخاطر المالية

في منتصف القرن الماضي عرف علم المالية مدخلا جديدا في نماذجه تمثل في مفهوم الخطر، فالمستثمرون يواجهون درجة معينة من المخاطرة مقابل توقعهم الحصول على عائد، وهناك أكثر من تعريف للمخاطر التي تتعرض لها الاستثمارات فمنها عدم التأكد من التدفقات النقدية المستقبلية الناتجة عن الاستثمار، واحتمال فشل المستثمر في تحقيق العائد المتوقع على الاستثمار، وكذلك درجة التذبذب أو التقلب في العائد المتوقع، أو هي مجموعة الأحداث التي تؤثر في عملية التنبؤ في تقدير وتقييم الأصول المالية، ومنه فإن المخاطر ترتبط بعدة مفاهيم هي درجة المخاطر، عدم التأكد، المجازفة، وتصنف المخاطر إلى مخاطر النشاط (الأعمال)، والمخاطر المالية والتي يقصد بها المخاطر التي يتعرض لها حملة الأصول المالية والتي ترتبط بالأسواق المالية التي تعمل فيها، نتيجة تقلبات المتغيرات المالية والتي تعتبر محل هذه الدراسة، لذلك يتناول هذا القسم مدخل لإدارة المخاطر المالية الذي يشكل الخطوة الأولى، حيث يتم تحديد المفاهيم الأساسية للمخاطر المالية وأنواعها واستراتيجيات إدارتها.

أولا: تعريف المخاطر المالية

من أهم التعريفات المقدمة لمفهوم المخاطر المالية ما يلي:

المخاطر المالية تمثل: "احتمالية تكبد خسائر نتيجة لتغيرات في أسعار السوق أو بسبب وقوع أحداث نادرة لكنها قد تؤدي إلى خسارة عالية مزعجة بشكل خاص بسبب أنها لا تكون متوقعة في الغالب، بمعنى أن المخاطر ترتبط بالتقلب المحتمل في العوائد، حيث يمكن القول إن المخاطر المالية عملية تهدف إلى التعامل مع حالة عدم

الفصل الأول: الإطار النظري للتنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

اليقين التي تنشأ من الأسواق المالية وتتضمن تقييم المخاطر المالية التي قد تتعرض لها الشركات وذلك لغرض وضع استراتيجيات إدارة تتماشى مع الأولويات والسياسات الداخلية". (كارين أ. هورشر 2008, et al., ص 20-21)

الخطر المالي يشير إلى: "موقف أو سلسلة من الأحداث المترابطة أو المتتابعة والتي تحدث تلقائياً أو نتيجة أحداث معينة، وبما أن وقوعها غير مؤكد فإن تحققها يؤثر على أهداف الشركة التي تتعرض لها، لذلك فالخطر المالي يتميز بصفتين هما: احتمالية حدوثها وأثارها أو جاذبيتها". (Bernard Barthélemy & Philippe Courrèges, 2004, p 11-13)

وحسب Mark S. Dorfman هناك تعريفان مميّزان يستخدمان عادة لمصطلح المخاطر المالية، الأول يعرف بأنها: "التباين في النتائج المحتملة لحدث ما بناء على الصدفة، أي أنه كلما زاد عدد النتائج المختلفة التي قد تحدث زاد الخطر، بمعنى أنه كلما زاد التباين حول الخسارة المتوقعة المتوسطة زاد الخطر"، أما التعريف الثاني فهو: "عدم اليقين بشأن الخسارة نتيجة تذبذب العائد المتوقع، أي أن المخاطر تتمثل في انحراف الأرقام الفعلية عن الأرقام المتوقعة، ودرجة المخاطرة هي مقياس للدقة التي يمكن بها التنبؤ بالعائد المتوقع وهنا كلما كانت دقة التنبؤ عالية كلما انخفضت درجة المخاطرة". (Mark S. Dorfman, 2004, p 7-8)

ومنه فإن المخاطر المالية تعبر عن الاحتمالية الكمية لتحقيق عوائد أقل من المتوقع أو تكبد خسائر، وتمثل تهديدا لعملية تحقيق أهداف المستثمر، بعبارة أخرى تشير المخاطر المالية إلى احتمال التأثير السلبي لأي حدث أو ظاهرة مستقبلية، فعند الإشارة إلى ورقة مالية أو أصل مالي فإن القيمة الحقيقية لها تتوقف على كل من التدفقات النقدية المتوقعة ودرجة المخاطر المرتبطة بتلك التدفقات ولذلك يعتبر العائد والخطر المحددات الرئيسية التي يجب التنبؤ بها لتقدير القيمة الحقيقية للورقة المالية، كما ينظر لمصادر المخاطر المالية إلى الخسائر المحتملة نتيجة تقلبات الأسواق المالية.

ثانياً: أنواع المخاطر المالية

يمكن تقسيم المخاطر المالية حسب مصدرها إلى الأنواع التالية:

1. مخاطر السوق

هي الخسائر المحتملة التي تنتج عن التغيرات التي تحدث على مستوى السوق المالي الراجع للعديد من الأسباب التي تؤثر على التدفقات النقدية المتوقعة ومعدل العائد المطلوب، أي تنتج عن التغيرات الكبيرة في الأسعار السوقية للأصول أو الأوراق المالية، وتعتبر هذه المخاطر مهمة للمستثمرين والمؤسسات المالية لأنها تؤثر مباشرة على قيمة المحافظ الاستثمارية، وتؤثر بشكل واضح على الأسواق المالية من خلال الأسهم العادية خاصة، وقد يختلف مستوى وشكل التعرض لمخاطر السوق حسب الصناعات أو الشركات، في حين هناك بعض مخاطر السوق التي تواجهها جميع الشركات أو جميع القطاعات دون استثناء، وتشمل مخاطر السوق كل من مخاطر

الفصل الأول: الإطار النظري للتنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

التداول ومخاطر عدم التوافق بين الأصول والخصوم، حيث تشمل مخاطر التداول المخاطر التي تواجهها الشركات في محافظ الاستثمار والتداول الخاصة بها بسبب التغيرات في أسعار الفائدة وأسعار الصرف وأسعار الأسهم وأسعار السلع الأساسية، أما مخاطر عدم التوافق بين الأصول والخصوم ينشأ من الاختلاف في حساسية أسعار الفائدة للأصول والخصوم المدرجة في الميزانية العمومية. (James Lam, 2014, p 209-210)

ولعل أهم المخاطر السوقية هي مخاطر الاستثمار في الأسهم لأنها المحرك الرئيسي للأسواق المالية، حيث يقوم الاستثمار في الأسهم على مبدأ المقابلة بين المخاطر والعائد فكلما زادت المخاطر كلما زاد مقدار العائد المطلوب، ولا شك في أن هذه المخاطر منها ما يتعلق بالطبيعة الاستثمارية حيث توجد المخاطرة أينما وجد الاستثمار، ومنها ما يتعلق بالأسهم نفسها لكونها أكثر تعرضاً للمخاطر من وسائل الاستثمار الأخرى لا سيما وأنها تتأثر كثيراً بالبيئة الاستثمارية والظروف الاقتصادية والسياسية والاجتماعية مما يجعل أسعارها تتذبذب صعوداً وهبوطاً، إضافة إلى أن الاستثمار بالأسهم يتطلب وجود الثقة بين المستثمرين والإدارة فعند الاستثمار في شركة ما فإن المستثمر يرهن رأسماله في حسن تصرف إدارة تلك الشركة وأداءها للذين كثيراً ما يكونان غير ناجعين سواء بقصد أو بدونه. (Jonathan Berk et al., 2014, p 345-346)

2. مخاطر الائتمان

الائتمان هو الحصول على سلعة أو خدمة مقابل إعطاء وعد بدفع قيمتها بالنقود بعد مدة زمنية يتم الاتفاق عليها، وتشير مخاطر الائتمان إلى احتمال عدم قدرة أو فشل الطرف الآخر على الوفاء بالتزاماته المالية، مما يؤدي إلى خسائر للمقرض، أو نتيجة عجز مصدر الأوراق المالية عن دفع المبالغ المستحقة للمقرضين في آجال الاستحقاق، هذا النوع من المخاطر له تأثير كبير على المؤسسات المالية والبنوك التي تقدم قروضاً واستثمارات دين، حيث يمكن أن يؤدي إلى خسائر كبيرة إذا لم يتم تقييمه وإدارته بشكل جيد. (Darrell Duffie & Kenneth J. Singleton, 2003, p 4)

3. مخاطر السيولة

الأصل الذي يمكن بيعه بسرعة وتحويله إلى نقدية بدون انخفاض في قيمته يتميز بدرجة عالية من السيولة، ومخاطر السيولة تحدث عندما تجد الشركة صعوبة في تحويل أصولها إلى سيولة نقدية بسرعة كافية وبدون انخفاض قيمتها لتلبية احتياجاتها المالية، حيث يعمل كل مستثمر على تحويل أوراقه المالية إلى نقود سائلة، قد تؤدي هذه المخاطر إلى خسائر بسبب الحاجة إلى بيع الأصول بسعر أقل من قيمتها السوقية، والمقياس الأساسي للسيولة هو حجم الفارق بين سعر العرض أو السعر الذي يرغب المستثمر في شراء الأوراق المالية به وسعر الطلب أو السعر الذي يرغب به المستثمر في بيع الأوراق المالية به، وكلما اتسع الفارق بين سعري العرض والطلب كلما زاد خطر السيولة. (Fabozzi Frank J & Peterson Drake Pamela, 2009, p 700-701)

4. مخاطر التضخم

مخاطر التضخم تشكل مصدرا مهما للمخاطر خارج السوق ونعني به احتمال انخفاض القدرة الشرائية للنقود بسبب الارتفاع المستمر والعام للأسعار، مما يؤثر على العوائد الحقيقية للاستثمارات والأصول المالية بمختلف أنواعها خصوصا تلك التي تقدم عائدا ثابتا كالسندات، من خلال انخفاض قيمتها الحقيقية. (Bodie Zvi et al., 2018, p 293)

كما يمكن تقسيم المخاطر المالية إلى مخاطر نظامية ومخاطر غير نظامية:

- **المخاطر النظامية:** تعرف على أنها خطر حدوث صدمة مفاجئة من شأنها أن تلحق الضرر بالنظام المالي وتخلق تأثيرات متتالية في جميع أنحاء الاقتصاد، وتنتج عن عوامل تؤثر في عوائد وأرباح جميع الأوراق المالية بوجه عام والتي تتداول في السوق المالي، ولا يقتصر تأثيرها على شركة معينة أو قطاع معين، فهي تعكس طبيعة النظام المالي ذاته فتسمى بالمخاطر العامة، وهذه العوامل غير قابلة للسيطرة إذ لا يمكن للمستثمر التحكم في تأثيرها، ولذلك تعرف بالمخاطر غير القابلة للتنوع، ومع ذلك يجب على المستثمر أن يكون على دراية مسبقا باحتمال تأثر الأوراق المالية بتلك المخاطر، ومن أمثلة العوامل المؤثرة التضخم، وبعض الأزمات المالية، كالحروب والأزمات الصحية، وتقلبات أسعار الفائدة. (Philippe Jorion GARP, 2007, p 634-635)
- **المخاطر غير النظامية:** هي مخاطر لا تؤثر في السوق ككل حيث تكون منفردة تتعلق بشركة فقط أو قطاع معين أو ورقة مالية معينة، وتكون مستقلة عن العوامل المؤثرة في النشاط الاقتصادي ككل فتسمى بالمخاطر الخاصة، وتنشأ نتيجة لسلسلة من الأحداث التي يكون وقوعها عرضيا حيث تحدث وفقا لتوزيعات احتمالية مختلفة، إذا هي مخاطر قابلة للتنبؤ على نحو مستقل لكل مؤسسة أو لكل قطاع، ومنه يمكن تجنبها بالتنوع. (Laurent Condamine et al., 2006, p 4)

ثالثا: الاستراتيجيات المتبعة في إدارة المخاطر المالية

إن إدارة المخاطر المالية كعلم يقوم على التحليل الواقعي للظواهر الاقتصادية وكفن من فنون صياغة النماذج القياسية، فهي عبارة عن المنهج أو المدخل العلمي للتعامل مع المخاطر عن طريق توقع الخسائر المحتملة التي يمكن أن تطرأ على الاستثمار من خلال تصميم وتنفيذ إجراءات من شأنها تقليل إمكانية حدوث الخسائر أو تقليل الأثر المالي لها، وتتناول إدارة المخاطر المالية العلاقة بين العائد المطلوب على الاستثمار وبين المخاطر التي تصاحب هذا الاستثمار والهدف من ذلك هو سعي المستثمر لتوظيف هذه العلاقة عن طريق تعظيم قيمة الاستثمار وتحقيق أكبر عائد ممكن في ظل أدنى المخاطر، لذلك يوضح هذا القسم ماهية إدارة المخاطر المالية أولا ثم التطرق للاستراتيجيات المتبعة في إدارة المخاطر المالية، كما يلي:

1- تعريف إدارة المخاطر المالية

يمكن توضيح ما يعنيه مصطلح إدارة المخاطر المالية من خلال التعاريف التالية:

تعرف إدارة المخاطر المالية على أنها: "إدارة الأحداث أو الإصابات التي لا يمكن التنبؤ بها بشكل أكيد والتي قد تترتب عنها خسائر محتملة الحدوث إذ لم يتم التعامل معها بشكل مناسب، وتحاول إدارة المخاطر المالية تحديد المخاطر وتقييمها وقياسها ثم تطوير التدابير المضادة واستخدام الأدوات المناسبة للتخفيف من تأثيرها، ولأن الفرص ضئيلة بدون درجة معينة من المخاطر فهذا لا يعني التخلص منها لأن ذلك قد يعني التخلص من العائد المتوقع". (Anthony Tarantino & Deborah Cernauskas, 2009, p 53-54)

ويشير Karen A. Horcher إلى أن: "عملية إدارة المخاطر المالية تتضمن التحليل الداخلي والخارجي، إذ يتكون الجزء الأول من العملية تحديد المخاطر المالية التي تواجه الشركة وإعطاء الأولوية لها وفهمها واتخاذ استراتيجيات تمكّنها من الاستمرار والمنافسة في ظل التحديات العالمية المعاصرة". (Karen A. Horcher, 2005, p 6-7)

وتعتبر إدارة المخاطر المالية قضية ليست بالمعاصرة فقد كانت تشكل تحدياً منذ أن كانت الأسواق وتقلبات الأسعار موجودة، بالإضافة إلى أنها عملية ديناميكية يجب أن تتطور مع الشركة وأعمالها. (Karen A. Horcher, 2005, p 19)

وتعرف إدارة المخاطر المالية على أنها: "مجموعة من الأنشطة التي من خلالها تستهدف تدنية الخسائر المحتملة من وقوع هذه المخاطر، إذ تتوفر للشركة استراتيجيتان واسعتان لإدارة المخاطر المالية متاحتان تتمثل إحداها في تحديد المخاطر واحدة تلو الأخرى والتعامل مع كل منها على حدة ويشار إليها غالباً بتحليل المخاطر، وتتمثل الاستراتيجية الأخرى في تقليل المخاطر من خلال التنوع الجيد، أو التأمين، أو التحوط، ويشار إلى ذلك غالباً باسم تجميع المخاطر". (John C. Hull, 2015, p 17)

من خلال التعاريف السابقة يمكن القول إن إدارة المخاطر المالية تتضمن كافة الأنشطة التي تحاول تغيير شكل العلاقة بين العائد المتوقع ودرجة المخاطر المرتبطة به، وذلك بهدف تعظيم قيمة الأصل الذي يتولد عنه هذا العائد، بالإضافة إلى أن النظام المتكامل لإدارة المخاطر المالية يعتمد على ثلاث مراحل أساسية هي: تحديد الخطر، قياس الخطر، واستخدام الأساليب أو الأدوات المناسبة لتدنية مستوى الخطر، أو منع حدوثه وتجنبه.

2- نهج إدارة المخاطر المالية

يستخدم المستثمر سواء كان فرد أو شركة غالباً العمليات التالية لإدارة المخاطر المالية: (Brigham & Houston, 2019, p 152-153)

- تحديد المخاطر التي تواجهها الشركة، وهنا يقوم مدير المخاطر بتحديد المخاطر المحتملة،

الفصل الأول: الإطار النظري للتنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

- قياس التأثير المحتمل لكل خطر، فبعض المخاطر صغيرة جدا بحيث لا تشكل أهمية كبيرة، في حين أن مخاطر أخرى قد تؤدي إلى تدمير الشركة، ومن المهم الفصل بين المخاطر حسب التأثير ثم التركيز على التهديدات الأكثر خطورة،
 - تحديد كيفية التعامل مع كل خطر ذي صلة، وفي أغلب الحالات يمكن تقليل التعرض للمخاطر المالية من خلال اتباع إحدى التقنيات التالية:
 - نقل المخاطر إلى شركات التأمين: غالبا ما يكون من المفيد التأمين ضد المخاطر ومع ذلك فإن قابلية التأمين لا تعني بالضرورة أن المخاطر يجب أن يغطيها التأمين في كثير من الحالات قد يكون من الأفضل للشركة أن تؤمن على نفسها، وهو ما قد يؤدي إلى تفاقم المشكلة يعني تحمل المخاطر بشكل مباشر بدلا من دفع طرف آخر لتحملها.
 - نقل الوظيفة التي تنتج المخاطر إلى طرف ثالث.
 - عقود المشتقات المالية لتقليل المخاطر: حيث تستخدم الشركات المشتقات المالية للتحوط من المخاطر.
 - تقليل احتمال وقوع حدث سلبي.
 - تقليل حجم الخسارة المرتبطة بحدث سلبي.
 - تجنب النشاط الذي يؤدي إلى المخاطرة تماما.
- ومما سبق يمكن تحديد ثلاث استراتيجيات رئيسية لإدارة المخاطر المالية وهي:

أ- استراتيجية ترك الموقف مفتوح

ويقصد بذلك الاحتفاظ بمستوى الخطر المالي على ما هو عليه، وتعتمد الشركة غالبا على هذه الاستراتيجية عندما تكون تكلفة إدارتها أعلى من المخاطر نفسها، أو حينما يكون مستوى الخطر ذات احتمالية منخفضة، وتندرج تحت هذه الاستراتيجية سياسة قبول الخطر. (Gérard-Philippe Ranson et al., 2006, p 20)

ب- استراتيجية تحمل مخاطر محسوبة

تتضمن هذه الاستراتيجية تحديد مستويات الخطر التي يمكن تحملها بالشركة ثم اتخاذ كافة التدابير المناسبة لتدنية المخاطر بها حتى هذا المستوى المقبول، وعادة ما تكون هذه الاستراتيجية شائعة عندما تتوفر بيانات كافية لتقدير احتمالية المخاطر وتأثيرها مما يتيح اتخاذ قرارات مستنيرة، وتندرج تحت هذه الاستراتيجية سياسة تخفيض الخطر، كالتنوع في خطوط منتجات الشركة (هيكل الاستثمار)، والتغيير في مستوى الرافعة المالية (هيكل التمويل)، واستخدام أدوات الهندسة المالية للحماية ضد مخاطر الأسعار. (Sophie Gaultier-

Gaillard & Jean-Paul Louisot, 2014, p 37)

ت- استراتيجيات تغطية كل الخطر

تهدف إلى التخلص من جميع المخاطر المالية المرتبطة بعملية معينة عن طريق تحييد مصدر الخطر بالنسبة للشركة، أي تدنية الخطر المالي إلى الصفر، ويندرج تحت هذه الاستراتيجيات سياسات تحويل الخطر كالتغطية الكاملة أو التأمين ضد الخطر أو التحوط باستخدام أدوات الهندسة المالية كالاتفاقيات طويلة الأجل والمشتقات، أو تحويل الخطر المالي. (Jean-Pierre Fouque et al., 2000, p 115)

المطلب الثاني: أساليب قياس المخاطر المالية

إن الأسواق المالية تتعرض لمخاطر متعددة نتيجة للظروف والعوامل البيئية التي تواجهها، فعدم التعرف على هذه العوامل وتطوير أساليب لقياسها سوف يعرض الشركات والمستثمرين لمخاطر وخسائر مالية، لأن إحدى الصعوبات الأساسية لعملية إدارة المخاطر هي استخدام العمليات العشوائية والأساليب الإحصائية، فالاستثمار هنا هو عبارة عن تضحية بمبالغ مؤكدة بغية الحصول على مبالغ مالية مستقبلية أي مبالغ غير مؤكدة، وهذا يتم اتخاذه بناء على العائد والمخاطرة، وكما هو معروف كلما زادت العوائد زادت المخاطرة، وهنا نتعامل مع نوع معين من المخاطر وهي المخاطر المالية المتعلقة بتقلبات أسعار الأسهم باعتبارها أهم المخاطر التي تتعرض لها الأسواق المالية خاصة مع الأزمات العالمية التي حدثت مؤخرا، ولذلك تقتصر هذه الدراسة على طرق ونماذج قياس هذا النوع من المخاطر المالية. وهنا يجدر الإشارة إلى التمييز بين نوعين من الطرق: نماذج قياس الخطر المستقل، ونماذج قياس الخطر في حالة محفظة مالية، ومن أهم النماذج المستخدمة لقياس الخطر المالي المستقل نموذج القيمة المعرضة للخطر والذي يعد من أشهر الأدوات لقياس المخاطر المحتملة، إلى جانب الأدوات الإحصائية وبعض النماذج الأخرى والتي يتم التطرق لها في هذا القسم.

أولا: الأدوات الإحصائية

هي من أهم الأساليب المستخدمة لتحليل مخاطر الاستثمار في الأسهم حيث توفر مؤشرات كمية لقياس التقلبات وعدم اليقين، تعتمد هذه الأدوات على قياس درجة التشتت في قيم المتغير المالي محل الاهتمام أو قياس درجة حساسيته تجاه التغيرات التي تحدث في متغير آخر، ومن أهم هذه الأدوات ما يلي:

1. المدى Range

والذي يتمثل في أبسط مقاييس التشتت الإحصائي، ويعرف بأنه الفرق بين أعلى قيمة وأدنى قيمة للمتغير المالي موضع الاهتمام، ويمكن استخدام المدى كمؤشر للحكم على المستوى النسبي للخطر، لكنه لا يعكس توزيع البيانات بشكل كامل، وكلما زادت قيمة المدى كان ذلك مؤشرا على ارتفاع مستوى الخطر المصاحب للمتغير المالي موضع الاهتمام. (Murray R. Spiegel & Larry J. Stephens, 2008, p 95)

2. التوزيعات الاحتمالية Probability Distributions

وهي تقدم أداة كمية أكثر تفصيلا من مقياس المدى، وذلك من خلال تتبع سلوك المتغير المالي، وتحديد القيم المتوقعة الحدوث في ظل الأحداث القابلة للتحقق، وتحديد التوزيع الاحتمالي لهذه القيم، واستخدامه في المقارنة بين مستويات الخطر المصاحبة لعدد من الأصول المستقلة، وبما يمكن من المفاضلة فيما بينها، أو بمعنى آخر هو وصف رياضي لاحتمالية وقوع نتائج مختلفة في بيانات عشوائية، وتستخدم التوزيعات الاحتمالية لفهم سلوك المتغيرات العشوائية وتقدير المخاطر، فكلما كان التوزيع الاحتمالي أكثر اتساعا نحو الطرفين، كان ذلك مؤشرا على ارتفاع مستوى الخطر. (خالد وهيب الراوي، 2000، ص 41)

3. الانحراف المعياري Standard Deviation

يعتبر أكثر المقاييس الإحصائية استخداما كمؤشر للخطر الكلي المصاحب للورقة المالية، وهو يقيس درجة تشتت قيم الأوراق المالية حول القيمة المتوقعة له، بمعنى يظهر مدى انتشار البيانات حول قيمتها المتوسطة، وكلما زادت قيمة الانحراف المعياري ذل ذلك على ارتفاع مستوى الخطر، على أساس أن الأوراق المالية التي تتفاوت عائداتها كثيرا من عام إلى آخر تكون أقل قابلية للتنبؤ وبالتالي أكثر خطورة من تلك التي لا تتباين عائداتها كثيرا، ويمكن حسابه كالآتي: (David S. Moore et al., 2009, p 40-44)

$$\sigma = \sqrt{\sigma^2}$$

لكن قد يسمح الانحراف المعياري بتساوي ورقتين في درجة الخطورة بالرغم من اختلاف النسب المئوية لانحراف العوائد عن الوسط الحسابي، وللتخلص من هذه المشكلة يتم استخدام التباين أو معامل الاختلاف كمقياس للخطر المالي.

4. معامل الاختلاف أو التباين Coefficient of Variation

هو مقياس نسبي (أو معياري) لدرجة التشتت حيث يربط بين الخطر (مقاسا بالانحراف المعياري) وبين العائد (مقاسا بالقيمة المتوقعة)، ولذلك يصبح معامل الاختلاف أكثر دقة وتفضيلا عن الانحراف المعياري عند المقارنة بين عدة أصول مستقلة ومختلفة فيما بينها من حيث العائد والخطر، إن معامل الاختلاف يعبر عن درجة الخطر لكل وحدة من العائد، أي أنه يقيس أساسا الفرق التربيعي المتوسط بين العائدات الفعلية والعائد المتوسط، وكلما ارتفعت قيمته دل ذلك على ارتفاع مستوى الخطر. (Stephen A. Ross et al., 2018, p 397-398)

ونلخص التباين في العبارة التالية: (Stephen A. Ross et al., 2018, p 424)

$$v = \sigma^2 = \sum R_i - E(R)^2 P_i$$

حيث:

σ^2 : التباين (مربع الانحراف المعياري)،

R_i : عائد الورقة المالية i ،

$E(R)$: التوقع الرياضي للعائد،

P_i : احتمال الورقة المالية i .

5. معامل بيتا Beta Coefficient

وهو مقياس لمدى حساسية قيم المتغير المالي للتغيرات التي تحدث في متغير آخر، كقياس درجة حساسية عائد سهم معين للتغيرات في عائد السوق، أين تظهر علاقة درجة خطورة السوق المالي وعلاقة الورقة المالية بالسوق، ويدل معامل بيتا المرتفع على ارتفاع درجة الحساسية وبالتالي ارتفاع مستوى الخطر. (Edwin J. Elton et al., 2014, p 135-137)

ثانيا: نموذج تسعير الأصول المالية (The Capital Asset Pricing Model (CAPM)

لقد أرسى تحليل Markowitzs للتباين المتوسط سنة 1950 تأسيس نموذج تسعير الأصول الرأسمالية CAPM الذي تم تطويره بشكل مستقل من قبل W.F.Sharpe عام 1964 و Treynor عام 1965 و Linter عام 1965 أيضا، ويعد CAPM أداة تحليلية شائعة لقياس المخاطر المنتظمة التي لا يمكن تقليلها بالتنوع، ويعتمد هذا النموذج على فكرة العقلانية بين العائد والمخاطرة، نموذج تسعير الأصل الرأسمالي هو نموذج يتعلق بالعائد المتوقع على أصل استنادا إلى مستواه من المخاطر المنتظمة المرتبطة بالسوق، أي يعكس العلاقة بين العائد والمخاطرة باستخدام معامل بيتا كمقياس للمخاطرة (المخاطر العامة فقط للورقة المالية بافتراض المخاطر الخاصة يتم التخلص منها تماما عن طريق التنوع للمحفظة الاستثمارية)، ويعتبر من أفضل النماذج التي توضح العلاقة التوازنية بين العائد المطلوب على الأصول والخطر، يشمل نموذج تسعير الأصول الرأسمالية على نوعين من العلاقات وهي: خط سوق رأس المال والذي يوضح العلاقة التوازنية بين العائد المتوقع لمحفظة الأوراق المالية والخطر الكلي (منتظم وغير منتظم)، وخط سوق الأوراق المالية والذي يوضح العلاقة بين العائد المتوقع لسهم الواحد وخطر السوق (الخطر المنتظم)، ويعتمد نموذج تسعير الأصول الرأسمالية على مفهوم توازن السوق حيث يكون العائد الزائد المتوقع على أي أصل محفوف بالمخاطر متناسبا مع العائد الزائد المتوقع على محفظة السوق، وتلخص في العلاقة التالية: (Carol Alexander, 2008, p 252-253)

$$E(R_i) = R_f + B_i(E(R_m) - R_f)$$

حيث:

$E(R_i)$: العائد المتوقع على الأصل،

R_f : معدل العائد الخالي من المخاطرة ويقاس بالعائد على السندات الحكومية،

B_i : معامل بيتا للورقة المالية وهي مقياس للمخاطرة السوقية،


الفصل الأول: الإطار النظري للتنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

$E(R_m)$: العائد المتوقع على محفظة سوق الأوراق المالية.

ومنه فإن معدل العائد المطلوب من قبل المستثمرين على الموجودات المالية يتكون من العائد الخالي من المخاطرة وعلاوة مخاطرة الورقة المالية السوقية $B_i(E(R_m) - R_f)$ وهي تمثل سعر المخاطرة التي يحصل عليه المستثمر كعائد إضافي لقبوله الاستثمار، كما يتضح أن عائد السوق هو المتغير الوحيد الذي يؤثر على عائد السهم.

والشكل التالي يوضح نموذج تسعير الأصول الرأس مالية:

الشكل رقم (1-4): نموذج تسعير الأصول الرأس مالية.



المصدر: محمد صالح الحناوي، نهال فريد مصطفى، جلال إبراهيم العبد، تقييم الأسهم والسندات؛ مدخل الهندسة المالية، المكتب الجامعي الحديث، الإسكندرية، 2007، ص 195.

حيث يوضح الشكل البياني خط سوق الأوراق المالية الذي يمثل العلاقة الخطية بين العائد المتوقع والمخاطر المنتظمة، أما النقطة R_f على المحور العمودي تمثل العائد الخالي من المخاطرة.

ثالثاً: نماذج القيمة المعرضة للخطر

القيمة المعرضة للخطر من أهم المقاييس المستخدمة لقياس مخاطر الأوراق المالية، حيث يساعد هذا الأسلوب على حساب مقدار الخسارة في الأوراق المالية خلال فترة زمنية محددة وباحتمال محدد ويختصر المخاطر الكامنة في الأوراق المالية في رقم واحد، والجدير بالذكر أن للقيمة المعرضة للخطر عدة أنواع ظهرت مع تزايد تقلبات الأسواق المالية نذكر أهمها فيما يلي:

1. القيمة المعرضة للخطر

تعتبر القيمة المعرضة للخطر Value at Risk وسيلة لتقييم مخاطر السوق، ومن ناحية أخرى يصف VAR التباين المحتمل في العائدات، تم تطبيق هذه التقنية سنة 1980 في الأسواق المالية للولايات المتحدة الأمريكية من قبل بنك Bankers Trust، ثم أصبحت أكثر انتشاراً بواسطة بنك الاستثمار JP Morgan في عام 1994 بفضل

الفصل الأول: الإطار النظري للتنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

نظامه المعروف RiskMetrics، والذي أصبح يستخدم على نطاق واسع من قبل جميع البنوك الكبرى تقريبا، خاصة وأن لجنة بازل للرقابة المصرفية أشارت إلى أن الأسواق المالية يجب أن تكون قادرة على تغطية مخاطر الخسائر للأوراق المالية لأفق زمني مقداره عشرة أيام وبدرجة ثقة مقدارها 99% لهذه المدة. (Kevin Dowd, 2005, p 9-10) وقد تطور مفهوم القيمة المعرضة للخطر نتيجة زيادة التقلبات في الأسواق المالية، وتطور المنتجات المشتقة خاصة بعد سلسلة الانهيارات والأزمات في أسواق الأوراق المالية، الأمر الذي دفع إلى التفكير في إنشاء مؤشر مشترك ومركب للمخاطر المالية.

أ- تعريف القيمة المعرضة للخطر

قدمت تعاريف عديدة للقيمة المعرضة للخطر منها:

يرى Yamada أنها: "تحديد أقصى خسارة في قيمة الاستثمار خلال بعد زمني محدد باحتمالية مقدرة نتيجة التقلبات في أسعار ومعدلات السوق المؤثرة بشكل مباشر في عائد الاستثمار". (YAMADA & PRIMBS, 2002, p 4) أما Philippe Jorion فيعتبر القيمة المعرضة للخطر: "مجموعة تقنيات أو مقياس إحصائي تبين أن الخسارة ممكن أن تحدث في أي مدة من الزمن وتحت أي مستوى من مستويات الثقة طبقا لمخاطر السوق ولشركات مالية وغير مالية، وهذا ما جعلها أداة مستقرة تساعد في التحكم في المخاطر، وبأنها جزء مكمل للمنهجية التي تشير إلى توزيع العوائد بين الاستخدامات المختلفة، وتكمن أعظم مزاياها في أنها تلخص المخاطر في رقم واحد يسهل فهمه". (Philippe Jorion, 2007, p 105-107)

كما أنها تمثل: "الحد الأقصى للخسارة المحتملة لمستثمر في قيمة أصل ما أو مجموعة أصول مالية (محفظة)، والتي ينبغي أن تتحقق مع وجود احتمال معين على مدى أفق محدد، بعبارة أخرى أنها أسوأ الخسائر المتوقعة على مدى فترة زمنية معينة ومستوى احتمال معين، ويمكن اعتبار القيمة المعرضة للخطر بوصفها نسبة مئوية من توزيع الأرباح والخسائر المرتبطة بملكية أحد الأصول أو مجموعة من الأصول خلال فترة معينة". (Raoul Fokou, 2006, p 11)

ومما سبق يمكن القول إن القيمة المعرضة للخطر هي مؤشر كمي يعبر عن قيمة الخسائر التي لا يمكن تجاوزها في ظل مستوى معين من المخاطر، ومدى زمني معلوم، مما يساعد على تلخيص المخاطر في قيمة واحدة وبشكل أفضل.

وفي هذا السياق يمكن تعريف القيمة المعرضة للخطر رياضيا كما يلي: (Alexander J. McNeil et al., 2015, p 64)

$$P(L) < VAR = 1 - \alpha$$

تعبر هذه الصيغة عن احتمال تجاوز الخسارة قيمة معينة VAR بحيث لا يزيد عن نسبة $1 - \alpha$ عادة 5%

أو 1% حسب مستوى الثقة، إذن قيمة VAR هي ببساطة نسبة مئوية لتوزيع الخسارة.

الفصل الأول: الإطار النظري للتنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

وعند بناء نماذج عوائد اللوغاريتمات نستخدم بدلا من ذلك قيمة المخاطر VAR استنادا إلى عوائد

اللوغاريتمات المحددة على النحو التالي: (Alexander J. McNeil et al., 2015, p 71)


$$L_{t+1}^{\Delta} = -V_t X_{t+1}$$

حيث تمثل X_{t+1} العوائد اللوغاريتمية اليومية للسهم، لذا يتم تعريف VAR عندئذ على أنه الرقم حتى

نحصل على عائد لوغاريتمي الأسوأ فقط مع احتمال α .

ويمكن تمثيل القيمة المعرضة للخطر بالمنحنى التالي:

الشكل رقم (5-1): التمثيل البياني للقيمة المعرضة للخطر.



Source: RiskMetrics Group, Value at Risk: Parametric Method, Monte Carlo Simulation, Historical Simulation, EliScholar – /

A Digital Platform for Scholarly Publishing at Yale, Yale School Management, 2015, p 1.

يوضح الشكل القيمة المعرضة للخطر ضمن الطرف الخلفي لمنحنى التوزيع باستخدام مستوى ثقة 95%، باستخدام التوزيع الاحتمالي للعوائد المالية، حيث يمثل ذيل المنحنى الخسائر ويمثل مقدمة المنحنى الأرباح، ويظهر أن القيمة المعرضة للخطر تقيس أسوأ خسارة يمكن أن يتعرض لها المستثمر ضمن مستوى معين من الثقة 95%، لذلك فإن قيمة VAR توفر أداة كمية لإدارة المخاطر المالية يمكن استخدامها لتحديد حدود الخسائر المحتملة.

ب- مناهج قياس القيمة المعرضة للخطر

يمكن تصنيف مناهج قياس القيمة المعرضة للخطر إلى ثلاث هي:

- المنهج المعلمي: يعرف أيضا باسم طريقة الارتباط أو الطريقة التحليلية ويفترض هذا المنهج أن التوزيع الاحتمالي للعوائد معروف ويتبع عادة توزيعا طبيعيا، يشمل نموذجين هما: التباين/التباين المشترك

الفصل الأول: الإطار النظري للتنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

ونموذج التقريب التربيعي، هذا المنهج مناسب للأسواق المستقرة نسبياً، تم استخدامه أول مرة من قبل Bachelier عام 1900 باعتماد نظرية الحد المركزي لاستنتاج توزيع طبيعي لحركات أسعار الأسهم في بورصة باريس واكتشف أن التقلبات المتتالية في أسعار الأسهم طبيعية تقريبا، وتعتبر الخطوة الحاسمة في هذا المنهج هي الحصول على المتوسط والانحراف المعياري للتوزيع الطبيعي من سلسلة البيانات التاريخية، بمجرد الحصول على هذه القيم يمكن حساب القيمة المعرضة للخطر. (Yun Hsing Cheung & Robert J. Powell, 2013, p 103)

- **المنهج غير المعلمي (المحاكاة):** لا يفترض هذا المنهج أي توزيع مسبق للعوائد أو أي فرضية، بل يعتمد على تحليل البيانات التاريخية أو المحاكاة العشوائية، فهو يتيح للبيانات إظهار قدرتها على الكشف عن المسار المستقبلي للعوائد، وهو الذي يشتق عبر تطبيق خطوات المحاكات. (Simone Manganelli & Robert F. Engel, 2001, p 10-11)

ومن أكثر الطرق شيوعاً لتقدير القيمة المعرضة للخطر في هذا النهج هي:

- نموذج المحاكاة التاريخية الذي يأخذ البيانات السابقة ويحسب الخسائر المتوقعة بناء على ترتيبها، ويعد من أكثر الطرق المستخدمة لتقدير القيمة المعرضة للخطر، والفرضية الكامنة وراء هذه الطريقة أن توزيع العوائد في المستقبل يشبه في تطوره الماضي القريب. (Zenti & Pallotta, 2001, p 4)
- ونموذج محاكاة مونت كارلو الذي يولد توزيعات افتراضية لأسعار الأصول باستخدام نماذج محاكاة معقدة، بمعنى محاكاة مسارات العمليات العشوائية المستخدمة لوصف تطور أسعار الأصول. (Cox & Cox, 2006, p 203-204)

- **منهج الشبكات العصبية الاصطناعية:** يعتمد هذا المنهج الشبكات العصبية الاصطناعية لتوقع VAR بناء على التعلم من البيانات التاريخية واستخراج الأنماط المعقدة، ويستخدم هذا النهج في الأسواق المالية شديدة التقلب، حيث تناول كل من Locarek-Junge and Prinzler سنة 1999 تقدير قيمة المخاطر في سوق سعر الصرف في سياق الشبكات العصبية الاصطناعية حيث أظهرت النتائج تفوقاً واضحاً للشبكات العصبية الاصطناعية على نماذج تقدير قيمة المخاطر الأخرى، وقد طرح He et al سنة 2018 نتائج مماثلة حيث اقترحوا نوعاً مبتكراً من الشبكات العصبية الاصطناعية من نوع EMD-DBN لتقدير قيمة المخاطر. (Anna Bijelic & Tilila Ouijjane, 2019, p 30)

2. القيمة المعرضة للخطر المشروطة CVAR أو العجز المتوقع ES

اقترح Rockafellar and Uryasev عام 2000 مقياساً للمخاطر يسمى العجز المتوقع كبديل للقيمة المعرضة للخطر نتيجة الانتقادات الموجهة لها، ففحين تم الاعتراف على نطاق واسع بالقيمة المعرضة للخطر كمعيار لقياس المخاطر منذ 1990 فقد تضاءلت مصداقيته إلى حد كبير أثناء الأزمات المالية في أواخر العقد الأول من القرن

الفصل الأول: الإطار النظري للتنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

الحادي والعشرين (2000) فإنها ليست مقياسا ثابتا للمخاطر، ولا تحتوي على جميع الخصائص المطلوبة لقياس المخاطر بشكل جيد، ولا تعطي أي إشارة على حجم تلك المخاطر في حالة الأزمات، حيث لاحظ أن الخسائر الفعلية تتجاوز مستويات القيمة المعرضة للخطر، ما أدى إلى إدراك أن الأسواق المالية المجهددة يمكن أن تسبب تأثيرات مدمرة تتجاوز نطاق ما يتم قياسه والتنبؤ به باستخدام نموذج VAR فكانت توقعاتها بعيدة إلى الحد الذي دفع لجنة بازل إلى تغيير نهجها التنظيمي سنة 2012 لاستبدال VAR، لذلك تم اقتراح القيمة المعرضة للخطر المشروطة أو المتوقعة CVAR والمعروفة أيضا بالعجز المتوقع (ES) أو Expected Shortfall أو التوقع المشروط للذيل Conditional Tail Expectation (CTE) وتعتبر أداة فعالة لقياس الخسائر المحتملة في ظل ظروف السوق المتطرفة. (Rockafellar & Uryasev, 2000, p 21-24)

تعرف CVAR بأنها: "القيمة المتوقعة للخسائر التي تتجاوز VAR عند مستوى ثقة معين، وتعد مقياسا ثابتا للمخاطر، إذ تقيس معدل القيمة المعرضة للمخاطر المتوقعة بدقة في حالة الخسائر الكبيرة التي تتجاوز القيمة المعرضة للخطر VAR". (Anthony Saunders & Marcia Millon Cornett, 2018, p 470-471) ومنه فإن CVAR تعبر عن الخسائر المتوقعة التي تتجاوز VAR في أسوأ الحالات وتعتبر أداة فعالة لقياس المخاطر التي تأخذ في الاعتبار الأحداث النادرة والخسائر الكبيرة، خاصة في ظل التوزيعات غير الطبيعية أو التقلبات الحادة.

ومن المميزات الرئيسية المقدمة لقيمة CVAR هي كما يلي: (Huang et al., 2008, p 2-3)

- على عكس VAR التي تركز على الحد الأدنى من الخسارة عند مستوى معين من الاحتمال، تعكس CVAR متوسط الخسائر التي تتجاوز حد قيمة VAR مما يوفر رؤية أعمق للمخاطر الشديدة.
- تتمتع قيمة CVAR بخصائص رياضية متفوقة على قيمة VAR حيث تعد ما يسمى بمقياس المخاطر المتناسك.
- انحراف CVAR هو منافس قوي للانحراف المعياري حيث يمكن استبدال الانحراف المعياري بانحراف CVAR على سبيل المثال في حساب نسبة بيتا للمحفظة المالية، توازن السوق، والمقاييس والتنبؤات المالية.
- يمكن إدارة المخاطر باستخدام قيمة CVAR بكفاءة عالية، كما يمكن تحسينها وتقييدها باستخدام أساليب البرمجة المحدبة والخطية، في حين يصعب تحسين VAR نسبيا.
- تعطي CVAR وزنا أكبر للأحداث النادرة والخسائر المرتفعة، مما يجعلها أداة أكثر دقة لتقييم المخاطر التي تكون لها تأثير كبير.

ويمكن التعبير عن العجز المتوقع رياضيا كما يلي: (Sergio M. Focardi & Frank J. Fabozzi, 2004, p 749)

$$CVAR_{\alpha}(L) = E[L|L \geq VAR_{\alpha}(L)]$$

حيث:


L : تمثل الخسارة العشوائية،

$VAR_{\alpha}(L)$: تمثل القيمة المعرضة للخطر عند مستوى ثقة α ،

$E[L|L \geq VAR_{\alpha}(L)]$: تعني التوقع الشرطي للخسائر التي تتجاوز القيمة المعرضة للخطر.

تعبّر هذه المعادلة عن المتوسط الشرطي للخسائر التي تتجاوز قيمة VAR عند مستوى ثقة معين، وهذا يعني أن CVAR تأخذ بعين الاعتبار ليس فقط الحد الأقصى للخسارة ولكن أيضا شدة الخسائر المحتملة التي تقع خارج هذا الحد.

الشكل رقم (6-1): منحني بياني يوضح كل من VAR and CVAR.



Source: Sergey Sarykalin, Gaia Serraino and Stan Uryasev, Value-at-Risk vs. Conditional Value-at-Risk in Risk Management and Optimization, Tutorials in Operations Research, INFORMS, 2008, p 272.

يوضح الشكل الفرق بين القيمة المعرضة للخطر VAR والقيمة المعرضة للخطر المشروطة CVAR، حيث CVAR تأخذ في الاعتبار متوسط الخسائر التي تتجاوز VAR مما يجعلها مقياساً أكثر شمولاً للمخاطر، خاصة في حالة وجود أحداث نادرة ذات تأثيرات كبيرة.

خلاصة الفصل الأول

تم التطرق في هذا الفصل إلى مدخل نظري للتنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية، ومن خلال المبحث الأول تم التعمق في أساسيات تقلبات أسعار الأسهم حيث تعتبر هذه التقلبات انعكاسا للسلوك الديناميكي للأسواق المالية، إذ تم التوصل إلى أن هذه التقلبات تتأثر بالعديد من العوامل سواء كانت عوامل مباشرة أو غير مباشرة، عوامل مرتبطة بالبيئة الاقتصادية أو تلك المرتبطة بالسوق بصفة عامة أو المرتبطة بالسهم بصفة خاصة ومنها المرتبط بالآزمات العالمية، ومن الملاحظ أن لكل عامل تأثير بشكل أو بآخر، وقد تبلورت العديد من النظريات التي تفسر هذه التقلبات من أشهرها النظرية السلوكية ونظرية كفاءة الأسواق المالية، ونظرية التقلبات العشوائية.

أما المبحث الثاني فقد ركز على التنبؤ بتقلبات أسعار الأسهم الذي يعتبر أداة أساسية للمستثمرين والمحللين الماليين لأنه يتيح لهم التعرف على الأنماط المستقبلية للسوق وتقليل تأثير المخاطر غير المتوقعة، وقد خلاص هذا المبحث إلى أن النماذج الإحصائية والتحليلية سواء التقليدية كالتحليل الأساسي والفني، أو الحديثة التي تعتمد على تحليل السلاسل الزمنية كنماذج GARCH، ونموذج التقلبات العشوائية ونماذج الذكاء الاصطناعي تساعد في تقديم رؤية متعمقة حول اتجاهات السوق المستقبلية.

في حين خصص المبحث الثالث لإدارة المخاطر المالية، فقد أظهرت دراسة هذا المبحث أن إدارة المخاطر المالية تعد محورا أساسيا لضمان استدامة الاستثمارات وحمايتها من الخسائر الجسيمة، وأن استخدام أدوات كالقيمة المعرضة للخطر والقيمة المعرضة للخطر المشروطة تمكن من تقييم الخسائر المحتملة وتوفير استراتيجيات استباقية لتقليل آثار المخاطر.

وبذلك يمكن القول إن السهم كغيره من الأوراق المالية يتأثر بعوامل مختلفة تجعله يتميز بتقلبات شديدة وهو بذلك أكثر خطورة، وقد أثارت التقلبات في أسعار الأسهم أثارت جدل كبير وسط الباحثين، ويتضح أن فهمها والتنبؤ بها وإدارة المخاطر المالية هي ركائز أساسية لتحقيق استراتيجيات استثمار مستدامة وفعالة، لذلك قام العديد من الباحثين بالبحث عن نماذج أكثر تطورا للوصول إلى الدقة المطلوبة، من بين هذه النماذج تقنيات الذكاء الاصطناعي التي من أهمها الشبكات العصبية الاصطناعية والتي يتم التطرق لها في الفصل الموالي.

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية.

المبحث الأول: مدخل عام للذكاء الاصطناعي.

المبحث الثاني: الشبكات العصبية الاصطناعية.

المبحث الثالث: الشبكات العصبية الاصطناعية والتنبؤ بتقلبات أسعار الأسهم في إدارة المخاطر
المالية.

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

تمهيد

مع تزايد تعقيد الأسواق المالية وحجم البيانات المتاحة وعدم الاستقرار في أسعار الأسهم وكثرة العوامل المؤثرة فيها أصبحت الأدوات التقليدية لتحليل البيانات والتنبؤ المالي غير كافية للتعامل مع هذه التحديات خاصة بعد الأزمة الصحية التي ضربت العالم أجمع كوفيد 19، خاصة في الدول التي توجد فيها بورصات متطورة. حيث نشهد كل يوم انعكاس التقدم الهائل للتكنولوجيا واستخدام البيانات على آلية عمل البورصات، بالإضافة إلى ذلك فقد جرى استحداث العديد من الأدوات التي تهدف إلى تلبية احتياجات العاملين فيها، فيما يتعلق بالإدارة العلمية للاستثمار في الأوراق المالية وتغطية الأنواع المتعددة من الأخطار الاقتصادية والمالية وأهم هذه الأدوات هي أنظمة التحليل التي تدرس تغيرات قيم الأسهم من أجل تحديد فيما إذا كان الاستثمار فيها مجديا بحيث يحقق أهداف المستثمر أو لا، ولكن مع هذه التطورات الملحوظة في الأنظمة أصبحت الحاجة تزداد إلحاحا للحصول على تهجين عدة أنواع من أنظمة التحليل والاستفادة من تقنيات الذكاء الصناعي لتقديم حلول متقدمة ومبتكرة خاصة في مجال التنبؤ المالي للوصول إلى أعلى درجات الدقة، وفي هذا السياق تلعب الشبكات العصبية الاصطناعية دورا محوريا في هذا التطور، نظرا لقدرتها الفائقة على معالجة البيانات الكبيرة والمعقدة والتعلم من الأنماط المخفية في هذه البيانات، إذ تعد الشبكات العصبية أحد الفروع الرئيسية للذكاء الاصطناعي، وقد أثبتت هذه الشبكات كفاءتها في العديد من التطبيقات بدء من التعرف على الصور والصوت وصولا إلى التنبؤات المالية، وقد جرت الكثير من الدراسات والأبحاث لتصميم نماذج لشبكات عصبية تقوم بإعطاء تنبؤات يومية عن قيم السهم.

يتم من خلال هذا الفصل إلى تقديم رؤية حول كيفية استخدام الشبكات العصبية الاصطناعية لتحسين دقة التنبؤات المالية وبالتالي تحسين إدارة المخاطر المالية، إذ يعد هذا الموضوع ذا أهمية كبيرة للمستثمرين والمحللين الماليين حيث يمكن أن يساهم في اتخاذ قرارات استثمارية أكثر استنارة وفعالية، لكن قبل التحدث عن الشبكات العصبية الاصطناعية واستخدامها في التنبؤ لابد أولا من التعرف إلى مختلف الأدبيات المتعلقة بالذكاء الاصطناعي كمدخل عام في المبحث الأول، بعد ذلك يتم الوقوف بأدق التفاصيل على نماذج الشبكات العصبية موضحا أنواعها وآلية عملها كمبحث ثاني، ويختتم الفصل بالمبحث الثالث الذي يسلط الضوء على أهمية تطبيق الشبكات العصبية الاصطناعية في التنبؤ المالي مستعرضا مزاياها وتحدياتها بالإضافة إلى خطوات تطبيقها.

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

المبحث الأول: مدخل عام للذكاء الاصطناعي

شهد العالم ثورة تكنولوجية غير مسبوقة بفضل التقدم السريع في مجال الذكاء الاصطناعي خاصة بعد جائحة كورونا حيث اتسع نطاق استخدام تقنيات الذكاء الاصطناعي في مختلف جوانب الحياة البشرية من خلال تحسين الكفاءة والإنتاجية وصولاً إلى تقديم حلول مبتكرة للمشكلات المعقدة، خاصة في مجال التمويل، والتي يتم تمكينها من خلال الحجم الكبير للبيانات المتاحة (البيانات الضخمة)، وقوة الحوسبة التي هي في متناول اليد اليوم، فعندما يتم تغذية نماذج الذكاء الاصطناعي بالبيانات الضخمة فإنها تعمل على تحسين القدرة على التنبؤ والأداء بطريقة تلقائية من خلال الخبرة المكتسبة من تلك البيانات، ويتيح إمكانية استخراج المعلومات الكامنة في البيانات لفتح رؤى يمكن تسخيرها في استراتيجيات الاستثمار وتخفيض مخاطره.

المطلب الأول: ماهية الذكاء الصناعي

بداية الذكاء الاصطناعي كان في خمسينيات القرن الماضي عندما بدأ عدد قليل من رواد الحوسبة الناشئة يتساءلون عما إذا كان من الممكن تصميم أجهزة الكمبيوتر للتفكير، وأول ظهور لمصطلح الذكاء الاصطناعي كان من قبل John McCarthy في مقترحه الذي قدمه من عام 1955-1956 بمؤتمر Dartmouth، الذي يعتبر بداية رسمية لمجال الذكاء الاصطناعي كحقل دراسي، والذي نظمته McCarthy إلى جانب Marvin Minsky، Nathaniel Rochester، و Claude Shannon، والذي جمع العديد من العلماء البارزين لمناقشة إمكانية تطوير آلات ذكية. (McCorduck Pamela, 2004, p 111-112)

وفي عام 1961 لعب Marvin Minsky دوراً مهماً في تأسيس مجال الذكاء الاصطناعي حيث ركزت أطروحته وبعض أعماله اللاحقة على الشبكات العصبية، ليواصل العمل على مسودة تم نشرها لاحقاً كمقال بعنوان Step Towards Artificial Intelligence. (Nilsson, 2009, p 79-80)

وخلال طفرة الأنظمة الخبيرة في الثمانينات وصل الذكاء الاصطناعي إلى ذروته، لتأتي مرحلة التطورات التكنولوجية في التسعينات فمع تطور الحواسيب وزيادة قدرتها على معالجة البيانات بدأت تطبيقات الذكاء الاصطناعي تشهد نجاحاً أكبر، لينتشر بسرعة في ما سمي بالألفية الثالثة خاصة بعد الجائحة التي ضربت العالم أواخر عام 2019 والتي عززت الحاجة للذكاء الاصطناعي في حياتنا اليومية في مختلف المجالات، وهذا الأخير لطالما اعتبر أحد فروع علوم الحاسوب، وإحدى الركائز الأساسية التي تقوم عليها صناعة التكنولوجيا في العصر الحالي.

أولاً: تعريف الذكاء الاصطناعي

تتكون كلمة الذكاء الاصطناعي من كلمتين هما الذكاء والاصطناعي ولكل منهما معنى، فالذكاء هو القدرة على إدراك وفهم الظروف أو الحالات الجديدة والمتغيرة، أما كلمة الصناعي أو الاصطناعي فتدل على كل ما يصنع أو

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار


الأسهم وإدارة المخاطر المالية

يصطنع، ومن هذا الأساس فالذكاء الاصطناعي بصفة عامة يقصد به الذكاء الذي يصنعه الإنسان في الآلة أو الحاسوب، ويتمثل مصطلح الذكاء الاصطناعي الذي يشار له بالاختصار AI، أنه قدرة الآلات والحواسيب الرقمية على القيام بمهام معينة تحاكي وتشابه تلك التي تقوم بها الكائنات الذكية، ويبقى التعريف الدقيق للذكاء الاصطناعي موضوع فيه الكثير من النقاش وقد تسبب في الكثير من الارتباك منذ ظهوره الى يومنا الحالي، ومن أهم التعاريف المقدمة للذكاء الاصطناعي ما يلي:

- الذكاء الاصطناعي هو: "فرع من فروع علوم الحاسوب يهدف إلى تطوير أنظمة قادرة على أداء المهام التي تتطلب ذكاء بشري". (Russell Stuart & Norvig Peter, 2010, p 1-2)
 - ويعرف الذكاء الاصطناعي من منظور التعلم الآلي على أنه: "يتضمن تصميم خوارزميات قادرة على تعلم الأنماط من البيانات وتحسين أدائها بمرور الوقت دون الحاجة إلى برمجة صريحة". (Jordan & Mitchell, 2015, p 255)
 - ويعرف على أنه: "استخدام الأنظمة الذكية لأتمتة المهام الفكرية المتكررة والمعقدة التي يؤديها البشر عادة كالتعرف على الصور ومعالجة البيانات". (Chollet, 2021, p 2)
 - الذكاء الاصطناعي هو: "السعي لتطوير آلات قادرة على التفكير والاستدلال بطرق تشبه العقل البشري، وتحاكي الابداع والتفكير، وقادرة على أن تتعلم وتطبق المعرفة الجديدة لتغير سلوكها بطريقة تجعلها تؤدي أداء أفضل في المستقبل". (Witten Ian H et al., 2011, p 7-8)
- ومنه يمكن تعريف الذكاء الاصطناعي بأنه مجموعة الجهود المبذولة لتطوير نظم المعلومات المحسوبة بطريقة تستطيع أن تتصرف فيها وتفكر بأسلوب مماثل للبشر، هذه النظم تستطيع أن تتعلم اللغات الطبيعية وإنجاز مهام فعلية بتنسيق متكامل أو استخدام صور وأشكال إدراكية لترشيد السلوك المادي، كما تستطيع في نفس الوقت تخزين الخبرات والمعارف الإنسانية المتراكمة واستخدامها في عملية اتخاذ القرارات، وللذكاء الاصطناعي مجالات فرعية تتصل ببعضها البعض وهي التعلم العميق والتعلم الآلي، والشكل التالي يوضح ذلك:

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

الشكل رقم (1-2): الذكاء الاصطناعي، التعلم الآلي، والتعلم العميق.



Source: Akshay Kulkarni, Adarsha Shivananda, Anoosh Kulkarni, Dilip Gudivada, Applied Generative AI for Beginners, Practical Knowledge on Diffusion Models, ChatGPT, and Other LLMs, First Edition, Apress, USA, 2023, P 3.

يظهر الشكل الارتباط بين كل من الذكاء الاصطناعي (AI) والتعلم الآلي (ML) والتعلم العميق (DL) حيث يظهر أن الذكاء الاصطناعي هو المجال الأوسع الذي يشمل تطوير أنظمة ذكية قادرة على أداء مهام تتطلب ذكاء بشريا، داخل هذا المجال يوجد التعلم الآلي ويتضمن خوارزميات تسمح لأجهزة الكمبيوتر بالتعلم من البيانات بدلا من برمجتها، ويتفرع بدوره إلى التعلم العميق، الذي يعتبر أحدث تطور في رحلة تطوير أنظمة الذكاء الاصطناعي. (Akshay Kulkarni et al., 2023, p 3)

ثانيا: الذكاء الاصطناعي والبيانات الضخمة

يعد الذكاء الاصطناعي والبيانات الضخمة من المجالات المتداخلة والمتكاملة التي تعمل جنبا إلى جنب لتعزيز القدرات التحليلية والتنبؤية في العديد من الصناعات، فالذكاء الاصطناعي يعتمد بشكل كبير على البيانات الضخمة لتدريب النماذج وتحسين دقتها وأدائها، بينما توفر البيانات الضخمة كميات هائلة ومتنوعة من المعلومات التي يمكن للذكاء الاصطناعي تحليلها واستغلالها بفعالية، أي أن البيانات الضخمة عبارة عن كميات هائلة من البيانات المهيكلة وغير المهيكلة، يتطلب تحليلها واستخراج المعلومات القيمة منها أدوات وتقنيات متقدمة، حيث يأتي الذكاء الاصطناعي ليكون الأداة المثلى لتحقيق ذلك بفعالية وسرعة مما يمكن الشركات والمستثمرين من اتخاذ قرارات مستنيرة بناء على رؤى مستمدة من البيانات. (Marr Bernard, 2015, p 15)

يتضمن دور الذكاء الاصطناعي في معالجة البيانات الضخمة العديد من العمليات مثل التنقيب عن البيانات والتصنيف والتنبؤ، يمكن للشبكات العصبية الاصطناعية وتقنيات التعلم العميق تحليل الأنماط

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار

الأسهم وإدارة المخاطر المالية

والعلاقات المعقدة في البيانات التي قد لا تكون واضحة بالوسائل التقليدية، هذا يمكن أن يشمل التحليل التنبؤي حيث يتم استخدام النماذج المستمدة من الذكاء الاصطناعي للتنبؤ بالسلوكيات والاتجاهات المستقبلية استناداً إلى البيانات الحالية، حيث تعتمد دقة وفعالية نماذج الذكاء الاصطناعي بشكل كبير على جودة وكمية البيانات المستخدمة في تدريبها. كما تتيح البيانات الضخمة عينات إحصائية ضخمة مما يعزز نتائج نماذج الذكاء الاصطناعي لذلك يتم تدريب هذه النماذج على مجموعات بيانات أكبر وأكثر تنوعاً، مما يحسن من قدرتها على التعميم والأداء في مختلف السيناريوهات، علاوة على ذلك فإن تقنيات التعلم الآلي والتعلم العميق تتطلب كميات هائلة من البيانات لتحقيق أفضل أداء وهو ما توفره البيانات الضخمة، فالقاعدة العامة هي أنه كلما كانت عينة البيانات أكبر كلما كانت منتجات التحليل أكثر دقة. (Russom Philip, 2011, p 9)

هناك العديد من التطبيقات العملية التي تستفيد من تزاوج الذكاء الاصطناعي والبيانات الضخمة والتي تتضمن مجموعة متنوعة من بنى الأجهزة والبرمجيات كتحسين خدمات العملاء وإدارة المخاطر المالية من خلال التحليل التنبؤي وتحليل البيانات الاقتصادية والمالية، وتحسين العمليات الصناعية من خلال تحليل البيانات التشغيلية، في كل هذه الحالات يتم استخدام ودمج الذكاء الاصطناعي مع البيانات الضخمة والتي تمكن من تحقيق تقدم كبير في القدرة على تحليل البيانات وتقديم تنبؤات دقيقة وفعالة تساعد في تحسين القرارات الاستراتيجية في مختلف المجالات، علاوة على ذلك يمكن إجراء التحليلات التي قد تستغرق ساعات أو أياماً في الماضي في ثواني. (Davenport Thomas H & Dyché Jill, 2013, p 22-28)


المطلب الثاني: نماذج التعلم في تطبيقات الذكاء الاصطناعي Types of Learning

القدرة على التعلم هي أحد أهم سمات الذكاء وهو من الأسس الحيوية وما يميز تطبيقات الذكاء الاصطناعي عن بقية النظم التقليدية، وتتم عملية التعلم من خلال خوارزميات متخصصة تدعى خوارزميات التعلم Learning Algorithmes، وبالتالي فإن التعلم هو عبارة عن التعرف التدريجي من خلال تدريب تطبيقات الذكاء الاصطناعي وتصحيح معلوماتها وتعديلها وتكرار هذه العملية، بمعنى تغييرات تدريجية بغرض الوصول إلى أقل نسبة خطأ ممكنة بين النتائج الفعلية والنتائج المتوقعة، من خلالها تكتسب الأنظمة القدرة على تحسين أدائها في مهمة معينة بمرور الوقت وباستخدام البيانات المتاحة.

تنقسم نماذج التعلم في الذكاء الاصطناعي إلى أربع فئات (التعلم بإشراف، التعلم بدون إشراف، التعلم شبه الخاضع للإشراف، والتعلم المعزز أو المختلط)، كل هذه النماذج تعتمد على طرق وتقنيات مختلفة لمعالجة البيانات واستخلاص الأنماط والمعلومات القيمة منها، مما يساهم في تطوير أنظمة ذكاء اصطناعي أكثر ذكاءً وفعالية، والشكل التالي يوضح هذه النماذج:

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

الشكل رقم (2-2): نماذج التعلم في الذكاء الاصطناعي.



المصدر: من اعداد الطالبة.

1. التعلم بإشراف Supervised Learning

تتلخص فلسفة التعلم في هذا النمط في توافر المخرجات المستهدفة، بمعنى آخر يتم التزويد بالخرج الصحيح الموافق لكل دخل من مجموعة تدريب تكون بمثابة مثال، وهي طريقة شائعة تستخدم للتدريب بحيث تقوم بمقارنة خرجها مع الهدف وتتعلم من أخطائها، ويكون الهدف في نظم التعلم المراقب بعد ذلك هو التنبؤ حيث يقارن الخرج المتنبئ به مع القيمة الحقيقية الموافقة للدخل وعندما يتطابق الخرج المتنبئ به مع القيمة الحقيقية لا يتم أي تعديل، بينما عندما يكون الخرج المتنبئ به أكبر أو أصغر من القيمة الحقيقية فإن الخطأ ينشر بشكل تراجمي بحيث يتم التعديل تبعاً لذلك. (Hastie et al., 2009, p 29)

ومن بين التقنيات التي تعتمد على هذا النوع من التعلم نجد:

أ- الشبكات العصبية Neural Networks

هي تقنيات حسابية مصممة لمحاكاة الطريقة التي يؤدي بها الدماغ البشري مهمة محددة من خلال معالجة موزعة ضخمة ومتوازنة تتكون من وحدات معالجة بسيطة هذه الوحدات ليست أكثر من عناصر حسابية تسمى الخلايا العصبية أو العقد العصبية والتي لها خاصية عصبية والتي تكون متصلة ببعضها البعض، ومن الناحية العلمية فإنه يقوم بتخزين المعلومات المعروفة والتجريبية لإتاحتها للمستخدم عن طريق ضبط الأوزان، وتدريب

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار

الأسهم وإدارة المخاطر المالية

الخوارزمية عن طريق تعديل الأوزان في العقد وتميرها إلى طبقات أخرى للتدريب وإخراج النتائج، وتظل الشبكات العصبية واحدة من أكثر أشكال التعلم شيوعا وتستحق الدراسة في حد ذاتها. (Andreas C. Müller & Sarah Guido, 2017, p 104-108)

ب- آلية ناقلات الدعم Support Vector Machines

عبارة عن خوارزمية تعلم آلي خاضعة للإشراف وقد أصبحت أدوات أساسية في مجال التعلم الآلي نظرا لخصائصها العامة وقدرتها على التنظيم، تستخدم في التصنيف والانحدار وقد توسعت لتشمل المسائل متعددة الفئات، ويمكن تقسيمها إلى نماذج خطية ونماذج غير خطية. (Kramer, 2016, p 68-69)

ت- أشجار القرار Decision Trees

هي تقنية شهيرة تستخدم في التعلم بإشراف لكل من مهام التصنيف والانحدار، من أحدث الأساليب التي تعمل على تقسيم مجموعة البيانات إلى مجموعات فردية استنادا إلى قيمة الميزات المدخلة مما يؤدي إلى نموذج يشبه شجرة القرارات، كما أنها جذابة أيضا من حيث إمكانية الترجمة الفورية، وهو ما يكون طبيعتها القائمة على القواعد، وهذا ما يجعلها شائعة في العديد من التطبيقات، تتميز ببساطتها وسهولة تفسيرها، عندما نستخدم العديد من أشجار القرار وتدمج معا تسمى بنموذج الغابة العشوائية Random Forests، وهي أهم تقنية من تقنيات أشجار القرار تستخدم للحصول على تنبؤات أكثر دقة واستقرارا. (Carrizosa et al., 2021, p 2-3)

ث- التعلم العميق Deep Learning

يعد التعلم العميق مجالا متطورا للتعلم الآلي ML يتمتع بقدرات تحليلية قوية، ويستخدم لتطبيقات مثل رؤية الكمبيوتر والمعلوماتية الحيوية ومعالجة اللغات الطبيعية، ويعتبر دليلا على تحسن كبير في الأداء مقارنة ببعض خوارزميات تعلم الآلة وقد تم استخدامه مؤخرا في تطبيقات مختلفة والتي تتطلب كميات كبيرة من البيانات لنقلها عبر الشبكة، وتوفر DL أداء أفضل مع البيانات مقارنة بالتعلم الآلي بالإضافة إلى ذلك يمكن أن تعمل مع ميزات جديدة يمكن استخدامها لحل المشكلات دون تفاعلات بشرية. (Murphy, 2012, p 995)

2. التعلم بدون إشراف Unsupervised Learning

ويطلق عليه أيضا بالتعلم الذاتي Self-Learning ففي هذا النموذج من التعلم لا يوجد أية حاجة من أجل تحديد الخرج الصحيح وربطه بدخل معين في عينات التدريب أي لا يتم توفير المخرجات المستهدفة لغرض التدريب، إذ يعرف التعلم بدون إشراف بأنه عملية لتحسين النماذج الأولية اعتمادا على أوجه التشابه بين مجموعات التدريب حيث يتم إعطاء مجموعة معطيات التدريب ويتم تحديد الترابط بين عينات التدريب وتصنف هذه العينات ضمن فئات عن طريق تعديل أوزان الوصلات، أي أن في هذه الطريقة فإنه يتم بناء أساليب التعليم

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار

الأسهم وإدارة المخاطر المالية

على أساس قدرتها على اكتشاف الصفات المميزة لها لما يعرض عليها من أشكال وأنساق وقدرتها على تطوير تمثيل داخلي لهذه الأشكال وذلك دون معرفة مسبقة وبدون عرض أمثلة لما يجب عليها أن تنتجه وذلك على عكس المبدأ المتبع في أسلوب التعليم بإشراف. (Akshay Kulkarni et al., 2022, p 17-18)

ومن بين التقنيات التي تعتمد على هذا النوع من نماذج التعلم: الانحدار الخطي، خوارزميات التجميع كخوارزمية K الجيران الأقرب، وخوارزمية التجميع K-means، تقنيات تقليل الأبعاد كتحليل المكونات الرئيسية principal component analysis (pca)، وخوارزمية t-distributed stochastic neighbor embedding (t-sne).

أ- الانحدار الخطي Linear Regression

الانحدار هو المصطلح الأكثر استخداما في التحليلات وعلوم البيانات والموجود من مدة طويلة، وهو يسجد العلاقة بين الوظيفة المستهدفة والوظائف المستقلة، الهدف منه هو التنبؤ بقيمة واحدة أو أكثر من المتغيرات المستهدفة المستمرة. (James et al., 2021, p 59-60)

ب- خوارزميات التجميع Clustering

هي عملية تقسيم البيانات إلى مجموعات أو عناقيد "K" بناء على التشابه بين النقاط داخل كل مجموعة، ويهدف التجميع إلى تحليل البيانات، التخزين والاسترجاع، والتعرف على الأنماط. (Murtagh & Contreras, 2017, p 2-3)

وتشمل هذه التقنية ما يلي:

- خوارزمية k الجيران الأقرب (K-Nearest Neighbors (KNN): تعد خوارزمية الجيران الأقرب طريقة تعليمية قائمة على الأمثلة، ولا يتضمن مرحلة التعلم في حد ذاتها، يتم تخزين البيانات التي تشكل جزء من مجموعة التدريب فقط، عند وصول مثال جديد ليتم تصنيفه تتم مقارنته بأمثلة التدريب (النماذج الأولية) باستخدام مقياس التشابه على الرغم من عدم وجود مرحلة التعلم حيث يتم تخزين البيانات كما هي في الذاكرة، إلا أن تصنيف حالة جديدة يكون مكلفا من ناحية أخرى حيث يجب مقارنة هذه الحالة بجميع الأمثلة المصنفة بالفعل، بالإضافة إلى ذلك يستخدم KPPV الأساسي جميع المتغيرات الوصفية للمثال لحساب التشابه مع المثال الجديد الذي سيتم تصنيفه، باستثناء قواعد البيانات الكبيرة كما هو الحال في استخراج البيانات، يتم النظر في المتغيرات التمييزية بنفس الطريقة التي يتم بها النظر إلى المتغيرات الأخرى (الأقل تمييزا) ولمعالجة هذه المشكلة يتم ترجيح المتغيرات وفقا لأهميتها، ويعتمد أداء الطريقة على عدد الجيران واختيار المسافة وطريقة الجمع بين استجابة الجيران. (Mathieu-Dupas Eve, 2010, p 2-4)

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

- **التجميع k-means:** يعد نهج K-means الذي اقترحه MacQueen في عام 1967 هو الأسلوب غير الخاضع للرقابة الأكثر شيوعاً وأبسطها وأكثرها كفاءة في أدبيات تجميع البيانات، تستخدم لتجميع البيانات إلى مجموعات حيث تبدأ باختيار النقاط التمثيلية k باعتبارها النقط الوسطى الأولية، يتم بعد ذلك تعيين نقطة إلى أقرب نقطة مركزية بناء على مقياس قرب معين تم اختياره، بمجرد تشكيل المجموعات يتم تحديث النقط الوسطى لكل مجموعة، يصنف هذا النهج الكائنات إلى مجموعات متعددة بحيث تكون الكائنات الموجودة في نفس المجموعة متشابهة قدر الإمكان أي تشابه كبير داخل الفئة، في حين أن الكائنات من مجموعات مختلفة تختلف قدر الإمكان. (Charu C Aggarwal & Chandan K Reddy, 2014, p 89)

ت- تقليل الأبعاد Dimensionality Reduction

تستخدم لتقليل عدد المتغيرات أو عدد الأبعاد في البيانات مما يسهل تصورها وتحليلها. (Aurélien Géron, 2022, p 237-238)
من تقنياتها الشهيرة:

- **تحليل المكونات الرئيسية (PCA) Principal Component Analysis:** يستخدم لتقليل عدد الأبعاد في البيانات مع الاحتفاظ بأكبر قدر ممكن من التباين، حيث يقوم بتدوير مجموعة من البيانات بطريقة تجعل المعالم التي تم تدويرها غير مرتبطة احصائياً. (Jolliffe I. T, 2002, p 1-2)
- **خوارزمية تضمين الجار العشوائي الموزع (T-distributed Stochastic Neighbor Embedding (T-SNE):** تهدف خوارزمية التعلم المتعدد بشكل أساسي لتصوير البيانات في بعدين أو ثلاثة أبعاد محاولاً الحفاظ على المعلومات التي تشير إلى النقاط المجاورة لبعضها البعض، لذلك نادراً ما يتم استخدامها لإنشاء أكثر من ميزتين جديدتين. (Vishal Rajput, 2023, p 107-108)

3. التعلم المختلط Hybrid Learning

ويسمى أيضاً التعلم المعزز Reinforcement Learning يقوم هذا النوع على أساس الدمج بين النموذجين السابقين، لكن لا يتم توفير البيانات المستهدفة، بدلاً من ذلك يتم اطلاق النموذج على صحة أو خطأ نتائجها فقط من خلال أسلوب "النقد" المتبع، إذ يتوقف التعلم المعزز على مبدأ تعظيم المكافأة وتقليل العقوبة، ومن أجل ذلك يتم تحديث الأوزان وقيم التحيز باستمرار بواسطة خوارزمية التعلم، يتضمن التعلم المعزز تعلم ما يجب فعله وكيفية ربط المواقف بالأفعال وذلك لزيادة إشارة المكافأة الرقمية إلى الحد الأقصى، علاوة على ذلك لا يتم إخبار المتعلم بالإجراءات التي يجب اتخاذها كما هو الحال في العديد من أشكال التعلم، ولكن بدلاً من ذلك يجب عليه اكتشاف الإجراءات التي تحقق أكبر قدر من المكافأة من خلال تجربتها. (Sutton & Barto, 2015, p 2-5)

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

ومن بين أشهر التقنيات التي تعتمد على هذا النوع من التعلم: خوارزمية Q-Learning وخوارزمية DDPG وخوارزمية SARSA (Sutton & Barto, 2018, p 42-43).

- **خوارزمية Q-Learning:** تستخدم لتعليم الوكلاء كيف يتصرفون في بيئات معينة من خلال تحسين سياسة العمل.
- **خوارزمية تدرج السياسة الحتمية العميقة (DDPG):** Deep Deterministic Policy Gradient تستخدم الشبكات العصبية العميقة لتحسين السياسات في البيئات المستمرة.
- **خوارزمية State Action Reward State Action (SARSA):** مشابهة لـ Q-Learning لكنها تأخذ في الاعتبار الحالة التالية والفعل التالي في تحديث السياسة.

4. التعلم شبه الخاضع للإشراف Semi-supervised Learning

يقع التعلم شبه الخاضع للإشراف SSL بين التعلم غير الخاضع للإشراف وبين التعلم الخاضع للإشراف ويجمع كمية صغيرة من البيانات المصنفة مع كمية أكبر من البيانات غير المصنفة للرقابة أثناء التدريب، بشكل أكثر رسمية هدف SSL هو استغلال البيانات غير المسماة لإنتاج دالة تنبؤ مع معلومات قابلة للتدريب، وهي أكثر دقة مما يمكن الحصول عليه باستخدام البيانات المسماة فقط، ومن بين أشهر التقنيات في التعلم شبه الخاضع للإشراف: (Chapelle et al., 2006, p 2-3)

- **التدريب الذاتي Self-Training:** تعتمد هذه التقنية على تدريب النموذج الأولي باستخدام مجموعة صغيرة من البيانات المصنفة، ثم استخدام هذا النموذج لتصنيف البيانات غير المصنفة، يتم إضافة النقاط الجديدة التي يتم تصنيفها بثقة عالية إلى مجموعة البيانات المصنفة، ويعاد تدريب النموذج مرارا وتكرارا.
- **التدريب المشترك Co-Training:** تستخدم هذه التقنية نماذج متعددة يتم تدريبها بشكل متزامن على مجموعات بيانات مختلفة لكن مترابطة، يتم تدريب كل نموذج على مجموعة فرعية من البيانات المصنفة، ثم يتم تبادل المعلومات بين النماذج لتحسين دقة التصنيف.
- **الطرق المعتمدة على الرسوم البيانية Graph-Based Methods:** تعتمد هذه الطرق على تمثيل البيانات على شكل رسم بياني، حيث تكون النقاط هي العقد والحواف تعبر عن العلاقات بينها، يتم استخدام خوارزميات الرسم البياني لنشر التسميات من البيانات المصنفة إلى البيانات غير المصنفة بناء على هيكل الرسم البياني.

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار

الأسهم وإدارة المخاطر المالية

المبحث الثاني: الشبكات العصبية الاصطناعية

تعد الشبكات العصبية الاصطناعية أحد أهم وأبرز تطبيقات الذكاء الاصطناعي، وهي تستند في تصميمها وعملها إلى محاكاة الشبكات العصبية البيولوجية الموجودة في الدماغ البشري، تهدف الشبكات العصبية الاصطناعية إلى تمكين الأنظمة الحاسوبية من التعلم واكتساب المعرفة من خلال التجربة وتحليل البيانات مما يمكنها من أداء مهام معقدة كالتعرف على الأنماط، التنبؤ، واتخاذ القرارات، إذ يمكنها إنجاز المهام الموكلة إليها عبر أسلوب التعلم الخاضع للإشراف من خلال اكتشاف الأنماط المميزة في البيانات التاريخية وبناء التوقعات على أساسها، وأثبتت الشبكات العصبية الاصطناعية نجاعتها مؤخراً في العديد من التطبيقات المالية والاقتصادية كالتمويل بالأزمات المالية، وتشكيل المحافظ الاستثمارية والنمذجة المالية فضلاً عن التنبؤ بالأسعار، واشتهرت بقدرتها على معالجة البيانات غير الخطية التي تتميز بالتعقيد والعشوائية الأمر الذي جعلها تتفوق على الأساليب الرياضية والنماذج الإحصائية التقليدية، إذ تمتلك قدرة فائقة وسرعة كبيرة في معالجة وتحليل البيانات واكتشاف الأنماط الخاصة بها واكتساب الخبرات من البيانات الكبيرة والمعقدة.

المطلب الأول: ماهية الشبكات العصبية الاصطناعية

يسعى هذا القسم إلى تقديم صورة واضحة حول الشبكات العصبية الاصطناعية، موضحاً أوجه التشابه بينها وبين الجهاز العصبي البشري (الشبكات العصبية البيولوجية) ومن ثم تقديم تعريفات لمفهوم الشبكات العصبية الاصطناعية، ليأتي بعدها تتبع التاريخي لتطور الشبكات العصبية الاصطناعية عبر الزمن.

أولاً: أوجه التشابه بين الخلية العصبية البيولوجية والعصبونات الاصطناعية


إن الدماغ البشري مؤلف من كم هائل ومعقد من الخلايا العصبية تزيد على 100 ترليون خلية لها ارتباطات داخلية معقدة مكونة شبكة كبيرة من الأعصاب (Neurons) تشترك مع بعضها ببعض الصفات مع خلايا الجسم الأخرى لكنه وحيد في قابليته في استقبال ومعالجة نقل الإشارة الكهروكيميائية على طول العصب والتي تشكل نظام الارتباط للدماغ، يحتوي العصب كما هو موضح في الشكل رقم (2-3) على ثلاثة أجزاء هي جسم الخلية (Cell Body) soma يحتوي على النواة Nucleus والذي يكون مسؤولاً عن معالجة الإشارات العصبية، والتفرعات الشجرية (Dendrites) والتي تستقبل الإشارات القادمة للعصبون من العصبونات المجاورة والمحور العصبي (Axon) تلخص وظيفته في نقل الإشارات العصبية الخارجية إلى العصبونات الأخرى إذ يلتقي بها عبر الروابط المشبكية، وتمتد التفرعات الشجرية (Dendrites) من جسم الخلية إلى الأعصاب الأخرى لتشكل شبكة عصبية،

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار

الأسهم وإدارة المخاطر المالية

وتمثل العقدة أو المشابك العصبية (Synapse) ممراً أو بوابة لربط التفرع الشجري القادم من عصب آخر، فهي نقاط الربط التي تستلم عضو الحس أو المستقبل الإشارات الكهربائية وتقوم بتحميل المعلومات بالوقت والسرعة نفسيهما. (Bishop & Bishop, 2024, p 16-17)

الشكل رقم (2-3): العصب البيولوجي.



Source: David Kriesel, A Brief Introduction Neural Networks, this work has been prepared in the framework of a seminar of the University of Bonn in Germany, 2005, P 20.

حين تصل الإدخالات إلى جسم الخلية بعضها يثير الخلية ويحفزها والأخرى تكبحها وتثبطها وتعمل العقدة (العصب) على دمج أو تراكم الإشارات في جسم الخلية لتجري لها عملية المعالجة عبر إجراء تجميع أو توحيد الإشارات الداخلة في إشارة واحدة وإجرائها تفاعلاً كهروكيميائياً، وعندما تتجاوز المستوى العتبة المطلوب (Threshold) للخلية سوف تكبح وتصدر الإشارة الخارجية لتمرر إلى الخلية الأخرى أو المجاورة على طول المحور العصبي (Axon)، ويقوم التفرع الشجري بتعديل (تغيير) سعة الإشارة المنقولة خلاله وهذا التعديل يتغير مع الزمن كما في عملية التعلم (Learning) للشبكة العصبية الاصطناعية. (Eric R Kandel et al., 2012, p 22-27)


أما الخلية العصبية الاصطناعية الموضحة في الشكل رقم (2-4) فقد صممت لتحكي الخصائص الأساسية للخلية العصبية البيولوجية، حيث تتألف من عقد أو وحدات معالجة متصلة معاً لتشكل شبكة من العقد وهذه الأخيرة عبارة عن وحدات حسابية تتلقى دخلاً معيناً ثم تعالجه بإجراء عمليات حسابية معينة من أجل تحقيق خرج معين ويمكن أن تكون عملية المعالجة بسيطة كجمع المدخلات أو قد تكون معقدة حيث يمكن لعقدة ما أن

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار

الأسهم وإدارة المخاطر المالية

تحتوي شبكة كاملة، كل اتصال بين هذه العقد يمتلك مجموعة من القيم تسمى الأوزان، حيث تمثل ترابطات الإدخال بخطوط تقابل التفرعات الشجرية والتي بدورها تمثل الإخراج لعصب آخر، وتحدد طريق تدفق البيانات بين العقد ويمكن لهذه الوصلات أن تكون أحادية الاتجاه ويكون تدفق البيانات في اتجاه واحد أو ثنائية الاتجاه وعندها يكون تدفق البيانات في اتجاهين وهنا تظهر الحلقات، فعندما تأتي الإشارة متمثلة بالمتجه (الإدخال) من ترابط معين تضرب بوزن الترابط (Weight of Connection) ومجموعة الأوزان تُمثل بالمتجه الذي يقابل اتساع التفرع الشجري البيولوجي، وتجمع الإشارات أو الإدخالات الموزونة (Weighted Inputs) في صندوق الجمع الذي يقابل جسم الخلية العصبية لتحديد مستوى التأثير (الفاعلية) (Level activation) لها لتنتج إشارة الإخراج ممثلة الإدخال لخلايا أخرى مرتبطة معها، وهكذا تجمع جميع الإدخالات الموزونة جبرياً لإنتاج الإخراج المتحقق، إن هذا التفاعل بين العقد والوصلات يقود إلى تحديد السلوك العام للشبكة الذي لا يمكن ملاحظته ضمن عناصر الشبكة ولهذا يمكن القول بأن قدرات الشبكة تحل محل قدرات العناصر منفصلة مما يجعل الشبكة عبارة عن أداة معالجة قوية جداً. (Haykin, 2009, p 10-11)

الشكل رقم (4-2): العصب الاصطناعي.



Source: Haykin Simon, Neural Networks and Learning Machines, Third Edition, Prentice Hall, New Jersey, 2009, P 11.

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

ثانياً: تعريف الشبكات العصبية الاصطناعية

تعددت تعاريف الشبكات العصبية الاصطناعية بتعدد أنواعها واستخداماتها فضلاً عن زاوية نظر الباحثين، نحاول إيجازها فيما يلي:

من أشهر التعاريف للشبكات العصبية الاصطناعية هو الذي اقترحه Teuvo Kohonen وهو من أبرز العلماء في هذا المجال في سبعينات وثمانينيات القرن الماضي يقول فيه: "الشبكات العصبية الاصطناعية هي أنظمة متوازنة بشكل كبير تتكون من معالجات ذات ترابط (تواصل) كثيف فيما بينها، تضم عناصر بسيطة وعادة ما تكون قابلة للتكيف وذات تنظيم هرمي، حيث تتفاعل مع كائنات العالم الحقيقي بنفس الطريقة التي يتفاعل بها النظام العصبي الطبيعي (البيولوجي) مع العالم الحقيقي". (Kohonen, 2001, p 78-80)

كما عرفت الشبكات العصبية الاصطناعية بأنها: "تقنيات شائعة للتعليم الآلي تحاكي آلية التعلم في الكائنات الحية، وهي أنظمة حسابية مستوحاة من عمل الدماغ البشري تتكون من وحدات معالجة بسيطة (العقد أو الخلايا العصبية) التي تتصل ببعضها البعض من خلال أوزان تخدم نفسها وقابلة للتعديل، وتعمل هذه الأنظمة على تعلم الأنماط من البيانات المدخلة لتحسين أدائها بمرور الوقت". (Aggarwal, 2018, p 1-2)

وعرفت كذلك بأنها: "شبكات حسابية تحاول محاكاة عملية اتخاذ القرار في الخلايا العصبية للجهاز العصبي المركزي البيولوجي بطريقة شاملة، بمعنى أن تكون المحاكاة إجمالية لكل خلية (خلية تلو الأخرى، وعنصراً بعد عنصر) إذ تستلهم المعرفة الفيزيولوجية للخلايا العصبية البيولوجية، وبالتالي فهي تختلف عن آلات الحوسبة التقليدية (الرقمية أو التناظرية) التي تعمل على استبدال أو تحسين أو التسريع في الحساب بغض النظر عن تنظيم عناصر الحوسبة وشبكاتها، يمكن لهذه الشبكات التعلم من البيانات المدخلة وتطبيق هذه المعرفة المكتسبة لحل المشكلات المعقدة وغير المحددة رياضياً، المشاكل غير الخطية والمشاكل العشوائية". (Graupe, 2013, p 1-2)

عرفت أيضاً بأنها: "طريقة للتعليم الآلي تمثل نموذجاً للدماغ البشري، إذ تتألف من عدد من الخلايا العصبية الاصطناعية تميل إلى أن تحتوي على روابط أقل من الخلايا العصبية البيولوجية، وتتلقى كل خلية عدداً من البيانات المدخلة ليتم تطبيق عليها عمليات معالجة بواسطة دوائر التنشيط التي ينتج عنها إخراج معين". (Panchal & Panchal, 2014, p 456)

ومنه فإن الشبكات العصبية الاصطناعية هي إحدى تقنيات الذكاء الاصطناعي صممت كنماذج رياضية تقوم على فكرة محاكاة تصرف الخلايا العصبية في العقل البشري في التفكير والتعلم، وهي نظام معالجة معلومات تفرعي أي تتكون من عقد عصبية يتم التوصيل بينها من خلال الأوزان، تقوم بمعالجة البيانات الخطية وغير الخطية من خلال عدد من الخوارزميات والحسابات المنطقية في وسائط رقمية إذ تقوم باكتشاف أنماط محددة

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار

الأسهم وإدارة المخاطر المالية

واستخدامها في التحليل أو التصنيف أو التنبؤ، وتتميز الشبكات العصبية الاصطناعية بمرونتها العالية في حل المشاكل غير الخطية مما يجعلها تتفوق على الأساليب التقليدية، لذلك تم تركيز قدر كبير من اهتمام الباحثين عليها.

ثالثا: مراحل تطور الشبكات العصبية الاصطناعية

رغم أن الشبكات العصبية الاصطناعية تعد من التقنيات الحديثة إلا أن هذا المجال تم تأسيسه قبل ظهور أجهزة الكمبيوتر فالجهد المبذول من أجل فهم الدماغ يعود إلى العمل الرائد للعالم Ramon Y Cajal سنة 1911 الذي قدم فكرة الخلايا العصبية باعتبارها المكونات الهيكلية للدماغ، بعدها في عام 1913 الذي تم فيه أول تطبيق عملي للشبكات البدائية حيث نفذ Russel جهازا هيدوليكيًا معتمدا على الفكرة العامة لهذه الشبكات. (Pagariya & Bartere, 2013, p 49-50)

ويمكن اعتبار فترة أربعينيات القرن الماضي وتحديدًا عام 1943 هي البداية الحقيقية لتطور هذه الشبكات عندما نشر العالمان في جامعة شيكاغو Warren McCulloch & Walter Pitts بحثًا يصف نموذجاً رياضياً لشبكة عصبية تتكون من عدد من العقد المترابطة بواسطة الأوزان بحيث أدخل فكرة الدالة الحدية Threshold Function والتي اعتبرت أساساً للنظم التي جاءت بعد ذلك، استخدمت لتوليد بعض الدوال المنطقية Logical Function التي تنتج استجابات لدوال أخرى، لكن من أهم السبلات في هذا النموذج هو عدم القدرة على التعلم، فالتكنولوجيا المتاحة في ذلك الوقت لم تسمح لهما بعمل الكثير. (Piccinini, 2004, p 175-176)

في عام 1949 أصدر كتاب للعالم الكندي Donald Olding Hebb والذي قام بتطوير نظام رياضي لتعلم الشبكات العصبية والذي يحمل اسم التعليم الهيبباني Hebbian Learning المبنية على فرضية تصف كيفية تتحكم التغيرات في أوزان التشابكات العصبية في الطريقة التي تثير بها الخلايا العصبية بعضها البعض، وتستند هذه الفرضية إلى عمليتي التعلم والذاكرة Learning and Memory إذ يؤدي التحفيز المتكرر بين العقد الفعالة إلى زيادة قوة الارتباط ليتم بعد ذلك تخزين التغيرات الحاصلة بين الروابط لاختيار أفضل الأوزان. (Kuriscak et al., 2015, p 27-30)

وفي عام 1951 قام Marvin Minsky واثنين من زملائه بالعمل على تصميم آلة للتعلم تحتوي على 40 عصبون متخذاً نموذج McCulloch أساساً لبنائها حيث يتم ضبط الموصلية للمشابك طبقاً لنجاح الآلة في تنفيذ عمل معين وذلك بتطبيق نظرية التعلم الهيبباني، أطلق عليها خلية الإدراك الحسي (Perceptron) بيرسبيترون وكان هذا النموذج بسيطاً نسبياً ويستخدم لتصنيف البيانات الثنائية، وفي عام 1958 قام عالم النفس الأمريكي الرائد في الذكاء الاصطناعي Frank Rosenblatt بتطوير نموذج بيرسبيترون ليصبح أحد النماذج الأولية للشبكات

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار

الأسهم وإدارة المخاطر المالية

العصبية الاصطناعية، حيث كانت بسيطة متمثلة بطبقة واحدة (Single layer) من الخلايا العصبية الاصطناعية التي يتم تعليمها، والتي تعد التطبيق الأقرب لمحاكاة الخلايا العصبية البيولوجية، كما قدم دراسة النماذج متعددة الطبقات المكونة من عناصر الإدراك واقترح نظرية عناصر الإدراك المجمع Perception Convergence Theorem، التي تؤدي إلى ضبط الأوزان بين المدخل والمخرج طبقاً لقيم الخطأ بين قيم الخرج المطلوب والمحسوب بالشبكة، وكانت عملية التعلم فيها مقتصرة على النماذج الخطية (Linear Models) لأغراض التقدير أو التصنيف أو التبويب أو التنبؤ لكنه لم يتوصل إلى طريقة رياضية واضحة لتعليم الطبقة الخفية، ويعد إسهامه طفرة حقيقية في مجال المحاكاة الآلية للشبكات العصبية. (Koduvally Hari M, 2015, p 113)

وقد أدى ضعف شبكة الإدراك الحسي للعالم Rosenblatt في معالجة البيانات غير الخطية إلى اهتمام العلماء في عملية البحث والتطوير في البنية الأساسية لشبكة Perceptron إلى أن تم التوصل إلى شكل جديد للإدراك الحسي بإضافة مستوى جديد أطلق عليه المستوى المخفي (المخياً) أو الطبقة المخفية (Hidden Layer)، أكسب الإدراك الحسي القدرة على حساب الدوال والعلاقات لنماذج البيانات الخطية واللا خطية، وفي عام 1960 تم إثبات أن الفرق أو الخطأ بين الخرج المطلوب والمحسوب يصل إلى قيمة صغرى عند شروط معينة من طرف العالم Widrow، وتطور هذا المستوى بإضافة أوزان تربط بين طبقة المدخلات والطبقة المخفية من قبل العالم Paul Werbos عام 1974. (عاشور مروان عبد الحميد، 2018، ص 24)

ونظراً إلى المشاكل التي واجهت شبكة الإدراك الحسي السابقة والضعف في التعلم فقد طور العلماء في منتصف الثمانينات خوارزمية انتشار الخطأ العكسي (Backpropagation Error) التي تعمل وفقاً لمبدأ الانحدار المتدرج Gradient Descent لتصحيح الأخطاء الناتجة في المخرجات كي يساعد الشبكات متعددة الطبقات على التعلم، ويعود اكتشاف هذه الخوارزمية في الحقيقة إلى عام 1960 إلا أنها قدمت رسمياً عام 1970 في أطروحة الدكتوراه للعالم الفنلندي Seppo Linnainmaa رغم أن تنفيذها لم يكن في مجال الشبكات العصبية، وقد تم تنفيذها في الشبكات العصبية لأول مرة عام 1986 على يد عدد من العلماء وهم كل من Rumelhart David and Hinton Geoffrey and Ronald Williams. (Altawell Najib, 2022, p 61)

من هنا بدأ الاهتمام العام بالشبكات العصبية حيث يعتبر Hecht-Nilson عام 1982 من أوائل الأشخاص الذين ساهموا في إدخال الشبكات العصبية إلى التطبيقات اليومية، فالشبكات العصبية غير قادرة على إنجاز المعجزات ولكنها تمتلك خصائص مبهمة ومقدرة عالية على تجاوز قيود الأساليب التقليدية في حل كثير من المسائل المعقدة، أهمها خاصية التوازي (Parallelism) وهو أساس معمارية الشبكة العصبية (Architecture Neural)

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار

الأسهم وإدارة المخاطر المالية

(Network)، حيث تعمل فيه خلايا الشبكة بشكل متزامن، كما أنها تمتلك قدرات عالية في معالجة البيانات الكبيرة وبسرعة عالية وكفاءة في التعلم بوصفها نتيجة تشير إلى قابليتها على الإجابة الدقيقة، أي تعرف ماذا سيكون الإخراج لهذا الإدخال، كما أنها تتميز بقدرتها على التكيف والتنظيم الذاتي (Self-organizing) وبذلك توفر قدرات معالجة موثوقاً بها، وفي عام 1987 أنشئت في الولايات المتحدة الأمريكية الجمعية الدولية للشبكات العصبية الاصطناعية INNS، إذ تضم مجموعة من العلماء والباحثين المهتمين في مجال الذكاء الاصطناعي والفهم النظري والحسابي للدماغ، وتعقد هذه الجمعية اجتماعاتها سنوياً وتقوم بنشر العديد من المؤلفات والمجلات المهمة بالشبكات العصبية وتطويرها. (David Brown, 2024)

وفي عام 2006 أطلق Geoffrey Hinton وآخرون ثورة التعلم العميق بتطوير خوارزميات تدريب فعالة للشبكات العميقة، والذي صمم للتعامل مع القيم غير الثنائية كلاحتمالات والتي يمكنها أن تتعلم العديد من المعلومات أكثر من النماذج التمييزية دون الإفراط في التخصيص، مما أدى إلى تحسن كبير في أداء العديد من التطبيقات. (Hinton et al., 2006, p 1547)

وفي عام 2010 استمر Geoffrey Hinton وزملائه في العمل على الشبكات العصبية الاصطناعية، وبدأوا في تحقيق إنجازات مهمة، إلى غاية عام 2011 حيث بدأ العالم Dan Ciresan من IDSIA في الفوز بمسابقات تصنيف الصور باستخدام الشبكات العصبية الاصطناعية المدربة بواسطة وحدة معالجة الرسومات، وهو أول نجاح عملي للتعلم العميق الحديث، لكن اللحظة الفاصلة جاءت في عام 2012 مع دخول مجموعة Hinton في تحدي تصنيف الصور السنوي واسع النطاق ImageNet أو تحدي التعرف البصري على نطاق واسع (ILSVRC)، ليتم اعتبار مهمة التصنيف بمثابة مشكلة تم حلها بالكامل مع مطلع عام 2015، ومنذ ذلك الوقت أصبحت الشبكات العصبية الاصطناعية هي الخوارزمية المستخدمة لجميع مهام الحاسوب بشكل عام، وتم تطبيقها في العديد من أنواع المشكلات الأخرى بسبب أدائها العالي وسهولة التدريب على مجموعات البيانات الضخمة. (Chollet, 2021, p 16-17)

لستمر الشبكات العصبية الاصطناعية في التقدم في عام 2020 مع تحسينات في البنية التحتية الحوسبية وزيادة توافر البيانات الضخمة مما أدى إلى تطبيقات ناجحة في مجالات متنوعة لعل أهمها والذي أحدث ضجة على نطاق واسع هي استخدام الشبكات العصبية المتطورة GPT-3 من قبل OpenAI التي تتضمن 175 مليار معلمة لتحقيق إنجازات هائلة في التوليد التلقائي للنصوص، بالإضافة إلى العديد من المهام الجديدة المصممة لاختبار التكيف السريع مع المهام التي من غير المرجح أن يتم تضمينها بشكل غير مباشر في مجموعة التدريب. (Brown et al., 2020, p 5)

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

المطلب الثاني: هيكلية الشبكات العصبية الاصطناعية

في هذا القسم يتم عرض الهيكلية الأساسية للشبكات العصبية الاصطناعية موضحين المكونات الرئيسية لها كالعقد والوصلات وكيفية تنظيمها في طبقات لتشكيل الشبكة، كما سيتم إلقاء نظرة على الأنواع المختلفة من الشبكات العصبية الاصطناعية على سبيل المثال لا الحصر مركزين على تلك التي تطبق في التنبؤات الاقتصادية والمالية.

أولاً: مكونات الشبكات العصبية الاصطناعية

جميع الشبكات العصبية تتألف من مجموعة من الوحدات الأساسية المعروفة باسم الخلايا العصبية أو العصبونات Neurons المتصلة معا في شكل طبقات Layer ويعد العصبون بمثابة وحدات معالجة ترتبط ببعضها البعض من خلال روابط تسمى الوصلات، تتنوع هذه الشبكات من حيث البنية والتعقيد، نظرا لطبيعة الروابط بين العصبونات أو العقد التي تحدد اتجاه تدفق الإشارات ضمن الشبكة، وقبل التطرق إلى مكونات العصبونات أو وحدات المعالجة علينا معرفة أنواع الطبقات المولفة للشبكات العصبية وعموما تتكون من ثلاث طبقات رئيسية أو أقل لأنه هناك شبكات أحادية الطبقة وشبكات متعددة الطبقات، وهذه الطبقات هي: (Karsoliya, 2012, p 714)

1. طبقة الإدخال Input Layer

وهي الطبقة الأولى والتي يتم عبرها تغذية الشبكة العصبية بالبيانات من الخارج التي تستقبلها بواسطة وحدات المعالجة (العصبونات)، وغالباً ما تحتوي الشبكات العصبية على طبقة إدخال واحدة تتكون من عدة عقد يكون عددها مساوياً لحجم المدخلات، وحدات المعالجة في هذه الطبقة لا يتم فيها أي معالجات لا عمليات حسابية ولا أي تحويل على البيانات، بل يقتصر دورها على استلام الإشارات العصبية وتمثيلها للطبقة اللاحقة، إذ ترتبط مع الطبقة المخفية بواسطة الأوزان المشبكية Synapses.

2. الطبقة المخفية Hidden Layer

الطبقة التي تقوم بمعظم العمليات الحسابية ومختلف المعالجات، وهي إحدى النتائج البحثية لمعالجة مشكلة البيانات غير الخطية، تتوسط هذه الطبقة بين طبقة الإدخال وطبقة الإخراج، وقد تتضمن الشبكات العصبية أكثر من طبقة مخفية واحدة وفقاً لمدى التعقيد في المشكلة المطروحة، وتتألف الطبقة المخفية من عدد من الخلايا العصبية والتي تحتوي بدورها على دالة الجمع Summation Function، ودالة التنشيط Activation Function.


الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

3. طبقة الإخراج Output Layer

وهي آخر طبقة في نموذج الشبكة العصبية وقد تحتوي هذه الطبقة على وحدة معالجة واحدة أو أكثر من واحدة وفقا للبنية المعمارية للشبكة، ترتبط مع الطبقة المخفية أو بطبقة الإدخال مباشرة بواسطة الأوزان المشبكية، وتتلخص وظيفتها في إنتاج القيمة النهائية من خلال تحويل القيمة الناتجة عن دالة التنشيط إلى القيمة المستهدفة بعد إجراء المعالجة اللازمة أو تقوم بإعادة هذه المخرجات كمدخلات مرة أخرى للشبكة وذلك عندما لا تتم معالجة البيانات كما هو مطلوب، ويعتمد عدد العقد في طبقة الإخراج على نوعية القيم المستهدفة، وتحتوي الشبكة عادة على طبقة مخرجات واحدة.

ولفهم هيكلية الشبكات العصبية الاصطناعية بشكل كامل من المهم النظر أيضا في مكونات العصبون، فهذا الأخير هو الوحدة الأساسية التي تتألف منها الطبقات في الشبكات العصبية الاصطناعية والذي يتألف بدوره من وصلات، دالة الجمع، دالة التنشيط، وظيفة الخسارة، وخوارزميات التحسين، والشكل التالي يوضح العلاقة بين هذه المكونات:

الشكل رقم (2-5): العلاقة بين الشبكة والطبقات، وظيفة الخسارة، وخوارزميات التحسين.



Source: François Chollet, J. J. Allaire, Deep Learning With R, Manning Publications, United States, 2018, P 51.

أ- الوصلات Connections

الوصلات أو المشابك Synapse بين العصبونات عبارة عن أوزان رقمية Weights في نطاق (0، 1) أو (-1، 1) يتم ضربها بالقيمة المدخلة قبل توحيد الإشارات في دالة الجمع، فالأوزان تحدد قوة وتأثير الإشارة المنتقلة من عصبون لآخر، أو من طبقة لأخرى، يجري وضعها بصورة عشوائية عند بداية التدريب يتم توليدها من توزيعات

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار


الأسهم وإدارة المخاطر المالية

إحصائية، ثم تعدل بعد ذلك بواسطة خوارزميات التعلم، وتعديل هذه الأوزان هو الجزء الأساسي في عملية التعلم، ويرمز للوزن بين عنصري معالجة i و j بالرمز W_{ij} (Haykin, 2009, p 10-11).

إذن يعتمد سلوك الشبكة العصبية الاصطناعية على كل من الأوزان ووظيفة الإدخال والإخراج (وظيفة النقل Transfer Function) المحددة للوحدات، وتقع هذه الوظيفة عادة ضمن ثلاث فئات: (Christos Stergiou & Dimitrios Siganos, 2011, p 8)

- التابع للوحدات الخطي Linear: حيث أن الخرج الناتج يتناسب مع إجمالي الخرج المرجح.
 - التابع لوحدات العتبة Threshold: الخرج يتحدد ضمن مستويين، اعتماداً على ما إذا كان إجمالي المدخلات أكبر من أو أصغر من قيمة عتبة معينة.
 - التابع للوحدات السينية Sigmoid: يتغير الخرج بشكل مستمر ولكن بشكل غير خطي مع تغيرات الدخل، هذا التابع يعطي أقرب تمثيل للخلايا العصبية الحقيقية.
- ونلجأ إلى عملية تهيئة الأوزان لمساعدة الشبكات العصبية الاصطناعية في الحفاظ على اتجاه التعلم المستقر وتقصير وقت التقارب، بغرض منع مخرجات تنشيط الطبقة من الانفجار أو الاختفاء أثناء مرحلة التعلم حيث يمكن أن يؤدي تدريب الشبكة دون تهيئة الوزن إلى بطء شديد في التقارب أو عدم القدرة على التقارب. (Deng et al., 2020, p 2)
- والشكل التالي يمثل عملية تهيئة الوزن:

الشكل رقم (2-6): رسم تخطيطي لعملية تهيئة الوزن.



Source: Wadii Boulila, Eman Alshantiti, Ayyub Alzahem, Anis Koubaa, and Nabil Mlaiki, An Effective Weight

Initialization Method for Deep Learning: Application to Satellite Image Classification, arXiv:2406.00348v1 [cs.CV], 2024, P

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

وفيما يلي تقنيات تهيئة الوزن الأكثر استخداماً: (Boulila et al., 2022, p 477-478)

- **التهيئة الصفيرية بالكامل والتهيئة الثابتة:** تضبط هذه الطريقة جميع الأوزان على صفر (أو ثابتة) بالإضافة إلى ذلك تكون جميع التنشيطات في جميع الخلايا العصبية متماثلة أي نفسها، مما يجعل هذا النوع من التهيئة مناسباً للنماذج الخطية.
- **التهيئة العشوائية:** تعمل هذه التقنية على تحسين عملية كسر التماثل وتوفير دقة أكبر، ويتم تهيئة الأوزان بشكل قريب جداً من الصفر وبشكل عشوائي، تمنع هذه الطريقة من تعلم نفس الميزة لمعلومات الإدخال.
- **تهيئة LeCun أو تطبيع التباين:** تهدف إلى منع اختفاء التدرجات أو انفجارها أثناء الانتشار العكسي من خلال حل التباين الذي يزداد مع عدد المدخلات وتعيين التباين الثابت.
- **تهيئة Xavier أو تهيئة Glorot:** اقترح Xavier طريقة أبسط وأكثر وضوح، حيث تكون الأوزان مثل تباين التنشيطات هي نفسها في كل طبقة وهذا سيمنع التدرج من الانفجار أو الاختفاء.
- **تهيئة HE أو تهيئة Kaiming:** تحافظ هذه التهيئة على عدم خطية دوال التنشيط كدالة التنشيط ReLU، ويمكن أن يؤدي تهيئة الأوزان باستخدام هذه الطريقة إلى تقليل أو تضخيم سعة المدخلات بشكل كبير.

ب- دالة التجميع Summation Function

تعتبر أول معالجة تقوم بها وحدة المعالجة هي حساب مجموع المدخلات المرجحة القادمة إلى الوحدة باستخدام دالة الجمع، وتتلخص وظيفة دالة الجمع في الشبكات العصبية الاصطناعية بتوحيد المدخلات المرجحة بواسطة الأوزان وذلك عن طريق جمع القيم المرجحة مضافاً لها مقدار التحيز للمدخلات كافة، أو بعبارة أبسط يتم ضرب كل قيمة مدخلة في وزنها المصاحب ومن ثم إيجاد المجموع لكل حواصل الضرب، وتعطى بالمعادلة التالية: (Haykin, 2009, p 10-11)

$$Y_k = \sum_{j=1}^m X_j W_{kj} + b_k$$

حيث:

- Y_k : تمثل ناتج عملية الجمع لكل وحدة معالجة k،
- X_j : القيمة المدخلة القادمة من الوحدة j والداخلية إلى الوحدة k،
- W_{kj} : تمثل الوزن الذي يربط وحدة المعالجة k بالوحدة j الموجودة في الطبقة السابقة،

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

- **Bi** (مقدار التحيز Bias): هي قيمة ثابتة يتم إضافتها إلى القيمة المدخلة المرجحة بواسطة الأوزان، يسمح مقدار التحيز بتغيير قيمة دالة التنشيط مما يجعل عملية التعلم أكثر واقعية، ويمكن تشبيهه مقدار التحيز بالمقدار الثابت في الدالة الخطية.

ت- دالة التنشيط Activation Function

تحتوي جميع الخلايا العصبية الاصطناعية على دوال تنشيط، وهي دالة رياضية تطبق على ناتج دالة التجميع وتقوم بتحويله إلى قيمة تستخدم كمدخل للطبقة التالية، ويساعد ذلك في تحديد ما إذا كان إخراج طبقة معينة مهماً أو لا لتمريره إلى الطبقة التالية. (Singh & Lone, 2020, p 163)

وتتلخص وظيفة دالة التنشيط في أنها تساعد في الحفاظ على نواتج دالة الجمع في نطاق معين ويتم ذلك بمقارنة نتيجة الجمع مع قيمة العتبة ويرمز لها بالرمز θ ليتحدد الناتج، ويطبق على المجموع عادة قبل المقارنة دالة تنشيط معينة وتتوقف مخرجات الشبكة بصورة أساسية على هذا التوزيع وبناءً على هذه الدوال التي تعطي الشبكة مخرجات محصورة ضمن المجال (0، 1) أو المجال (1، -1)، إذ عندما يتم ضرب المدخلات في الأوزان المرجحة مضافاً لها مقدار التحيز في مرحلة التدريب، فإن تكرار العملية ينتج قيماً كبيرة جداً مما يجعل عملية التدريب صعبة ويزيد من تعقيد المشكلة، كما تقوم دالة التنشيط بإضافة اللا خطية إلى الشبكات العصبية الاصطناعية مما يجعلها قادرة على حل المشاكل غير الخطية. (Moolayil Jojo, 2016, p 237)

وتوجد العديد من دوال التنشيط المستخدمة والتي تختلف بحسب الوظيفة المطلوبة، غير أنها تندرج جميعاً في ثلاثة أصناف رئيسية، وهي كالتالي:


- **دالة التنشيط الثنائية Binary Step Activation Function**: تعد من الدوال الأساسية البسيطة، إذ تعمل على أساس العتبة Threshold، وتقوم بتنشيط الخلايا فقط إذا كانت قيمة الإدخال أكبر أو أصغر من عتبة ما، يتوافق مخرج العقدة بعد ذلك مع إحدى القيمتين المحتملتين كما يوحي اسم الدالة وتقتصر عادة على (0 أو 1) تبعاً لشرط العتبة، إذ لا يمكن للدالة الثنائية توليد أكثر من إخراج واحد، ونظراً لبساطتها فإن الاستخدام الأساسي لهذه الوظيفة هو تصنيف البيانات في التصنيف الثنائي، وتعطى الصيغة الرياضية لها كالتالي: (Oliva Diego et al., 2021, p 456)

$$f(x) = \begin{cases} 0, & \text{for } x < 0 \\ 1, & \text{for } x \geq 0 \end{cases}$$

ويوضح الشكل التالي الرسم البياني لدالة التنشيط الثنائية:

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

الشكل رقم (2-7): الرسم البياني لدالة التنشيط الثنائية.



Source: Oliva Diego, Essam H Houssein, Hinojosa Salvador, Metaheuristics in Machine Learning: Theory, Houssein and Applications, First Edition, Springer, AG, 2021, p457.


- دالة التنشيط الخطية Linear Activation Function: تتميز الدالة الخطية عن سابقتها في أنها تسمح بتوليد عدة مخرجات تتناسب مع حجم البيانات المدخلة، ومع ذلك، فإنها غير قابلة للاشتقاق أو مشتقتها ثابت مما يجعلها تفتقر إلى خاصية الانتشار العكسي للتدرج Backpropagation Gradient، وبالتالي انعدام إمكانية تصحيح الأخطاء المهمة في تعلم الشبكات العصبية الاصطناعية ومنها لا يتم تحسين تنبؤات الشبكة، إذ تؤدي الشبكة العصبية ذات التنشيط الخطي باتجاه واحد إلى تلخيص تشغيل الشبكة العصبية متعددة الطبقات كشبكة عصبية أحادية الطبقة، وتمثل المخرجات حصيلة للجمع الخطي، وتتمثل صيغة الدالة الخطية في المعادلة التالية: (Sharma et al., 2020, p 312)

$$f(x) = x$$

ويوضح الشكل التالي الرسم البياني لدالة التنشيط الخطية:

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

الشكل رقم (2-8): الرسم البياني لدالة التنشيط الخطية.



Source: Siddharth Sharma, Simone Sharma, Anidhya Athaiya, Activation Functions In Neural Networks, International Journal of Engineering Applied Sciences and Technology, 2020 Vol. 4, Issue 12, ISSN No. 2455-2143, Pages 310-316, P 312.

- دوال التنشيط غير الخطية **Nonlinear Activation Function**: تكون البيانات التي تمثل المشكلة غير خطية بطبيعتها، وبالتالي تفشل دوال التنشيط الخطية في تنشيط المدخلات، لذلك بحث العلماء في تطوير دوال التنشيط بحيث يمكنها معالجة البيانات غير الخطية، ويوجد اليوم العديد من الدوال المستخدمة في التعلم الآلي عموماً والشبكات العصبية خصوصاً، إذ تمتاز هذه الدوال علاوة على كونها لا خطية بقابليتها للتفاضل **Differentiable** مما يسمح للشبكة العصبية تطبيق خوارزمية الانتشار العكسي لتصحيح الأخطاء، هذا ما يساعدها على تعلم الأنماط المعقدة في البيانات. (Kiliçarslan & Celik, 2021, p 1)


ومن تلك الدوال نذكر ما يلي:

- الدالة السينية **Sigmoid Function**: تعد من أشهر دوال التنشيط غير الخطية وأكثرها استخداماً في الانحدار اللوجستي والشبكات العصبية لعمليات التصنيف الثنائي (البيناري)، وهي دالة متزايدة بشكل رتيب وتقترب من بعض القيم المحدودة أيضاً، إذ تقوم بتحويل البيانات اللانهائية $(-\infty, +\infty)$ إلى نطاق $(0, 1)$ من خلال تطبيق دالة اللوغاريتم، مما يجعل مشاكل التصنيف أسهل، وتتمثل صيغة الدالة السينية والرسم التخطيطي لها كالتالي: (Montavon Grégoire et al., 2012, p 17-18)

$$Sigmoid(x) = \frac{1}{1 + \exp^{-x}}$$

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

الشكل رقم (9-2): رسم تخطيطي لدالة التنشيط السينية.




Source: Montavon Grégoire, Orr Geneviève B, & Müller Klaus-Robert, Neural networks: tricks of the trade, (Vol 7700), Second Edition, springer, Berlin Heidelberg, 2012, P 18.

– دالة الظل الزائدي (Hyperbolic Tangent (Tanh): تتشابه دالة الظل الزائدي مع الدالة السينية، إلا أنها تختلف في القيمة المنشطة في ناتج التحويل، إذ تقوم بتحويل البيانات المدخلة إلى نطاق (1، -1)، وهذا ما يجعلها أقل إعاقة للشبكة العصبية أثناء التدريب، وتتمثل صيغة الدالة الزائدي والرسم البياني لها كالتالي: (Ghatak, 2019, p 37)

$$\text{Tanh}_{(x)} = \frac{\exp^x - \exp^{-x}}{\exp^x + \exp^{-x}}$$

الشكل رقم (10-2): رسم تخطيطي يوضح دالة التنشيط الظل الزائدي.




Source: Ghatak Abhijit, Deep learning with R, First Edition, Springer, Singapore, 2019, P 37.

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

– دالة الوحدة الخطية المصححة أو المعدلة **Rectified Linear Unit (ReLU)**: في وظائف التنشيط السابقة تنشأ مشكلة التدرج المتلاشي لأنه لا يمكن اشتقاقها بعد قيمة عتبة معينة، لذلك تم تطوير وظيفة تنشيط لإيجاد حل لهذه المشكلة، وهي دالة ReLU التي يمكنها إجراء عملية الاشتقاق، وتعتبر هذه الدالة واحدة من أبرز دوال التنشيط غير المشبعة، ومن أكثر دوال التنشيط المستخدمة في الطبقات المخفية، وتُعد هذه الدالة نصف مصححة، إذ يتراوح إخراجها بين (0، ∞) فعندما تكون القيمة المدخلة أقل من 0 يكون إخراج الدالة 0، في حين إذا كانت المدخلات أكبر من 0 يكون إخراج الدالة مساويا لقيمة المدخلات ذاتها، والمعادلة التالية تمثل صيغة دالة الوحدة الخطية المصححة: (Nair & Hinton, 2010, p 808-809)

$$ReLU(x) = \max(x, 0)$$

الشكل رقم (2-11): رسم تخطيطي لدالة التنشيط ReLU.



Source: Chollet François, Deep learning with Python, Second Edition, Manning Publications Co, Shelter Island, 2021, P 100.

– دالة **LeakyReLU**: من العيوب المحتملة لدالة ReLU أنها تحتو على تدرج صفري فعندما لا يتم تنشيط الخلية العصبية يمكن أن يؤدي ذلك إلى عدم تنشيط الخلايا العصبية التي لم يتم تنشيطها في البداية لأن التحسين القائم على التدرج لن يضبط أوزانها، بالإضافة إلى ذلك يمكن أن يؤدي ذلك إلى إبطاء عملية التعلم بسبب التدرجات الصفرية الثابتة، وللتغلب على هذه المشكلة قام Mass وآخرون بتقديم دالة التنشيط LeakyReLU الذي تعرف بالمعادلة التالية: (Maas et al., 2013, p 2-3)

$$LReLU(x) = \max(x, 0) + \lambda \min(x, 0)$$


الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

حيث:

λ : معلمة محددة مسبقا في النطاق (0، 1).

بالمقارنة مع ReLU فإن LeakyReLU تضغط الجزء السالب بدلا من تعيينه إلى صفر ثابت مما يسمح بتدرج صغير غير صفري عندما لا يتم تنشيط الخلية العصبية.

الشكل رقم (2-12): رسم تخطيطي لدالة التنشيط LeakyReLU.




Source: Siddharth Sharma, Simone Sharma, Anidhya Athaiya, Activation Functions in Neural Networks, International Journal of Engineering Applied Sciences and Technology, 2020 Vol. 4, Issue 12, ISSN No. 2455-2143, Pages 310-316, P 313.

– دالة ReLU البارامترية PReLU: هي تحسين على دالة التنشيط ReLU حيث يتم تعلم الميل للجزء السلبي من الوظيفة أثناء التدريب بدلا من تعيينه إلى قيمة ثابتة كما هو الحال في LeakyReLU، فبدلا من استخدام معلمة محددة مسبقا λ في LeakyReLU على سبيل المثال، تتعلم دالة التنشيط الوحدة الخطية المعدلة البارامترية PReLU بشكل تكيفي معلمات المعدل لتحسين الدقة، إذ تساعد في حل مشكلة توقف الخلايا العصبية من خلال السماح بتدفق بعض القيم السالبة، ويتم تعريف دالة PReLU رياضيا كالتالي: (Anirudh Aggarwal et al., 2022, p 335-346)

$$PReLU(x) = \max(x, 0) + \lambda_k \min(x, 0)$$

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

الشكل رقم (2-13): رسم تخطيطي لدالة التنشيط PRelu.



Source: Anirudh Aggarwal, Mohit Bansal, Tanishq Verma, Apoorvi Sood, Residual in Residual Cascade Network for Single-Image Super Resolution. In Advances in Information Communication Technology and Computing, Springer, Singapore, 2022, p 335.

حيث يمثل λ_k المعلمة المستفادة للقناة k نظرا لأن PRelu لا يقدم سوى عدد قليل جدا من المعلمات الإضافية، على سبيل المثال، فإن عدد المعلمات الإضافية هو نفس عدد القنوات في الشبكة، فلا يوجد خطرا إضافي للتعلم الزائد والتكلفة الحسابية الإضافية لا تذكر، يمكن أيضا أن يتم تدريبها في وقت واحد مع معلمات أخرى عن طريق الترحيل العكسي.

- دالة التنشيط SWISH: تجمع بين الدالة السينية و Relu، ويتم تعريفها رياضيا على النحو التالي: (Ramachandran et al., 2017, p 5)

$$f(x) = x * \sigma(x)$$


حيث $\sigma(x)$ هي الدالة السينية ل x المعطاة بالصيغة التالية:

$$\sigma(x) = \frac{1}{1 + e^{-x}}$$

فإن دالة التنشيط SWISH دالة سلسة وغير رتيبة تستكمل بشكل غير خطي بين الوظيفة الخطية ووظيفة Relu، وهي قابلة للتفاضل مما يجعلها مناسبة في تدريب الشبكات العصبية باستخدام طرق تحسين تعتمد على التدرج، والشكل التالي يوضح الرسم البياني لدالة SWISH:

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

الشكل رقم (2-14): رسم تخطيطي لدالة التنشيط SWISH.



Source: Elfwing Stefan, Uchibe Eiji, & Doya Kenji, Sigmoid-weighted linear units for neural network function approximation in reinforcement learning, Neural Networks, arXiv:1702.03118v2 [cs.LG], 2017, p 4.

- دالة Softmax: تشبه تقريبا الدالة السينية تستخدم بشكل رئيسي في الطبقة الأخيرة من نموذج التصنيف المتعدد الطبقات في الشبكات العصبية، تحول مجموعة من القيم إلى مجموعة من احتمالات مجاميعها تكون 1، مما يجعلها مناسبة لتفسير نتائج النموذج كاحتمالات للانتماء إلى فئات متعددة، وتصاغ رياضيا بالعلاقة التالية: (Oliva Diego et al., 2021, p 458)

$$y_i = \frac{e^{z_i}}{\sum_{j=1}^k e^{z_j}}$$

حيث:

- y_i : هو الاحتمال المحسوب للفئة i ،

- K : عدد الفئات الممكنة،

- z_i : قيمة المدخل للفئة i .

ث- دالة الخطأ Error function

دالة الخسارة أو دالة الخطأ هي المقياس الذي يساعد الشبكة على فهم ما إذا كانت تتعلم في الاتجاه الصحيح، وبعبارة أخرى لتبسيط دالة الخسارة وكأنها النتيجة التي تحصل عليها في عدة اختبارات فإذا كان هناك تحسن في نتائج الاختبارات فهذا مؤشر جيد على الأداء، أما إذا انخفضت نتائج الاختبار فسيكون الحكم هو أن أدائه يتراجع وأنه يحتاج إلى تغيير أساليب دراسته أو معداته من أجل التحسن، وبالمثل في الشبكة العصبية يجب فهم ما إذا كانت تعمل على تحسين عملية التعلم الخاصة بها في كل تكرار أو لا، حيث يتم تحديد الخرج المتوقع

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار

الأسهم وإدارة المخاطر المالية

من أجل أي دخل ولكن خلال عملية التعلم يكون الخرج الفعلي y - الناتج عن الشبكة - لا يساوي بالضبط الخرج المطلوب d ، يكمن الهدف الرئيسي من تصحيح الخطأ في استخدام إشارة التعلم المساوية للفرق بين القيمة المطلوبة والقيمة الناتجة $y-d$ من أجل تعديل الأوزان حتى يتم تقليل هذا الخطأ بشكل تدريجي، واعتماداً على نوع نتيجة البيانات أو الخرج المطلوب فلدينا العديد من دوال الخسارة القياسية المحددة في التعلم الآلي، بالنسبة لحالات استخدام الانحدار حيث يكون التنبؤ النهائي رقماً مستمراً كنتائج الاختبارات أو عدد الوحدات المنتجة أو أسعار الأسهم، فإن أهم دوال الخسارة الشائعة المتاحة هي: (Moolayil, 2019, p 32-33)

- متوسط الخطأ التربيعي (Mean Squared Error (MSE): يحسب متوسط مربعات الخطأ عن طريق تربيع الأخطاء وقسمتها على عدد المشاهدات، إذ يُستخدم هذا المقياس لتجاوز إزالة القيم السالبة ولكن يأخذ عليه تضخيم قيمة الخطأ، ويحسب كما في المعادلة: (James et al., 2013, p 29)

$$MSE = \frac{1}{n} \sum_{i=1}^n \epsilon_i^2$$

- جذر متوسط الخطأ التربيعي (Root Mean Squared Error (RMSE: بغرض تجاوز مشكلة تضخيم الأخطاء في المقياس السابق، يستخدم الجذر التربيعي لقيمة MSE ويحسب كما في المعادلة التالية: (Mauro Andrea De, 2021, p 133)

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n \epsilon_i^2}$$

- الخطأ المطلق المتوسط (Mean Absolute Error (MAE: تحسب كمتوسط مجموع الفروق المطلقة بين القيم المتوقعة والقيم الحقيقية، صيغته الرياضية كالتالي: (Andina Diego & Duc Truong Pham, 2007, p 99)

$$MAE = \sum_{n=1}^k |A - P|$$

- متوسط النسبة المئوية للخطأ المطلق (Mean Absolute Percentage Error (MAPE: يقيس متوسط النسبة المئوية للفروق المطلقة بين القيم المتوقعة والقيم الحقيقية حيث يتم التعبير عنه كنسبة مئوية مما يجعله مفيداً لقياس الخطأ بالنسبة لحجم القيم، وتصاغ بالمعادلة التالية: (Hyndman & Athanasopoulos, 2018, p 79)

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار

الأسهم وإدارة المخاطر المالية

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\%$$

- **دالة Huber Loss:** هي دالة خسارة تستخدم في نماذج الانحدار التي تحتوي على ضجيج أو قيم متطرفة لأنها تقلل من تأثيرها على عملية التعلم وتحسن من أداء نماذج التنبؤ بالسلاسل الزمنية المالية مقارنة باستخدام دوال تقليدية مما يعزز من دقة النماذج في فهم الاتجاهات الحقيقية للأسعار دون تشويه ناتج عن القيم الشاذة، وهذا ما يجعلها مناسبة جداً في حالة البيانات المالية التي تتسم بالتقلب ووجود تطرفات، وتعد مزيجاً بين MSE و MAE حيث تسعى للاستفادة من مزايا كل منهما وتجنب عيوبهما، في حالة كانت الأخطاء صغيرة تعمل دالة Huber لتتصرف مثل MSE أي أنها تعاقب الأخطاء الصغيرة بدرجة أكبر لتشجيع النموذج على الدقة العالية، أما في حالة الأخطاء الكبيرة (نقاط شاذة) تتحول Huber لتتصرف مثل MAE مما يجعلها أكثر مقاومة للتأثير السلبي للقيم المتطرفة، يتم حساب دالة Huber بالمعادلة التالية: (Juan R. Terven et al., 2025, p 12-13)

$$L(y, \hat{y}) = \begin{cases} \frac{1}{2} (y - \hat{y})^2 & \text{for } |y - \hat{y}| \leq \delta \\ \delta \left(|y - \hat{y}| - \frac{1}{2} \delta \right) & \text{otherwise} \end{cases}$$


ج- خوارزمية التحسين Optimizers

هي الجزء الأكثر أهمية في تدريب الشبكات العصبية الاصطناعية حيث تلعب دوراً حاسماً في تحسين أوزان الشبكة بهدف تقليل الخطأ وتحسين أداء النموذج، حيث تعتبر الشبكة ذات الأوزان العشوائية والبنية المحددة هي باختصار نقطة البداية للنموذج، يمكن للنموذج أن يقوم بالتنبؤ في هذه المرحلة لكنه سيكون دائماً بلا قيمة، تأخذ الشبكة عينة تدريب واحدة وتستخدم قيمها كمداخلات للخلايا العصبية في الطبقة الأولى والتي تنتج بعد ذلك مخرجات بوظيفة التنشيط المحددة، والتي تصبح مدخلاً للطبقة التالية وهكذا سيكون ناتج الطبقة النهائية هو التنبؤ لعينة التدريب، هنا تظهر وظيفة دالة الخطأ والتي تساعد على فهم مدى جودة أو ضعف أداء مجموعة الأوزان الحالية على عينة التدريب، الخطوة الموالية للنموذج هي تقليل الخطأ وذلك عن طريق معرفة التحديثات التي يجب أن يقوم بها على تلك الأوزان لتقليل الخطأ وهنا تأتي خوارزميات التحسين التي تساعد على فهم هذه الخطوة، تعتمد هذه الخوارزميات على تقنيات رياضية وإحصائية لفهم مقدار التغيير الذي ستشهده الشبكة في

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

دالة الخطأ عن طريق إجراء تغيير بسيط في وزن الخلايا العصبية، والذي سيكون بالزيادة أو النقصان، ومن بين خوارزميات التحسين المختلفة المتوفرة نذكر ما يلي: (Moolayil, 2019, p 35-36)

- **نزول المتدرج (GD): Gradient Descent**: تعتبر خوارزمية GD واحدة من أكثر خوارزميات التحسين شهرة في تعلم الآلة، تعمل على تحديث الأوزان باتخاذ خطوات متكررة في اتجاه معاكس لميل دالة الخسارة وذلك لتقليل قيمة الخسارة لأن هذا يعتبر اتجاه الهبوط الأكثر انحداراً، ويتم حساب التدرج لكامل مجموعة البيانات قبل تحديث الأوزان، هناك ثلاث متغيرات لنسب التدرج، والتي تختلف في كمية البيانات التي نستخدمها لتقييم درجة دالة الهدف. (Kubat, 2017, p 97-98)
- الشكل رقم (2-15): خوارزمية نزول المتدرج.



Source: Haji Saad Hikmat, & Abdulazeez Adnan Mohsin, Comparison of optimization techniques based on gradient descent algorithm: A review, PalArch's Journal of Archaeology of Egypt/Egyptology, 2021, 18(4), P 2716.

- **نزول التدرج الكتلتي (BGD): Batch Gradient Descent**: نزول التدرج على دفعات يطلق عليه أحيانا باسم GD الفانيليا، يشابه GD التقليدي ولكنه يستخدم دفعات batches من البيانات لتحديث الأوزان بدلا من استخدام كامل مجموعة البيانات، حيث يكتشف الخطأ لكل فرد في قاعدة بيانات التدريب، لكن تتم مراجعة أوزان النموذج بعد تقييم جميع الأفراد في قاعدة البيانات، ويتم حساب التدرج لكل دفعة وتحديث الأوزان بناء على متوسط التدرج لتلك الدفعة، تشبه هذه العملية برمتها الحلقة، وتعرف باسم حلقة التدريب، ويحسب BGD تدرج دالة الخطأ فيما يتعلق بمعلمات لمجموعة بيانات التدريب بأكملها. (Haji Saad Hikmat & Mohsin Abdulazeez, 2021, p 2717)

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

نوضح BGD في المعادلة التالية: (Pattanayak, 2017, p 63)

$$\theta_{new} = \theta_{old} - \eta \cdot \nabla_{\theta} J(\theta)$$

حيث تمثل:

– θ_{new} : الوضع التالي،

– θ_{old} : الوضع الحالي،

– η : معدل التعلم أو حجم الخطوة،

– $\Delta_{\theta} J(\theta)$: اتجاه الزيادة الأسرع.

– نزول التدرج العشوائي (Stochastic Gradient Descent (SGD): لقد أثبتت خوارزميات نزول المتدرج

العشوائي فعاليتها في تحسين نماذج التعلم واسعة النطاق، ويشير المصطلح العشوائي إلى آلية أو طريقة

مرتبطة باحتمال عشوائي لذلك بدلا من تمرير قاعدة التعلم بأكملها في كل تكرار لتحديث أوزان النموذج

يتم اختيار عدد قليل فقط من العينات، بعدها يحدث الأوزان لكل عينة من البيانات بشكل

فردى. (Bottou, 2010, p 2-3)

يهدف SGD إلى إيجاد الحد الأدنى عن طريق تعديل بنية الشبكة بعد كل خطوة تعليمية، ويعمل هذا

الأسلوب ببساطة على تقليل الخطأ عن طريق تقريب التدرج لمجموعة مختارة عشوائيا بدلا من العثور على التدرج


في أساس التدريب، كما هو موضح في المعادلة التالية: (Joshi, 2023, p 3)

$$\mathcal{W}_{t+1} = \mathcal{W}_t - \eta \cdot \nabla_{\mathcal{W}} J(\theta; \mathcal{x}; \mathcal{y})$$

والشكل التالي يوضح دالة SGD:

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

الشكل رقم (2-16): رسم بياني لدالة SGD.



Source: Ruder Sebastian, An overview of gradient descent optimization algorithms, 2016, arXiv:1609.04747, P 3.

– نزول التدرج مصغر الدفعات (Mini-Batch Gradient Descent (MBGD): يجمع بين مزايا GD و SGD

باستخدام دفعات صغيرة من البيانات، الفرق الرئيسي بين الانحدار المتدرج على دفعات صغيرة والانحدار المتدرج على دفعات هو أنه بدلاً من حساب تدرج دالة التكلفة على مجموعة التدريب بأكملها، يحسب الانحدار المتدرج على دفعات صغيرة التدرج على مجموعة فرعية عشوائية صغيرة من مجموعة التدريب، وهذا يقلل من التكلفة الحسابية ويسرع من تقارب الخوارزمية، هناك مفاضلة بين معدل التقارب والتجاوز عند تحديد معدل التعلم، إذا كان معدل التعلم مرتفعاً جداً فقد نتجاوز الحد الأدنى ونبدأ في الارتداد دون الوصول إلى الحد الأدنى، ومن ناحية أخرى إذا كان معدل التعلم منخفضاً جداً فقد يكون التدريب طويلاً جداً، في معظم الحالات بالنسبة لخوارزميات GD لا يعمل التعلم الثابت بشكل جيد في عملية تحديث الوزن، ستطلب الخوارزمية معدل تعلم أعلى في المراحل الأولية لتحقيق النجاح الأمثل السريع، ومع ذلك في المراحل النهائية سيتعين على الخوارزمية تعديل معدل التعلم. (Li et al., 2014, p 662)


• خوارزمية الدفع Momentum: تضاف مكوناً للدفع إلى تحديثات الأوزان، حيث تم تصميم

Momentum للتعلم بسرعة خاصة عند مواجهة انحناءات كبيرة، أو تدرجات صغيرة ولكن صاخبة، أو تدرجات ثابتة، يعد استخدام مصطلح الزخم أسلوباً آخر يمكن أن يساعد الشبكة في التخلص من الحدود الدنيا لدالة الخطأ، ربما يكون هذا هو الامتداد الأكثر شيوعاً لخوارزمية الانتشار العكسي من الصعب العثور على حالات أخرى لا يتم فيها استخدام هذا النهج ولا يشير التدرج إلى الحد الأدنى عند

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

نقاط محددة على السطح وسوف تتأرجح خطوات GD المتعاقبة من جانب إلى آخر وتتقدم ببطء شديد نحو الحد الأدنى. (da Silva et al., 2017, p 71-72)

ويوضح الشكل التالي كيف يؤدي دمج الزخم عن طريق تخميد هذه التذبذبات إلى التقارب نحو الحد الأدنى. الشكل رقم (2-17): مقارنة خوارزميات SGD مع الزخم وبدونه.



Source: Ruder Sebastian, An overview of gradient descent optimization algorithms, 2016, arXiv:1609.04747, P 4.

- **الهبوط التدريجي التكيفي (Adaptive Gradient Descent (AdaGrad):** إنها طريقة تحدد وتيرة التعلم حسب الموقف، حيث تعدل معدل التعلم لكل معلمة بناءً على تاريخ التدرج المتراكم، وبما أن المعدل الفعلي يتم حسابه من المعلمات فإن معدلات التعلم تميل إلى التكيف عن طريق قياسها بما يتناسب عكسياً مع الجذر التربيعي المتدرج لمجموع قيمها التربيعية التاريخية، سيكون للتدرج الأعلى للمعلمات ذات المشتقات الجزئية الأكبر للخسارة معدل تعلم منخفض في حين أن المعلمات ذات المشتقات الجزئية الصغيرة لديها معدل تعلم منخفض نسبياً، يفيد في التعامل مع الميزات النادرة ولكنه قد يبطئ مع مرور الوقت بسبب تراكم التدرجات. (Goodfellow et al., 2016, p 307)
- **دلتا التكيفية (Adaptive Delta (AdaDelta):** المعروفة باسم خوارزمية معدل التعلم التكيفي LR Adaptatif يمكنه ضبط معدل التعلم تلقائياً وزيادة دقة التنبؤ، فهي تحسن من AdaGrad عن طريق الحد من تراكم التدرجات وتقليل الاعتماد على تاريخ التدرج الطويل حيث يركز على نطاق معين من التحديثات الأخيرة، ويعمل باستخدام نوافذ متعددة ذات حجم ثابت بدلاً من تجميع التدرجات، كما سيقوم فقط بمراقبة التدرجات المتاحة داخل النافذة. (Aggarwal, 2018, p 139-140)
- **جذر متوسط مربع الانتشار (Root Mean Square Propagation (RMSProp):** إحدى الخوارزميات العشوائية التكيفية الأكثر شيوعاً للتعلم العميق (الشبكة العصبية العميقة DNN) هي RMSProp حيث تعدل معدلات التعلم بناءً على متوسط الأثر المربع للتدرج، ويحافظ على معدل التعلم المتكيف عبر حساب المتوسط الأسّي لمربعات التدرجات. (Goodfellow et al., 2016, p 307-308)

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

• **تقدير اللحظة التكيفية (Adaptive Moment Estimation (Adam):** تقيس معدلات التعلم القابلة للتكيف لكل معلمة باستخدام تقديرات متوسطة للتدرج ومربعات التدرج، ويعد Adam أحد أكثر استراتيجيات التحسين شيوعاً في مجال الشبكات العصبية، حيث الاسم مأخوذ من لحظات التكيف، وهو مزيج من RMSProp و Momentum مع بعض الفروق المهمة، تأخذ عملية التسوية في الاعتبار متغير التدرج السلس وتوفر آلية تصحيح التحيز، يقلل Adam من التكاليف الحسابية ويتطلب ذاكرة وقت تشغيل أقل، وهو ثابت في مقياس التدرج القطري. (Moolayil, 2019, p 37-38)

• **دالة تقدير اللحظة التكيفية مع تحليل الأوزان المنفصل Adaptive Moment Estimation with Decoupled Weight Decay (AdamW):** هي نسخة محسنة من خوارزمية Adam وتستخدم بشكل واسع في تدريب الشبكات العصبية العميقة، والفرق الرئيسي بين Adam و AdamW يكمن في طريقة تطبيق الوزن التعديلي Weight Decay، حيث في Adam يتم تضمين معامل الوزن التعديلي داخل عملية تحديث التدرجات gradients مما يؤدي إلى تداخل بين معدل التعلم والتجسيم المنتظم regularization وبالتالي تقليل كفاءة النماذج أحياناً، أما في AdamW فقد تم فصل الوزن التعديلي عن التدرج الفعلي ما يجعل التحديث أكثر استقراراً ويزيد من قدرة النموذج على التعميم وتقليل احتمالية الإفراط في التكيف خاصة في المهام الحساسة كالتنبؤ ببيانات مالية شديدة التقلب كمؤشرات الأسهم. (Loshchilov & Hutter, 2019, p 7-8)

ح- معدل التعلم Learning Rate

هو أحد أهم المعايير في عملية تدريب الشبكات العصبية الاصطناعية ويشير إلى حجم الخطوة التي تتخذها الخوارزمية أثناء تحديث الأوزان مع كل تكرار عند تقليل وظيفة التكلفة باستخدام خوارزمية التحسين، فإذا كان معدل التعلم كبيراً جداً فإن النموذج قد يتجاوز الحد الأدنى المحلي ولا يصل إلى التوازن، وإذا كان معدل التعلم صغيراً جداً فإن النموذج قد يستغرق وقتاً طويلاً للتقارب أو قد يتوقف في الحد الأدنى المحلي غير المناسب، ويتم تحديث الأوزان في الشبكة العصبية باستخدام المعادلة التالية: (Nielsen, 2015, p 19-20)

$$W = W - \eta \cdot \nabla J(W)$$

حيث:

– W : يمثل الأوزان،

– η : يمثل معدل التعلم،

– $\nabla J(W)$: يمثل التدرج لوظيفة التكلفة بالنسبة للأوزان.

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

ثانيا: أنواع الشبكات العصبية الخاصة بالتنبؤ

هناك العديد من أنواع الشبكات العصبية الاصطناعية والتي تختلف في مكوناتها والهدف المرجو من بنائها، فقد تكون شبكات ذات طبقة واحدة Single Layer Networks أو شبكات متعددة الطبقات Multi Layer Networks أي تتكون من ثلاث طبقات طبقة إدخال، طبقة إخراج تتوسطهما طبقة مخفية أو أكثر من طبقة مخفية، وعدد المدخلات وعدد الخلايا (العقد) في الطبقة المخفية تحدد بحسب درجة تعقيد المسألة وحجم الإدخال إلى أن نصل إلى النموذج الأمثل، ونظرا لكثرة هذه الأنواع فسيتم التركيز على الشبكات العصبية المختصة في التنبؤ نظرا لأن هذه الدراسة تهدف إلى التنبؤ بأسعار الأسهم، ومن بين الشبكات العصبية المختصة في هذا المجال على سبيل المثال لا الحصر ما يلي:


1. شبكة الإدراك الحسي متعددة الطبقات Multi-layer Perceptron (MLP)

ويطلق عليها كذلك اسم الشبكة المغذية أو شبكة التغذية الأمامية (Feed-Forward Networks (FFN)، تعد من أكثر الشبكات استخداما في التنبؤ بالسلاسل الزمنية بسبب ميزة توفير مشتقات غير صفيرية فيما يتعلق بإشارات الإدخال، تقوم فكرة هذه الشبكة على استخدام القيم السابقة للسلسلة الزمنية كمدخلات للشبكة، توجد بها طبقة مخفية Hidden Layer واحدة أو أكثر تتوسط بين طبقتي الإدخال والإخراج وتربط بينهما بواسطة الأوزان Weights، إذ تحتوي الطبقات المخفية على دوال تنشيط غير خطية كدوال Sigmoid، Tanh و Softmax وغيرها، مما يكسبها قدرة على معالجة البيانات غير الخطية، ويعتمد عدد الطبقات المخفية في هذه الشبكة على المشكلة المطلوب معالجتها ومدى تعقيدها، مع الإشارة إلى أن زيادة الطبقات المخفية يمكن أن يزيد من تعقيد المشكلة في بعض الأحيان، وتُعد الشبكة متعددة الطبقات الأكثر استخداما كون أغلب المشاكل في الواقع العملي تكون غير خطية، بالتالي يستدعي ذلك وجود شبكة قادرة على معالجتها. (Bhattacharyya Siddhartha, 2019, p. 255-256)

والشكل التالي يوضح مخطط هيكلية الشبكة متعددة الطبقات MLP:

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

الشكل رقم (2-18): هيكلية الشبكة العصبية متعددة الطبقات MLP.



Source: Bhattacharyya Siddhartha, Intelligent Innovations in Multimedia Data Engineering and Management, First Edition, IGI Global, USA, 2019, p255.


2. الشبكة ذات الأساس الإشعاعي (RBFN) Radial Basis Function Network

إحدى أنواع الشبكات العصبية الاصطناعية، قدمت لأول مرة بواسطة Broomhead and Lowe 1988، تتشابه في هيكليتها مع شبكة الإدراك الحسي متعددة الطبقات MLP بالرغم من بعض الاختلافات، إذ تتكون من ثلاث طبقات فقط، طبقة الإدخال التي تحتوي على عقد مكافئة لعدد المتغيرات المتنبئة، يتم تمرير المدخلات مباشرة كمتجه إلى الطبقة الآتية دون تغيير إذ تعتمد على المسافات الإقليدية، كما تحتوي هذه الشبكة على طبقة مخفية واحدة تتضمن عقدا مكافئة لعينة التدريب، وتحتوي الطبقة المخفية على دوال تنشيط ذات الأساس الإشعاعي كالدالة الغاوسية Gaussian Function، وتتمثل ميزة RBFN في عدم وجود أوزان اتصال بين طبقة الإدخال والطبقة المخفية، وتحتوي أيضا على طبقة إخراج ترتبط مع الطبقة المخفية بواسطة الأوزان المشبكية، إذ يكون خرج الشبكة عبارة عن المجموع المرجح لمخرجات الطبقة المخفية، تقوم هذه الشبكة بتحويل المدخلات بطريقة غير خطية ثم إيجاد المنحنى المناسب لإعطاء النتائج الصحيحة، وتستخدم شبكة ذات الأساس الإشعاعي في معالجة مشاكل وظائف التقريب، السلاسل الزمنية، التصنيف، التحكم بالأنظمة، وغيرها، إذ تمتاز هذه الشبكات بقدرتها على التكيف والتعديل عن طريق سرعتها في التعلم، وتعميمها الجيد، ومنحنى الدالة يكون سلسا وشعاعي التناظر. (Yeung et al., 2010, p 12)

ويوضح الشكل التالي مخطط هيكلية الشبكة ذات الأساس الإشعاعي RBFN:

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

الشكل رقم (2-19): هيكلية الشبكة ذات الأساس الإشعاعي RBFN.



Source: Siddique Nazmul, Adeli Hojjat, Computational Intelligence: Synergies of Fuzzy Logic, Neural Networks and Evolutionary Computing, First Edition, Wiley & Sons, Ltd, United Kingdom, 2013, p112.

3. الشبكات العصبية المتكررة (RNNs) Recurrent Neural Networks

تسمى أيضا بشبكات التغذية الخلفية Feed-Back Networks والشبكات العصبية الديناميكية أو العقد أو الخلايا العصبية، ظهرت في الثمانينات من القرن الماضي نتيجة لجهود العديد من العلماء والباحثين في مجال الذكاء الاصطناعي والتعلم الآلي، وبالضبط في عام 1986 من طرف العالم Rumelhart وآخرون، وتعد شبكة هوبفيلد Hopfield 1982 واحدة من أوائل الشبكات التكرارية التي قدمت، تبعها بعد ذلك شبكة جوردن Jorden 1986 ثم شبكة إيلمان Elman 1990، إلا أنها اكتسبت مؤخرا شعبية كبيرة لقدرتها على حل بعض المشكلات التي تعتمد على التسلسل الزمني للأحداث، إذ على النقيض من الأنواع الأخرى للشبكات العصبية، تتميز الشبكات العصبية المتكررة بوجود حلقات للتغذية العكسية Feedback Loops مما يسمح لها بتخزين المعلومات عبر المسار الزمني، إذ تعتمد الشبكات التكرارية على مبدأ الذاكرة في نقل البيانات المتسلسلة بواسطة أجزاء خاصة في الطبقة المخفية تدعى State، وهو ما يجعلها قادرة على التنبؤ بالقيم المستقبلية بناء على الأحداث السابقة. (Fouad et al., 2020, p 366-367)

إن هيكلية الشبكة المتكررة تتضمن ثلاثة عناصر رئيسية، هي المدخلات، والطبقة المخفية، فضلا عن المخرجات، إذ تتلخص فكرة الشبكات المتكررة في تمرير المدخلات إلى الطبقة المخفية، والتي تقوم بتوليد إخراجين، الأول يتجه إلى طبقة الإخراج على شكل مخرج للشبكة، والثاني يتم تمريره على شكل متسلسل Sequential أو متجه Vector إلى عقدة أخرى أو العقد نفسها في الخطوة الزمنية اللاحقة مما يعد كإدخال للعقدة الآتية يحمل معلومات عن التنشيط السابق، إذ يتم جمع المعلومات الحالية مع التنشيط السابق (الإخراج في الخطوة الزمنية السابقة) في العقدة الحالية، وهو ما يجعل الشبكة تتذكر المعلومات السابقة التي تقوم على أساسها ببناء التوقعات، لهذا تُستخدم الشبكات التكرارية في تطبيقات الترجمة، والتعرف على الكلام، فضلا عن التنبؤ


الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار

الأسهم وإدارة المخاطر المالية

بالسلاسل الزمنية، وتحتوي الطبقة المخفية في الشبكات التكرارية دالة الظل الزائدي Tanh كدالة تنشيط للمحافظة على البيانات في نطاق (1، -1)، كما تضم الأوزان الرابطة بين الطبقات على غرار الأنواع الأخرى من الشبكات العصبية. (Lazzeri, 2021, p 145-146)

والشكل التالي يوضح معمارية الشبكة العصبية المتكررة:

الشكل رقم (20-2): هيكلية الشبكة العصبية المتكررة RNNs.



Source: Dev Dipayan, Deep Learning with Hadoop, First Edition, Packt Publishing, UK, 2017, p 108.

تصنف الشبكة المتكررة إلى أربع فئات رئيسية وفقا لعدد المدخلات وعدد المخرجات، إذ تتضمن شبكة واحد إلى واحد، شبكة واحد إلى متعدد، شبكة متعدد إلى واحد، وشبكة متعدد إلى متعدد، كما يلي: (Arif, 2020, p 33-)

(34)

- شبكة واحد إلى واحد: في هذه الشبكة يتم تمرير مدخل واحد للحصول على مخرج واحد، ومن الأمثلة عليها تطبيقات الكتابة.
- شبكة واحد إلى متعدد: في هذه الشبكة يتم توليد العديد من المخرجات والطبقات المخفية المتشعبة بواسطة إدخال واحد، ومن الأمثلة عليها تطبيقات التعليق على الصور.
- شبكة متعددة إلى واحد: كما يوحي الاسم، إذ يتم في هذه الشبكة الحصول على اخراج واحد عن طريق عدد من المدخلات، ومن الأمثلة على هذه التنبؤ بالأسعار.
- شبكة متعددة إلى متعدد: يتم تمرير عدد من المدخلات للحصول على عدد من المخرجات، مع الإشارة إلى إمكانية أن تكون المدخلات والمخرجات بأعداد مختلفة، ومن الأمثلة على هذه الشبكة تطبيقات الترجمة. وعلى الرغم من أن الشبكات المتكررة نجحت في نمذجة بيانات السلاسل الزمنية التي لم يكن بإمكان الشبكات العصبية التقليدية نمذجتها، إلا أنها تواجه بعض المشاكل في التعامل مع السلاسل الزمنية الطويلة خاصة التي تحتوي على مركبي الاتجاه والموسمية، بسبب مشكلة انفجار Exploding أو تلاشي Vanishing قيمة الانحدار المتدرج و/أو الأوزان المتأرجحة. (A. V Joshi, 2020, p 124)

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار


الأسهم وإدارة المخاطر المالية

4. شبكة الذاكرة طويلة المدى (Long Short Term Memory (LSTM)

قدمت شبكة الذاكرة طويلة المدى من طرف Schmidhuber and Hochreiter 1997، في محاولة لمعالجة مشكلتي تلاشي التدرج أو انفجاره في الشبكات المتكررة عند تطبيق خوارزمية الانتشار الخلفي عبر الزمن، وهو ما يجعل شبكة RNNs عاجزة عن الاحتفاظ بالتبعية (المعلومات) لمدى طويل عبر الزمن، وتعد شبكة LSTM نموذجاً محسناً من الشبكات التكرارية مصممة لمعالجة مشكلة النسيان لديها، إذ جرى تعديل بنية الشبكة بغرض جعلها قادرة على الاحتفاظ بالمعلومات المهمة لفترة زمنية مناسبة، وكذلك تحديد المعلومات غير المهمة للتخلص منها، حيث تعتمد على آلية البوابات Gates في التحكم بالمعلومات المدخلة، إذ تتكون من ثلاث بوابات هي: بوابة النسيان Forgetting Gate، بوابة الإدخال Input Gate، وبوابة الإخراج Output Gate، وتكون هذه البوابات عبارة عن دوال سينية تسيطر على مرور المعلومات عن طريق تنشيط القيم المدخلة في نطاق (0، 1)، إذ أن قيمة التنشيط 1 تعني السماح بمرور المعلومات والاحتفاظ بها، بينما على العكس من ذلك تعني قيمة 0 عدم السماح بمرورها. (Patel et al., 2022, p 131)

إن الاختلاف الجوهرى بين الشبكة التكرارية التقليدية RNNs وشبكة LSTM هي أن الأخيرة تقوم بتقسيم قيمة التنشيط في الطبقة المخفية إلى حالتين مخفيتين، الأولى يطلق عليها الحالة المخفية وهي نفسها في شبكة RNNs ويتم استخدامها في تقدير قيم الإخراج، والثانية يطلق عليها حالة الخلية Cell State يتم استخدامها لحفظ المعلومات المتسلسلة زمنياً، إذ يشار إليها أحياناً بالذاكرة الداخلية، ويتم تقاسم هذه الحالتين في كل خطوة زمنية على طول مسار البيانات المدخلة ويمكن توضيح هيكلية شبكة الذاكرة طويلة كالتالي: (Xiong, 2020, p 234-235)

الشكل رقم 2-21): البنية الهيكلية لشبكة الذاكرة طويلة LSTM.



Source: Achyut Ghosh, Soumik Bose, Giridhar Maji, Narayan C Debnath, Soumya Sen, Stock price prediction using LSTM on Indian share market, In Proceedings of 32 nd international conference on Computer Applications in Industry and Engineering, Vol


الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

5. الشبكة العصبية للانحدار العام (GRNN)

هي نوع من الشبكات العصبية التي تستخدم أساساً في مسائل الانحدار والتنبؤ، تم اقتراحها بواسطة Donald Specht's عام 1991 وهي تعتبر نوعاً من الشبكات العصبية الاحتمالية PNN وتعد GRNN ملائمة للتطبيقات التي تتطلب نمذجة غير خطية، وتتمتع بقدرة على التكيف مع البيانات المختلفة دون الحاجة إلى عملية تدريب طويلة ومعقدة، أهم مزايا GRNN هي بساطتها، ويمكن أن يكون عيبها هو حجم الشبكة الكبير والتكلفة الحسابية المرتبطة بهذه الشبكة. (Siddique & Adeli, 2013, p 115-117)

تتكون GRNN من طبقتين الأولى تتكون من الخلايا العصبية ذات الأساس الإشعاعي والتي تكون وظيفة النقل فيها غاوسية، أما الطبقة الثانية تتكون من الخلايا العصبية ذات وظيفة النقل الخطي، والشكل التالي يوضح معمارية الشبكة العصبية للانحدار العام.

الشكل رقم (2-22): معمارية شبكة GRNN.



Source: Siddique Nazmul, Adeli Hojjat, Computational Intelligence: Synergies of Fuzzy Logic, Neural Networks and Evolutionary Computing, First Edition, Wiley & Sons, Ltd, United Kingdom, 2013, p117.


6. الشبكات العصبية العميقة (DNNs)

انبثق مفهوم التعلم العميق من الشبكات العصبية الاصطناعية وبدأت ممارسة التعلم العميق في الستينيات أو قبل ذلك، حيث تم نشر أول نموذج شعبي للهندسة المعمارية العميقة DNN من قبل Ivakhnenko and Lapa في عام 1965 باستخدام الإدراك الحسي متعدد الطبقات للتغذية العميقة الخاضع للإشراف. (Dev, 2017, p 32-33)

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

تتكون من عدة طبقات مخفية معقدة مع مجموعة واسعة من الطبقات المختلفة، تساعد هذه الطبقات الإضافية النموذج وعلى غرار الشبكات العصبية التقليدية على نمذجة علاقات غير خطية معقدة، وفهم المشكلات بشكل أفضل وتوفير حلول مثالية في مجموعة واسعة من التطبيقات بما في ذلك التنبؤ، تمتاز بقدرتها على تعلم ميزات أكثر تعقيدا بفضل العمق الكبير في البنية، والشكل التالي يوضح بنية الشبكة العصبية العميقة. (Prince, 2023, p 41-46)

الشكل رقم (2-23): بنية الشبكة العصبية العميقة DNN.



Source: Bossey M Mostafa, Noha El-Attar, Samy Abd-Elhafeez, Wael A Awad, Machine and Deep Learning Approaches in Genome: Review Article, Alfarama Journal of Basic & Applied Sciences, January, Volume 2, Issue 1, 2021, p 108.


7. شبكة الانحدار الذاتي غير الخطية ذات المدخلات الخارجية Nonlinear Autoregressive Vetwork with Exogenous Inputs (NARX)

تستخدم بيانات الإدخال الخارجية للتنبؤ بالبيانات المستقبلية حيث تكون مخرجات النظام الفعلية بمثابة مدخلات للنموذج، وتستخدم في التنبؤ بالسلاسل الزمنية وتحليل الأنظمة الديناميكية، يتميز هذا النموذج بقدرته على التعامل مع البيانات المعقدة والمتغيرة بمرور الوقت وأيضا مع النماذج التي تعتمد على البيانات التاريخية وكذلك المدخلات الخارجية وهذا يعني أن النموذج يربط القيمة الحالية لسلسلة زمنية بكل من القيم السابقة لنفس السلسلة والقيم الحالية والماضية للسلسلة الخارجية أي للسلسلة المحددة خارجيا والتي تؤثر على السلسلة محل الاهتمام، كما يمكن استخدامها في النمذجة غير الخطية. (Du & Swamy, 2019, p 354-356)

والشكل التالي يوضح بنية شبكة NARX:

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

الشكل رقم 2-24: بنية شبكة NARX.



Source: Luis Cicero Bezerra Da Silva, Jorge Leonid Aching Samatelo, Marcelo Eduardo Vieira Segatto, João Paulo Bazzo, Jean Carlos Cardozo Da Silva, Cicero Martelli, and Maria José Pontes, NARX neural network model for strong resolution improvement in a distributed temperature sensor, Applied Optics, Vol 57, No 20, 10 July 2018, p 5860.

8. شبكة المحول Transformer


ظهرت خوارزمية المحول Transformer في الورقة العلمية المشهورة بعنوان "Attention is All You Need" في ديسمبر 2017 والذي كتبها أعضاء فريق Google Brain وباحثون من Google Research، حيث تفوقت على النماذج السابقة المتقدمة في مجال اللغة الطبيعية وتحليل البيانات، إذ كانت أسرع في التدريب مقارنة بالبنى المعمارية السابقة وحققت نتائج تقييم أعلى. (Denis Rothman, 2021, p. 01-02)

ونموذج المحول هو نموذج تعلم عميق يعتمد على تقنية آلية الانتباه الذاتي (Self-Attention) والذي يطلق عليه أحيانا بالانتباه الداخلي، وهو نموذج معماري يتجنب التكرار يعمل جنباً إلى جنب مع الشبكات العصبية الاصطناعية، ويستخدم لتحليل البيانات المتسلسلة كالنصوص والسلاسل الزمنية، وهو يعتبر من أهم التطورات في مجال الذكاء الاصطناعي الحديث، يعمل النموذج على تحويل أو نقل المعلومات عبر النقاط الزمنية في البيانات لتحديد الأنماط والعلاقات المهمة، بدلاً من معالجة البيانات نقطة تلو الأخرى، يقوم المحول بمعالجة البيانات بشكل متواز باستخدام آلية الانتباه متعدد الرؤوس (Multi-Head Attention)، يستخدم عادة لمعالجة النصوص الطبيعية، تحليل السلاسل الزمنية، والتصنيف والتنبؤ. (Vaswani et al., 2017, p 2-4)

والشكل التالي يوضح بنية نموذج المحول Transformer:

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

الشكل رقم (25-2): بنية نموذج المحول Transformer.



Source: Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., ... & Polosukhin, I.

Attention is All You Need. Advances in Neural Information Processing Systems (NeurIPS), 2017, p 3.

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار

الأسهم وإدارة المخاطر المالية

المبحث الثالث: الشبكات العصبية الاصطناعية والتنبؤ بتقلبات أسعار الأسهم في إدارة المخاطر المالية

إحدى القضايا الأكثر تحدياً في مجال الاقتصاد والتمويل هي التنبؤ بالتقلبات المالية لأسعار مختلف الأدوات المالية خاصة في بيئة تتسم بالتغير السريع والتقلبات المستمرة، لذلك استعمل المحللين الماليين والاقتصاديين من أجل هذا الهدف العديد من النماذج للوصول إلى أعلى دقة في التنبؤ من بينها الشبكات العصبية الاصطناعية، وسيركز هذا المبحث على تقديم فهم شامل لكيفية استخدام الشبكات العصبية الاصطناعية في مجال التنبؤ المالي عامة وتطبيقها في التنبؤ بتقلبات أسعار الأسهم خاصة.

المطلب الأول: تطبيق الشبكات العصبية الاصطناعية في التنبؤ بالتقلبات وإدارة المخاطر المالية

هذا القسم يسلط الضوء على أمثلة عملية على استخدام الشبكات العصبية الاصطناعية في التنبؤ بالتقلبات المالية، والاقتصادية وصولاً إلى استخدامها في التنبؤ بأسعار الأسهم، بالإضافة إلى المميزات التي تتمتع بها الشبكات العصبية والتي تجعلها أداة فعالة في هذا المجال.

أولاً: استخدامات الشبكات العصبية الاصطناعية في التنبؤ بالتقلبات وإدارة المخاطر المالية

في ظل المنافسة الشديدة التي تميز المجتمعات الحديثة والاقتصاديات المتقدمة، تصبح القدرة على التنبؤ بالمستقبل ضرورة ملحة لضمان البقاء والاستمرارية في بيئة تتسم بالتعقيد والتغير السريع والتقلبات المستمرة. تساهم حالة عدم اليقين حول المستقبل والخوف من المجهول في زيادة أهمية التنبؤ الدقيق القائم على بيانات سابقة، وهو ما يمكن أن يدفع بالمستثمرين، سواء كانوا أفراداً أو شركات، نحو تحقيق النجاح. من هنا، برزت أهمية التطورات في مجالات بحوث العمليات، الإحصاء، والعلوم الحاسوبية، حيث تم تطوير أساليب تنبؤ متقدمة استبدلت الطرق التقليدية التي كانت تعتمد على الحدس والحظ، كمنهجية بوكس جينكينز Box-Jenkins، وهولت ونترز Holt-Winters 1960، على الرغم من أن هذه الطرق تعطي توقعات دقيقة في مجال السلاسل الزمنية الخطية، إلا أنها تتسم بعائق المكونات المشوشة أو اللا خطية التي تكثر في الواقع العملي، مما دفع بالمستثمرين للبحث عن أدوات قوية لتوجيه قراراتهم بشكل أكثر استناداً إلى البيانات والأنماط الموثوقة، فجاءت الشبكات العصبية الاصطناعية كأسلوب حديث للتنبؤ وتجاوزاً لتلك العوائق، حيث بدأ استخدامها في التنبؤ كأول مرة من طرف العالمين Farber & Lapedes 1987 أين تم استخدام شبكات Perceptron متعددة الطبقات للتنبؤ بسلسلة زمنية عشوائية، منذ ذلك الحين تم اقتراح عدة بنى هندسية من التوابع الشعاعية الأساسية (radial basis function) والشبكات التكرارية (Ulbricht) على الرغم من أن أغلبية الدراسات تتبنى وتختار الشبكة متعددة الطبقات. (Guang-Bin Huang et al., 2004, p 25)

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

- ففي سنة 2004 استخدمت الشبكات العصبية الاصطناعية مع عدد من أساليب الاقتصاد القياسي للتنبؤ بنمو الناتج المحلي الإجمالي في ماليزيا باستخدام مؤشرات الاقتصاد القائم على المعرفة استنادا إلى بيانات السلاسل الزمنية التي تم جمعها من 1995-2000 إذ تم استخدام شبكة MLP مع خوارزمية Backpropagation لتدريب نموذج الشبكة العصبية. (MOHD ZUKIME HJ MAT JUNOH, 2004)
- وفي سنة 2010 تم استخدام الشبكات العصبية للتنبؤ بسعر الصرف الأجنبي في الهند للتغلب على مشكلة اللا خطية في بيانات سعر الصرف، وكانت البيانات التاريخية عبارة عن سلسلة زمنية للأسعار اليومية والشهرية للدولار الأمريكي، الجنيه الإسترليني، والين الياباني. (Pradhan & Kumar, 2010)
- وفي سنة 2014 استخدمت الشبكات العصبية للتنبؤ بأسعار الأسهم لبورصة نيويورك إلى جانب منهجية Box-Jenkins (ARIMA). (Adebiyi et al., 2014)
- في عام 2015 استخدمت الشبكات العصبية لتقييم الجدارة الائتمانية لمقترض قروض النظير للنظير Peer-To-Peer، في فنلندا، وقد تم استخدام المعلومات الديموغرافية والمالية للزبائن للفترة من 2009 إلى 2015. (Byanjankar et al., 2015)
- كما استخدمت الشبكات العصبية في نفس العام للتنبؤ بمؤشرات أسواق الأسهم بشكل مستقل في الدنمارك وألمانيا واليابان والسويد والولايات المتحدة الأمريكية، إذ تم استخدام شبكة الإدراك الحسي متعددة الطبقات MLP. (Karlsson & Nordberg, 2015)
- في 2018 استخدم نموذج الذاكرة الطويلة من الشبكات العصبية التكرارية إلى جانب بعض تقنيات التعلم الآلي في التنبؤ بأسعار الأسهم لمؤشر S&P500، إذ جرى الاعتماد على البيانات التاريخية إلى جانب تحليل المشاعر والأخبار والمدونات عبر الأنترنت. (Tipirisetty, 2018)
- وفي سنة 2020 استخدم نموذج الذاكرة الطويلة من الشبكات العصبية المتكررة RNN-LSTM إلى جانب شبكة الانتشار الخلفي المحسنة بواسطة الخوارزمية الجينية BPNN-GA للتنبؤ بمبيعات التأمين لعدد من القطاعات في الصين، وكانت البيانات عبارة عن فواتير المبيعات لأربع سنوات من عام 2016 إلى عام 2019. (Wang, 2020)
- واستخدم نفس النموذج في نفس الفترة لكن إلى جانب بعض تقنيات التعلم الآلي ونماذج الانحدار للتنبؤ بأسعار 500 سهم مدرج لمؤشر S&P500 من أجل استخدامها في بناء محفظة استثمارية فعالة. (Ta et al., 2020)

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار الأسهم وإدارة المخاطر المالية

- في نفس السنة أي عام 2020 استخدم نوع من الشبكات العصبية الاصطناعية تسمى أجهزة التشفير التلقائي المتغيرة VAEs والتي قدمت نهجا جديدا لقياس مخاطر السوق يسمى القيمة المشفرة المعرضة للخطر Encoded VAR، والتي تعتبر آلة تنبؤية لإدارة المخاطر. (Arian et al., 2020)
- في سنة 2022 تم تقديم نهجا احتماليا للتعليم العميق مع الاستفادة من تقنيات التنبؤ بالسلاسل الزمنية ذات الإمكانات العالية لرصد مخاطر محفظة معينة بطريقة فعالة للغاية، سمي هذا النهج DeepVaR والذي يستفيد من الشبكات العميقة. (Fatouros et al., 2023)
- في سنة 2023 تم اقتراح GARCHNet وهو نهج جديد غير خطي للتباين الشرطي يجمع بين بنية الشبكة العصبية LSTM مع نموذج GARCH، وذلك للتنبؤ بالقيمة المعرضة للخطر. (Buczynski & Chlebus, 2024)
- في سنة 2024 تم استخدام نوع جديد من الشبكات العصبية الاصطناعية تدعى بالشبكات العصبية التلافيفية CNN إلى جانب نموذج الذاكرة الطويلة LSTM للتنبؤ بأسعار البيتكوين وكانت البيانات المستخدمة هي سعر إغلاق البيتكوين من 2017 إلى 2023. (Cahyadi & Zahra, 2024)

ثانيا: مميزات الشبكات العصبية الاصطناعية للتنبؤ بالتقلبات المالية

تعتبر الشبكات العصبية المتدربة في مجال معين كخبير في تحليل البيانات في هذا المجال لذا يمكن الاستفادة منها في تنبؤات أو تقديرات لحالة جديدة كونها تستخدم لاستخراج النماذج وتحديد الطرق التي تكون معقدة للبشر وللأنظمة التقنية الأخرى وذلك لقدرة الشبكات العصبية الاصطناعية العالية على اشتقاق المعنى من البيانات المعقدة أو غير الدقيقة، بالإضافة إلى أن هذه النظم تستمد قوتها من خلال هيكلها المتوازي الموزع وقدرتها على تطوير نفسها من خلال التعلم والتدريب باستخدام المعطيات المتوفرة كما أنها أكثر مرونة في البيئات المتغيرة فنقول إنها ممتازة في التأقلم مع التغيرات الحاصلة والمفاجئة على الرغم من أنها تأخذ بعض الوقت لتتلاءم معها، وبالتالي قدرتها على التعميم Generalization الذي يشير إلى قدرة الشبكات العصبية على توفير مخرجات منطقية لمدخلات جديدة لم تكن متواجدة في مرحلة التعلم. (Christos Stergiou & Dimitrios Siganos, 2011, p 219)

وبالإضافة إلى ذلك تمتاز الشبكات العصبية بعدة خصائص تجعلها مناسبة للتنبؤ، يمكن تلخيصها فيما يلي:

يلي: (Kantardzic Mehmed, 2019, p 232-233)

- التعلم التكيفي Adaptive Learning: الشبكات العصبية الاصطناعية لها القدرة على تعلم كيفية تنفيذ المهام بالاعتماد على عينات من المعطيات يتم إدخالها في البداية كخبرة أولية، بمعنى أن النموذج العصبوني يتميز بقدرته على التكيف مع التطورات الحاصلة والظروف المحيطة الحالية التي بإمكانها أن تفقده فعاليتها في التمييز مع مرور الزمن، عن طريق تعديل أوزانها استجابة للبيانات الجديدة التي تتعرض

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار

الأسهم وإدارة المخاطر المالية

لها خلال فترة التدريب، بالمختصر أنها تتكيف مع التغيرات في البيانات وتتعلم أنماطا جديدة بمرور الوقت، كذلك يمكنها التعامل مع البيانات غير الثابتة من خلال التكيف معها بالوقت الحقيقي Real-time Adaptivity.

- التنظيم الذاتي Self-Organization: الشبكات العصبية الاصطناعية يمكنها أن تخلق أو تولد نمطا لتنظيم أو لتمثيل البيانات التي يتم استقبالها خلال مرحلة التعلم دون الحاجة إلى تدخل بشري كبير من خلال تعديل هيكلها وأوزانها بشكل تلقائي استنادا للبيانات المدخلة.
- عمليات في الزمن الحقيقي Real Time Operation: أي يمكنها أن تنفذ حسابات وعمليات على التوازي، بمعنى تعمل على معالجة البيانات في وقت واحد عبر خلايا عصبية متعددة، مما يسمح لها بتسريع عمليات التدريب والاستدلال، تمكنها من حل المشاكل المعقدة التي تضم فرضيات كثيرة ومعلومات متغيرة بشكل سريع وفعال.
- تسامحية مع الأخطاء Fault Tolerance: يقصد به أن عند التعطل الجزئي للشبكة فيمكن أن يقود إلى تخفيض الأداء وليس إلى توقف العمل نهائيا، توجد في الشبكات العصبية خاصية التسامح مع الأخطاء، بمعنى أن أداءها لا يتدهور في ظل وجود بيانات عشوائية أو بيانات مفقودة، وهذه الميزة مهمة في التنبؤ بالسلاسل الزمنية التي تنطوي على بيانات عشوائية أو مفقودة، وهذا بفضل قدرتها على التعميم والتعلم من الأخطاء.
- لها المقدرة على التعلم والتدريب: أي يمكن تعويمها وتدريبها مما يمكنها من التذكر والتكيف وتوفير الحلول للمسائل المتشابهة حتى وإن كانت المدخلات منقوصة أو مشوشة، حيث تستطيع الشبكات العصبية التعلم ذاتيا من العينات المقدمة لعملية التعلم (التدريب) من خلال ضبط الأوزان الرابطة بين الطبقات المكونة للشبكة العصبية، إذ تمثل الأوزان المعدلة المعرفة المخزنة ضمنيا للمشكلة المطروحة، وبالتالي تكون قادرة على توقع المخرجات للمدخلات الجديدة.
- لها المقدرة على حل المشاكل المعقدة بدون إعطائها خوارزمية الحل وهذه الميزة تميزها عن البرامج التقليدية التي لا يمكنها حل المشكلة إذا لم يتم إعطاؤها الخوارزمية التي تمكنها من إيجاد الحل.
- تقوم بتوفير حلول لا يمكن إيجادها بالطرق المنطقية أو التحليلية (الاعتيادية) المستخدمة في البرامج التقليدية.
- اللا خطية: تمتاز الشبكات العصبية بقدرتها على معالجة البيانات الخطية وغير الخطية، إلا أنها اشتهرت بخاصية المعالجة غير الخطية، إذ أن غالبية المشاكل في الواقع غير خطية لا سيما السلاسل الزمنية العشوائية وغير المستقرة كأسعار الأسهم، فإن الشبكات العصبية لا تتطلب فروضا إحصائية لاختبار استقرار السلاسل الزمنية، إذ يمكنها التعامل مباشرة مع أي نمط من السلاسل الزمنية، حيث أنها

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار

الأسهم وإدارة المخاطر المالية

تتمكن من إيجاد العلاقات غير الخطية بين المتغيرات وأخذها بعين الاعتبار في إعطاء النتائج، ولهذا استطاعت أن تتفوق على الأساليب الإحصائية التقليدية.

- وحدة التصميم والتحليل: تتمتع الشبكات العصبية بشكل أساس بالعمومية كمعالجات للمعلومات، إذ توفر إطاراً موحداً لتصميم وتحليل نماذج التعلم الآلي، وبالتالي يتم استخدام نفس المبادئ، الترميز، والمنهجية في جميع المجالات التي تتضمن تطبيقاً للشبكات العصبية.

المطلب الثاني: خطوات بناء نموذج لشبكة عصبية اصطناعية للتنبؤ بتقلبات أسعار الأسهم وقياس المخاطر المالية

استخدمت الشبكات العصبية الاصطناعية لغرض التنبؤ بشكل واسع كونها لا تحتاج إلى شروط صارمة ودقيقة، كما أنه يمكن تفسير سلوك البيانات غير الخطية، ويمكن تلخيص خطوات بناء نموذج للشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار الأسهم وقياس المخاطر المالية باستخدام نموذج CVAR كما يلي:

أولاً: اختيار المتغيرات وجمع البيانات

يقصد باختيار المتغيرات اختيار المدخلات والمخرجات المستخدمة في تدريب الشبكة العصبية، إذ تنطوي عملية اختيار المدخلات على أهمية بالغة في بناء نموذج الشبكة العصبية لما لها من دور في التأثير على دقة التنبؤ، فقد يعتقد بأن اختيار عدد كبير من البيانات بوصفها مدخلات للشبكة يسهم في زيادة دقة التنبؤ، وأحد أهم العوامل الحاسمة في اختيار الأسلوب الأنسب لعملية التنبؤ، إذ تستلزم عملية التنبؤ اختيار الأسلوب الملائم لنمط البيانات المستهدفة، بالتالي فإن أسلوب التنبؤ في حالة الأسهم الجديدة التي لا تحتوي على بيانات تاريخية يختلف عن أسلوب التنبؤ في حالة الأسهم المتداولة، وعلى أساس ذلك فإن الشبكات العصبية الاصطناعية يمكنها التعامل مع مختلف أنواع البيانات بغض النظر عن طبيعتها أو درجة التعقيد التي تنسجم بها، إذ تختلف عن الأساليب التقليدية بعدم وجوب تحقيق الفروض المبدئية لاستقرار السلاسل الزمنية، بعد تحديد عدد المتغيرات ونوعها، يتم جمع البيانات التي تمثل المدخلات والمخرجات من قواعد البيانات. (Enke & Thawornwong, 2005, p 932-933)

وفي حالة الأسهم تتألف البيانات من مختلف أنواع الأسعار اليومية للمؤشرات المعلنة بواسطة سوق الأسهم (البورصة) والتي تم التطرق لها في الفصل الأول.

ثانياً: المعالجة المسبقة للبيانات (معالجة البيانات المفقودة)

على الرغم من أن الشبكات العصبية يمكنها التعامل مع البيانات غير الخطية وغير المكتملة أو الغامضة وتحديد الأنماط بين المدخلات والمخرجات بعكس الأساليب الإحصائية الأخرى، يوصى بالمعالجة المسبقة للبيانات قبل تغذية الشبكة العصبية بها بغرض تقليل وقت التعلم وتقليل الضوضاء وبالتالي تحسين الأداء وتبسيط

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار

الأسهم وإدارة المخاطر المالية

الضوء على العلاقات المهمة واكتشاف الاتجاهات المحتملة، وعلى هذا الأساس فإن مشكلة البيانات المفقودة شائعة في تحليل السلاسل الزمنية لا سيما فيما يتعلق ببيانات مؤشرات الأسهم، إذ من المعلوم بأن الأسواق المالية لا تعمل طوال الأسبوع وعادة ما تتوقف أثناء العطل والمناسبات، هذا بالإضافة إلى الظروف المختلفة الأخرى التي تسبب بفقدان جزء من البيانات، وبالتالي ستكون البيانات غير مكتملة ولهذا تواجه الأساليب الإحصائية مشكلة كبيرة في السلاسل الزمنية التي تحتوي على بيانات مفقودة، وعليه توجد عدة أساليب إحصائية ورياضية لمعالجة البيانات المفقودة كحذف المشاهدات التي تتضمن بيانات مفقودة، أو بالتعويض والتكرار بدلا من البيانات المفقودة، كذلك تستخدم مقاييس النزعة المركزية كالوسط والوسيط لمعالجة المفقود من البيانات، بالإضافة إلى طرق الانحدار وطرق التنقيب عن البيانات وغيرها الكثير. (Chirita Mioara, 2012, p 64)

ثالثا: تقسيم البيانات

وتعد من أهم العمليات في بناء نموذج الشبكات العصبية، إذ تقسم البيانات على ثلاث مجاميع فرعية تدعى مجموعة التدريب Training Set، مجموعة الاختبار Testing Set، ومجموعة التحقق Validation Set وينسب مختلفة عادة ما تكون الحصة الأكبر لمجموعة التدريب، إذ تستخدم مجموعة التدريب للتعرف على الأنماط الموجودة في البيانات في عملية تدعى Fitting، أما مجموعة الاختبار لتقييم قدرة النموذج المدرب، وفقا لنوع الشبكة وخوارزمية التعلم التي تم اختيارها، وفيما يتعلق بمجموعة التحقق فتستخدم لفحص تطابق أو تباين النتائج وأداء الشبكة، وتجدر الإشارة إلى أن هنالك بعض التطبيقات تكفي بتقسيم البيانات على مجموعتين، مجموعة التدريب، ومجموعة التحقق. (Yao & Lim Tan, 2002, p 760)

رابعا: تخصيص نموذج الشبكة العصبية

توجد العديد من الشبكات العصبية المستخدمة في التنبؤ بأسعار الأسهم، والتي تختلف بحسب بنيتها وطرق الترابط بين الطبقات وأداء كل منها، وعلى مستوى الشبكة نفسها هنالك العديد من الطرق لبناء المعمارية وتحديد عدد الطبقات المخفية، والمعلومات، وعدد العقد المخفية، وعدد عقد الإخراج ووظائف النقل، وخوارزميات التحسين، إذ تشير معمارية الشبكة إلى كيفية تنظيمها، ويعد عملية الاختيار هذه مهمة صعبة لا سيما في الطبقة المخفية، فقد وجد الباحثون أنها تتم بناء على الأدبيات السابقة والخبرة والتعلم عن طريق العمل والتجربة والخطأ، فلا يوجد معيار محدد يمكن الأخذ به لجميع المشاكل، أما بالنسبة لطبقتي الإدخال والإخراج فعادة ما يتم تحديد عدد العقد بعدد المدخلات والمخرجات المطلوبة، وفيما يتعلق باختيار دوال التنشيط فليس هنالك ثمة معيار معين، إذ يتعلق اختيار دالة التنشيط المناسبة في الغالب بالمشكلة المطروحة أو الوظيفة المطلوب

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار

الأسهم وإدارة المخاطر المالية

إنجازها، إلا أن دوال التنشيط الأكثر استخداماً في تطبيقات التنبؤ هي الدالة السينية، دالة الظل الزائدي، ودالة

(Chaigusin, 2011, p 24-27).Relu

خامساً: تدريب الشبكة العصبية

إن عملية التدريب في الشبكات العصبية هي القضية الأكثر أهمية في تصميم بنية الشبكة العصبية، وهي عملية تحسين تعمل بغرض تقليل دالة الخسارة عن طريق التعديل المستمر للأوزان، إذ تبدأ عملية التدريب بتزويد الشبكة بالمدخلات والمخرجات المرغوبة ليتم بعدها حساب المخرجات المتوقعة التي يتم مقارنتها بالمخرجات المستهدفة (الفعلية) للحصول على قيمة الخطأ الذي تسعى الشبكة إلى تقليله عن طريق خوارزمية الانتشار الخلفي، إن أهم المشاكل التي تواجه عملية تدريب الشبكة العصبية هي فرط التدريب Overtraining، إذ تعرف هذه الحالة بأنها نزعة طريقة التعلم في الشبكة العصبية للتطابق مع مجموعة التدريب بحيث تصبح النتائج مطابقة تماماً نتيجة لزيادة وقت التدريب أو إضافة الكثير من الطبقات المخفية مما يزيد الترابط في الشبكة العصبية بالتالي فقدان القدرة على التعميم، وهذا يقود لمشكلة فرط الملاءمة Overfitting، إذ تحدث هذه المشكلة عندما تؤدي الشبكة بشكل ضعيف في ملاءمة مجموعة الاختبار بالرغم من أنها مطابقة تماماً لعينة التدريب، عندها يجب إيقاف عملية التدريب على الرغم من أن الاستمرار في التدريب يقلل الخطأ، ولتجنب مشكلة فرط الملاءمة تستخدم عدة آليات، منها تقليل عينة التدريب وتخصيص نسبة منها كمجموعة تحقق، وينحصر دور مجموعة التحقق في فحص الأداء بعد انتهاء عملية التدريب بما يعني أنها لا تعمم، بالتالي هنالك ضرورة لأن تكون بنية الشبكة العصبية ملائمة للبيانات المدخلة، بما يعني عدم استخدام عدد كبير من الطبقات المخفية والمعلمات إذا كانت المشكلة لا تستوجب ذلك، إذ يتوجب أن يكون عدد المعلمات في بنية الشبكة أقل بشكل ملحوظ من النقاط الموجودة في مجموعة التدريب، كذلك فإن أحد البدائل للتغلب على المشكلة هو إيقاف التدريب عند الوصول لأدنى خطأ (Tsang et al., 2007, p 457).

وتستخدم التطبيقات العملية للشبكات العصبية بعض التقنيات لتجنب هذه المشكلة كالإيقاف المبكر Early Stopping، إذ تعني إيقاف التدريب عند عدم وجود تحسن في مجموعة التحقق لمنع التدهور في أداء الشبكة العصبية، كذلك تستخدم تقنية التسريب Dropout، التي تعني التخلص مؤقتاً من بعض الخلايا العصبية غير المهمة للمشكلة المطروحة بالتالي الحصول على بنية أبسط للشبكة وخطأ تعميم أقل (Rosa et al., 2020, p 40).

(41)

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار

الأسهم وإدارة المخاطر المالية

سادسا: التقييم

تبدأ هذه الخطوة مباشرة بعد انتهاء عملية التدريب، إذ يجري اختبار أداء النموذج المدرب للشبكة العصبية عن طريق تطبيقه على بيانات من خارج عينة التدريب للتحقق من دقة الأداء، ويفترض بنموذج الشبكة العصبية أن يكون أداؤه معمما على عينة الاختبار للحكم على دقته، إذ تشير دقة الأداء إلى مدى قدرة النموذج في تقدير عينة الاختبار، وعلى الرغم من ذلك، فإن دقة التنبؤ لا تعني بالضرورة أن تكون النتائج دقيقة كليا، فمهما بلغت دقة الأساليب المستخدمة في التنبؤ يبقى هنالك احتمالاً لوجود بعض الانحرافات في القيمة المتوقعة عن القيم الحقيقية وهذا ما يدعى بخطأ التنبؤ، إذ يعرف خطأ التنبؤ بأنه الفرق بين القيمة الحقيقية والقيمة المتنبئ بها، وعلى أساس ذلك يتم تقييم أداء نموذج الشبكة العصبية وفقا لمقاييس الأداء المعروفة (المذكورة في الأقسام السابقة) كمقياس متوسط مربعات الخطأ، وجذر متوسط مربعات الخطأ، فضلا عن معامل الارتباط لمقياس العلاقة بين القيم الحقيقية والقيم المتنبئ بها، إذ كلما انخفضت قيمة مقاييس الخطأ وارتفعت نسبة معامل الارتباط دل ذلك على زيادة دقة النموذج. (Martin T. Hagan et al., 2014, p 900-903)

سابعا: التنفيذ

تعد خطوة التنفيذ الأخيرة في بناء نموذج الشبكات العصبية الاصطناعية، إذ يفترض في هذه الخطوة أن نتائج تقييم الأداء التي تم الحصول عليها في الخطوة السابقة مقبولة بما في معناه أن النموذج جاهز للتنبؤ، بعد إجراء عدة عمليات تدريب والتحقق من أدائه من خلال اختبار دقته في التعميم، ويقوم النموذج في هذه الخطوة بالتنبؤ بالقيمة المستقبلية، وهي من أهم الخطوات حيث تختبر الشبكة من حيث قدرة التكيف وإمكانية إعادة التدريب والوصول إلى أقل خطأ عند تغير البيانات. (Chirita Mioara, 2012, p 64)

في هذه الدراسة لا يتم التوقف عند عملية التنبؤ بل تنتقل بعدها إلى قياس المخاطر المالية باستخدام نموذج القيمة المعرضة للمخاطر المتوقعة أو المشروطة CVAR، وذلك بالاعتماد على القيم المتنبئ بها واستعمالها كمدخلات لقياس القيمة المعرضة للخطر المشروطة CVAR.

الفصل الثاني: الشبكات العصبية الاصطناعية واستخدامها في التنبؤ بتقلبات أسعار

الأسهم وإدارة المخاطر المالية

خلاصة الفصل الثاني

قدم هذا الفصل تفصيل شامل لأساسيات تمثّل العمود الفقري لفهم واستخدام الشبكات العصبية الاصطناعية كإحدى تطبيقات الذكاء الاصطناعي في عملية التنبؤ المالي وإدارة المخاطر المالية، حيث تناول المبحث الأول أساسيات الذكاء الاصطناعي بما في ذلك التعريفات والمفاهيم وتاريخ تطوره وهذا الأساس النظري قدم الخلفية اللازمة لفهم التعقيدات المرتبطة بهذا المجال الواسع.

أما المبحث الثاني خصص للشبكات العصبية الاصطناعية حيث تم توضيح مختلف التعاريف المقدمة لها وأوجه التشابه بينها وبين الشبكات العصبية البيولوجية، انتقالا للبنية الأساسية لهذه الشبكات وآلية عملها وكيف يمكنها محاكاة العمليات العقلية البشرية وتم استعراض كيفية تصميم الشبكات العصبية من اختيار المعمارية المناسبة إلى وظائف التنشيط وخوارزميات التحسين.

أما في المبحث الثالث تم التركيز على التطبيق العملي للشبكات العصبية في التنبؤ بالتقلبات وإدارة المخاطر المالية عامة وتقلبات أسعار الأسهم خاصة، هنا تم عرض أهم استخدامات الشبكات العصبية الاصطناعية سواء في التنبؤ بالتقلبات أو في إدارة المخاطر المالية، وما يميز الشبكات العصبية، انتقالا إلى الخطوات اللازمة لبناء نموذج فعال بدء من جمع البيانات واختيار المتغيرات مروراً بالمعالجة المسبقة للبيانات وصولاً إلى تدريب وتقييم النموذج إلى التنفيذ والتنبؤ وقياس CVAR كأداة لقياس المخاطر المحتملة مما يضيف بعداً تحليلياً مهماً للنموذج، يقدم هذا القسم إطاراً توضيحياً لكيفية تقديم هذه التقنية رؤى دقيقة وقرارات مستنيرة في بيئات معقدة وديناميكية كالأسواق المالية.

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

المبحث الأول: تعريف البيانات والمتغيرات المستخدمة في النموذج.

المبحث الثاني: بناء الشبكة العصبية الاصطناعية.

المبحث الثالث: اختبار النموذج وتطبيقه في عملية التنبؤ وقياس القيمة المعرضة للخطر المشروطة.

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

تمهيد

تعد النمذجة والتنبؤ بالأسواق المالية من الأدوات الأساسية في تحليل المخاطر وإدارة الاستثمارات حيث تستخدم نماذج رياضية وإحصائية لتقدير تحركات الأسواق المالية وتقييم المخاطر المحتملة، يعتبر التنبؤ الدقيق عاملا حاسما في اتخاذ القرارات الاستثمارية حيث يساعد المستثمرين والمؤسسات المالية على الحد من المخاطر وتعظيم العوائد، في هذا السياق تعد القيمة المعرضة للخطر المشروطة أحد أهم المقاييس المستخدمة في إدارة المخاطر المالية إذ يوفر تقديرا أكثر دقة للخسائر المحتملة في ظل الظروف السوقية غير المتوقعة مقارنة بمقياس القيمة المعرضة للخطر التقليدي، ولذلك يركز هذا الفصل على إسقاط الجانب النظري الذي تطرقنا فيه إلى استخدام الشبكات العصبية الاصطناعية في التنبؤ بتقلبات أسعار الأسهم ودورها في قياس المخاطر المالية باستخدام نموذج القيمة المعرضة للخطر المشروطة CVAR، وهذا من خلال إيجاد نموذج للتنبؤ بأسعار إغلاق اليوم التالي لأسهم مؤشر BIST100، حيث اعتمدت الدراسة على بعض البيانات المالية تم استخدامها كمداخلات للشبكة العصبية الاصطناعية إذ تم تقسيمها إلى ميزات خارجية وميزات داخلية أو ذاتية مرتبطة بمؤشر BIST100 وهي: مؤشر S&P500، مؤشر Dow Jones، مؤشر Nasdaq، مؤشر Small Cap 2000، أسعار الذهب، ومؤشرات التداول اليومية الخاصة بمؤشر BIST100 وهي: أعلى سعر، أدنى سعر، سعر الافتتاح، وأسعار الإغلاق لعشرين يوم السابقة، بالإضافة إلى بعض الميزات التي يتم حسابها كالتقلبات الشرطية والانحراف المعياري والمتوسط المتحرك الأسّي وغيرها، وهذا للفترة من 24 جانفي 2001 إلى غاية 30 نوفمبر 2024 كعينة تدريب، تحقق، واختبار للنموذج، ومحاولة التنبؤ بفترة 30 يوم التالية لفترة الدراسة أي من 2 إلى 31 ديسمبر 2024، وذلك بالاستعانة بلغة البرمجة Python.

يقدم هذا الفصل نظرة تفصيلية على خطوات تصميم وتنفيذ نموذج الشبكات العصبية الاصطناعية المستخدمة، انطلاقا من تعريف البيانات والمتغيرات المستخدمة كتعريف بورصة إسطنبول ووصف وتحليل بيانات ومتغيرات الدراسة كمبحث أول ثم إظهار هيكلية وبناء نموذج الشبكة العصبية الاصطناعية وأيضا معالجة البيانات وتقسيمها وتدريب النموذج والتحقق منه كمبحث ثاني، وصولا إلى اختبار النموذج وتطبيقه في التنبؤ بأسعار الأسهم المستقبلية وإظهار دوره في إدارة المخاطر المالية عن طريق قياس القيمة المعرضة للخطر المشروطة CVAR وتقديم النتائج المتوصل لها كمبحث ثالث.

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

المبحث الأول: تعريف البيانات والمتغيرات المستخدمة في النموذج

يهدف الإحاطة الشاملة بالجانب التطبيقي، تم تخصيص هذا القسم لوصف وتحليل بيانات الدراسة التي استخدمت لتحقيق أهدافها واختبار فرضياتها، حيث تم استخدام سلسلة أسعار المؤشر الرئيسي الممثل لسوق إسطنبول للأوراق المالية الذي يرمز له بمؤشر BIST100 بغرض التنبؤ بأسعاره المستقبلية وحساب القيمة المعرضة للخطر المشروطة للفترة المتنبئ بها، إذ تم الحصول على أسعار الإغلاق اليومية وبعض المؤشرات من نشرات التداول اليومية المفصّل عنها، للفترة من 24 جانفي 2001 إلى غاية 30 نوفمبر 2024، كعينة تدريب، تحقق، واختبار بمقدار 8713 صفًا و37 عمود تمثل بعض البيانات المالية المستخدمة كمدخلات للنموذج، ومدة 30 يوم الممثلة لشهر ديسمبر كفترة تنبؤ، لذلك تم التطرق للتعريف بسوق إسطنبول المالي والممثلة بمؤشرها الرئيسي BIST100 كمطلب أول كونها البيانات الهدف والأساسية في الدراسة، وتوضيح عملية وصف وتحليل جميع البيانات المستخدمة في الدراسة كمطلب ثاني.

المطلب الأول: التعريف بسوق إسطنبول للأوراق المالية ومؤشر BIST100

سوق إسطنبول للأوراق المالية هي السوق الرئيسي في تركيا، وتهدف إلى تنظيم تداول الأدوات المالية المختلفة، في هذا القسم يتم التعريف بالتفصيل على سوق إسطنبول للأوراق المالية ومؤشرها الرئيسي BIST100 الذي يعتبر أساس الدراسة.

أولاً: سوق إسطنبول للأوراق المالية

تلعب بورصة إسطنبول دوراً حيوياً في الاقتصاد التركي، حيث توفر مصدر تمويل أساسي للشركات المحلية والدولية، كما تعتبر مؤشراتها الرئيسية مؤشرات حيوية لأداء الاقتصاد التركي، وأيضاً تساهم في تعزيز الشفافية المالية وتقديم فرص للمستثمرين للاستثمار في الشركات المدرجة.

1- نشأة سوق إسطنبول للأوراق المالية

سوق إسطنبول للأوراق المالية المعروف حالياً باسم بورصة إسطنبول Borsa Istanbul أو BIST، بدأ نشاط البورصة في العهد العثماني وتحديدًا في عام 1886 وحملت في ذلك الوقت اسم تحويلات دار السعادة، وتأسست رسمياً في العهد الجمهوري في 26 ديسمبر 1985 تحت اسم سوق إسطنبول للأوراق المالية واقتصرت نشاطاتها على خدمات المقاصة والوساطات المالية بين البنوك في تركيا خاصة تلك التي لديها فروع خارج البلاد وكانت تحمل اسم

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

إسطنبول للقيم المنقولة، أول تداول شهدته بورصة إسطنبول كان يوم 3 ديسمبر 1986 لأسهم 19 شركة مدرجة فيها، وفي 5 أبريل 2013 تم دمجها مع سوق الذهب التركي ومقاصة المشتقات المالية لتشكل هيكل حديث ومنظم حملت اسمها الحالي بورصة إسطنبول، وشعارها الرسمي المعروف حالياً، وبتاريخ 24 فيفري 2017 تم نقل 90% من أسهم البورصة إلى ملكية صندوق الثروة السيادي التركي بموجب مرسوم رسمي، وتتوزع أسهم بورصة إسطنبول حالياً بنسب 80.6% لصندوق الثروة السيادي التركي، و10% لجهاز قطر للاستثمار، و2.27% لبورصة إسطنبول التجارية، و1.3% لاتحاد أسواق المال التركية، و5.83% موزعة على مستثمرين آخرين. (borsaistanbul, 2025)

ويتأثر بورصة إسطنبول حالياً أريشا أريجان ويشغل الاقتصادي التركي هاكان أتيلا منصب مديرها العام، بلغ عدد الشركات التي يتم تداول أسهمها عام 2020 في بورصة إسطنبول 477 شركة، تشمل الشركات بنوك الاستثمار والتنمية والبنوك التجارية والمؤسسات الوسيطة وشركات العقارات والصناعات الطبية والغذائية، وغيرها من الشركات التي تتداول أسهمها بالعملة المحلية "الليرة التركية". (borsaistanbul, 2025)

تدير بورصة إسطنبول العديد من الأسواق المالية، بما في ذلك سوق الأسهم الرئيسية وأسواق الدين والسلع والعقود الآجلة، السوق الرئيسية تشمل شركات محلية وعالمية مسجلة، ويعتبر مؤشر BIST100 الذي يتبع أداء أكبر 100 شركة مدرجة أحد أبرز المؤشرات المالية في السوق، بالإضافة إلى المؤشرات الأخرى التي تعكس أداء السوق: BIST50 وBIST30. (borsaistanbul, 2025)

الغرض الرئيسي من بورصة إسطنبول هو توفير بيئة مستقرة وموثوقة حيث تنطبق شروط المنافسة الحرة على أدوات سوق رأس المال والعملات الأجنبية والأحجار الكريمة والمعادن والعقود وغيرها من الوثائق التي يراها مجلس أسواق رأس المال مناسبة، باختصار، جميع أنواع الأوراق المالية المتاحة للتداول في البورصة في إطار القوانين المعمول بها، لإتاحة البيع والشراء بطريقة عملية وفعالة داخل البيئة، أيضاً تسهيل الجمع بين أوامر البيع والشراء لهذه الأوراق المالية بما يحقق الغرض، وإنشاء وتطوير عدد من الأسواق والمنصات لتحديد الأسعار الناتجة والإعلان عنها، وتعد إدارة وتشغيل البورصات وأسواق الأوراق المالية من بين الأمور أو الأنشطة الرئيسية لمنظمة بورصة إسطنبول، ويتم تدقيق المؤسسة من قبل مجلس أسواق رأس المال ضمن مبادئ قانون أسواق رأس المال. (borsaistanbul, 2025)

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

2- أنواع الأسواق في بورصة إسطنبول

هناك أنواع مختلفة من الأسواق في البورصة التركية، وكلها تقع ضمن واحدة من الفئات الرئيسية الثلاث: (أصول للاستشارات والتداول المالي، 2025)

- **سوق الأوراق المالية:** والذي يضم في حد ذاته عدة مجموعات فرعية: السوق الوطنية، السوق الوطنية الثانوية، السوق الوطنية الثانية، سوق الاقتصاد الجديد (بازار)، سوق ETF، قائمة المراقبة (بازار)، سوق الجملة، وسوق القسائم، سوق قسيمة الحقوق.
- **سوق السندات:** سوق السندات والأوراق المالية وهو سوق منظم لتداول الأوراق المالية ذات الدخل الثابت، ويتكون من ثلاثة أجزاء: سوق اتفاقيات إعادة الشراء وإعادة الشراء العكسي، سوق البيع والشراء لمرة واحدة، سوق العقارات.
- **بورصة المشتقات التركية:** تأسست بورصة المشتقات التركية في عام 2002، وفي عام 2005 أصبح أسهمها المختصر TURKDEX، تسعى هذه البورصة إلى إنشاء وابتكار وتوسيع الأدوات المالية التي تعمل على المخاطرة للمستثمرين.

شروط الاستثمار في البورصة التركية أول شيء يجب على المستثمرين الراغبين في الاستثمار في بورصة السلع فعله هو العثور على وسيط وفتح حساب استثماري في بنك مرخص من قبل SPK (مجلس البورصة). (أصول للاستشارات والتداول المالي، 2025)

3- ساعات التداول في أسواق بورصة إسطنبول

تختلف ساعات التداول في بورصة إسطنبول حسب الأسواق العاملة داخل المؤسسة: (أصول للاستشارات والتداول المالي، 2025)

- **سوق الأسهم (يوم كامل):** يبدأ جمع الأوامر الافتتاحية عند الساعة 09.40 ويتم إجراء أول معاملة عند الساعة 09.55. تعمل طريقة المزاد المستمر بين الساعة 10.00 - 18.00. تتم المعاملات الأخيرة وجلسة الإغلاق بين الساعة 18.00 - 18.10.
- **سوق الأسهم (نصف يوم):** يتم الافتتاح في الساعة 09.40 مع جمع الطلبات كما هو الحال في اليوم الكامل. تتم آخر المعاملات وجلسة الإغلاق بين الساعة 12.30 - 12.40.
- **سوق العقود الآجلة والخيارات (VIOP):** تعقد جلسات اليوم الكامل بين الساعة 09.20 - 18.10 في سوق مشتقات الأسهم وبين الساعة 09.20 - 18.15 في أسواق المشتقات الأخرى، تعقد جلسات نصف

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

يوم بين الساعة 09.20 - 12.40 في سوق مشتقات الأسهم وبين الساعة 09.20 - 12.45 في أسواق المشتقات الأخرى.

- سوق سندات الدين: تبدأ الجلسة في الساعة 09.30 وينتهي الساعة 17.30 في الأيام الكاملة وفي الساعة 11.50 في نصف يوم.
- سوق المعادن الثمينة: تتم في هذا السوق المعاملات على مدار الساعة.
- سوق معاملات الإقراض: ساعات الجلسة من 09.45 إلى 17.30.
- سوق الألماس والأحجار الكريمة: ساعات الجلسة بين الساعة 09.45 – 17.30 كما هو الحال في سوق الإقراض.

ثانياً: مؤشر BIST100

يعد BIST100 المؤشر الرئيسي للسوق يرمز له بالرمز XU100، ويمثل أعلى 100 شركة مدرجة من حيث القيمة السوقية والسيولة وحجم التداول، الشركات المدرجة في المؤشر تنتمي لقطاعات متنوعة كالبنوك، الطاقة، الصناعة، وتكنولوجيا المعلومات، أطلق المؤشر لأول مرة في عام 1986 وشهد مراحل نمو متفاوتة حيث أصبح من المعايير الأساسية لقياس أداء السوق التركي، حقق المؤشر مكاسب قوية على مدى العقود الماضية، وكان أداؤه في بعض السنوات متميزاً بشكل ملحوظ، لا سيما في ظل التغيرات الاقتصادية والسياسات النقدية في تركيا. (borsaistanbul, 2025)

الجدول التالي يوضح عدد الشركات المدرجة في مؤشر BIST100 حسب نوع القطاع:

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

الجدول رقم (3-1): عدد الشركات المدرجة في سوق إسطنبول للأوراق المتداولة حسب القطاعات لسنة 2025.

الرقم	القطاع	عدد الشركات
1	الزراعة، الغابات، وصيد الأسماك	5
2	التعدين واستغلال المحاجر	7
3	الصناعات التحويلية	242
4	الكهرباء، الغاز، والمياه	36
5	البناء والأشغال العامة	14
6	تجارة الجملة والتجزئة	26
7	النقل والتخزين	12
8	المؤسسات المالية	159
9	خدمات التعليم والصحة والرياضة والترفيه	9
10	تكنولوجيا	39
11	الأنشطة المهنية والعلمية والتقنية	4
12	الأنشطة الإدارية وخدمات الدعم	8
13	الأنشطة العقارية	4
14	الفنادق والمطاعم	14
15	المعلومات والاتصالات	6

Source: (KAP Kamuyu Aydınlatma Platform, 2025)

يعكس التوزيع القطاعي للشركات المدرجة في مؤشر BIST100 تنوع الاقتصاد التركي وانفتاحه على عدة مجالات إنتاجية وخدمية، يلاحظ أن قطاع الصناعات التحويلية يتصدر القائمة بـ 242 شركة، ما يعكس الأهمية الاستراتيجية للصناعة في الاقتصاد التركي، ويليهما قطاع المؤسسات المالية بـ 159 شركة مما يدل على تطور القطاع المالي والبنكي التركي وتوسعه في تقديم الخدمات الاستثمارية والمصرفية، كما يحتل قطاع التكنولوجيا موقعا متقدما بـ 39 شركة في دلالة واضحة على تطور البنية التكنولوجية والابتكار في السوق التركي، وتبرز قطاعات أخرى بعدد متوازن كالكهرباء والغاز والمياه، وتجارة الجملة والتجزئة، والنقل والتخزين ما يدل على الاهتمام بالبنية التحتية والخدمات اللوجستية، أما القطاعات التي تسجل عددا محدودا من الشركات كالأنشطة المهنية والعلمية والتقنية، الأنشطة العقارية فقد تشير إلى إما طبيعتها المتخصصة أو أنها لا تشكل بعد ثقلًا سوقيًا كبيرًا في المؤشر،

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

من جهة أخرى يظهر وجود شركات في كل من قطاع البناء والأشغال العامة والفنادق والمطاعم، والتعليم والصحة والرياضة والترفيه، إلى بداية نهج نحو تنويع اقتصادي يعزز الخدمات المجتمعية والتكنولوجية ودور القطاعات المرتبطة بالبنية التحتية والسياحة في دعم النشاط الاقتصادي، يوضح هذا التنويع مدى شمولية مؤشر BIST100 وانعكاسه لمجموعة واسعة من الأنشطة الاقتصادية مما يجعله مؤشرا قويا لأداء الاقتصاد الكلي وتوجهاته المستقبلية.

ولقد مر المؤشر بفترات تاريخية مهمة من بينها: في عام 2001 شهد المؤشر انخفاضا كبيرا بسبب الأزمة الاقتصادية التركية، في عام 2008 تأثر بأزمة الرهن العقاري العالمية، في عام 2013 شهد انتعاش بفضل الإصلاحات المالية وتحسن الاقتصاد التركي، في عام 2018 واجهت تركيا أزمة عملة حادة حيث فقدت الليرة التركية جزءا كبيرا من قيمتها مما أثر سلبا على أداء البورصة وزاد من مخاوف المستثمرين، أما في عام 2022 سجل مؤشر BIST100 أداء قويا مسجلا أكبر ارتفاع له بنسبة تزيد عن 150% بالليرة التركية وهو الأعلى منذ عام 1999، كما سجل أيضا ارتفاعا ملحوظا في جويلية 2024. (العربية، 2025)

يتم تعديل الشركات المدرجة في المؤشر كل ثلاثة أشهر لضمان تمثيله لـ 100 شركة الأكثر نشاطا، ويحسب مؤشر BIST100 باستخدام منهجية الوزن حسب القيمة السوقية (Market Capitalization Weighted Method)، يتم حساب القيمة السوقية لكل شركة في المؤشر بضرب سعر سهمها في عدد الأسهم القائمة للشركة، بعد ذلك تجمع القيم السوقية لجميع الشركات المدرجة بالمؤشر، يقسم المجموع الناتج على معامل يسمى القاسم (Divisor) وهو ثابت يستخدم للحفاظ على استمرارية القيمة عند إدخال تغييرات على مكونات المؤشر، بالإضافة إلى تعديل القيمة السوقية للشركة عند حدوث توزيع أرباح أو تجزئة للأسهم لضمان أن المؤشر لا يتأثر بأي أحداث غير تداولية، لذلك يتم تحديث قيمة المؤشر ونشرها بشكل مستمر خلال جلسات التداول مما يسمح للمستثمرين والمتداولين بتتبع أداء السوق التركي بشكل لحظي، حيث تلعب تغييرات الأسعار وحركة الأسهم داخل المؤشر دورا رئيسيا في تحديد قيمته. (gurufocus, 2025)

المطلب الثاني: وصف وتحليل بيانات ومتغيرات الدراسة

قبل التطرق لوصف وتحليل بيانات الدراسة يتم اختيار وتوضيح مجموعة البيانات المستخدمة في النموذج، فبالإضافة إلى أسعار الإغلاق اليومية لعشرين يوم السابقة لمؤشر BIST100، يتم استخدام بعض البيانات المالية الإضافية كميزات والمتمثلة في مؤشرات التداول اليومية لأسهم مؤشر BIST100 وهي: سعر الافتتاح، أعلى سعر، وأدنى سعر، بالإضافة إلى أسعار إغلاق أسهم أول خمس مؤشرات رئيسية في البورصة

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

العالمية وهي: S&P 500 ، Dow Jones ، Nasdaq ، S&P 500 VIX ، Small Cap 2000 ، وأسعار الذهب وأسعار النفط باعتبارهما عاملين مهمين في السوق المالي، حيث تم الحصول على هذه البيانات من الموقع العالمي Investing (investing, 2024)، مع إضافة بعض المؤشرات الفنية التي يتم حسابها انطلاقاً من أسعار مؤشر BIST100 كالتقلبات الشرطية، الانحراف المعياري، المتوسط المتحرك الأسّي، والقيم المتطرفة أو الشاذة.

أولاً: تعريف متغيرات الدراسة

لغرض تحقيق هدف الدراسة المتمثل في معرفة دور التنبؤ بتقلبات أسعار الأسهم في إدارة المخاطر المالية تم تحديد المتغيرات الأساسية التي تعكس العلاقة بين تقلبات الأسعار والمخاطر المالية المحتملة، وتتمثل المتغيرات فيما يلي:

1- المتغير التابع

يتمثل المتغير التابع في المخاطر المالية والتي يتم التعبير عنها بالقيمة المعرضة للخطر المشروطة Conditional Value at Risk (CVAR) ويعكس هذا المقياس الحد الأقصى للخسائر المتوقعة في أسوأ 5% من السيناريوهات مما يجعله أحد أهم أدوات قياس المخاطر في الأسواق المالية، يتم استخدام CVAR في تقييم الأداء المالي والاستراتيجيات الاستثمارية نظراً لدقته في تقدير الخسائر المحتملة خلال الفترات التي تشهد تقلبات حادة، تم الاعتماد في حساب CVAR على المنهج غير المعلمي وتحديد نموذج المحاكاة التاريخية الذي يعد من أكثر الأساليب بساطة وواقعية كونه لا يفترض شكلاً معيناً لتوزيع العوائد، بل يعتمد على البيانات التاريخية، والصياغة الرياضية لحساب CVAR بهذا النموذج تكون كالتالي:

$$CVAR_{\alpha}(R_t) = E[R_t | R_t \leq VAR_{\alpha}]$$

حيث:

R_t : يمثل العائد في الفترة t ،

VAR_{α} : تمثل القيمة المعرضة للخطر عند مستوى ثقة α أي 95%،

$E[R_t | R_t \leq VAR_{\alpha}]$: يعني المتوسط الشرطي للعوائد الأسوأ من VAR ، أي متوسط أسوأ 5% من

العوائد.

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

2- المتغير المستقل

يمثل قلب أسعار الأسهم المتغير المستقل في الدراسة ويتم التعبير عنه من خلال العائد اللوغاريتمي اليومي المستند إلى بيانات الإغلاق اليومي لمؤشر BIST100، يساعد هذا المتغير في قياس معدل التغير اليومي في أسعار المؤشر مما يتيح فهم درجة تقلباته وتأثيرها على المخاطر المالية، ويتم حساب العائد اليومي للمؤشر باستخدام الصيغة اللوغاريتمية التالية:

$$R_t = \log \left(\frac{P_t}{P_{t-1}} \right)$$

حيث:

P_t : السعر في اللحظة الزمنية الحالية والمتمثلة في اليوم،

P_{t-1} : السعر في اللحظة الزمنية السابقة أي في اليوم السابق.

تم اختيار هذه المتغيرات لأنها تعكس بشكل مباشر العلاقة بين التغيرات السعرية للأسهم والمخاطر المالية الناتجة عنها، حيث أن التقلبات الحادة في أسعار الأسهم تؤثر بشكل كبير على قيمة المخاطر المالية وبالتالي على قدرة المستثمرين على إدارة محافظهم الاستثمارية بشكل فعال، ويعتبر استخدام CVAR في هذا السياق مناسباً نظراً لأنه يوفر تقديراً أكثر دقة للخسائر المحتملة مقارنة بالقيمة المعرضة للخطر التقليدية VAR إذ يأخذ في الاعتبار القيم المتطرفة التي قد تؤثر على الاستقرار المالي.

بناءً على هذه المنهجية سيتم تحليل العلاقة بين العائد اللوغاريتمي اليومي لمؤشر BIST100 والمخاطر المالية المتمثلة في CVAR وذلك لمعرفة مدى قدرة التنبؤ بتقلبات الأسعار على تقييم دقيق للمخاطر المستقبلية.

ثانياً: تعريف البيانات المستخدمة في النموذج

تم تقسيم البيانات المستخدمة في النموذج إلى الأنواع الثلاثة التالية:

1- بيانات الإخراج أو الهدف

وتتمثل في أسعار الإغلاق اليومية لمؤشر BIST100 والتي تمثل السعر الحالي المراد التنبؤ به.

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

2- بيانات الإدخال الميزات الخارجية

تمثل البيانات التي لا ترتبط بمؤشر BIST100 بشكل مباشر لكن لها تأثير في تقلبات أسعارها والتي يتم اختيارها حسب درجة الارتباط مع المؤشر، وتتمثل في البيانات التالية:

- **سعر الافتتاح:** في الأسواق المالية يمثل سعر الافتتاح مصطلحا يستخدم لتحديد السعر الأول الذي يبدأ به تداول المؤشر في جلسة التداول في يوم معين، وقد يكون هذا السعر متطابقا مع سعر الإغلاق الذي تم تسجيله في الجلسة السابقة أو قد يختلف عنه بسبب العوامل التي تحدث بعد ساعات عمل سوق البورصة، تلك العوامل تؤثر على سعر الأسهم وتتسبب في تغيرها، من أبرز هذه العوامل أوامر البيع والشراء المجمعة قبل افتتاح السوق مما يعكس مستوى العرض والطلب عند بداية الجلسة، الأخبار أو الأحداث الاقتصادية التي حدثت.
- **أعلى سعر:** يمثل أعلى مستوى سعري وصل إليه السهم أو المؤشر خلال جلسة التداول، هذا السعر يظهر الحد الأقصى الذي كان المشترون على استعداد لدفعه في ذلك اليوم، ارتفاع هذا السعر قد يكون مؤشرا على وجود طلب قوي أو أحداث إيجابية دفعت بالسعر إلى الأعلى.
- **أدنى سعر:** هو أدنى سعر تم تسجيله للسهم أو المؤشر خلال جلسة التداول، ويظهر هذا السعر أدنى مستوى للعرض أو مستوى الدعم خلال اليوم، وقد يستخدم لتحديد قوة أو ضعف المؤشر في ظل تقلبات السوق.
- **حجم التداول:** يقصد به عدد الأسهم أو العقود التي تم تداولها خلال جلسة معينة، ارتفاع حجم التداول عادة ما يدل على اهتمام قوي بالسهم أو المؤشر بينما يشير انخفاضه إلى ضعف في النشاط أو قلة الاهتمام.
- **مؤشر S&P 500:** مؤشر ستاندارد آند بورز 500 أو اختصارا إس آند بي 500 هو مؤشر أسهم يضم أسهم أكبر 500 شركة مالية أمريكية من بنوك ومؤسسات مالية، أطلق عام 1957 ووصل إلى أعلى نقطة عند 1965 في 9 أكتوبر وفي عام 2007 يعتبر اليوم الأخير لانتعاش الأسواق العالمية حيث تبعه انهيارات أسواق وبورصات العالم ووصل المؤشر إلى دون 800 نقطة في نوفمبر 2008 بعد انهيار الأسواق العالمية، وبلغ المؤشر ارتفاعه التاريخي الثاني في الخامس والعشرين من شهر أوت 2014، حيث وصل 2000 نقطة، ويعتبر أحد أهم مؤشرات أسواق الأسهم الرئيسية والأكثر متابعة واستخداما من طرف المحللين في جميع أنحاء العالم، وهو أحد أهم المعايير لقياس السوق الأمريكي والذي يعكس التنوع الصناعي والاقتصادي إذ يجمع بين عدة قطاعات داخل السوق الأمريكية.

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

- **مؤشر Dow Jones:** هو واحد من أقدم مؤشرات الأسهم وأكثرها شهرة، تم إنشاؤه في 26 ماي 1896 من قبل الصحفي المالي الأمريكي Charles Dow الذي أسس أيضا صحيفة وول ستريت جورنال وشركة داو جونز وشركاءه، في البداية كان المؤشر يضم 12 شركة صناعية كبرى تم اختيارها لتمثيل قطاعات متنوعة من الاقتصاد الأمريكي، كان الهدف من ذلك تقديم مقياس بسيط وموثوق يعكس الاتجاه العام للسوق حيث كان يتم حساب المؤشر من خلال جمع أسعار إغلاق أسهم هذه الشركات وقسمتها على عددها، مع تطور الاقتصاد الأمريكي توسع المؤشر ليشمل 20 شركة في عام 1916، ثم 30 شركة عام 1928 وهو العدد المعتمد حتى اليوم، وهي من أكبر الشركات المتداولة علنا في الولايات المتحدة حاليا، وأصبح يحسب مؤشر داو جونز بطريقة تعتمد على أسعار الأسهم حيث يمنح وزن أكبر للأسهم ذات الأسعار الأعلى، ورغم الانتقادات التي توجه إليه بسبب هذه الطريقة في الحساب وقلة الشركات التي يضمها إلا أنه لا يزال يعتبر أحد أبرز المؤشرات التي تعكس صحة الاقتصاد الأمريكي ويستخدم على نطاق واسع من قبل المستثمرين.
- **مؤشر Nasdaq:** جاءت تسميته من اختصار (National Association of Securities Dealers Automated Quotations system) وبالعبارة (نظام تحديد الأسعار المؤتمن التابع للمؤسسة القومية لوسطاء الأوراق المالية) هي سوق مالي أمريكي أنشئ في عام 1971، تم الإطلاق الفعلي للبورصة يوم 8 فبراير 1971 بمئة نقطة، وبذلك تعتبر أول بورصة تتعامل بالشاشات الإلكترونية، وهي أكبر بورصة إلكترونية أمريكية متخصصة في تسعير أسهم شركات التكنولوجيا والابتكار، تضم أكثر من 3000 شركة مدرجة في بورصة ناسداك، حيث أصبحت إحدى البورصات الأمريكية الكبرى والتي تنافس بورصة نيويورك (NYSE).
- **مؤشر S&P 500 VIX:** يعرف بمؤشر التقلب حيث يقيس مستوى التقلب المتوقع للأسواق المالية بناء على أسعار الخيارات في مؤشر S&P 500، تم إنشاؤه بواسطة بورصة شيكاغو للخيارات (CBOE) في عام 1993، كما يعرف أيضا باسم مؤشر الخوف لقدرته على تقديم إشارات بشأن المخاطر المستقبلية.
- **مؤشر Small Cap 2000:** يتبع أداء 2000 من أصغر الشركات المدرجة ضمن مجموعة Russell 3000، ويستخدم لتقييم أداء الشركات الصغيرة في السوق الأمريكية، تم إنشاء مؤشر راسل 2000 لأول مرة في عام 1984 من قبل مجموعة راسل الاستثمارية، إذ تم تصميم هذا المؤشر كمؤشر منخفض الحجم للشركات الصغيرة والنامية في سوق الأسهم الأمريكية.
- **سعر الذهب:** يمثل سعر الذهب العالمي والذي يعد من أصول الملاذ الآمن وأكثر فعالية بالمقارنة بأي معدن ثمين آخر يستخدم في الاستثمار، يستخدم عادة لتقييم اتجاهات السوق واستقرار الاقتصاد العالمي، يشير الاستثمار في الذهب، كما يوحي الاسم، إلى شراء وبيع الذهب ويعد أكثر المعادن الثمينة استثمارا،

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

يشتري المستثمرون الذهب عموماً لتنويع المخاطر، وخاصة من خلال استخدام العقود الآجلة ومشتقاتها، ويخضع سوق الذهب مثل أي سوق آخر إلى المضاربات والتقلبات، ومع تقلب الطلب على الذهب، يتقلب سعره أيضاً هذا يعني أنه يمكن للمستثمرين شراء الذهب عندما تكون الأسعار منخفضة وبيعه عندما ترتفع الأسعار لتحقيق ربح.

- **سعر النفط:** هو السعر الذي يباع به برميل النفط غير المكرر في الأسواق العالمية، يعتبر هذا السعر مؤشراً اقتصادياً مهماً لأنه يؤثر بشكل مباشر على الاقتصاديات العالمية لا سيما في الدول المنتجة والمستهلكة للنفط.

- **اليوم والشهر:** إضافة اليوم والشهر كمميزات في النموذج يساعد في التقاط الأنماط الموسمية والدورية التي تؤثر على تحركات الأسعار في الأسواق المالية، فبعض الأسواق المالية تظهر أنماط دورية مرتبطة بالأشهر أو الأيام مثل تأثير شهر جانفي أو تقلبات نهاية السنة، كما أنه في بعض الأسواق يلاحظ أن الأسهم تميل للانخفاض في أول الشهر والارتفاع في منتصفه.

- **التقلبات الشرطية:** يتم حساب وتقدير التقلبات الشرطية أو التذبذب اليومي Conditional Volatility باستخدام نموذج التقلبات العشوائية (Stochastic Volatility Model - SV) تم الاعتماد على مكتبة NumPyro في لغة Python استناداً إلى سلسلة العوائد اليومية لمؤشر BIST100، إذ تبدأ العملية باستخراج بيانات العوائد اليومية من العمود 1-1 والذي يمثل العائد السابق بيوم واحد للعائد الحالي للمؤشر هذه البيانات يتم استخدامها كنقطة انطلاق لتقدير تقلبات السوق، يتم بناء النموذج عبر تعريف دالة $sv_model(y)$ حيث y تمثل بيانات العوائد اليومية للمدة T التي تمثل عدد المشاهدات أو عدد الأيام، يفترض أن العوائد تتبع توزيعاً طبيعياً بمتوسط μ يتم تقديره من توزيع طبيعي قياسي $Normal(0, 1)$ ومعامل الارتباط الذاتي ϕ المقدّر الذي يقيس تأثير القيم السابقة على الحالية والمستخرج من توزيع $Beta(2, 2)$ بالإضافة إلى σ الذي يمثل انحراف الابتعاد عن المتوسط، ويفترض أنه يتبع توزيع نصف طبيعي $Half-Normal(1)$ لضمان القيم الموجبة، يعتمد النموذج على سلسلة زمنية لمحاكاة حركة العوائد باستخدام Gaussian Random Walk لتوليد التقلبات الشرطية h ، يتم استخدام خوارزمية NUTS (No-U-Turn Sampler) ضمن إطار خوارزمية متقدمة لسلاسل ماركوف مونت كارلو MCMC (Markov Chain Monte Carlo) لتقدير المعلمات الخلفية للنموذج من خلال تشغيل 4 سلاسل متعددة لضمان استقرار النتائج مع 1000 خطوة تسخين (فترة الاستبعاد الأولي) لضبط النموذج و2000 عينة بعد التسخين، بعد تنفيذ النموذج يتم استخراج العينات الخلفية للمعلمات باستخدام `mcmc.get_samples()` وتحديد القيم الخاصة بسلسلة التقلبات `h_samples`، يتم حساب المتوسط الأمسي لهذه القيم باستخدام المعادلة:


الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

`mean_volatility = np.exp(np.mean(h_samples, axis = 0) / 2)`

للحصول على التقلب الشرطي، تعرض النتائج النهائية والتي توفر تقديرا دقيقا للتقلبات التي تؤثر على حركة الأسعار في الأسواق المالية، من خلال طباعة قيم متوسط التقلبات الشرطية وحفظها في ملف csv لدمجها مع مدخلات نموذج الشبكات العصبية الاصطناعية، ونلخص النتائج في المنحنى التالي:

الشكل رقم (3-1): التقلبات الشرطية باستخدام نموذج التقلبات العشوائية.



المصدر: من إعداد الطالبة بالاعتماد على مخرجات برنامج Python.

يعرض الرسم البياني نموذج التقلب العشوائي حيث توضح السلسلة الزمنية لتقلبات السوق المقدرة، حيث تظهر السلسلة استقرارا نسبيا في مستويات التقلب مع بقاء التقلب عند مستويات منخفضة وبعض الارتفاعات الطفيفة المتفرقة والتي قد تعكس استجابة السوق لأحداث معينة، يمكن أن يفسر هذا النمط عادة على أنه مؤشر على عودة السوق إلى حالة من الاستقرار النسبي بعد تجاوز كل صدمة قوية، وهذا ما يؤكد وجود ظاهرة تراجع التقلب حيث تتجمع فترات التقلب المرتفع تليها فترات استقرار نسبي مع مرور الوقت، يعكس قدرة السوق التركي على امتصاص الصدمات والتكيف مع التغيرات حيث تظهر مقاومة تدريجية للتقلبات الحادة، من الناحية العملية تعد نتائج هذا النموذج مدخل مهم لبناء توقعات مستقبلية دقيقة بسلوك الأسواق المالية وتطوير نماذج أكثر دقة لتقدير المخاطر المالية مما يعزز من قدرة المستثمرين على اتخاذ قرارات استثمارية مدروسة تعتمد على فهم ديناميكيات التقلب.

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

- **الانحراف المعياري (Standard Deviation):** مقياس إحصائي يستخدم لتحديد مدى تشتت القيم حول المتوسط مما يساعد في قياس درجة التقلب في أسعار الأسهم، في سياق التنبؤ بأسعار الأسهم يساعد في فهم التقلبات السوقية حيث يشير الانحراف العالي إلى سوق متقلب بينما يشير الانحراف المنخفض إلى استقرار الأسعار وتحركها ضمن نطاق ضيق، في تحليل السلاسل الزمنية يتم حساب الانحراف المعياري باستخدام نافذة متحركة Rolling Window لحساب التغيرات في فترات زمنية محددة وذلك باستخدام `rolling().std()` وهي دالة من مكتبة pandas لحساب الانحراف المعياري عبر إطار زمني معين، في هذا النموذج تم اختيار فترتين 7 أيام و14 يوم السابقة للسعر الحالي لمؤشر BIST100 لتحديد مدى تذبذب العوائد خلال هذه الفترات، هذه الطريقة تضمن أن التنبؤات تأخذ في الاعتبار التقلبات السابقة مما يساعد النموذج على التكيف مع ديناميكيات السوق المتغيرة، ويمكن كتابة الانحراف المعياري بالمعادلة التالية:

$$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2}$$

حيث:

X_i : هو السعر في اليوم i ،

μ : هو متوسط الأسعار خلال النافذة الزمنية المختارة،

n : عدد الفترات الزمنية.

- **القيم المتطرفة أو الشاذة (Extreme Value Score):** تعتبر إطار إحصائي أو مقياس يستخدم لنمذجة الأحداث النادرة أو القيم القصوى التي تتجاوز حدا معيناً في البيانات، وتحديد مدى تطرف القيم في مجموعة بيانات بناء على نظرية القيم القصوى Extreme Value Theory وهي تستخدم على نطاق واسع في إدارة المخاطر المالية لقياس وتوقع الخسائر الشديدة في الأسواق، ولتحديد النقاط التي قد تمثل تحركات سعرية غير عادية في السوق المالي، ويتم استخدام هذه الميزة لتحسين أداء النماذج التنبؤية عبر إعطائها معلومات إضافية حول القيم الشاذة في البيانات التاريخية، يتم حسابه باستخدام توزيع القيم القصوى Extreme Value Distribution إذ يتم تقدير معلمات توزيع القيم القصوى Generalized

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

Extreme Value Distribution باستخدام الإحصاء الاستدلالي ثم حساب الدالة التراكمية التي تتخذ

الصيغة الرياضية التالية:

$$F(x) = \exp \left(- \left(1 + \xi \frac{x - \mu}{\sigma} \right)^{-\frac{1}{\xi}} \right)$$

حيث:

μ : القيمة المتوقعة Mean،

σ : مقياس التشتت Scale،

ξ : معامل الشكل Shape Parameter.

ليتم حساب القيم المتطرفة Extreme Value Score كالتالي:

$$EVS = 1 - F(x)$$

في لغة البرمجة python يتم تقدير المعلمات وتحديد القيم المتطرفة باستخدام `genextreme.fit()` و `genextreme.cdf()` من مكتبة `scipy.stats` وهي مخصصة لنمذجة القيم القصوى ضمن نظرية القيم المتطرفة (EVT).

- المتوسط المتحرك الأسّي (Exponential Moving Averag): هو نوع من المتوسطات المتحركة التي تعطي وزناً أكبر للبيانات الحديثة مما يجعله أكثر حساسية لتغيرات الأسعار الحالية هذه الخاصية تجعله أداة قوية في التحليل الفني حيث يساعد في التقاط الاتجاهات الحالية للأسعار بشكل أكثر دقة مقارنة بأنواع المتوسطات الأخرى كالمتوسط المتحرك البسيط، في سياق التنبؤ بأسعار الأسهم واستراتيجيات التداول يتم تطبيق المتوسط المتحرك الأسّي بفترات 7 أيام و14 يوم السابقة للسعر الحالي لمؤشر BIST100، إذ يساعد في تحديد الاتجاهات قصيرة ومتوسطة الأجل، كما يستخدم في استراتيجيات التداول حيث يشير التقاطع بين المتوسط المتحرك قصير وطويل المدى إلى إشارات بيع أو شراء، بفضل حساسيته للتغيرات الحديثة فإن المتوسط المتحرك الأسّي يحسن دقة التنبؤات ويساعد في التكيف مع ديناميكيات السوق المتغيرة، يتم حسابه باستخدام `ewm().mean()` وهي دالة من مكتبة `pandas`، ويمكن تقديم الصيغة الرياضية للمتوسط المتحرك الأسّي كالتالي:

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

$$EMA_t = \alpha \times P_t + (1 - \alpha) \times EMA_{t-1}$$

حيث:

P_t : هو السعر الحالي،

α : معامل تنعيم يحسب بالعلاقة التالية:

$$\alpha = \frac{2}{N + 1}$$

3- بيانات الإدخال الميزات الذاتية

تتمثل في الميزات التاريخية المرتبطة بشكل مباشر بمؤشر BIST100 وتتمثل في أسعار الإغلاق السابقة إذ تعتبر ميزة ذاتية الانحدار (Autoregressive Feature) حيث يعتمد السعر الحالي على الأسعار السابقة، تم استخدام 20 يوم السابقة إذ تمثل تقريبا شهر تداول في الأسواق المالية، يتم إنشاء ميزات جديدة من $t-1$ إلى غاية $t-20$ بحيث تمثل سعر الإغلاق في الأيام السابقة، وإدخال هذه القيم في النموذج كمتغيرات مستقلة مما يساعد على التنبؤ بالأسعار المستقبلية بناء على الاتجاهات السابقة.

ثالثا: وصف وتحليل بيانات الدراسة

في هذا القسم سيتم التعريف بطبيعة السلاسل الزمنية لأسعار إغلاق وعوائد مؤشر BIST100، من خلال تحليل الخصائص الإحصائية والارتباطات بين المتغيرات المدخلة ويشمل هذا التحليل دراسة تطور أسعار وعوائد مؤشر BIST100 عبر الزمن لفهم الاتجاهات العامة والتقلبات التي تؤثر على المؤشر، الوصف الإحصائي لأسعار مؤشر BIST100 والمؤشرات المالية المرتبطة به، وأخيرا تحليل قيم الارتباط بين البيانات المدخلة في النموذج ومؤشر BIST100 وذلك لتقييم مدى تأثير العوامل المختلفة على تحركات المؤشر وتحسين دقة التنبؤات المستقبلية. يعد هذا التحليل خطوة أساسية لفهم ديناميكيات سوق الأسهم التركي وتحديد مدى ملائمة البيانات المستخدمة في النموذج للتنبؤ بتقلبات أسعار مؤشر BIST100.


1- دراسة تطور أسعار أسهم مؤشر BIST100

يتم تقديم منحنى تطور أسعار أسهم مؤشر BIST100 خلال فترة الدراسة باستخدام سعر الإغلاق اليومي للمؤشر، تم الاعتماد على مكتبة Matplotlib.Pyplot في لغة Python لرسم المنحنى، وكان الشكل كالتالي:

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

الشكل رقم (2-3): منحني تطور أسعار أسهم مؤشر BIST100 خلال فترة الدراسة.



المصدر: من إعداد الطالبة بالاعتماد على مخرجات برنامج Python.

يعرض الشكل (2-3) صورة شاملة لحركة أسعار مؤشر BIST100 لفترة الدراسة من عام 2001 حتى عام 2024، حيث يظهر اتجاها تصاعديا ملحوظا طويل الأمد خاصة من عام 2020 مع تسارع في وتيرة النمو بشكل حاد حتى عام 2024، مما يشير إلى مراحل متعددة من النمو والركود تعكس دورات اقتصادية متعددة، قبل عام 2020 تظهر الأسعار تقلبات طفيفة مما يدل على استقرار نسبي في السوق التركي خلال هذه الفترة، بعد عام 2020 شهد المؤشر ارتفاعا حادا ومتزايدا ما قد يفسر بتغيرات اقتصادية داخلية وخارجية، أو أحداث عالمية كالأزمة الصحية العالمية والتي تدفع المستثمرين نحو السوق التركي كسوق ناشئ يوفر فرصا استثمارية، ما يعكس تعافي الاقتصاد التركي بعد تداعيات جائحة كورونا مدعوما بسياسات مالية ونقدية توسعية تبنتها الحكومة التركية لتحفيز الاقتصاد، في المقابل تظهر فترات تصحيح حادة خلال الأزمات الاقتصادية مما يشير إلى فترات من تقلبات السوق العالية المرتبطة بأحداث اقتصادية مهمة، هذا النمط من النمو المتسارع يعزز أهمية دراسة استدامة هذا الارتفاع

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم


مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

وقدرة السوق على امتصاص الصدمات المستقبلية، تدل فترات الاستقرار النسبي بين موجات الصعود والهبوط على وجود فترات من الثقة النسبية في السوق حيث يكون المستثمرون أكثر حذرا في قراراتهم الاستثمارية، كما يظهر المنحنى تأثير الأحداث غير المتوقعة والتي تسبب صدمات سعرية حادة قد تغير اتجاه السوق بشكل سريع.

2- دراسة تطور عوائد أسهم مؤشر BIST100

بعد تقديم منحنى تطور أسعار أسهم مؤشر BIST100 يتم إظهار منحنى تطور عوائد أسهم المؤشر خلال فترة الدراسة باستخدام العائد اللوغاريتمي اليومي للمؤشر، تم الاعتماد أيضا على مكتبة Matplotlib.Pyplot في لغة Python لرسم المنحنى، وكان الشكل كالتالي:

الشكل رقم (3-3): منحنى تطور عوائد أسهم مؤشر BIST100 خلال فترة الدراسة.



المصدر: من إعداد الطالبة بالاعتماد على مخرجات برنامج Python.

يظهر الشكل (3-3) لتطور عوائد أسهم مؤشر BIST100 مستوى التقلبات في السوق التركي في فترة الدراسة من عام 2001 إلى غاية 2024، يتسم هذا المنحنى بوجود تقلبات مرتفعة جدا وهو ما يعد سمة أساسية للأسواق الناشئة التي تتأثر بسرعة بالتغيرات الاقتصادية والسياسية، يظهر المنحنى نمطا واضحا يعرف بتجميع التقلبات (Volatility Clustering) حيث تتبع الفترات ذات العوائد الكبيرة سواء إيجابية أو سلبية بعضها البعض، مما يشير إلى أن الصدمات الاقتصادية تؤثر على سلوك السوق لفترات ممتدة ولا تختفي تأثيراتها بسرعة هذا النمط يتماشى مع خصائص الأسواق المالية الناشئة التي تنطوي على مخاطر عالية وتتأثر بسهولة بالعوامل النفسية

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

والاستثمارية، تشير الفترات ذات القمم المرتفعة والانخفاضات الحادة إلى وجود أحداث اقتصادية كبرى أو تغييرات في السياسات المالية والنقدية.

كما يظهر الشكل تبين واضح في شدة التقلبات بين الفترات الزمنية المختلفة، حيث قبل عام 2008 كانت العوائد تتسم بتقلبات عالية وهو ما يعكس طبيعة الأسواق الناشئة غير المستقرة آنذاك، وخلال 2008 أي خلال الأزمة المالية العالمية سجلت تقلبات حادة حيث شهدت العوائد انخفاضات كبيرة نتيجة تأثيرات الأزمة على الأسواق العالمية، كما تظهر تقلبات مشابهة خلال أزمة العملة التركية في 2018 حيث شهدت الأسواق تذبذبا حادا بسبب فقدان الثقة في استقرار الاقتصاد الكلي، أما في الفترة من 2010 إلى غاية 2020 تقلصت التقلبات النسبية مما يشير إلى نوع من الاستقرار النسبي في السوق خلال هذه الفترة، أما بعد عام 2020 بدأت التقلبات تتزايد مرة أخرى بشكل ملحوظ ما قد يفسر بتأثيرات الأزمة الصحية العالمية والأوضاع الاقتصادية العالمية المضطربة، تبرز الفترات التي تقل فيها التقلبات نوعا من الاستقرار النسبي مما يعكس بيئة استثمارية أكثر أمنا وثقة بين المستثمرين، ومع ذلك يشير عودة التقلبات بسرعة إلى أن هذا الاستقرار قد يكون هشاً ويتأثر بسهولة بأي صدمات خارجية أو داخلية، كما يوضح المنحنى وجود تحيز واضح نحو السلبية في بعض الفترات مما يدل على تزايد المخاطر النظامية التي تؤثر على السوق بأكمله وليس فقط على شركات محددة، علاوة على ذلك يظهر المنحنى تقلبا أكبر في الفترات الأولى من الدراسة مقارنة بالفترات اللاحقة مما قد يرتبط بتحسين الاستقرار الاقتصادي أو تطور البنية التحتية للسوق المالية، مع ملاحظة وجود قيم شاذة في بعض الفترات دلالة على وجود حدث استثنائي أثر بشكل مفاجئ على السوق.

عند دمج تحليل منحنى الأسعار مع منحنى العوائد نحصل على فهم أكثر عمقا لديناميكيات سوق الأسهم التركي، فبينما يظهر منحنى الأسعار الاتجاهات العامة طويلة الأمد فإن منحنى العوائد يكشف عن المخاطر القصيرة الأجل والتقلبات التي يواجهها المستثمرون، توضح أن ارتفاع الأسعار غالبا ما يكون مصحوبا بتقلبات معتدلة، بينما تشهد فترات الهبوط تقلبات حادة وهو ما يتماشى مع فرضية أن الأسواق أكثر اضطرابا في فترات الخسائر.

3- الوصف الإحصائي لأسعار أسهم مؤشر BIST100

في هذا القسم يتم وصف وتحليل البيانات المستخدمة في بناء نموذج الشبكة العصبية باستخدام بعض مقاييس الإحصاء الوصفي كالمدى، المتوسط، والانحراف المعياري.

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

الجدول رقم (2-3): الوصف الإحصائي لأسعار التداول لمؤشر BIST100.

	BIST100	Open	High	Low
count	8763	8763	8763	8763
mean	1334.9928	1334.7417	1347.6057	1320.1147
std	2178.5061	2179.6112	2200.1772	2155.3732
min	71.6	71.6	74.77	67.97
25%	368.915	368.915	372.71	365.65833
50%	693.11	693.79	699.33	685.03
75%	1020.6283	1021.895	1029.37	1012.3267
max	11172.75	11194.41	11252.11	11119.3

المصدر: من إعداد الطالبة بالاعتماد على مخرجات برنامج Python.

يحتوي الجدول رقم (2-3) على الوصف الإحصائي لأسعار التداول لمؤشر BIST100، حيث يعرض متوسطات القيم والانحراف المعياري والقيم الدنيا والقصوى، إضافة إلى القيم الربعية (25%، 50%، 75%) لمتغيرات كأسعار الإغلاق (BIST100) وسعر الافتتاح وأعلى وأدنى سعر، حيث يظهر متوسط سعر الإغلاق ما قيمته 1334.993 مما يعكس مستوى الأداء العام للسوق خلال فترة الدراسة، أما الحد الأقصى لسعر إغلاق المؤشر بلغ 11172.75 والذي يشير إلى فترات نمو تتماشى مع الاتجاه التصاعدي الواضح في الرسم البياني لأسعار الإغلاق، أما فيما يخص الحد الأدنى فقد بلغ 71.6، يلاحظ وجود تباين كبير في قيم هذه البيانات يشير إلى تقلبات كبيرة في أداء المؤشر والتي يدعمها قيمة الانحراف المعياري المرتفعة والتي بلغت 2178.506 مما يعكس ديناميكية كبيرة في حركة السوق خلال فترة الدراسة، القيم الربعية تعكس توزيعاً غير متجانس حيث يظهر ارتفاع ملحوظ في الربع الأعلى مقارنة بالوسيط مما يدل على وجود فترات أداء قوي دفع بالمؤشر إلى مستويات عالية.

يبلغ المتوسط الحسابي لسعر الافتتاح 1334.742 مع انحراف معياري قدره 2179.611 وهو قريب جداً من متوسط قيمة سعر الإغلاق مما يشير إلى استقرار نسبي في الفجوات السعرية عند بداية التداول اليومي، الحد الأدنى 71.6 والحد الأقصى 11194.41 يعكسان نطاقاً واسعاً من التغيرات السعرية وهو أمر متوقع نتيجة لفترات النمو والتراجع الاقتصادي، التوزيع الربعي يظهر نمطاً مشابهاً لأسعار الإغلاق مما يؤكد الترابط الوثيق بين أداء السوق وسعر الافتتاح، أيضاً يدل على استقرار نسبي خلال جلسات التداول اليومية.

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

أعلى سعر سجل متوسطا قدره 1347.606 مع انحراف معياري يبلغ 2200.177 وهو أعلى من متوسط سعر الافتتاح مما يدل على وجود فرص لتحقيق أرباح يومية بسبب تقلبات الأسعار داخل الجلسات، الحد الأقصى البالغ 11252.11 يظهر قدرة المؤشر على تحقيق مكاسب كبيرة في بعض الفترات، يشير الفارق بين الوسيط الذي قيمته 699.33 والربع الأعلى الذي قيمته 1029.37 إلى أن السوق شهد عدة فترات من الارتفاعات القوية، أدنى سعر متوسطه الحسابي بلغ 1320.115 مع انحراف معياري قدره 2155.373 مما يعكس درجة تقلب مماثلة لما هو موجود في المؤشرات الأخرى.

أدنى قيمة سجلت 67.97 وهو مستوى منخفض جدا مقارنة بالقيم الأخرى، مما يعكس فترات أزمات حادة أثرت على السوق، من المهم ملاحظة أن الحد الأدنى أقل بكثير من الربع الأول الذي قيمته 365.6583 مما يدل على وجود تأثير قوي لبعض الأزمات التي دفعت الأسعار للانخفاض الحاد.

تكشف هذه الإحصائيات عن سوق يتمتع بدرجة عالية من التقلبات وهو ما يتطلب إدارة فعالة للمخاطر المالية لاتخاذ قرارات الاستثمار، كما تشير الانحرافات الكبيرة بين القيم الدنيا والقصوى إلى حساسية السوق للتغيرات الاقتصادية والسياسية.

4- تحليل بيانات الإدخال الميزات الخارجية

لغرض تحسين أداء نموذج الشبكات العصبية الاصطناعية والحصول على أفضل النتائج، تم اختيار مؤشرات مالية يومية وفقا لارتباطها بسعر إغلاق أسهم مؤشر BIST100 والتي تعتبر الخصائص المميزة للنموذج، إذ يتم ترشيح المؤشرات المالية اليومية التي ترتبط بسعر الإغلاق ارتباطا قوية واستبعاد المؤشرات التي لا ترتبط بسعر الإغلاق أو يكون ارتباطها ضعيفا، والسبب في ذلك يعود إلى إمكانية تأثيرها سلبا على أداء الشبكة العصبية وبالتالي الحصول على نتائج غير دقيقة، ويوضح الجدول رقم (3-3) قيم الارتباط للمؤشرات المالية بسعر إغلاق أسهم مؤشر BIST100.

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

الجدول رقم (3-3): قيم الارتباط للمؤشرات المالية اليومية بسعر إغلاق أسهم مؤشر BIST100.

	BIST100	S&P500	DowJon	Nasdaq	S&P500VIX	SCa2000	Gold	OilWTI	Open	High	Low	vol
BIST100	1	0.803974	0.763114	0.788534	-0.133933	0.656492	0.672185	0.21356	0.99972	0.999818	0.999814	-0.34735
S&P500	0.803974	1	0.993682	0.994604	-0.1717089	0.959666	0.797297	0.173485	0.803576	0.803637	0.803741	-0.43542
DowJon	0.763114	0.993682	1	0.985557	-0.1846828	0.975563	0.805579	0.180735	0.762666	0.762785	0.762797	-0.41914
Nasdaq	0.788534	0.994604	0.985557	1	-0.1263385	0.953043	0.803518	0.157006	0.788158	0.788155	0.78836	-0.44644
S&P500VIX	-0.13393	-0.17171	-0.18468	-0.12634	1	-0.2499	-0.07276	-0.1515	-0.13353	-0.13306	-0.13427	-0.07796
SCa2000	0.656492	0.959666	0.975563	0.953043	-0.249904	1	0.81007	0.229792	0.65599	0.656022	0.656264	-0.31904
Gold	0.672185	0.797297	0.805579	0.803518	-0.0727558	0.81007	1	0.494132	0.672075	0.671941	0.672301	-0.11468
OilWTI	0.21356	0.173485	0.180735	0.157006	-0.1514981	0.229792	0.494132	1	0.21323	0.213418	0.213241	0.153402
Open	0.99972	0.803576	0.762666	0.788158	-0.1335292	0.65599	0.672075	0.21323	1	0.99995	0.99993	-0.34714
High	0.999818	0.803637	0.762785	0.788155	-0.1330619	0.656022	0.671941	0.213418	0.99995	1	0.999923	-0.3476
Low	0.999814	0.803741	0.762797	0.78836	-0.1342725	0.656264	0.672301	0.213241	0.99993	0.999923	1	-0.34675
vol	-0.34735	-0.43542	-0.41914	-0.44644	-0.0779623	-0.31904	-0.11468	0.153402	-0.34714	-0.3476	-0.34675	1

المصدر: من إعداد الطالبة بالاعتماد على مخرجات برنامج Python.

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

يمثل الجدول مصفوفة الارتباط بين مؤشر BIST100 وعدة مؤشرات مالية عالمية كمؤشر S&P500 و Dow Jones و Nasdaq، بالإضافة إلى متغيرات مالية كأسعار الذهب والنفط الخام وبعض بيانات التداول كسعر الافتتاح، أعلى سعر، أدنى سعر، وحجم التداول، إذ يتمتع المؤشر بعلاقات ارتباط متفاوتة مع باقي المؤشرات المالية والسلع الأساسية وبيانات التداول اليومية، أظهر المؤشر ارتباطا موجبا قويا جدا مع بيانات الأسعار اليومية الخاصة كسعر الافتتاح، أعلى سعر، وأدنى سعر مما يعكس الطبيعة المتوقعة لتقارب هذه القيم نظرا لاعتمادها على نفس حركة السوق اليومية، كما أنه يتمتع بعلاقة ارتباط قوية جدا أيضا مع المؤشرات الرئيسية العالمية الكبرى مؤشر S&P500 و Dow Jones و Nasdaq، و Small Cap 2000 مما يدل على تأثير السوق التركي بالعوامل الاقتصادية العالمية خاصة المتعلقة بالاقتصاد الأمريكي، أيضا يرتبط المؤشر بشكل قوي أيضا مع أسعار الذهب مما يعكس تأثير السوق التركي بأسعار الذهب باعتباره أصلا استثماريا آمنا في فترات عدم الاستقرار الاقتصادي، على النقيض يظهر المؤشر ارتباط ضعيف مع أسعار النفط الخام مما يشير إلى أن أسعار النفط لا تشكل تأثيرا قويا على حركة المؤشر التركي ربما لعدم اعتماد الاقتصاد التركي بشكل مباشر على صادرات النفط، المثير للاهتمام هو الارتباط السلبي الضعيف مع كل من حجم التداول VOL ومؤشر S&P 500 VIX مما يشير إلى العلاقة العكسية بين ارتفاع حجم التداول الذي يكون غالبا مصحوبا بتقلبات سلبية أو عدم استقرار في الأسعار وهو نمط شائع في الأسواق الناشئة حيث يتزايد النشاط في فترات الهبوط أو عند حدوث تغيرات كبيرة في السوق، والعلاقة العكسية بين ارتفاع مؤشر S&P 500 VIX المعروف بمؤشر الخوف أي ارتفاع المخاوف والتقلبات المتوقعة في السوق الأمريكي الذي يعبر عن ارتفاع التوتر وعدم اليقين في الأسواق العالمية ويزيد من المخاوف المتعلقة بالمخاطر ما يؤدي عادة إلى سحب المستثمرين لأموالهم من الأسواق الناشئة كسوق تركيا ما يعكس سلبي على مؤشر BIST100.

هذا التباين في علاقات الارتباط يعكس تعدد العوامل المؤثرة على مؤشر BIST100 بدء من العوامل العالمية وصولا إلى المؤشرات المالية الداخلية للسوق التركي، ومنه يتم استبعاد كل من أسعار النفط وحجم التداول وأسعار مؤشر S&P 500 VIX من الميزات المستخدمة في النموذج واعتبار المؤشرات الباقية كمدخلات مميزة للنموذج.

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

المبحث الثاني: بناء الشبكة العصبية الاصطناعية

في هذا القسم يتم توضيح الهيكل العام للشبكة العصبية الاصطناعية المستخدمة في النموذج ومختلف خطوات معالجة البيانات وتدريبها، وقبل هذا لابد من التعرف على كيفية تنفيذ هذه الشبكة، إذ تم بناءها وتنفيذها على منصة Anaconda Navigator باستخدام لغة Python في بيئة عمل Jupyter بواسطة مجموعة من التبعيات والمكتبات التابعة لهذه اللغة، والمتمثلة في كل من: Keras، pandas، numpy، seaborn، scikit-learn، tensorflow، matplotlib.pyplot.

المطلب الأول: التجهيز المسبق للبيانات

يعتمد بناء نموذج الشبكة العصبية الاصطناعية المستخدمة في الدراسة على التجهيز المسبق ومعالجة البيانات المفقودة في سلسلة المدخلات بالإضافة إلى مدى خضوعها للتدريب والتحقق بشكل مناسب من حيث الوقت وعدد فترات التكرار لتصحيح الأخطاء، إذ تشكل هذه المحددات عوامل حاسمة في أداء الشبكة العصبية الاصطناعية وما ستؤول إليه نتائج الدراسة، ويمكن استعراض خطوات معالجة البيانات وتدريبها والتحقق منها كما يلي:

أولاً: معالجة البيانات

تحتوي عينة الدراسة على نقص في بياناتها نتيجة للتوقف عن التداول والظروف الطارئة فضلاً عن العطل الرسمية، لهذا تتم عملية معالجة البيانات بمرحلتين، الأولى يتم فيها معالجة البيانات الناقصة أو القيم المفقودة مما يجعل البيانات كاملة وبشكل يومي متتابع وفقاً لفترة الدراسة، أما المرحلة الثانية فيتم فيها تطبيع بيانات العينة في نطاق محدد مما يسهل عملية التدريب ويحسن أداء النموذج وذلك عن طريق حساب العائد اليومي لسعر الأسهم، وذلك كما يلي:

1- معالجة القيم المفقودة

لمعالجة القيم المفقودة من البيانات تم اعتماد طريقة الاستيفاء Interpolation الذي يستخدم بشكل شائع في البيانات الزمنية بناءً على القيم المجاورة لها، يعد هذا الأسلوب من الأدوات الشائعة للحفاظ على استمرارية السلسلة الزمنية وتقليل تأثير التوقفات المفاجئة على تحليل البيانات، فبدلاً من حذف القيم المفقودة التي تؤدي إلى فقدان بعض المعلومات المهمة نستخدم طريقة استيفاء القيم المفقودة بطريقة تحافظ على الاتجاه العام

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

للسلسلة الزمنية، تم الاعتماد على طريقة الاستيفاء الخطي Linear Interpolation حيث يقوم بحساب القيم المفقودة بناء على خط مستقيم بين النقاط المعروفة قبلها وبعدها، لأن الأسعار تتحرك بسلاسة في معظم الحالات والاستيفاء الخطي يعطي تقديراً معقولاً للقيم المفقودة، ولتحقيق هذه الطريقة في python تم استخدام دالة interpolate() من مكتبة pandas حيث توفر طرقاً متعددة لاستيفاء البيانات المفقودة كالاستيفاء الخطي linear والاستيفاء متعدد الحدود polynomial والاستيفاء التكراري spline، تبدأ العملية بقراءة البيانات من ملف CSV وتحويل عمود التاريخ Date إلى صيغة تاريخية (Datetime Format) لضمان سهولة التعامل معها، بعد ذلك يتم إنشاء نطاق زمني شامل (all_dates) يغطي الفترة الممتدة من 24 يناير 2001 إلى 30 نوفمبر 2024 باستخدام دالة pd.date_range() مما يضمن أن جميع الأيام متضمنة في البيانات، حتى تلك غير المسجلة في الملف الأصلي كعطلات نهاية الأسبوع أو أيام الإغلاق المؤقتة للسوق، يتم دمج التواريخ الجديدة مع البيانات الأصلية باستخدام merge() بطريقة left join، مما يؤدي إلى إدراج القيم الأصلية مع ترك الأيام غير المسجلة كقيم مفقودة (NaN)، لتطبيق عليها طريقة الاستيفاء الخطي عبر الدالة interpolate(method='linear', limit_direction='both') على كل الأعمدة المستخدمة، إن استخدام الخيار method='linear' يسمح بتقدير القيم الناقصة بطريقة تعتمد على خط مستقيم بين القيم المعروفة قبل وبعد القيمة المفقودة، أي أنها تعمل على تقدير القيم المفقودة بناء على الاتجاه الخطي بين القيم المجاورة مما يضمن استمرارية البيانات دون إدخال تحيز كبير، أما الوسيط limit_direction='both' فيستخدم لتمكين ملء القيم المفقودة سواء كانت في بداية السلسلة أو نهايتها مما يضمن تغطية كاملة للفترة الزمنية المحددة، في النهاية يتم حفظ البيانات المعالجة في ملف CSV جديد، مما يوفر مجموعة بيانات كاملة وخالية من القيم المفقودة يعكس هذا النهج أهمية الحفاظ على تكامل البيانات الزمنية عند التعامل مع الأسواق المالية حيث يعد توفر بيانات متسقة أمراً حاسماً عند بناء نماذج التنبؤ وإدارة المخاطر.

2- حساب العائد اليومي للأسعار

تعد هذه الخطوة أساسية في معالجة البيانات المالية، حيث يستخدم العائد اليومي لتقييم اتجاه السوق، قياس التقلبات، وتحديد المخاطر المالية، وفي الدراسة يتم استخدامه لتحديد العلاقة بين تقلبات الأسعار والمخاطر المالية، مما يساهم في تحسين إدارتها وتطوير استراتيجيات استثمار أكثر كفاءة، يتم حساب العائد اليومي لبيانات الدراسة في برنامج python باستخدام مكتبة Pandas ومكتبة NumPy إذ يتم استبعاد الأعمدة غير المستخدمة في الحساب والمتمثل في عمود التاريخ، ليتم تطبيق معادلة العائد اللوغاريتمي على جميع الأسعار المختارة باستخدام الدالة np.log() مع الإزاحة الزمنية (1) shift وذلك للحصول على التغيرات اليومية بين الأسعار المتتالية، بعد ذلك يتم تنظيف البيانات عبر إزالة القيم المفقودة الناتجة عن عملية

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

الإزاحة اليومية، وأخيرا يتم حفظ القيم المحسوبة في ملف CSV جديد لاستخدامها في التحليل والنمذجة المستقبلية.

3- تنعيم البيانات

تنعيم البيانات Data Smoothing هو تقنية تستخدم لتقليل الضوضاء Noise والتقلبات العشوائية في البيانات الزمنية، مما يسمح باستخراج الاتجاهات الأساسية Trends والأنماط طويلة المدى دون أن تتأثر بالنقاط الشاذة والتغيرات العشوائية قصيرة المدى، يساعد تنعيم البيانات في تحسين دقة التنبؤ من خلال تركيز النموذج على الاتجاهات طويلة المدى بدلا من الضوضاء العشوائية، إضافة إلى التقليل من تأثير القيم الشاذة Outliers التي قد تؤدي إلى تحيز في النموذج، أيضا اكتشاف الاتجاهات الأساسية في الأسواق المالية كالصعود أو الهبوط على المدى الطويل، تم استخدام طريقة تحويل (Wavelet Transformer) حيث تستخدم موجات رياضية Wavelets لتحليل الإشارات المالية وإزالة الضوضاء من البيانات، ميزة هذه الطريقة أكثر قوة ومرونة وتزيل الضوضاء بكفاءة دون تشويه الاتجاهات.

في برنامج python تم استخدام مكتبتين رئيسيتين لتنفيذ عملية التنعيم وهما: مكتبة NumPy لحساب القيم الإحصائية اللازمة، ومكتبة (pyWavelets (pywt لتنفيذ تحويل الموجات وإزالة التشويش من البيانات، تبدأ العملية بإنشاء نسخة من البيانات الأصلية للحفاظ على القيم المنعمة ثم يتم تحديد الأعمدة التي سيتم تطبيق التنعيم عليها مع استثناء العمود الذي يحتوي على التواريخ، يتم تعريف دالة wavelet_denoising() التي تقوم بتطبيق تحليل الموجات المتقطع (Discrete Wavelet Transform - DWT) باستخدام الموجة Daubechies-4 (db4) وتقسيم الإشارة إلى مستويات متعددة وفقا للمعامل level=3، بعد ذلك يتم حساب عتبة إزالة الضوضاء بناء على الانحراف المعياري للمستوى الأخير من التحليل ويتم استخدام طريقة العتبة الناعمة (Soft Thresholding) لإزالة الضوضاء من معاملات الموجات، مما يسمح بالحفاظ على المعلومات الأساسية للسلسلة الزمنية دون فقدان الاتجاهات الرئيسية، أخيرا يتم إعادة بناء الإشارة المنعمة باستخدام إعادة تركيب الموجات (Inverse Wavelet Transform - IWT)، مع التأكد من أن طول الإشارة الناتجة يطابق طول البيانات الأصلية، بعد تطبيق التنعيم على جميع الأعمدة المحددة يتم حفظ القيم المنعمة في ملف CSV لاستخدامها في التحليل والنمذجة لاحقا، تعد هذه الطريقة أكثر كفاءة حيث تتيح إزالة الضوضاء دون تشويه بنية البيانات أو فقدان المعلومات المهمة المتعلقة بالتقلبات السوقية.

4- تطبيع البيانات

بعد إجراء المعالجة للقيم المفقودة وتنعيم البيانات يتم تطبيع البيانات وهي عملية تحويل الميزات الرقمية إلى نطاق قياسي (-1، 1)، بحيث لا تؤثر القيم القصوى Extreme Values أو التوزيع غير المنتظم للبيانات على أداء النموذج لضمان توافق نطاق القيم وتجنب التحيز الناتج عن تباين الوحدات، من بين طرق التطبيع اخترنا طريقة Robust Scaler وهي إحدى طرق تطبيع البيانات التي تستخدم المئينات Percentiles بدلا من المتوسط والانحراف المعياري مما يجعلها أكثر مقاومة للقيم الشاذة مقارنة بطرق التطبيع الأخرى، فعند التعامل مع البيانات المالية كأسعار الأسهم والعوائد قد تحتوي هذه البيانات على قيم متطرفة Outliers يمكن أن تؤثر على أداء النموذج إذا تم استخدام طرق تطبيع تقليدية والتي تعتمد على المتوسط والانحراف المعياري، طريقة Robust Scaler تحل هذه المشاكل عن طريق استخدام المئينات وهي النطاق الرباعي Interquartile Range IQR وبذلك تقليل تأثير القيم الشاذة مما يجعلها مثالية للبيانات المالية المتقلبة، بالإضافة إلى أنها تحافظ على العلاقة بين القيم الأصلية دون تشويهها، ويمكن تلخيص هذه الطريقة بالعلاقة الرياضية التالية:

$$X_{scaled} = \frac{X - median(X)}{IQR(X)}$$

حيث:

X : القيمة الأصلية،

المتوسط Median: يستخدم بدلا من المتوسط الحسابي مما يقلل تأثير القيم الشاذة،

IQR (Interquartile Range): الفرق بين الربع الأول والربع الثالث:

$$IQR = Q3 - Q1$$

في برنامج بايثون يتم استخدام وحدة المعالجة المسبقة sklearn.preprocessing من مكتبة scikit-learn والذي يحتوي على أداة RobustScaler لتنفيذ عملية التطبيع Scaling، يعمل RobustScaler على إزالة الوسيط (median) وتقسيم القيم على المجال بين الربعين (Interquartile Range - IQR) بدلا من استخدام المتوسط والانحراف المعياري كما في StandardScaler، مما يجعله أكثر مقاومة للقيم الشاذة، في هذا الكود يتم تطبيع مجموعتين من الميزات: الأولى X_{ar} وهي الميزات الذاتية التي تعبر عن القيم التاريخية للمؤشر، والثانية X_{exog} وهي الميزات الخارجية التي تتضمن العوامل المؤثرة الأخرى كالمؤشرات المالية العالمية والبيانات الأخرى، يتم تطبيق

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

RobustScaler أولاً على بيانات التدريب باستخدام `fit_transform()` حيث يقوم بحساب المعاملات الإحصائية (الوسيط والربيعين) ثم يطبق التحويل، أما بيانات التحقق والاختبار فيتم استخدام `transform()` فقط لضمان الاتساق مع التحويل المطبق على بيانات التدريب، يتم ذلك لكل من البيانات الذاتية والبيانات الخارجية لضمان تطبيعها بنفس الطريقة قبل إدخالها إلى النموذج التنبؤي.

يعد هذا الأسلوب ضروريا عند التعامل مع الأسواق المالية عالية التقلب حيث يمكن أن تحتوي البيانات على قمم حادة أو انحرافات مفاجئة مما يجعل الأساليب التقليدية للتطبيع أقل كفاءة، باستخدام RobustScaler يتم تحسين استقرار القيم المدخلة للنموذج مما يساعد في تحسين أداء النموذج وتقليل تأثير القيم المتطرفة على النتائج.

ثانياً: تقسيم البيانات

بعد عملية معالجة البيانات وتطبيعها تبدأ عملية تقسيم البيانات إلى عينة التدريب وعينة التحقق وعينة الاختبار قبل تزويد الشبكة العصبية بها، الغرض من تقسيم البيانات هو اختبار قدرة النموذج في التعميم على البيانات التي لم يتدرب عليها، إذ تستخدم عينة التدريب في التعلم واكتشاف الأنماط وخصائص البيانات، فيما تستخدم عينة التحقق لتقييم أداء النموذج أثناء عملية التدريب والتأكد من عدم وجود تباين كبير في الأداء، أو ما يطلق عليها بمشكلة فرط التخصيص (Overfitting) التي يمكن أن تسبب بنتائج عكسية في النهاية، بينما يتم استخدام عينة الاختبار بعد انتهاء عملية التدريب لتقييم الأداء النهائي للنموذج ومدى قدرته على التعميم، وقد تم تقسيم بيانات الدراسة وفقاً للجدول التالي:

الجدول رقم (3-4): تقسيم بيانات الدراسة.

عدد الميزات	الميزات الذاتية التاريخية	الميزات الخارجية	BIST100	المجموع	التاريخ المقابل لكل عينة
20	16	1	37		
6957	6957	6957	6957	257409	من 08/02/2001 إلى 25/02/2020
1392	1392	1392	1392	51504	من 26/02/2020 إلى 18/12/2023
348	348	348	348	12876	من 19/12/2023 إلى 30/11/2024
8697	8697	8697	8697	321789	من 08/02/2001 إلى 30/11/2024

المصدر: من إعداد الطالبة بالاعتماد على مخرجات برنامج Python.

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

يوضح الجدول رقم (3-4) تقسيم بيانات الدراسة إذ تم تقسيم البيانات كمرحلة أولية إلى 3 مسارات حسب الميزات الذاتية التاريخية والميزات الخارجية والهدف هو السعر المتنبئ به، وتم استخدام طريقة `train_test_split` من مكتبة `scikit-learn` لتقسيم البيانات إلى مجموعات تدريب، التحقق، والاختبار، ويبدأ النموذج بتحديد الميزات الخارجية المتمثلة في كل من مؤشر `S&P500`، `DowJon`، `Nasdaq`، `SCa2000`، `Gold`، بالإضافة إلى مؤشرات التداول اليومية المتمثلة في سعر الافتتاح، أعلى سعر، أدنى سعر، وأيضا كل من اليوم، الشهر، التقلبات الشهرية، الانحراف المعياري ل 7 أيام ول 14 يوم، المتوسط المتحرك الأسّي ل 7 أيام ول 14 يوم، والقيم المتطرفة، يتم أيضا تضمين الميزات الذاتية التي تمثل بيانات العوائد السابقة على مدار 20 يوم، وأيضا تحديد الخرج أو الهدف والمتمثل في مؤشر `BIST100`، نلاحظ فقط أنه عدد المشاهدات الأولية لكل ميزة كان 8713 مشاهدة تم فقدان بعض المشاهدات بسبب العمليات الحسابية التي طبقت للحصول على بعض الميزات الإضافية ليتم التوصل إلى 8697 مشاهدة لكل ميزة، تم تقسيمها كالتالي:

كانت عينة التدريب التي نسبتها 80 % تعادل 6957 مشاهدة لكل ميزة بمجموع 139140 مشاهدة للميزات الذاتية التاريخية ومجموع 111312 مشاهدة للميزات الخارجية ومجموع 6957 مشاهدة للإخراج وهو السعر `BIST100`، أي بمجموع كلي 257409 مشاهدة لعينة التدريب، أما عينة التحقق التي نسبتها 16 % تعادل 1392 مشاهدة لكل ميزة بمجموع 27840 مشاهدة للميزات الذاتية التاريخية ومجموع 22272 مشاهدة للميزات الخارجية ومجموع 1392 مشاهدة للإخراج وهو السعر `BIST100`، أي بمجموع كلي 51504 مشاهدة لعينة التحقق ككل، فيما يخص عينة الاختبار نسبتها أيضا 4 % تعادل 348 مشاهدة لكل ميزة بمجموع 6960 مشاهدة للميزات الذاتية التاريخية ومجموع 5568 مشاهدة للميزات الخارجية ومجموع 348 مشاهدة للإخراج وهو السعر `BIST100`، أي بمجموع كلي 12876 مشاهدة لعينة الاختبار ككل، فكانت مجموع الميزات الذاتية التاريخية بواقع 173940 مشاهدة، بينما مجموع الميزات الخارجية بواقع 139152 مشاهدة، أما مجموع بيانات `BIST100` فكانت بواقع 8697 مشاهدة، وبمجموع كامل 321789 تمثل عدد مشاهدات عينة الدراسة ككل.

المطلب الثاني: بناء الشبكة العصبية الاصطناعية وتدريبها

في هذا القسم يتم تحديد بنية نموذج الشبكة العصبية الاصطناعية الملائم للدراسة وتدريبها بغرض الوصول لأداء أفضل، بحيث يتم شرح تفاصيل بناء الشبكة العصبية بما في ذلك تصميم الطبقات، دوال التنشيط المستخدمة، خوارزميات التحسين، ودوال التقييم، ليتم تحليل أداء النموذج والتحقق من دقته في التنبؤ بالقيم المستقبلية لمؤشر `BIST100`.

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

أولاً: الهيكل العام للشبكة العصبية الاصطناعية

ولأن تحديد نموذج الشبكة العصبية الملائم لعينة الدراسة يعتمد بشكل كبير على تحديد الهيكل المناسبة للشبكة من حيث عدد الطبقات وما تحتويه كل طبقة من عقد، فضلاً عن دوال التنشيط وخوارزميات التحسين، والتي يجب أن تكون متوافقة مع مشكلة الدراسة، بيد أنه ليست هناك معايير محددة يمكن الاعتماد عليها في تحديد تلك المكونات إذ تشير الأدبيات إلى ضرورة إجراء عدة محاولات تجريبية والاستدلال بمبدأ التجربة والخطأ في تحديد هيكل الشبكات العصبية الاصطناعية التي تلائم المشكلة المطروحة، وفيما يخص الشبكة المستخدمة في الدراسة تم إجراء عدة تجارب للوصول إلى الهيكلية الأمثل، والتي تلائم مشكلة الدراسة المتمثلة بالتنبؤ بتقلبات أسعار أسهم مؤشر سوق إسطنبول للأوراق المالية BIST100 ودوره في قياس القيمة المعرضة للخطر المشروطة أو المتوقعة CVAR، وقد تم التوصل إلى اعتماد نوع من الشبكات العصبية الاصطناعية تدعى نموذج المحول Transformer Models والتي تم بناءها باستخدام مجموعة من المكتبات أهمها tensorflow.keras ويمكن استعراض هيكلها كما يلي:

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم مؤشر BIST100 وقياس القيمة المعرضة للخطر
المشروطة CVAR

الجدول رقم (3-5): مكونات هيكلية الشبكة العصبية الاصطناعية المستخدمة.

نوع الطبقة Layer Type	طبقة الإدخال	طبقة الانتباه متعدد الرؤوس	طبقات الإسقاط	طبقات الإضافة	طبقات التطبيع	طبقات كثيفة	طبقة التسوية	طبقة الدمج	طبقة التطبيع بالدفعات	طبقة الإخراج
	InputLayer	MultiHeadAttention	Dropout	Add	LayerNormalization	Dense	Flatten	Concatenate	BatchNormalization	OutputLayer
عدد الطبقات	2	1	3	2	2	4	1	1	1	1
عدد العقد Neurons	20/16	20	20/20/32	20/20	20/20	64/20/64/32	20	84	32	1
دالة التنشيط Activation	Hyperbolic Tangent (tanh)									
خوارزمية التحسين Optimizer	AdamW (Adaptive Moment Estimation with Weight Decay)									

المصدر: من إعداد الطالبة بالاعتماد على مخرجات برنامج Python.

نموذج Transformer يعد من أحدث النماذج المستخدمة في التنبؤ بالسلاسل الزمنية المالية حيث يعتمد على استخدام الشبكات العصبية العميقة جنباً إلى جنب مع آلية الانتباه متعدد الرؤوس Multi-Head Attention والتي تتيح للنموذج التعلم من الأنماط الزمنية المعقدة مع الاستفادة من المعلومات التي تقدمها الميزات الخارجية، يبدأ النموذج بمعالجة بيانات الإدخال إذ يتم أولاً إعادة تشكيل بيانات الميزات الذاتية التاريخية ($X_{ar_train_scaled}$ و $X_{ar_val_scaled}$ و $X_{ar_test_scaled}$) بحيث تصبح متوافقة مع مدخلات طبقة Transformer والتي تحتاج إلى بيانات بتنسيق ثلاثي الأبعاد (عدد العينات، طول التسلسل، عدد الميزات) ولهذا السبب يتم استخدام الأداة `reshape()` لتغيير أبعاد البيانات إلى (`batch_size, 1, num_features`)، أما البيانات الخارجية $X_{exog_train_scaled}$ فيتم تمريرها كما هي لأنها لا تحتاج إلى تحويل زمني، بعد معالجة بيانات الإدخال يتم استقبالها بطبقة مدخلات Input Layer يتم بعد ذلك تمرير المتغيرات الزمنية إلى كتلة Transformer المصممة لاكتشاف الأنماط المعقدة في السلاسل الزمنية كما تسمح للنموذج بتحديد التأثيرات الزمنية للعوامل المختلفة في بيانات الإدخال، تتكون من طبقة انتباه متعددة الرؤوس Multi-Head Attention عددها 8 رؤوس، إذ تستخدم هذه الطبقة آلية الانتباه الذاتي Self-Attention Mechanism لحساب الأهمية النسبية لكل نقطة بيانات بالنسبة للنقاط الأخرى، مما يساعد على تعلم العلاقات المعقدة بين القيم التاريخية المختلفة، بعد حساب الأوزان داخل طبقة الانتباه متعدد الرؤوس يتم تطبيق Dropout بنسبة 30% وهي تقنية تستخدم لمنع فرط التكيف Overfitting من خلال تعطيل بعض الوحدات العشوائية أثناء التدريب مما يساعد النموذج على تعميم العلاقات في البيانات بدلاً من حفظها، يتبع هذا إضافة اتصال تخطي Skip Connection بين مخرجات الانتباه والمدخلات الأصلية للحفاظ على تدفق المعلومات عبر الطبقات العميقة ومنع مشكلة تلاشي التدرج، يتم بعدها تطبيق طبقة تطبيع Layer Normalization لتحسين استقرار القيم ومنع انفجار التدرجات أثناء التدريب، ثم تمر المخرجات عبر شبكة عصبية تغذية أمامية Feed-Forward Network ذات طبقتين كثيفتين الأولى بعدد وحدات مخفية 64 ودالة تفعيل Tanh التي تساعد على التقاط العلاقات غير الخطية، والثانية تعيد تقليل الأبعاد لتناسب مع مدخلات الانتباه الأصلية، ليتم أيضاً تطبيق Dropout بنسبة 30% بعد كل طبقة لمنع فرط التكيف وتكرار عملية التطبيع والاتصال التخطي بين مخرجات شبكة التغذية الأمامية والمخرجات السابقة لضمان عدم فقدان المعلومات المهمة والحفاظ على استقرار النموذج.

تمرر المخرجات من كتلة Transformer إلى طبقة Flatten لتحويلها إلى بعد واحد قبل دمجها مع المتغيرات الخارجية، والتي تتم معالجتها عبر طبقات كثيفة Dense Layers ذات 64 وحدة مخفية ودالة تفعيل Tanh، مما يسمح للنموذج بالتعلم من كلا المصدرين، يمر هذا الدمج عبر طبقات كثيفة إضافية ذات 32 وحدة، تليها طبقة تطبيع Batch Normalization لتحسين استقرار الأوزان أثناء التدريب وتسريعه وتحسين التعميم، بالإضافة إلى

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

Dropout بنسبة 10% لتقليل فرط التكيف، تنتهي الشبكة بطبقة إخراج Output Layer مكونة من وحدة واحدة مسؤولة عن إنتاج تنبؤ واحد يمثل القيمة العددية المتوقعة وهي العائد اليومي لمؤشر BIST100 باستخدام دالة تنشيط tanh.


ثانيا: تدريب الشبكة العصبية الاصطناعية والتحقق من أداءها

بعد معالجة البيانات وتقسيمها تأتي مرحلة التدريب، إذ تعد أهم المراحل في عمل الشبكات العصبية الاصطناعية بصورة عامة، فكلما كانت الشبكة مدربة بشكل جيد كلما كان الأداء والنتائج أفضل، ولذلك تهدف مرحلة التعلم والتدريب إلى تعزيز وتحسين قدرة النموذج على الاستجابة لموقف معين أو حل مشكلة معقدة أو تنفيذ مهمة، ومن خلال تقليل مخاطر أخطاء التكلفة سيكون من الضروري مراعاة جودة البيانات من أجل تجنب أي اتجاه متحيز في النتائج مع الحفاظ على الدقة المثلى، لذلك فإن تدريب الشبكة العصبية الاصطناعية عبارة عن عمليات رياضية تتم بواسطة خوارزميات التحسين المعروفة، إذ يتلخص هدف التدريب في محاولة الحصول على الأوزان المثلى للشبكة العصبية بتوليد قيما عشوائية للأوزان الرابطة بين الطبقات لتقوم بعد ذلك بإجراء التصحيحات اللازمة وفقا لعدد الأخطاء الحاصلة، وتعتمد عملية التدريب بشكل كبير على الوقت المحدد للتدريب وعدد فترات التكرار لتصحيح الأخطاء (Epochs)، إضافة إلى حجم دفعات البيانات (Batch Size) المراد تصحيحها لكل فترة تكرارية، ويخضع تحديد هذه العوامل في كثير من الأحيان إلى مبدأ التجربة والخطأ، وعلى أساس ذلك فإن الدراسة استقرت على استخدام خوارزمية التحسين Adamw والتي تتميز بكفاءتها العالية في تحسين أداء الشبكات العصبية وتكيفها السريع مع البيانات، وذلك بمعدل تعلم 0.0005 و Weight Decay لتقليل التذبذب في الأوزان، كما تم استخدام دالة الخسارة Huber Loss والتي تجمع بين Mean Squared Error (MSE) و Mean Absolute Error (MAE) مما يجعلها أكثر استقرارا في التعامل مع القيم المتطرفة، وأيضا مراقبة الأداء باستخدام دالة MSE كمقياس خطأ، يتم استخدام أيضا كل من Early Stopping لإيقاف التدريب عندما لا يتحسن النموذج بعد 5 حقبة متتالية، ReduceLROnPlateau لتقليل معدل التعلم بمقدار 50% عند تباطؤ التحسن، ModelCheckpoint لحفظ أفضل نموذج بناء على أقل قيمة Val-loss، تمت عملية التدريب على مدار 100 حقبة أو دورة (Epochs) باستخدام دفعات بيانات صغيرة (Batch Size = 64) لتحقيق استقرار في تحديث الأوزان ولضمان تحسين أداء النموذج في التنبؤ بالقيم المستقبلية لمؤشر BIST100، وتقليل الفروقات بين النتائج المتوقعة والحقيقية، كما تم تخصيص مجموعة تحقق (Validation Set) لمراقبة أداء النموذج أثناء التدريب وتجنب الإفراط في التكيف، يمكن تلخيص أداء النموذج أثناء عمليتي التدريب والتحقق في منحى الخسارة كالتالي:

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

الشكل رقم (3-4): منحني خسارة النموذج أثناء عمليتي التدريب والتحقق.



المصدر: من إعداد الطالبة بالاعتماد على مخرجات برنامج Python.

يظهر الرسم البياني تطور خسارة النموذج أثناء عملية التدريب Train Loss والتحقق Validation Loss عبر الدورات Epochs، حيث يمثل الخط الأزرق خسارة مجموعة التدريب بينما الخط البرتقالي يمثل خسارة مجموعة التحقق، إذ نلاحظ في بداية التدريب تكون الخسارة مرتفعة بشكل ملحوظ مما يشير إلى أن النموذج لم يتعلم الأنماط بعد ومع استمرار التدريب تنخفض الخسارة بسرعة خلال أول 20 دورة مما يدل على أن النموذج يكتسب معرفة حول البيانات ويتحسن أداؤه تدريجياً، بعد هذه المرحلة تصبح الخسارة شبه مستقرة حيث تصل إلى قيمة قريبة جداً من الصفر مما يشير إلى أن النموذج قد وصل إلى حالة التقارب المثلى حيث لم يعد هناك تحسن كبير في الأداء.

من خلال مقارنة المنحنيين نلاحظ أن خسارة التدريب وخسارة التحقق تتبعان مساراً متشابهاً مما يشير إلى أن النموذج يتعلم بشكل جيد دون حدوث فرط التكيف، فلو كان هناك فرق كبير بين المنحنيين بحيث تستمر

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

خسارة التحقق في الارتفاع بعد عدد معين من الدورات فقد يكون ذلك مؤشرا على أن النموذج أصبح متخصصا جدا في مجموعة التدريب وغير قادر على التعميم على البيانات الجديدة.

بما أن كل من خسارة التدريب والتحقق تنخفضان بسلاسة وتستقران عند قيم صغيرة جدا فإن ذلك يدل على أن النموذج قد تم تدريبه بشكل فعال وهو قادر على التعميم على البيانات الجديدة بدرجة عالية من الدقة، هذا المنحنى تم الحصول عليه بعد استخدام آليات تحسين قوية مثل AdamW وتقنيات تنظيم مما يساعد في تحقيق أداء متوازن ومنع النموذج من الوقوع في مشاكل كفرط التكيف أو ضعف التعلم.

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

المبحث الثالث: اختبار النموذج وتطبيقه في عملية التنبؤ وقياس القيمة المعرضة للخطر المشروطة

يركز هذا المبحث على اختبار أداء النموذج المستخدم في التنبؤ ومدى دقته في تقدير تقلبات السوق إضافة إلى التنبؤ بالقيم المستقبلية لشهر ديسمبر وحساب القيمة المعرضة للخطر المشروطة CVAR كأداة لتقييم المخاطر القصوى، مما يسمح بفهم أعمق لسلوك الأصول المالية في ظل السيناريوهات المختلفة واتخاذ قرارات استثمارية مدروسة تعتمد على أسس كمية دقيقة.

المطلب الأول: اختبار وتقييم النموذج

في هذا القسم يتم استعراض نتائج اختبار النموذج المبني لعينة اختبار من خارج عينة التدريب والتحقق، إذ بعد عملية تدريب النموذج والتحقق من أدائه تأتي مرحلة اختبار النموذج المدرب على مجموعة اختبار مستقلة أي على بيانات من خارج عينة التدريب، إذ تلعب هذه العملية دوراً حيوياً في إنشاء نموذج التعلم الآلي، وللتأكد من كفاءة التعميم وإمكانية استخدامه بفعالية على البيانات الحقيقية، بحيث يتم تقدير عينة الاختبار التي لم يسبق للنموذج التعرف عليها، وتم تقييم دقة النموذج التي على أساسها تم اختيار أفضل نموذج بواسطة مقاييس أداء مختلفة هي: متوسط مربع الخطأ (MSE)، متوسط الخطأ المطلق (MAE)، معامل التحديد R^2 ، و PCD والتي تعطي فكرة واضحة عن مدى دقة النموذج في التنبؤ بالقيم الجديدة، ولتقييم النتائج بشكل أكثر واقعية تم تحويل القيم المتوقعة والملاحظة إلى نطاقها الأصلي أي يتم إزالة التنعيم منها باستخدام تقنية إضافة المتبقيات Residuals Reconstruction في هذه الطريقة يتم حساب الفرق بين القيم الأصلية والمنعومة والذي يمثل التشويش أو التغيرات قصيرة الأجل التي أزالها التنعيم باستخدام تحويل الموجات ثم يتم إعادة إدخال هذه الفروقات إلى القيم المتنبئ بها لاستعادة التقلبات الحقيقية في البيانات مما يضمن أن التنبؤات تعكس الديناميكيات الفعلية للسوق بدلاً من أن تكون غير واقعية، ثم بعد ذلك إنشاء إطار بيانات (DataFrame) لمقارنة القيم الحقيقية بالقيم المتوقعة مما يسمح بتقييم أداء النموذج في التنبؤ بالسوق وتحليل دقة التوقعات بشكل مرئي، في برنامج python يتم استخدام مكتبة sklearn.metrics لحساب مقاييس التقييم المستخدمة والتي يمكن توضيحها كالتالي:

- متوسط مربع الخطأ (Mean Squared Error (MSE): هو أحد مقاييس تقييم الأداء المستخدمة في النماذج الإحصائية والتعلم الآلي لقياس مدى دقة التنبؤات التي يقوم بها النموذج مقارنة بالقيم الحقيقية، يتم حسابه بأخذ متوسط مربعات الفروقات بين القيم المتوقعة والقيم الحقيقية، فكلما كانت

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

قيمة MSE أصغر كان النموذج أكثر دقة في التنبؤات، يمكن تلخيص هذه العملية في الصيغة الرياضية التالية:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

حيث:

n : عدد العينات،

y_i : هي القيمة الحقيقية للنقطة i ،

$\hat{y}_i$: القيمة المتوقعة للنموذج للنقطة i .

- متوسط الخطأ المطلق (MAE): يعتبر أيضا أحد المقاييس الإحصائية المستخدمة في تقييم أداء النماذج التنبؤية، يستخدم لقياس مدى دقة التنبؤات من خلال حساب متوسط الفرق المطلق بين القيم الحقيقية والقيم المتوقعة، بخلاف متوسط مربع الخطأ MSE فإن MAE لا يربح الأخطاء مما يجعله أقل حساسية للقيم المتطرفة، فكلما كانت القيم أصغر كلما كان التنبؤ أكثر دقة، ويمكن تلخيص هذه العملية في الصيغة الرياضية التالية:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

- معامل التحديد R^2 : Coefficient of Determination R^2 : مقياس إحصائي يستخدم لتقييم جودة النموذج التنبؤي، حيث يقيس مدى تفسير النموذج للتغيرات في البيانات، إذ كلما كان معامل التحديد أكبر كلما كان النموذج يفسر التغيرات في البيانات بشكل مثالي، يتم حسابه باستخدام المعادلة التالية:

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2}$$

حيث:

$\sum (y_i - \hat{y}_i)^2$: هو مجموع المربعات المتبقية ويمثل الأخطاء بين القيم الحقيقية والمتوقعة،

$\sum (y_i - \bar{y})^2$: هو مجموع المربعات الكلي ويمثل التباين الكلي في البيانات،

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

y_i : القيم الحقيقية،

$\hat{y}_i$: القيم المتوقعة من النموذج،

$\bar{y}$: المتوسط الحسابي للقيم الحقيقية.

- قدرة التنبؤ بالاتجاه (PCD) Predictive Capability Direction: هو مؤشر إحصائي يستخدم لتقييم دقة التنبؤ باتجاه تغير الأسعار في الأسواق المالية، يعتمد على مقارنة الاتجاه الفعلي (الصاعد أو الهابط) للأصل المالي بالاتجاه المتوقع من النموذج دون الاهتمام بالقيمة العددية للخطأ، يتم حسابه انطلاقاً من تحديد التغيرات الفعلية والتغيرات المتوقعة حيث:

التغير الفعلي في الأسعار يتم حسابه كالتالي:

$$\Delta y_{actual,t} = y_{actual,t} - y_{actual,t-1}$$

التغير المتوقع يتم حسابه بنفس الطريقة كالتالي:

$$\Delta y_{pred,t} = y_{pred,t} - y_{pred,t-1}$$

ثم مقارنة إشارات التغير الفعلي (+ أو -) مع إشارات التغير المتوقع فإذا كانت مطابقة يعتبر صحيحاً وإذا كانت مختلفة يعتبر خاطئاً، بعدها يتم حساب نسبة الاتجاهات المتوقعة بشكل صحيح مقارنة بإجمالي عدد التوقعات كالتالي:

$$PCD = \left(\frac{\text{عدد الاتجاهات الصحيحة}}{\text{إجمالي عدد التوقعات}} \right) \times 100$$

ويمكن تلخيص هذه العملية في الصيغة الرياضية التالية:

$$PCD = \frac{1}{N} \sum_{t=2}^N 1 \left(\text{sign}(\Delta y_{actual,t}) = \text{sign}(\Delta y_{pred,t}) \right) \times 100$$

حيث:

1: هو دالة المؤشر (Indicator Function) تعيد 1 إذا كانت الإشارتان متطابقتين و 0 إذا لم تكونا كذلك،

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

$sign(x)$: تعني إشارة العدد x أي تعيد +1 إذا كان موجبا و-1 إذا كان سالبا و0 إذا كان صفرا.

N : عدد النقاط الزمنية في العينة.

وبعد تطبيق النموذج على عينة الاختبار تم الحصول على النتائج الموضحة في الجدول التالي:

الجدول رقم (3-6): نتائج تقييم النموذج المستخدم في الدراسة على بيانات الاختبار.

المقياس	القيمة
MSE	0.000018
MAE	0.003206
R2 Score	0.8581
PCD	85.88

المصدر: من إعداد الطالبة بالاعتماد على مخرجات برنامج Python.

- من الجدول نلاحظ أن $MSE = 0.000018$ منخفضة جدا مما يشير إلى أن متوسط مربع الأخطاء بين القيم الحقيقية والمتوقعة صغير جدا، هذا يدل على أن النموذج لديه دقة جيدة في تقليل الخطأ المطلق.
- قيمة $MAE = 0.003206$ وهي قيمة صغيرة جدا مما يعني أن متوسط الفرق المطلق بين القيم المتوقعة والحقيقية هو حوالي 0.34% من القيم الفعلية وهو خطأ صغير جدا بالنظر إلى طبيعة البيانات المالية، بما أن MAE لا يتأثر بالقيم الشاذة مثل MSE فإن هذا يؤكد أن النموذج يقدم تنبؤات قريبة جدا من القيم الحقيقية دون تأثير كبير من القيم المتطرفة، وهذا يدل على أن النموذج لا يعاني من أخطاء كبيرة متكررة وهو مؤشر إيجابي على كفاءته في التنبؤ بعوائد السوق.
- القيم المنخفضة لكل من MAE و MSE معا تشير إلى أن النموذج قادر على التنبؤ بمستويات العوائد بشكل دقيق إلى حد كبير، أو بعبارة أخرى النموذج يمكنه إجراء تنبؤات دقيقة لمعظم القيم دون انحرافات كبيرة مما يعزز موثوقيته عند استخدامه في إدارة المخاطر المالية.
- $R^2 \text{ Score} = 0.858147$ هذه القيمة تعني أن 85.81% من التغيرات في العوائد الفعلية يمكن تفسيرها بواسطة النموذج مما يدل على قدرة عالية للنموذج في تفسير الأنماط داخل البيانات، هذه القيمة تعتبر جيدة جدا لأن هناك نسبة 14.19% فقط من التغيرات في البيانات لا تزال غير مفسرة أي أن النموذج لا يستطيع تفسيرها مما يعني أن هناك عوامل أخرى تؤثر على العوائد لم يتم تصميمها في الدراسة، ومن جهة عادة إذا كانت قيمة R^2 أعلى من 0.80 فهذا يعتبر مؤشرا على أن النموذج قوي ويفسر مقدارا كبيرا من

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

التغيرات، هذا يشير إلى أن النموذج يلتقط معظم الأنماط الحقيقية في السوق ولا يبالغ في التكيف مع البيانات بل يحتفظ بتوازن جيد بين الدقة والقدرة على التعميم، مما يجعله أداة تنبؤية قوية.

- نسبة $PCD = 85.88$ تعني أن النموذج يتوقع الاتجاه الصحيح لحركة السوق بنسبة عالية جدا مما يجعله أداة قوية لاتخاذ القرارات في سوق مالي شديد التقلب، أي أن 85.88% من التغيرات الفعلية في الأسعار تم التنبؤ بها بالاتجاه الصحيح مما يعزز موثوقية النموذج في التنبؤ باتجاهات السوق العامة.

بالنظر إلى جميع المقاييس المذكورة أعلاه يمكننا القول بأن النموذج يعمل بكفاءة عالية في التنبؤ بالعوائد المالية أو الاتجاهات العامة، وأن النموذج قابل للاستخدام الفعلي في تطبيقات التحليل المالي وإدارة المخاطر المالية حيث يقدم توقعات دقيقة ويمكن الاعتماد عليه في دعم اتخاذ القرارات المالية والاستثمارية، وبالتالي يعتبر النموذج ناجحا وجيدا ضمن الإطار المالي الذي تم تطبيقه فيه ويمكن الوثوق به في تقديم تنبؤات ذات دقة عالية مع مستوى جيد من الاستقرار والقدرة التفسيرية.

المطلب الثاني: التنبؤ بالقيم المستقبلية لأسعار مؤشر BIST100 وحساب CVAR

يعد التنبؤ بالمستقبل أحد أهم الجوانب في نمذجة الأسواق المالية، حيث تتيح للمستثمرين والمحللين إمكانية تقييم المخاطر المحتملة واتخاذ قرارات استثمارية مستنيرة نظرا للطبيعة الديناميكية للأسواق المالية، فإن دقة التنبؤ تلعب دورا حاسما في نجاح الاستراتيجيات المالية وإدارة المخاطر، وهذا ما يهدف إليه هذا القسم حيث يتم حفظ وتحميل النموذج المدرب والذي اخترناه سابقا في برنامج python ليتم استدعائه فيما بعد وتطبيقه على بيانات مستقبلية، وحساب القيمة المعرضة للخطر للقيم المتوقعة والقيم الحقيقية والمقارنة بينهما.

أولا: التنبؤ بالقيم المستقبلية لأسعار مؤشر BIST100

بعد تقييم دقة النموذج على عينة الاختبار يتم حفظه وتحميله ليتم استدعائه فيما بعد لتطبيقه على بيانات جديدة تمتد من 2 ديسمبر إلى غاية 31 ديسمبر 2024 وذلك من أجل الحصول على تقديرات للعوائد المستقبلية لمؤشر BIST100 ولتحقيق هذا الهدف نقوم بالمراحل التالية:

1- تحضير بيانات شهر ديسمبر لاستخدامها في التنبؤ

قبل استخدام النموذج المدرب للتنبؤ بالقيم المستقبلية لمؤشر BIST100 خلال شهر ديسمبر يجب تجهيز البيانات المستقبلية بنفس الطريقة التي تم بها إعداد بيانات التدريب والاختبار، يتضمن ذلك جمع بيانات السوق المالي لشهر ديسمبر التي تشمل بيانات الإدخال التاريخية والخارجية فقط والتي تعتبر مدخلات لعملية التنبؤ، ثم

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

تطبيق نفس عمليات المعالجة التي تم استخدامها سابقا انطلاقا من معالجة البيانات المفقودة، حساب العوائد، تنعيم البيانات وتطبيعها باستخدام نفس القيم التي تم حسابها أثناء التدريب لضمان توافق القيم الجديدة مع نطاق القيم المستخدمة في النموذج المدرب، أخيرا يتم إعادة هيكلة البيانات بنفس الشكل المطلوب من قبل نموذج بحيث تكون جاهزة للإدخال في النموذج.

2- استدعاء النموذج المدرب وتطبيقه على البيانات المستقبلية


بعد تجهيز بيانات الإدخال لشهر ديسمبر يتم استدعاء النموذج المدرب الذي تم حفظه وتحميله مسبقا أثناء مرحلة التدريب، يمكن تحقيق ذلك باستخدام مكتبة TensorFlow/Keras عبر استدعاء النموذج باستخدام `keras.models.load_model()`، بعد التحميل يتم تمرير بيانات الإدخال إلى النموذج باستخدام `model.predict()` للحصول على التنبؤات المستقبلية الخاصة بمؤشر BIST100 للأيام القادمة، ومن المهم التأكد من أن تنسيق البيانات المدخلة متوافق تماما مع متطلبات النموذج الأصلية، كعدد الميزات المدخلة وشكل المصفوفات لتجنب حدوث أي أخطاء أثناء التنبؤ.

3- تحليل نتائج التنبؤ ومقارنة القيم المتوقعة بالقيم الحقيقية

بمجرد الحصول على القيم المتوقعة لشهر ديسمبر يتم إجراء تحليل شامل للمقارنة بين القيم المتوقعة والقيم الفعلية، يتم استخدام مقاييس التقييم الإحصائية المستخدمة في اختبار النموذج وهي متوسط مربع الخطأ MSE، متوسط الخطأ المطلق MAE، معامل التحديد R^2 Score، ومقياس PCD لقياس مدى دقة التوقعات، بالإضافة إلى ذلك رسم مخطط زمني يوضح المقارنة بين كل من القيم المتوقعة والحقيقية باستخدام مكتبة `matplotlib.pyplot` أو `seaborn`، والذي يمكن إظهاره في الشكل التالي:

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

الشكل رقم (3-5): مقارنة بين الأسعار الفعلية والمتنبئ بها لمؤشر BIST100 خلال ديسمبر 2024.



المصدر: من إعداد الطالبة بالاعتماد على مخرجات برنامج Python.

يوضح الشكل مقارنة بين الأسعار الحقيقية لمؤشر BIST100 الممثلة بالخط الأزرق والقيم المتنبئ بها من النموذج والممثلة بالخط الأحمر المتقطع خلال شهر ديسمبر 2024 حيث نلاحظ أن النموذج يحقق أداء قويا في تتبع القيم الحقيقية مع بعض الفروقات الطفيفة في بعض الفترات، يمكن تحليلها بناء على مراحل حركة الأسعار خلال الشهر كما يلي:

- في بعض المناطق وخاصة خلال فترات الارتفاع السريع مثل الفترة من 2 إلى 11 ديسمبر نجد أن النموذج يبالغ قليلا في تقدير القمم السعرية حيث تكون القيم المتوقعة اعلى من القيم الفعلية هذا يشير إلى أن النموذج يتأثر بشكل كبير بحركة الصعود السابقة ويقوم بتوقع ارتفاعات أعلى مما يحدث فعليا، قد يكون هذا ناتجا عن تأثير الاتجاهات السابقة القوية على استجابات النموذج.
- من 12 إلى 17 ديسمبر وأثناء حدوث انخفاضات في الأسعار يمكن ملاحظة أن النموذج يقترب كثيرا من القيم الحقيقية ولكنه قد يقلل من حدة الانخفاض في بعض الحالات، مما يشير إلى أن النموذج قد يكون لديه درجة من الحذر في توقع الهبوط الحاد.

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

- من 18 إلى 22 ديسمبر وخلال الفترات التي تكون فيها الأسعار مستقرة نسبياً مع تذبذبات طفيفة نلاحظ تطابق الأسعار الفعلية والمتنبئ بها بشكل وثيق، وأن التوقعات تتبع القيم الفعلية بدقة جيدة جداً مما يدل على أن النموذج قادر على استيعاب الأنماط السعرية القصيرة المدى بدقة مقبولة.
- من 23 إلى 27 ديسمبر حيث انخفضت الأسعار ثم تعافت بسرعة يمكن ملاحظة أن النموذج نجح في التقاط الانعكاس والتعافي بسرعة جيدة لكنه قلل من حدة التقلبات، بمعنى آخر النموذج لا يتوقع ارتفاعات وانخفاضات بنفس الدرجة التي تحدث بها في الواقع مما يجعله أكثر تحفظاً خلال التحولات الحادة في الأسعار.
- في نهاية الفترة من 28 إلى 31 ديسمبر نجد أن القيم المتوقعة قريبة جداً من القيم الحقيقية مما يشير إلى أن النموذج حافظ على دقته حتى نهاية فترة التنبؤ وهو مؤشر على استقراره العام وعدم وجود تدهور في أدائه مع مرور الوقت.
- بشكل عام نلاحظ أن النموذج يقترب كثيراً من القيم الحقيقية ولكنه قد يقلل من حدة الانخفاض في بعض الحالات، أي أن الأسعار المتوقعة تكون أعلى قليلاً من القيم الحقيقية أثناء التراجع وأن النموذج قد يكون لديه درجة من الحذر في توقع الهبوط الحاد، مع ملاحظة تطابق الأسعار الفعلية والمتنبئ بها بشكل وثيق خاصة في الفترات التي يكون فيها السوق في حالة تصحيح أو حركة جانبية، مع مقدرة النموذج على التقاط الانعكاسات السعرية بدقة معقولة مما يعزز موثوقيته في التنبؤ، الفروقات الملحوظة يمكن تفسيرها بأن النموذج قد يكون متأثراً بحركة الأسعار السابقة أو أنه يميل إلى التنبؤ بشكل أكثر تحفظاً أثناء فترات الهبوط وأعلى قليلاً أثناء الصعود، ومنه يمكن القول أن النموذج يحقق دقة جيدة في تتبع الأسعار الفعلية خاصة في ظل سوق شديد التقلب إذ يعتبر الوصول لهذه الدقة أمراً صعباً.
- هذا بالنسبة للمقارنة بين القيم المتنبئ بها والقيم الحقيقية أما فيما يخص الاتجاه العام فعند تحليله في المنحنى نلاحظ أن النموذج ينجح في التقاط التوجهات الرئيسية للسوق، حيث يتحرك منحنى التوقعات بشكل متناسق مع المنحنى الحقيقي مما يعكس قدرة النموذج على فهم الأنماط السعرية السابقة وإسقاطها على المستقبل، ويمكن تقسيم تحليل الاتجاه العام إلى عدة مراحل رئيسية ومدى دقة النموذج في كل مرحلة كالتالي:
- من 2 إلى 9 ديسمبر يتضح أن النموذج يواكب الاتجاه الصاعد في بداية الشهر مع انحياز طفيف نحو التفاؤل في فترات الاتجاه الصاعد وهو أمر شائع في بعض النماذج التنبؤية التي تعتمد على العلاقات التاريخية.

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

- من 10 إلى 17 ديسمبر حيث الأسعار تبدأ في الانخفاض في هذه الفترة يبدو أن النموذج ينجح في التقاط الاتجاه الهبوطي بسرعة وبدقة جيدة، يظهر هذا أن النموذج لديه استجابة جيدة لتغير الاتجاهات ولكنه قد يقلل من حدة التراجعات الفعلية.
- من 18 إلى 22 ديسمبر في هذه المرحلة يتحرك السوق في نطاق عرضي مع تقلبات طفيفة وهنا نلاحظ أن النموذج ينجح في تتبع الاتجاهات القصيرة المدة بدقة عالية، مما يشير إلى أنه لا يعتمد فقط على الاتجاهات طويلة الأمد بل لديه القدرة على معالجة الحركات السعرية الصغيرة نسبياً.
- من 23 إلى 27 ديسمبر في هذه المرحلة يشهد تعاف سريع في الأسعار الذي يلي الانخفاض القوي وهنا يظهر أن النموذج استطاع التقاط الهبوط في الأسعار بدقة مقبولة ورغم ذلك تمكن النموذج من التنبؤ بحركة الارتداد reversal بشكل جيد مما يعزز من فعاليته في توقع نقاط الانعكاس الرئيسية.
- في نهاية الشهر من 28 إلى 31 ديسمبر نلاحظ أن النموذج يتابع الاتجاه العام دون انحراف كبير مما يدل على استقرار أدائه وعدم وجود تدهور في دقته مع مرور الزمن.
- بشكل عام يظهر أن النموذج يتمتع بقدرة جيدة على التنبؤ بالاتجاه العام للسوق، كما أن قدرته على التقاط الانعكاسات تعزز من موثوقيته في الأسواق المالية شديدة التقلب.

بعد إظهار منحنى المقارنة بين القيم المتوقعة والقيم الحقيقية والاتجاه العام للأسعار وللتأكد من نتائج المنحنى يتم الانتقال إلى تحليل مقاييس التقييم الإحصائية والتي يمكن تلخيصها في الجدول التالي:

الجدول رقم (3-7): نتائج تقييم النموذج المستخدم في التنبؤ بقيم مؤشر BIST100 خلال شهر ديسمبر

2024.

المقياس	القيمة
MSE	0.00001
MAE	0.002599
R2 Score	0.8637
PCD	96.55

المصدر: من إعداد الطالبة بالاعتماد على مخرجات برنامج Python.

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

تعكس نتائج التقييم التي تم الحصول عليها أداء قويا للنموذج في التنبؤ بأسعار مؤشر BIST100 لشهر ديسمبر، حيث يظهر متوسط مربع الخطأ MSE قيمة منخفضة جدا $MSE=0.00001$ مما يشير إلى أن الفروقات بين القيم الحقيقية والمتوقعة صغيرة للغاية، وهو مؤشر إيجابي على دقة النموذج، كما أن متوسط الخطأ المطلق MAE بقيمة 0.002599 يعزز هذه النتيجة حيث يدل على أن متوسط الانحراف المطلق بين القيم الحقيقية والمتوقعة صغير جدا مما يشير إلى استقرار النموذج وعدم وجود أخطاء كبيرة في التوقعات.

أما معامل التحديد R^2 Score فقد سجل قيمة 0.8637 وهو رقم يعكس قدرة النموذج على تفسير 86.37% من التغيرات في البيانات الفعلية، مما يدل على جودة عالية في التنبؤ ويشير إلى أن النموذج يتمتع بمستوى جيد من التعميم وقوة العلاقة بين المدخلات والمخرجات، من جهة أخرى فإن مقياس PCD الذي بلغ 96.55% يعد مؤشرا هاما لقياس دقة التنبؤ باتجاه السوق حيث تعني هذه النتيجة أن النموذج كان قادرا على توقع الاتجاه الصحيح للأسعار بنسبة 96.55% من الحالات، أي يتنبأ باتجاه الأسعار بشكل دقيق جدا حيث يطابق الاتجاه الفعلي لحركة السوق في معظم الحالات، مما يعكس موثوقية كبيرة في تنبؤ الاتجاهات العامة للسوق المالي.

خلاصة القول تشير هذه النتائج إلى أن النموذج يقدم أداء ممتازا في التنبؤ بأسعار مؤشر BIST100 مع خطأ صغير جدا ودقة عالية في التنبؤ بالاتجاه العام، مما يشير إلى قدرته على تقديم تنبؤات دقيقة فيما يتعلق بأسعار المؤشر خلال الفترة المدروسة.

ثانيا: حساب القيمة المعرضة للخطر المشروطة للقيم المتوقعة والقيم الحقيقية

في سياق تحليل أسعار مؤشر BIST100 يساعد حساب القيمة المعرضة للخطر المشروطة لكل من القيم الفعلية والقيم المتوقعة في تقييم مدى دقة النموذج في تقدير المخاطر المستقبلية، فإذا كانت CVAR للقيم المتوقعة قريبة من CVAR للقيم الفعلية فهذا يشير إلى أن النموذج قادر على التنبؤ ليس فقط بالقيم والاتجاهات العامة ولكن أيضا بالمخاطر الفعلية التي يواجهها السوق، أما في حال وجود اختلافات كبيرة فقد يدل ذلك على أن النموذج يقلل أو يبالغ في تقدير حجم المخاطر، لذلك يتم في هذا القسم حساب CVAR لكلا البيانات المتوقعة والفعلية، ثم مقارنة القيم المستخرجة لفهم مدى دقة النموذج في تقدير المخاطر المتوقعة للأسواق المالية.

- **خطوات حساب CVAR:** حساب القيمة المعرضة للخطر المشروطة CVAR لكل من العوائد الفعلية والعوائد المتنبئ بها لمؤشر BIST100 لشهر ديسمبر يعتمد على تحديد الخسائر المتوقعة في الحالات القصوى مما يساعد في تقييم دقة النموذج في تقدير المخاطر المالية، ولتطبيق هذه العملية في برنامج

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

python يتم الاعتماد على مكتبة riskfolio إذ نبدأ أولاً بتحديد مستوى الثقة حيث يتم ضبطها عند 95% وهو مستوى شائع الاستخدام في قياس المخاطر المالية أي أننا نريد قياس أسوأ 5% من توزيع العائدات، بعدها يتم حساب القيمة المعرضة للخطر VAR باستخدام دالة np.percentile() حيث يقوم VaR_actual_95 بحساب الحد الأدنى للخسائر المحتملة عند 95% للبيانات الفعلية، ويقوم VaR_predicted_95 بنفس العملية لكن للقيم المتنبئ بها، هذا يعطينا عتبة الحد الأدنى للخسائر القصوى التي يمكن أن يتعرض لها مؤشر BIST100 عند مستوى الثقة المحدد، من ثم يتم استخراج جميع القيم التي تكون أقل من أو تساوي قيمة VAR من بيانات العوائد لكل من القيم الفعلية والمتنبئ بها، ليتم حساب المتوسط لهذه القيم باستخدام mean()، النتيجة النهائية هي متوسط الخسائر في أسوأ 5% من الحالات أي أن CVAR يحدد ما الذي يمكن أن نخسره في أسوأ الحالات عندما يتم تجاوز قيمة VAR، يتم عرض قيم CVAR لكل من العوائد الفعلية والمتوقعة للمقارنة بينهما.

- حساب نسبة الخطأ في CVAR: يهدف هذا الجزء إلى قياس نسبة الخطأ بين القيمة المعرضة للخطر المشروطة CVAR للعوائد الحقيقية والمتنبئ بها مما يسمح بتقييم دقة النموذج في تقدير المخاطر المالية، يتم ذلك عبر حساب الفرق النسبي بين القيمتين إذ يتم أولاً حساب الفرق المطلق بين CVAR العوائد الحقيقية CVaR_actual_95 والمتنبئ بها CVaR_predicted_95 باستخدام abs(CVaR_actual_95 - CVaR_predicted_95)، بعدها يتم قسمة الفرق المطلق على القيمة المطلقة لـ CVAR العوائد الحقيقية abs(CVaR_actual_95) ليتم ضرب النتيجة في 100 لتحويلها إلى نسبة مئوية وعرض النتيجة، ويمكن تلخيص هذه العملية في المعادلة التالية:

$$CVAR\ Error = \frac{|CVAR_{actual} - CVAR_{predicted}|}{|CVAR_{actual}|} \times 100$$

يظهر الجدول التالي النتائج المتوصل إليها:

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

الجدول رقم (3-8): تحليل القيمة المعرضة للخطر المشروطة ونسبة الخطأ فيها.

البيان	القيمة
للعوائد الحقيقية CVAR	-0.0154
للعوائد المتنبئ بها CVAR	-0.0169
نسبة الخطأ في CVAR	9.37%

المصدر: من إعداد الطالبة بالاعتماد على مخرجات برنامج Python.

تشير القيم المحسوبة للقيمة المعرضة للخطر المشروطة CVAR إلى الحد الأقصى للخسائر المتوقعة في أسوأ 5% من الحالات يعادل -1.54% للعوائد الحقيقية تعني أنه في أسوأ 5% من الحالات التاريخية للعوائد الحقيقية يتوقع أن تكون متوسط الخسارة اليومية حوالي 1.54%، و -1.69% للعوائد المتنبئ بها والتي تعني أنه في أسوأ 5% من الحالات التاريخية للعوائد المتنبئ بها يتوقع أن تكون متوسط الخسارة اليومية حوالي 1.69%، هذه الأرقام تبرز قدرة النموذج المستخدم على تقديم تقديرات دقيقة للمخاطر المالية، حيث أن الفرق بين القيمتين يبقى ضئيلاً نسبياً مما يعكس توافقاً كبيراً بين تنبؤات النموذج والواقع الفعلي للسوق وأنه يتبع بشكل وثيق الاتجاهات الحقيقية للسوق في فترات الخسائر القصوى، هذا التقارب في التقدير يدل على أن النموذج لا يجيد فقط توقع الاتجاه العام للسوق بل يحسن أيضاً تمثيل سلوك السوق في الفترات الحرجة ذات المخاطر العالية الأمر الذي يكسب هذا النموذج أهمية عملية في مجال إدارة المخاطر المالية، وبذلك فإن النموذج يظهر جدارة واضحة في محاكاة سلوك الخسائر القصوى مما يعزز الاعتماد عليه كأداة فعالة في دعم اتخاذ القرار الاستثماري في بيئات السوق المتقلبة.

نسبة الخطأ المحسوبة في القيمة المعرضة للخطر المشروطة CVAR والتي بلغت 9.37% تشير إلى أن النموذج يمتلك دقة عالية جداً في تقدير المخاطر المستقبلية حيث إن نسبة الخطأ أقل من 15% وهي النسبة المقبولة عامة في إدارة المخاطر والتي تعتبر معياراً لجودة التقدير، هذه النتيجة تعني أن القيم المتوقعة للخسائر القصوى في أسوأ السيناريوهات قريبة جداً من القيم الحقيقية مما يعزز موثوقية النموذج في تحليل المخاطر المالية لمؤشر BIST100.

بالنظر إلى أن الأسواق المالية وخاصة الأسواق الناشئة كمؤشر BIST100 تتسم بدرجة عالية من عدم اليقين والتقلبات الحادة فإن الحصول على نسبة خطأ منخفضة بهذا الشكل يعد مؤشراً على أن النموذج قادر

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

على محاكاة وتحليل الاتجاهات المستقبلية بدقة عالية، كذلك يعكس الأداء الجيد للنموذج في تقدير CVAR مدى فعاليته في استيعاب الأنماط التاريخية للسوق والتكيف معها مما يجعله أداة قوية لاتخاذ القرارات الاستثمارية وإدارة المخاطر المالية.

بشكل عام هذه النتائج تعزز الثقة في النموذج المستخدم وتدعم إمكانية الاعتماد عليه في التنبؤ بالمخاطر المستقبلية بشكل دقيق مما يمنح المستثمرين ومديري المخاطر أداة تحليلية ذات كفاءة عالية لتقييم المخاطر المحتملة واتخاذ قرارات مالية مبنية على معطيات موثوقة.

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

خلاصة الفصل الثالث

تناول هذا الفصل دراسة حالة سوق إسطنبول المالي وذلك بالتركيز على مؤشر BIST100 الذي يعد من أبرز المؤشرات المالية المستخدمة لقياس أداء السوق، مع تحليل بيانات الدراسة وتوصيفها إحصائياً من خلال دراسة أسعار الإغلاق اليومية والعوائد اللوغاريتمية، حيث طبقت عدة تقنيات لمعالجة البيانات بما في ذلك معالجة القيم المفقودة باستخدام تقنية الاستيفاء الخطي، وتنعيم البيانات، وتطبيعها باستخدام تقنية RobustScaler لضمان استقرار القيم وإزالة تأثير القيم الشاذة.

تمت إضافة ميزات هندسية جديدة كالمتوسط المتحرك الأسّي، الانحراف المعياري، وحساب القيم المتطرفة باستخدام Extreme Value Score إلى جانب بعض المؤشرات الرئيسية في السوق المالي ومؤشرات التداول اليومية لمؤشر BIST100 والميزات الذاتية التاريخية المتمثلة في 20 يوم سابقة لسعر الإغلاق الحالي، مما يعزز قدرة النموذج على التقاط الأنماط الخفية في البيانات المالية، ليتم بعد ذلك بناء نموذج الشبكات العصبية الاصطناعية باستخدام نموذج Transformer الذي يعتمد على آلية Multi-Head Attention لتحليل العلاقات الزمنية للبيانات المالية، تم التوصل إلى النموذج اعتماداً على بيانات تاريخية مقسمة إلى مجموعات تدريب، تحقق، واختبار، مع ضبط خوارزمية التحسين AdamW واستخدام دالة الخسارة Huber لمراعاة القيم المتطرفة إلى جانب تطبيق تقنيات مثل Dropout و Batch Normalization لتحسين قدرة النموذج على التعميم وتجنب فرط التكيف.

أخيراً يقيم أداء النموذج باستخدام مقاييس R^2 ، MAE، MSE، و PCD، حيث أظهرت النتائج دقة مرتفعة في التنبؤ بتقلبات واتجاهات أسعار مؤشر BIST100، مع نسبة خطأ منخفضة عند حساب القيمة المعرضة للخطر المشروطة CVAR، بما أن نسبة الخطأ في CVAR هي 9.37% تبقى ضمن نطاق القبول الممتاز فإن هذا يشير إلى أن النموذج المستخدم في التنبؤ يتمتع بكفاءة عالية في تقدير تقلبات أسعار الأسهم مما يؤدي إلى حسابات دقيقة للمخاطر القصوى، بعبارة أخرى عندما يكون التنبؤ بالتغيرات السعرية دقيقاً فإن تقدير CVAR يصبح أكثر موثوقية وبالتالي يتحسن قياس المخاطر التي قد يواجهها المستثمرون أو المؤسسات المالية، بالإضافة إلى ذلك النتائج تؤكد أن النموذج قادر على التقاط الأنماط الرئيسية في السوق مما يساعد في التنبؤ بتحركات الأسعار المستقبلية وبالتالي تقديم تقديرات دقيقة للخسائر المحتملة، هذا يعني أن استخدام منهجيات التنبؤ المتطورة يمكن أن يساهم بشكل مباشر في تحسين استراتيجيات إدارة المخاطر المالية لا سيما في الأسواق المتقلبة مثل مؤشر BIST100، كما أن النموذج يظهر قوة الجمع بين المعلومات الزمنية والتغيرات الاقتصادية الكلية في تحسين

الفصل الثالث: استخدام الشبكات العصبية الاصطناعية للتنبؤ بتقلبات أسعار أسهم

مؤشر BIST100 وقياس القيمة المعرضة للخطر المشروطة CVAR

دقة التنبؤ بحركة الأسعار، تكمن أهمية هذا النهج في قدرته على استيعاب ديناميكية السوق المعقدة والتكيف مع البيانات الجديدة مما يجعله أداة قوية لتحليل الأسواق المالية وتقديم رؤى قيمة لاتخاذ القرارات الاستثمارية.

خاتمة

تم في هذه الدراسة التنبؤ بتقلبات أسعار أسهم مؤشر BIST100 لسوق إسطنبول للأوراق المالية إذ ركز على معالجة البيانات، تحليل العوائد وتطوير نموذج متقدم للتنبؤ بتقلبات الأسعار وحساب القيمة المعرضة للخطر المشروطة، فبعد تنظيف البيانات واستكمال القيم المفقودة بطريقة تضمن الحفاظ على دقة السلسلة الزمنية، تم حساب العوائد اليومية لفهم ديناميكيات التغيرات السعرية، كما استخدمت تقنيات التنعيم عبر تحويل الموجات Wavelet Transform لتقليل الضوضاء وتحسين جودة نوعية البيانات، ليتم بعدها تطبيق منهجية التطبيع لضبط نطاق القيم وتسهيل عملية التدريب للنموذج، أما على مستوى النمذجة فقد تم بناء وتطوير نموذج عصبي يعتمد على شبكة المحول Transformer بدمج شبكة عصبية عميقة مع آلية الانتباه متعدد الرؤوس لتفسير تأثير العوامل الخارجية، كما تم استخدام دالة Huber Loss الذي ساعد في تقليل تأثير القيم الشاذة خلال التدريب إلى جانب خوارزمية AdamW لتحسين الأداء وضبط التحديثات بشكل أكثر كفاءة وفعالية، أيضا تم الاعتماد على استراتيجيات مثل تقليل معدل التعلم عند الحاجة والتوقف المبكر Early Stopping مما يقلل من مشاكل فرط التدريب وبذلك يعزز ويقوي من استقرار النموذج، بعد تدريب النموذج تم التحقق من أدائه عبر مجموعة من المقاييس التي حسبت بعد تطبيق النموذج على عينة الاختبار، لتأتي بعد ذلك مرحلة تطبيق النموذج في التنبؤ بالقيم المستقبلية لشهر ديسمبر مع حساب القيمة المعرضة للخطر المشروطة CVAR لمقارنة المخاطر المالية بين المتنبئ بها والقيم الحقيقية، مما مكن من تقييم فعالية وكفاءة النموذج في إدارة المخاطر المالية.

أولا: اختبار الفرضيات

1. الفرضية الأولى: ظهرت العديد من الطرق الحديثة للتنبؤ بتقلبات أسعار الأسهم التي تتميز بقدرتها

على استيعاب الأنماط الزمنية المعقدة للسلاسل الزمنية والتعامل مع العلاقات غير الخطية.

تؤكد الأدبيات الحديثة أن التطورات في مجال الذكاء الاصطناعي وتعلم الآلة أدت إلى ظهور العديد من الأساليب المتقدمة القادرة على التعامل مع الطبيعة المعقدة والديناميكية للأسواق المالية والتنبؤ بتقلبات أسعار الأسهم، ومن أبرز هذه الطرق أو هذه النماذج الشبكات العصبية الاصطناعية، ونماذج Transformer، وشبكة الذاكرة الطويلة الأمد، التي تتميز بقدرتها على استيعاب الأنماط المعقدة والتعامل مع العلاقات غير الخطية، واستخراج أهم المعلومات من البيانات التاريخية الضخمة، تتفوق هذه النماذج على الأساليب التقليدية من خلال قدرتها على اكتشاف العلاقات الخفية بين المتغيرات المالية وتكييفها مع ديناميكية الأسواق مما جعلها أدوات فعالة لتحسين دقة التنبؤات المالية، وهو ما يثبت صحة الفرضية الأولى.

2. **الفرضية الثانية:** تعتبر القيمة المعرضة للخطر VAR والقيمة المعرضة للخطر المشروطة CVAR أهم الأدوات الحديثة والمتقدمة التي تستخدم في قياس وإدارة المخاطر المالية.

تعتبر كل من القيمة المعرضة للخطر VAR والقيمة المعرضة للخطر المشروطة CVAR من أهم الأدوات الحديثة والمتقدمة والتي يتم الاعتماد عليها في قياس وإدارة المخاطر المالية، فالقيمة المعرضة للخطر توفر تقديراً لأقصى الخسائر أو أقل العوائد المحتملة عند مستوى ثقة معين وخلال فترة زمنية محددة مما يسمح بتحديد نطاق الخطر المقبول، أما القيمة المعرضة للخطر المشروطة فهي تكمل القيمة المعرضة للخطر VAR عن طريق قياس متوسط الخسائر التي قد تتجاوز حدود VAR، وهذا ما يجعلها أكثر دقة ومصدقية في التقاط واستيعاب المخاطر الشديدة والمفاجئة، وهو ما يثبت صحة الفرضية الثانية.

3. **الفرضية الثالثة:** تقدم الشبكات العصبية الاصطناعية دقة عالية في التنبؤ بتقلبات أسعار أسهم مؤشر BIST100.

تدعم النتائج التطبيقية المتوصل إليها صحة هذه الفرضية، حيث أظهرت نماذج الشبكات العصبية الاصطناعية المستخدمة والمبنية وفقاً لنموذج المحول Transformer الذي يجمع بين آليات الانتباه متعددة الرؤوس والشبكات العصبية العميقة، أداء ودقة عالية في التنبؤ بتقلبات أسعار أسهم مؤشر BIST100، فقد حقق النموذج مؤشرات أداء قوية تمثلت في انخفاض متوسط الخطأ المطلق MAE ومتوسط مربع الخطأ MSE، مع تحقيق معامل تحديد R^2 مرتفع مما يعكس قدرة النموذج على تفسير نسبة كبيرة من تباين البيانات الفعلية، كما حقق النموذج نسبة دقة في توقع اتجاه السعر قوية جداً مما يدل على كفاءته في التقاط الاتجاهات السعرية، ويعود هذا الأداء القوي إلى قدرة هذه الشبكات على التعامل مع خصائص البيانات المالية كالضخامة والتقلبات العالية والعلاقات غير الخطية بين المتغيرات، كما أثبتت قدرتها على استخراج الأنماط الزمنية المعقدة المخفية في السلاسل الزمنية التاريخية للمؤشر، مما ساهم في تحسين دقة التنبؤات مقارنة سواء بنماذج الشبكات العصبية الأخرى أو بالطرق التقليدية.

4. **الفرضية الرابعة:** يمكن استغلال التنبؤات بالقيم المستقبلية لمؤشر BIST100 الناتجة عن نماذج الشبكات العصبية الاصطناعية في تحسين قرارات إدارة المخاطر.

نتائج الدراسة التطبيقية المتوصل إليها تؤكد صحة هذه الفرضية والتي تنص على أن التنبؤات المستقبلية لشهر ديسمبر لأسعار أسهم مؤشر BIST100 التي تم الحصول عليها باستخدام الشبكات العصبية الاصطناعية بالتحديد نموذج المحول ساهمت بشكل فعال وكفى في تحسين عمليات إدارة المخاطر المالية، فقد مكنت هذه

التنبؤات الدقيقة من احتساب وقياس القيمة المعرضة للخطر المشروطة CVAR بشكل أكثر دقة وموثوقية، إذ أظهرت النتائج عند مقارنة القيمة المعرضة للخطر المشروطة للعوائد المتوقعة والقيمة المعرضة للخطر المشروطة للعوائد الحقيقية لشهر ديسمبر أن الفرق النسبي بينهما منخفض وأقل بكثير من العتبة المقبولة، هذا التوافق العالي بين القيم المتوقعة والحقيقية في أسوأ 5% من السيناريوهات يثبت ويدل أن النموذج نجح ليس فقط في التنبؤ بالاتجاه العام وقيمة العوائد ولكن أيضا في تقدير المخاطر القصوى بطريقة دقيقة وموثوقة، مما يمنح المستثمرين أدوات عملية لاتخاذ قرارات استثمارية أكثر استنارة وتحوطا ضد التقلبات الحادة، وهو ما يساهم بفعالية في توفير تقديرات مستقبلية دقيقة للقيمة المعرضة للخطر المشروطة CVAR وبذلك دعم إدارة المخاطر المالية.

ثانيا: النتائج النظرية

من خلال الدراسة النظرية تم التوصل للنتائج التالية:

- تقلبات أسعار الأسهم تعكس تغيرات في قيمتها نتيجة عوامل متعددة تشمل الظروف الاقتصادية، الأداء المالي للشركات، والأحداث غير المتوقعة.
- النظريات المفسرة لتقلبات أسعار الأسهم تتنوع بين نظريات عقلانية مثل نظرية كفاءة الأسواق المالية ونظرية المشي العشوائي، وأخرى تأخذ بعين الاعتبار العوامل السلوكية مثل نظرية الفقاعات ونظرية البجعة السوداء.
- التنبؤ المالي هو عملية تقدير الاتجاهات المستقبلية للأسواق المالية بالاعتماد على بيانات حالية وتاريخية.
- أدوات التنبؤ تتراوح بين النماذج التقليدية كالتحليل الأساسي والتقني، والنماذج الحديثة كالسلاسل الزمنية وتطبيقات الذكاء الاصطناعي التي أصبحت تلعب دورا متزايدا الأهمية.
- الأدوات الإحصائية مثل الانحراف المعياري والتباين والتوزيعات الاحتمالية تساعد في قياس المخاطر المالية، بينما تستخدم نماذج القيمة المعرضة للخطر (VAR و CVAR) ونموذج تسعير الأصول الرأسمالية لتقييم المخاطر المحتملة واتخاذ قرارات استثمارية مستنيرة.
- تلعب البيانات الضخمة دورا أساسيا في تطوير مختلف تطبيقات الذكاء الاصطناعي حيث توفر كميات هائلة من المعلومات التي تستخدم في تحسين دقة النماذج التنبؤية.

- طرق التعلم في الذكاء الاصطناعي تشمل التعلم بالإشراف، والتعلم بدون إشراف، والتعلم المختلط، والتعلم شبه الخاضع للإشراف، والتي تختلف من حيث مستوى التدخل البشري ومدى توفر البيانات المصنفة.
- الشبكات العصبية الاصطناعية هي إحدى نتائج ثورة الذكاء الاصطناعي والتعلم الآلي، والتي أوجدت في الأساس لإنجاز المهام المعقدة وإيجاد الحلول السريعة للمشاكل التي تتطلب قدرا كبيرا من العمليات الرياضية والمنطقية، إذ استخدمت في مجالات واسعة كالطب، الهندسة، الفضاء، والشؤون العسكرية.
- الشبكات العصبية تتكون من عدة طبقات (المدخلة، المخفية، والإخراج) وتستخدم في التنبؤ المالي بفضل قدرتها على التعلم من البيانات غير الخطية.
- شاع استخدام الشبكات العصبية الاصطناعية مؤخرا في عمليات التنبؤ على نطاق واسع في الدراسات والأبحاث المالية والاقتصادية، إذ تعتمد على تتبع المسار الزمني للأحداث السابقة والمتغيرات المؤثرة في الحالة المراد التنبؤ بها ومحاولة توقع السلوك المستقبلي لتلك الحالة من خلال توظيف بعض الخوارزميات والتقنيات المعقدة.
- الشبكات العصبية الاصطناعية تستخدم بشكل متزايد في التنبؤ الاقتصادي، التنبؤ بالآزمات المالية، والتنبؤ بالأسواق المالية، نظرا لقدرتها على تحليل كميات ضخمة من البيانات واستخراج الأنماط الخفية، فضلا عن إمكانيةها في التعلم الذاتي وتحديد الأنماط المميزة في البيانات السابقة من أجل الاعتماد عليها في بناء التوقعات المستقبلية.
- تعددت أنواع الشبكات العصبية الاصطناعية المستخدمة في مختلف المجالات ومنها التنبؤ بتقلبات أسعار الأسهم، ومن بين أبرز الشبكات العصبية المستخدمة في هذا المجال الشبكات العصبية العميقة، الشبكات العصبية المتكررة، شبكات الذاكرة طويلة المدى، وشبكات المحول.

ثالثا: النتائج التطبيقية

من خلال الدراسة التطبيقية تم التوصل إلى النتائج التالية:

- تحليل البيانات كشف عن وجود فجوات زمنية في السجلات التاريخية نتيجة العطل والمناسبات تم التعامل معها ومعالجتها بطريقة الاستيفاء الخطي والتي ضمنت تسلسل زمني متكامل للبيانات دون إدخال تشوهات ساعدت في الحفاظ على دقة السلسلة الزمنية واتساقها.

- تطبيق تحويل الموججات ساهم في تقليل الضوضاء، وساعدت في الكشف عن الأنماط الأساسية في السلسلة الزمنية دون فقدان المعلومات المهمة المتعلقة بالاتجاهات والتقلبات.
- استخدام RobustScaler لتطبيع البيانات أدى إلى تحسين أداء النموذج من خلال التقليل والحد من تأثير القيم المتطرفة.
- استخدام نموذج المحول Transformer المزود بآلية الانتباه متعدد الرؤوس المدمجة مع شبكة عصبية عميقة مكن من التقاط الأنماط الزمنية بكفاءة عالية.
- دمج المتغيرات الخارجية مع البيانات الزمنية أدى إلى إيجاد نموذج أكثر تكيفا مع ديناميكيات السوق.
- دمج المعلومات الزمنية والمتغيرات الخارجية عبر نموذج المحول Transformer باستخدام آلية الانتباه مع شبكة عصبية إضافية أدى إلى تحسين وتعزيز دقة التنبؤ.
- ضبط النموذج عبر AdamW و Huber Loss ساهم في تحسين الدقة وتقليل الخطأ في التنبؤات.
- منحني الخسارة أظهر أن الفرق بين الخسارة التدريبية وخسارة التحقق ظل متوازنا طوال فترة التدريب مما يدل على تجنب مشاكل فرط التدريب أو نقص التدريب وهذا يشير إلى ضبط جيد لمعاملات النموذج، كذلك أظهر استقرار الأداء أي لم يظهر تذبذب كبير أثناء التدريب مما يدل على كفاءة النموذج في التعلم.
- استجابة النموذج بشكل جيد للمتغيرات الحادة في البيانات يدل على قدرته على التعامل مع التقلبات.
- أظهرت نتائج تقييم النموذج المبني على بيانات الاختبار دقة جيدة مع انخفاض في قيم MSE و MAE مما يعكس قدرة النموذج على التعلم من البيانات التاريخية وتعزيز جودة التنبؤ.
- عند مقارنة الرسم البياني لتنبؤات النموذج المبني مع القيم الحقيقية يظهر تطابقا عاليا مع الاتجاهات الحقيقية للأسعار مما يدل على أن النموذج استطاع التقاط أنماط السوق بكفاءة.
- الرسم البياني لأسعار مؤشر BIST100 المتنبئ بها لشهر ديسمبر مقابل الأسعار الحقيقية أظهر أن نموذج المحول Transformer تمكن من محاكاة تحركات السوق بشكل جيد وهذا ما يعزز مصداقيته في التنبؤ المستقبلي، كما أكدت نتائج تقييم أداء النموذج باستخدام مقاييس الدقة MSE و MAE ومعامل التحديد و PCD فعاليتها في التنبؤ بتقلبات الأسعار واتجاهها بدقة عالية.
- CVAR المتنبئ به كان قريبا جدا من القيمة الحقيقية مما يدل على أن النموذج استطاع توقع المخاطر المستقبلية بدقة عالية.

- الفرق بين القيمة المعرضة للخطر المشروطة CVAR الحقيقية والمتنبئ بها كان ضمن النطاق المقبول مما يثبت كفاءة النموذج في قياس المخاطر المالية وبالتالي إدارتها.
- تعد هذه الدراسة خطوة متقدمة ومطورة نحو فهم سلوك الأسواق المالية باستخدام تطبيقات الذكاء الاصطناعي، حيث أثبت نموذج Transformer فعاليته في التنبؤ بحركات الأسعار بدقة عالية، وبالتالي فإن النتائج المتوصل إليها توفر أدوات قوية للمتداولين والمحللين الماليين لمساعدتهم في اتخاذ قرارات استثمارية أكثر دقة ومصداقية، ومع التقدم المستمر في التعلم العميق وتطبيقات الذكاء الاصطناعي يمكن توقع تحسينات إضافية في النماذج المستقبلية لرفع كفاءة تحليل الأسواق بشكل أكبر.

أثبتت النتائج أن التنبؤ الدقيق بتقلبات الأسعار يعزز من جودة قياس القيمة المعرضة للخطر المشروطة CVAR مما يجعله أداة حاسمة في تقييم المخاطر المالية وقياسها وبذلك اتخاذ قرارات استثمارية فعالة، لذلك فإن دمج نماذج التنبؤ المتطورة في استراتيجيات تحليل المخاطر المالية يعد خطوة ضرورية لضمان تقديرات موثوقة للقيمة المعرضة للخطر المشروطة وهو ما يبرز الدور المهم والمحوري للتنبؤ في تحسين أدوات قياس وإدارة المخاطر في الأسواق المالية، ومنه فإن نموذج المحول Transformer يمكن استخدامه كأداة دقيقة لتقليل الخسائر عن طريق تقدير المخاطر المالية المحتملة ومنه اتخاذ قرارات استثمارية مبنية على تنبؤات دقيقة لتقلبات الأسعار.

رابعاً: اقتراحات وآفاق الدراسة

حاولت هذه الدراسة تقديم مساهمة مقبولة في تطوير نماذج تحليل الأسواق المالية وبناء على ما تم التوصل إليه من نتائج نقترح:

- إمكانية توسيع نطاق البحث عبر استخدام تقنيات تعلم عميق أكثر تعقيداً أو دمج متغيرات اقتصادية إضافية.
- الجمع بين المعرفة النظرية والتطبيق العملي للأدوات الكمية مع التأكيد على أهمية استخدام تقنيات الذكاء الاصطناعي والنماذج الإحصائية المتقدمة والمدمجة مع التعلم العميق أو التعلم الآلي لتحسين دقة التنبؤات ودعم اتخاذ قرارات استثمارية أفضل وبذلك يقلل من تأثير شدة التقلبات غير المتوقعة في الأسواق المالية ومنه تحقيق توازن فعال بين المخاطرة والعائد.

- يمكن الاستفادة من النموذج في دعم القرارات المالية مع إمكانية تطويره مستقبلا عبر إضافة متغيرات جديدة أو استخدام تقنيات تعلم آلي أكثر تقدما كالنماذج الهجينة التي تجمع بين الشبكات العصبية والتعلم المعزز.
- تجربة نماذج هجينة تجمع بين Transformer و Graph Neural Networks (GNNs) لدراسة العلاقات بين مختلف الأسهم والأسواق المالية والمتغيرات الاقتصادية الأخرى.
- اختبار نماذج هجينة تجمع بين الشبكات العصبية الاصطناعية ونماذج اقتصادية تقليدية كنموذج GARCH ونموذج التقلبات العشوائية لتعزيز دقة التنبؤ.
- تطبيق منهجيات وتقنيات مختلفة لمعالجة القيم المفقودة مثل Kalman Filter لتحسين جودة البيانات قبل التدريب.
- توسيع الدراسة لتشمل أسواق مالية أخرى لمقارنة أداء النموذج عبر بيئات اقتصادية مختلفة.
- تصميم أداة برمجية أو نظام دعم قرار مبني على النموذج المقترح ليساعد صناع القرار أو المستثمرين في التنبؤ بالأسعار وقياس وتحليل المخاطر المالية.

قائمه المراد جمع

أولاً: المراجع العربية

1. أز هري الطيب الفكي أحمد. (2017). *أسواق المال* (الطبعة الأولى). (دار الجنان للنشر والتوزيع).
2. أسامة عبد الخالق الأنصاري. (2006). *الإدارة المالية*. دار كتب عربية.
3. أصول للإستشارات والتداول المالي. (2025, January 23). بورصة إسطنبول. <https://www.osoulfx.com/a/9651>.
4. أمين السيد أحمد لطفي. (2006). *التحليل المالي لأغراض تقييم ومراجعة الأداء والاستثمار في البورصة*. الدار الجامعية.
5. إبراهيم الكراسنة. (2010). *إرشادات عملية في تقييم الأسهم والسندات*. معهد السياسات الاقتصادية، صندوق النقد العربي.
6. احمد حسن الهيبي & فخر الدين أيوب اوس. (2012). دور السياسات النقدية والمالية في النمو الاقتصادي. مجلة جامعة الأنبار للعلوم الاقتصادية والإدارية. 08.
7. الجريش عبد الله سليمان. (2018). *تداول الأسهم في السوق المالية: دراسة تأصيلية مقارنة* (الطبعة الأولى). (دار المنهل).
8. العربية. (2025, January 23). بورصة إسطنبول. <https://www.alarabiya.net/aswaq>.
9. أيهم محمود الحميد. (2020). *الكفاءة السعرية والتنبؤ بمؤشر السوق المالي باستخدام النماذج القياسية والشبكات العصبونية الاصطناعية: دراسة مقارنة بين سوق دمشق للأوراق المالية وبعض أسواق المال العربية* [بحث علمي مقدم لنيل درجة الدكتوراه في التمويل والمصارف].
10. بشارت بهاء محمد سعد. (2021). *زكاة الأسهم دراسة فقهية مقارنة* [رسالة ماجستير].
11. بودريوة أ. & عبد الحكيم س. (2019). أثر بعض متغيرات الاقتصاد الكلي على المؤشر العام لأسعار الأسهم في بورصة الدار البيضاء المغربية. مجلة الباحث <https://doi.org/10.35156/0505-000-019-021> 313-324.
12. حاووط م. س. (2020). استخدام المؤشرات الفنية والشبكات العصبونية للتنبؤ بحركة أسعار الأسهم: دراسة تطبيقية على بورصة عمان. مجلة جامعة القدس المفتوحة للبحوث الإدارية والاقتصادية. 44, (14), 5.
13. حماد طارق عبد العال. (2006). *التحليل الفني والتحليل الأساسي للأوراق المالية*. الدار الجامعية.
14. خالد بن عبد العزيز السهلاوي & عبد القادر محمد أحمد عبد الله. (2007). *الإدارة المالية* (الطبعة الخامسة). (مطابع السروات للطباعة والنشر).
15. خالد وهيب الراوي. (2000). *الأسواق المالية والنقدية* (الطبعة الأولى). (دار المسيرة).
16. سالم صلال راهي الحسنوي. (2019). *أساسيات الإدارة المالية* (الطبعة الأولى). (الدار المنهجية للنشر والتوزيع).
17. شعبان محمد إسلام البرواري. (2002). *بورصة الأوراق المالية من منظور إسلامي دراسة تحليلية نقدية* (الطبعة الأولى). (دار الفكر).
18. طارق عبد العال حماد. (2008). *التقييم وإعادة هيكلة الشركات*. الدار الجامعية.
19. طلال كداوي. (2008). *تقييم القرارات الاستثمارية*. دار اليازوري للنشر والتوزيع.
20. عاشور مروان عبد الحميد. (2018). *الشبكات العصبونية الاصطناعية وطرائق تنبؤ السلاسل الزمنية* (الطبعة الأولى). (دار الذاكرة للنشر والتوزيع).
21. عدنان تايه النعيمي & أرشد فؤاد التميمي. (2007). *التحليل والتخطيط المالي اتجاهات معاصرة*. دار اليازوري.
22. ليث حليم مالك الحجيبي. (2022). *التنبؤ بأسعار الأسهم باستخدام الشبكات العصبونية الاصطناعية: دراسة لعينة من الشركات المدرجة في سوق العراق للأوراق المالية* [رسالة الماجستير في العلوم المالية والمصرفية]. <https://doi.org/10.13140/RG.2.2.27233.79201>
23. فاخر عبد الستار حيدر. (2002). *التحليل الاقتصادي لتغيرات الأسعار الأسهم المنهج الاقتصادي الكلي*. دار المريخ للنشر.
24. فليح حسن خلف. (2006). *الأسواق المالية والنقدية* (الطبعة الأولى). (جدارا للكتاب العلمي للنشر والتوزيع).
25. كارين أ. هورشر، عطاء الله وارد خليل & محمد عبد الفتاح العشماوي. (2008). *أساسيات إدارة المخاطر المالية*. مكتبة الحرية للنشر والتوزيع.
26. محمد صالح جابر. (2005). *الاستثمار في الأسهم والسندات وإدارة المحافظ* (الطبعة الثالثة). (دار وائل للنشر).
27. محمد صالح الحناوي، نهال فريد مصطفى & جلال إبراهيم العبد. (2007). *تقييم الأسهم والسندات، مدخل الهندسة المالية*. المكتب الجامعي الحديث.
28. محمد عبد الله شاهين محمد. (2018). *أسواق المال بين الأرباح والخسائر: العوائد والمخاطر* (الطبعة الأولى). (دار حميثرا للنشر والترجمة والتوزيع).

قائمة المراجع

29. محمد عبده & محمد مصطفى. (1998). *تقييم الشركات والأوراق المالية لأغراض التعامل في البورصة*. الدار الجامعية للطباعة والنشر.
30. محمد محمود الخطيب. (2010). *الأداء المالي وأثره على عوائد الشركات المساهمة* (الطبعة الأولى). (دار الحامد للنشر والتوزيع).
31. محمد مطر. (2015). *إدارة الاستثمارات الإطار النظري والتطبيقات العملية* (الطبعة السابعة). (دار وائل للطباعة والنشر والتوزيع).
32. محمود محمد الداغر. (2005). *الأسواق المالية؛ مؤسسات أوراق بورصات Vol. :الإصدار الأول* (الطبعة الأولى). (دار الشروق للنشر والتوزيع).
33. مروان جمعة درويش. (2019). *فعالية التنبؤ بمؤشر بورصة فلسطين باستخدام نموذج الشبكات العصبية الاصطناعية: مقارنة بنموذج الانحدار الذاتي*. مجلة جامعة القدس المفتوحة للبحوث الإدارية والاقتصادية. 75-95, 10(3), <https://doi.org/https://doi.org/10.5281/zenodo.2545384>
34. مصطفى يوسف كافي. (2014). *تحليل وإدارة بورصة الأوراق المالية*. دار مؤسسة رسلان للطباعة والنشر والتوزيع.
35. مقابلة سهيل & عيسى محمد. (2013). *كيف تستثمر بسوق الأسهم* (الطبعة الأولى).
36. منير إبراهيم هندي. (2006). *الأوراق المالية وأسواق المال*. توزيع منشأة المعارف.
37. منير إبراهيم هندي. (2008). *أساسيات الاستثمار وتحليل الأوراق المالية الأسهم والسندات* (الطبعة الثانية). (منشأة المعارف).
38. نزار كاظم الخيكاني & حيدر يونس الموسوي. (2018). *السياسات الاقتصادية* (الطبعة الأولى). (دار اليازوري).
39. نظير رياض محمد الشحات. (2007). *إدارة محافظ الأوراق المالية في ظل حوكمة الشركات*. مجلة الدراسات والبحوث التجارية، العدد. 1(36)

ثانيا: المراجع الأجنبية

1. Adebisi, A. A., Adewumi, A. O., & Ayo, C. K. (2014). Comparison of ARIMA and Artificial Neural Networks Models for Stock Price Prediction. *Journal of Applied Mathematics*, 2014, 1–7. <https://doi.org/10.1155/2014/614342>
2. Aggarwal, C. C. (2018). *Neural Networks and Deep Learning*. Springer International Publishing. <https://doi.org/10.1007/978-3-319-94463-0>
3. Akshay Kulkarni, Adarsha Shivananda, & Anoosh Kulkarni. (2022). *Natural Language Processing Projects, Build Next-Generation NLP Applications Using AI Techniques* (First Edition). Apress.
4. Akshay Kulkarni, Adarsha Shivananda, Anoosh Kulkarni, & Dilip Gudivada. (2023). *Applied Generative AI for Beginners, Practical Knowledge on Diffusion Models, ChatGPT, and Other LLMs* (First Edition). Apress.
5. Alain Rivet. (2003). *Gestion financière Analyse et politique financières de l'entreprise*. Ellipses Edition.
6. Alexander J. McNeil, Rüdiger Frey, & Paul Embrechts. (2015). *Quantitative Risk Management: Concepts, Techniques and Tools* (Revised Edition). Princeton University Press.
7. Altawell Najib. (2022). *Introduction to Machine Olfaction Devices* (First Edition). Academic Press Elsevier.
8. Andina Diego, & Duc Truong Pham. (2007). *Computational Intelligence: For engineering and manufacturing* (First Edition). Springer US. <https://doi.org/10.1007/0-387-37452-3>
9. Andreas C. Müller, & Sarah Guido. (2017). *Introduction to Machine Learning with Python, A Guide for Data Scientists* (First Edition). O'Reilly Media, Inc.
10. Anirudh Aggarwal, Mohit Bansal, Tanishq Verma, & Apoorvi Sood. (2022). Residual in Residual Cascade Network for Single-Image Super Resolution. Proceedings of AICTC 2021. In Vishal Goar, Manoj Kuri, Rajesh Kumar, & Tomonobu Senjyu (Eds.), *Advances in Information Communication*

- Technology and Computing* (Vol. 392). Springer. <https://doi.org/https://doi.org/10.1007/978-981-19-0619-0>
11. Anna Bijelic, & Tilila Ouijjane. (2019). *Predicting Exchange Rate Value-at-Risk and Expected Shortfall: A Neural Network Approach* [Master Thesis in Finance]. Lund University.
 12. Annaïck Guyvarc'h, Arnaud Thauvron, & Alain Burlaud. (2012). *Finance Manuel* (5e Edition). Fourcher Edition.
 13. Anthony Saunders, & Marcia Millon Cornett. (2018). *Financial Institutions Management A Risk Management Approach* (Ninth Edition). McGraw-Hill Education.
 14. Anthony Tarantino, & Deborah Cernauskas. (2009). *Risk management in finance: six sigma and other next generation techniques*. John Wiley & Sons, Inc.
 15. Arian, H., Moghimi, M., Tabatabaei, E., & zamani, shiva. (2020). Encoded Value-at-Risk: A Predictive Machine for Financial Risk Management. *SSRN Electronic Journal*.
<https://doi.org/10.2139/ssrn.3712704>
 16. Arif, T. M. (2020). *Introduction to Deep Learning for Engineers: Using Python and Google Cloud Platform* (First Edition). Springer International Publishing. <https://doi.org/10.1007/978-3-031-79665-4>
 17. Aswath Damodaran. (2012). *Investment valuation: tools and techniques for determining the value of any asset* (Third Edition). John Wiley & Sons, Inc.
 18. Aurélien Geron. (2022). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems* (Third Edition). O'Reilly Media.
 19. Bernard Barthélemy, & Philippe Courrèges. (2004). *Gestion des Risque Méthode d'optimisation globale* (Deuxième édition). Éditions d'Organisation.
 20. Bhattacharyya Siddhartha. (2019). *Intelligent Innovations in Multimedia Data Engineering and Management* (First Edition). IGI Global. <https://doi.org/10.4018/978-1-5225-7107-0>
 21. Bhowmik, R., & Wang, S. (2020). Stock Market Volatility and Return Analysis: A Systematic Literature Review. *Entropy*, 22(5), 522. <https://doi.org/10.3390/e22050522>
 22. Bishop, C. M., & Bishop, H. (2024). *Deep Learning: Foundations and Concepts*. Springer International Publishing. <https://doi.org/10.1007/978-3-031-45468-4>
 23. Blanchard, O., & Watson, M. (1982). *Bubbles, Rational Expectations and Financial Markets* (Issue 0945). <https://EconPapers.repec.org/RePEc:nbr:nberwo:0945>
 24. Bodie Zvi, Kane Alex, & Marcus Alan J. (2014). *Investments* (Tenth Edition). McGraw-Hill.
 25. Bodie Zvi, Kane Alex, & Marcus Alan J. (2018). *Investments* (Eleventh Edition). McGraw-Hill Education.
 26. borsaistanbul. (2025, January 23). بورصة إسطنبول. <https://www.borsaistanbul.com/tr/>.
 27. Bottou, L. (2010). Large-Scale Machine Learning with Stochastic Gradient Descent. In *Proceedings of COMPSTAT'2010* (pp. 177–186). Physica-Verlag HD. https://doi.org/10.1007/978-3-7908-2604-3_16
 28. Boulila, W., Driss, M., Alshantiti, E., Al-Sarem, M., Saeed, F., & Krichen, M. (2022). Weight Initialization Techniques for Deep Learning Algorithms in Remote Sensing: Recent Trends and Future Perspectives. In *Advances on Smart and Soft Computing* (pp. 477–484).
https://doi.org/10.1007/978-981-16-5559-3_39
 29. Boulila, W., Alshantiti, E., Alzahem, A., Koubaa, A., & Mlaiki, N. (2024). An effective weight initialization method for deep learning: Application to satellite image classification. *Expert Systems with Applications*, 254, 124344. <https://doi.org/10.1016/j.eswa.2024.124344>

30. Bradley, X., & Descamps, C. (2005). Monnaie, banque, financement. In *Monnaie, banque, financement*. Hyper Cours Dalloz.
31. Brigham, E. F. ., & Houston, J. F. . (2019). *Fundamentals of financial management*. Cengage Learning.
32. Brown, T. B., Mann, B., Ryder, N., Subbiah, M., Kaplan, J., Dhariwal, P., Neelakantan, A., Shyam, P., Sastry, G., Askell, A., Agarwal, S., Herbert-Voss, A., Krueger, G., Henighan, T., Child, R., Ramesh, A., Ziegler, D. M., Wu, J., Winter, C., ... Amodei, D. (2020). *Language Models are Few-Shot Learners*.
33. Buczynski, M., & Chlebus, M. (2024). GARCHNet: Value-at-Risk Forecasting with GARCH Models Based on Neural Networks. *Computational Economics*, 63(5), 1949–1979.
<https://doi.org/10.1007/s10614-023-10390-7>
34. Burton G Malkiel. (2014). *A Random Walk Down Wall Street: The Time-Tested Strategy for Successful Investing*. W. W. NORTON & COMPANY.
35. Byanjankar, A., Heikkila, M., & Mezei, J. (2015). Predicting Credit Risk in Peer-to-Peer Lending: A Neural Network Approach. *2015 IEEE Symposium Series on Computational Intelligence*, 719–725.
<https://doi.org/10.1109/SSCI.2015.109>
36. Cahyadi, J., & Zahra, A. (2024). Bitcoin Price Prediction Model Development Using Convolutional Neural Network (CNN) and Long Short-Term Memory (LSTM). *Journal La Multiapp*, 5(2), 52–62.
<https://doi.org/10.37899/journallamultiapp.v5i2.1070>
37. Campbell, P. (2017). *Look What Entrepreneurs, Business Owners, Investors, and Advisors Are Saying About This Gem of a Book*.
38. Chandrika, P. V., & Srinivasan, K. S. (2021). Predicting Stock Market Movements Using Artificial Neural Networks. *Universal Journal of Accounting and Finance*, 9(3), 405–410.
<https://doi.org/10.13189/ujaf.2021.090315>
39. Carol Alexander. (2008). *Market Risk Analysis Quantitative Methods in Finance*. John Wiley & Sons.
40. Carrizosa, E., Molero-Río, C., & Romero Morales, D. (2021). Mathematical optimization in classification and regression trees. *TOP*, 29(1), 5–33. <https://doi.org/10.1007/s11750-021-00594-1>
41. Chaigusin, S. (2011). *An investigation into the use of neural networks for the prediction of the stock exchange of Thailand* [This thesis is presented in fulfilment of the requirements for the degree of Doctor of Information Technology, Edith Cowan University].
<https://api.semanticscholar.org/CorpusID:166779017>
42. Chapelle, O., Schölkopf, B., & Zien, A. (2006). *Semi-Supervised Learning*. MIT Press.
43. Charu C Aggarwal, & Chandan K Reddy. (2014). *DATA CLUSTERING Algorithms and Applications*. CRC Press is an imprint of Taylor & Francis Group, an Informa business/Chapman & Hall Data Mining and Knowledge Discovery Series.
44. Chirita Mioara. (2012). *Usefulness of Artificial Neural Networks for Predicting Financial and Economic Crisis* (Issue 2). University of Galati Fascicle I. Economics and Applied Informatics. www.ann.ugal.ro/eco
45. Chollet, F. (2021). *Deep Learning with Python* (Second Edition). Manning Publications Co.
46. Christos Stergiou, & Dimitrios Siganos. (2011). NEURAL NETWORKS. *96 Journal, Imperial College London*, 14(2), 218–231. http://www.doc.ic.ac.uk/~nd/surprise_96/journal/vol4/cs11/report.html
47. Clyde P. Stickney. (1998). The Academic's Approach to Securities Research: Is it Relevant to the Analyst? *Journal of Financial Statement Analysis*, 2(4).
48. Cox, D., & Cox, M. (2006). *The Mathematics of Banking and Finance*. John Wiley & Sons Ltd.

49. Coyle Brian. (2002). *Debt and Equity Markets, Overview of the Markets* (Revised Edition). Financial World Publishing Global Professional Publishing, IFS House.
50. da Silva, I. N., Hernane Spatti, D., Andrade Flauzino, R., Liboni, L. H. B., & dos Reis Alves, S. F. (2017). *Artificial Neural Networks A Practical Course*. Springer International Publishing. <https://doi.org/10.1007/978-3-319-43162-8>
51. Darrell Duffie, & Kenneth J. Singleton. (2003). *Credit Risk: Pricing, Measurement, and Management*. Princeton University Press, Princeton and Oxford.
52. Davenport Thomas H, & Dyché Jill. (2013). *Big Data in Big Companies*. International Institute for Analytics.
53. David Brown. (2024). *International Neural Network Society*. <https://www.inns.org> .
54. David Ruppert, & David S. Matteson. (2015). *Statistics and Data Analysis for Financial Engineering with R examples* (Second Edition). Springer.
55. David S. Moore, George P. McCabe, & Bruce A. Craig. (2009). *Introduction to the Practice of Statistics* (Sixth Edition). W. H. Freeman and Company.
56. Deng, Z., Cao, Y., Zhou, X., Yi, Y., Jiang, Y., & You, I. (2020). Toward Efficient Image Recognition in Sensor-Based IoT: A Weight Initialization Optimizing Method for CNN Based on RGB Influence Proportion. *Sensors*, 20(10), 2866. <https://doi.org/10.3390/s20102866>
57. Denis Rothman. (2021). *Transformers for Natural Language Processing: Build innovative deep neural network architectures for NLP with Python, PyTorch, TensorFlow, BERT, RoBERTa, and more*. Packt Publishing.
58. Dev, Dipayan. (2017). *Deep learning with Hadoop : build, implement and scale distributed deep learning models for large-scale datasets* (First Edition). Packt Publishing Ltd.
59. Du, K.-L., & Swamy, M. N. S. (2019). *Neural Networks and Statistical Learning* (Second Edition). Springer London. <https://doi.org/10.1007/978-1-4471-7452-3>
60. Edward Bassetti. (2007). *Technical Analysis of Stock Trends* (9th Edition). Amacom.
61. Edwin J. Elton, Martin J. Gruber, Stephen J. Brown, & William N. Goetzmann. (2014). *Modern Portfolio Theory and Investment Analysis* (Ninth Edition). John Wiley & Sons.
62. Elfving, S., Uchibe, E., & Doya, K. (2017). Sigmoid-Weighted Linear Units for Neural Network Function Approximation in Reinforcement Learning. *Neural Networks*.
63. Enke, D., & Thawornwong, S. (2005). The use of data mining and neural networks for forecasting stock market returns. *Expert Systems with Applications*, 29(4), 927–940. <https://doi.org/10.1016/j.eswa.2005.06.024>
64. Eric R Kandel, James H Schwartz, Thomas M Jessell, Steven A Siegelbaum, & A J Hudspeth. (2012). *Principles of Neural Science* (Fifth Edition). McGraw-Hill Education/Medical.
65. Eugene F. Brigham, & Houston F. Joel. (2016). *Fundamentals of Financial management* (14Ed Edition). Cengage Learning.
66. Fabozzi Frank J, & Peterson Drake Pamela. (2009). *Finance: Capital Markets, Financial Management, and Investment Management*. John Wiley & Sons.
67. Fama, E. F. (1970). Efficient Capital Markets: A Review of Theory and Empirical Work. *The Journal of Finance*, 25(2), 383–417. <https://doi.org/10.2307/2325486>
68. Fatouros, G., Makridis, G., Kotios, D., Soldatos, J., Filippakis, M., & Kyriazis, D. (2023). DeepVaR: a framework for portfolio risk assessment leveraging probabilistic deep neural networks. *Digital Finance*, 5(1), 29–56. <https://doi.org/10.1007/s42521-022-00050-0>

69. Ferran Eilís, & Look Chan Ho. (2014). *Principles of Corporate Finance Law* (Second Edition). OXFORD University Press.
70. Fouad, M. M., Mahany, A., & Katib, I. (2020). Masdar: A Novel Sequence-to-Sequence Deep Learning Model for Arabic Stemming. In *Advances in Intelligent Systems and Computing* (Vol. 1038, pp. 363–373). Springer. https://doi.org/10.1007/978-3-030-29513-4_26
71. François Chollet, & J. J. Allaire. (2018). *Deep Learning With R*. Manning Publications.
72. Frank K. Crundwell. (2008). *Finance for Engineers Evaluation and Funding of Capital Projects*. Springer-Verlag edition.
73. Frank K. Reilly, & Keith C. Brown. (2012). *Investment Analysis and Portfolio Management* (Tenth Edition). South-Western Cengage Learning.
74. George E.P. Box, Gwilym M. Jenkins, Gregory C. Reinsel, & Greta M. Ljung. (2016). *Time series analysis: forecasting and control* (Fifth edition). John Wiley & Sons, Inc. Publication.
75. Gérard-Philippe Ranson, Dominique Chesneau, Jean-François Théodore, & Philippe de Ladoucette. (2006). *Trésorerie risques de marchés et gouvernement d'entreprise* (2e édition). Economica.
76. Ghatak, A. (2019). *Deep Learning with R* (First Edition). Springer Singapore. <https://doi.org/10.1007/978-981-13-5850-0>
77. Ghosh, A., Bose, S., Maji, G., Debnath, N. C., & Sen, S. (2019). Stock Price Prediction Using LSTM on Indian Share Market. In *Proceedings of 32 Nd International Conference on Computer Applications in Industry and Engineering*, 101–190. <https://doi.org/10.29007/qgcz>
78. Gitman Lawrence J, & Zutter Chad J. (2012). *Principles of Managerial Finance* (Thirteenth Edition). Pearson Education. www.myfinancelab.com
79. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
80. Graupe, D. (2013). *Principles of Artificial Neural Networks* (3rd Edition, Vol. 7). World Scientific Publishing Co. Pte. Ltd. <https://doi.org/10.1142/8868>
81. Guang-Bin Huang, Qin-Yu Zhu, & Chee-Kheong Siew. (2004). Extreme learning machine: a new learning scheme of feedforward neural networks. *2004 IEEE International Joint Conference on Neural Networks (IEEE Cat. No.04CH37541)*, 985–990. <https://doi.org/10.1109/IJCNN.2004.1380068>
82. Gunnar Bardsen, Øyvind Eitrheim, Eilev S. Jansen, & Ragnar Nymoen. (2005). *The Econometrics of Macroeconomic Modelling* (First published). Oxford University Press.
83. gurufocus. (2025, January 23). بورصة إسطنبول BIST100 مؤشر. <https://www.gurufocus.com/>
84. Haji Saad Hikmat, & Mohsin Abdulazeez, A. (2021). Comparison of optimization techniques based on gradient descent algorithm: A review. *PalArch's Journal of Archaeology of Egypt/Egyptology*, 18(4), 2715–2743.
85. Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction* (Second Edition). Springer. <https://doi.org/10.1007/978-0-387-84858-7>
86. Haykin, S. S. . (2009). *Neural networks and learning machines* (Third Edition). Prentice Hall/Pearson.
87. Herbert B. Mayo. (2021). *Investment an Introduction* (13e Edition). Cengage Learning.
88. Hinton, G. E., Osindero, S., & Teh, Y.-W. (2006). A Fast Learning Algorithm for Deep Belief Nets. *Neural Computation*, 18(7), 1527–1554. <https://doi.org/10.1162/neco.2006.18.7.1527>
89. Huang, D., Zhu, S.-S., Fabozzi, F. J., & Fukushima, M. (2008). Portfolio selection with uncertain exit time: A robust CVaR approach. *Journal of Economic Dynamics and Control*, 32(2), 594–623. <https://doi.org/10.1016/j.jedc.2007.03.003>

90. Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: Principles and Practice* (Second Edition). OTexts.
91. investing. (2023, April 17). أكبر انهيارات الأسواق في التاريخ. Investing.
92. investing. (2024, November 30). *World and Sector Indices*. <https://sa.investing.com>.
93. James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). *An Introduction to Statistical Learning with Applications in R* (First Edition, Vol. 103). Springer New York. <https://doi.org/10.1007/978-1-4614-7138-7>
94. James, G., Witten, D., Hastie, T., & Tibshirani, R. (2021). *An Introduction to Statistical Learning with Applications in R* (Second Edition). Springer US. <https://doi.org/10.1007/978-1-0716-1418-1>
95. James Lam. (2014). *Enterprise risk management: from incentives to controls* (Second Edition). Published by John Wiley & Sons, Inc.
96. James M Wahlen, Stephen P Baginski, & Mark T Bradshaw. (2018). *Financial Reporting, Financial Statement Analysis and Valuation* (9e Edition). Cengage Learning Inc.
97. James R. Hitchner. (2011). *Financial Valuation Application and Models* (3rd Edition). John Wiley & Sons, Inc.
98. Jean-Pierre Fouque, George Papanicolaou, & K. Ronnie Sircar. (2000). *Derivatives in Financial Markets with Stochastic Volatility* (First Published). Cambridge University Press.
99. John C. Hull. (2015). *Risk management and financial institutions* (Fourth Edition). John Wiley & Sons, Inc.
100. John C. Hull. (2022). *Options, futures, and other derivatives* (Eleventh Edition). Pearson.
101. Jolliffe I. T. (2002). *Principal Component Analysis* (Second Edition). Springer-Verlag. <https://doi.org/10.1007/b98835>
102. Jonathan Berk, Peter Demarzo, Jarrad Harford, Guy Ford, Vito Mollica, & Nigel Finch. (2014). *Fundamentals of Corporate Finance* (2nd edition). Pearson Australia Group Pty Ltd.
103. Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255–260. <https://doi.org/10.1126/science.aaa8415>
104. Joshi, G. (2023). *Optimization Algorithms for Distributed Machine Learning*. Springer International Publishing. <https://doi.org/10.1007/978-3-031-19067-4>
105. Joshi, A. V. (2020). *Machine Learning and Artificial Intelligence* (First Edition). Springer International Publishing. <https://doi.org/10.1007/978-3-030-26622-6>
106. Juan R. Terven, Cordova-Esparza, D.-M., Romero-González, J.-A., Ramírez-Pedraza, A., & Edgar A. Chavez-Urbiola. (2025). A comprehensive survey of loss functions and metrics in deep learning. *Artificial Intelligence Review*, 58(195), 195. <https://doi.org/10.1007/s10462-025-11198-7>
107. Kantardzic Mehmed. (2019). *Data Mining: Concepts, Models, Methods, and Algorithms* (Third Edition). Wiley-IEEE Press.
108. KAP Kamuyu Aydinlatma Platform. (2025, April 20). *Merkezi Kayit Istanbul*. <https://www.kap.org.tr/tr/sektorler>.
109. Karen A. Horcher. (2005). *Essentials of Financial Risk Management*. John Wiley & Sons, Inc.
110. Karlsson, S., & Nordberg, M. (2015). *Stock market index prediction using artificial neural networks trained on foreign markets AND HOW THEY COMPARE TO A DOMESTIC ARTIFICIAL NEURAL NETWORK* [Degree Project, IN Computer Science, First Level]. KTH ROYAL INSTITUTE OF TECHNOLOGY.

111. Karsoliya, S. (2012). Approximating Number of Hidden layer neurons in Multiple Hidden Layer BPNN Architecture. *International Journal of Engineering Trends and Technology*, 3(6). <http://www.internationaljournalsrg.org>
112. Kevin Dowd. (2005). *Measuring Market Risk* (Second Edition). John Wiley & Sons Ltd.
113. Kiliçarslan, S., & Celik, M. (2021). RSigELU: A nonlinear activation function for deep neural networks. *Expert Systems with Applications*, 174, 114805. <https://doi.org/10.1016/j.eswa.2021.114805>
114. Koduvely Hari M. (2015). *Learning Bayesian Models With R: Become an Expert in Bayesian Machine Learning Methods Using R and Apply the to Solve Real-world Big Data Problems*. Packt Publishing Ltd.
115. Kohonen, T. (2001). *Self-Organizing Maps* (Third Edition, Vol. 30). Springer-Verlag Berlin Heidelberg. <https://doi.org/10.1007/978-3-642-56927-2>
116. Kramer, O. (2016). *Machine Learning for Evolution Strategies* (First Edition, Vol. 20). Springer International Publishing. <https://doi.org/10.1007/978-3-319-33383-0>
117. Kriesel, D. (2005). *A Brief Introduction Neural Networks. this work has been prepared in the framework of a seminar.* http://www.dkriesel.com/en/science/neural_networks<http://www.dkriesel.com/en/tech/snipe>
118. Kubat, M. (2017). *An Introduction to Machine Learning* (Second Edition). Springer International Publishing. <https://doi.org/10.1007/978-3-319-63913-0>
119. Kuriscak, E., Marsalek, P., Stroffek, J., & Toth, P. G. (2015). Biological context of Hebb learning in artificial neural networks, a review. *Neurocomputing*, 152, 27–35. <https://doi.org/10.1016/j.neucom.2014.11.022>
120. Laurent Condamin, Jean-Paul Louisot, & Patrick Naim. (2006). *Risk Quantification: Management, Diagnosis and Hedging*. John Wiley and Sons Ltd.
121. Lazzeri, F. (2021). *Machine Learning for Time Series Forecasting with Python* (First Edition). John Wiley & Sons.
122. Li, M., Zhang, T., Chen, Y., & Smola, A. J. (2014). Efficient mini-batch training for stochastic optimization. *Proceedings of the 20th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 661–670. <https://doi.org/10.1145/2623330.2623612>
123. Loshchilov, I., & Hutter, F. (2019, January 4). Decoupled Weight Decay Regularization. *Published as a Conference Paper at ICLR*.
124. Maas, A. L., Hannun Awni Y, & Ng Andrew Y. (2013). Rectifier Nonlinearities Improve Neural Network Acoustic Models. *Proceedings of the 30th International Conference on Machine Learning*. <https://api.semanticscholar.org/CorpusID:16489696>
125. Malkiel Burton Gordon. (2011). *A Random Walk Down Wall Street: The Time-Tested Strategy for Successful Investing*. W. W. Norton & Company.
126. Mark S. Dorfman. (2004). *Introduction to Risk Management and Insurance* (Eighth Edition). Published by Prentice Hall.
127. Marr Bernard. (2015). *Big Data: Using SMART Big Data, Analytics and Metrics to Make Better Decisions and Improve Performance* (First Edition). John Wiley & Sons Ltd.
128. Martin T. Hagan, Howard B. Demuth, Mark Hudson Beale, & Orlando De Jesús. (2014). *Neural Network Design* (2nd Edition). eBook.
129. Mathieu-Dupas Eve. (2010). Algorithme des k plus proches voisins pondérés et application en Diagnostic. In *42èmes Journées de Statistique*.

130. Mauro Andrea De. (2021). *Data Analytics Made Easy: Analyze and present data to make informed decisions without writing any code*. Packt Publishing Ltd.
131. McCorduck Pamela. (2004). *Machines Who Think: A Personal Inquiry into the History and Prospects of Artificial Intelligence*. A. K. Peters, Ltd.
132. Michèle Mollet, & Georges Langlois. (2011). *Finance d'entreprise DCG6-Manuel et applications* (4e Édition). Foucher.
133. MOHD ZUKIME HJ MAT JUNOH. (2004). PREDICTING GDP GROWTH IN MALAYSIA USING KNOWLEDGE-BASED ECONOMY INDICATORS: A COMPARISON BETWEEN NEURAL NETWORK AND ECONOMETRIC APPROACHES. *Sunway College Journal*, 1, 39–50.
134. Montavon Grégoire, Orr Geneviève B, & Müller Klaus-Robert. (2012). *Neural Networks: Tricks of the Trade* (Second Edition, Vol. 7700). Springer Berlin Heidelberg. <https://doi.org/10.1007/978-3-642-35289-8>
135. Moolayil, J. (2019). *Learn Keras for Deep Neural Networks A Fast-Track Approach to Modern Deep Learning with Python*. Apress. <https://doi.org/10.1007/978-1-4842-4240-7>
136. Moolayil Jojo. (2016). *Smarter Decisions–The Intersection of Internet of Things and Decision Science* (First Edition). Packt Publishing Ltd.
137. Mostafa, B., El-Attar, N., Abd-Elhafeez, S., & Awad, W. (2021). Machine and Deep Learning Approaches in Genome: Review Article. *Alfarama Journal of Basic & Applied Sciences*, 2(1), 105–113. <https://doi.org/10.21608/ajbas.2020.34160.1023>
138. Murphy, K. P. . (2012). *Machine learning : a probabilistic perspective*. Massachusetts Institute of Technology Press, MIT Press.
139. Murray R. Spiegel, & Larry J. Stephens. (2008). *Theory and Problems of STATISTICS* (Fourth Edition). McGraw-Hill.
140. Murtagh, F., & Contreras, P. (2017). Algorithms for hierarchical clustering: an overview, <sc>II</sc>. *WIREs Data Mining and Knowledge Discovery*, 7(6). <https://doi.org/10.1002/widm.1219>
141. Nair, V., & Hinton, G. E. (2010). Rectified Linear Units Improve Restricted Boltzmann Machines. *Proceedings of the 27th International Conference on Machine Learning*, 807–814. <https://api.semanticscholar.org/CorpusID:15539264>
142. Neil Shephard. (2005). *Stochastic Volatility Selected Readings*. Oxford University Press.
143. Nielsen, M. (2015). *Neural Networks and Deep Learning*. Determination Press. www.liuhao.me
144. Nilsson, N. J. (2009). *The Quest for Artificial Intelligence*. Cambridge University Press. <https://doi.org/10.1017/CBO9780511819346>
145. Oliva Diego, Essam H Houssein, & Hinojosa Salvador. (2021). *Metaheuristics in Machine Learning: Theory and Applications* (First Edition, Vol. 967). Springer International Publishing. <https://doi.org/10.1007/978-3-030-70542-8>
146. Pagariya, R., & Bartere, M. (2013). Review Paper on Artificial Neural Networks. *International Journal of Advanced Research in Computer Science*, 4(6). www.ijarcs.info
147. Panchal, F. S., & Panchal, M. (2014). Review on Methods of Selecting Number of Hidden Nodes in Artificial Neural Network. *International Journal of Computer Science and Mobile Computing*, 3(11), 455–464. www.ijcsmc.com
148. Patel, M., Padiya, J., & Singh, M. (2022). Fake News Detection Using Machine Learning and Natural Language Processing. In Mohamed Lahby, Al-Sakib Khan Pathan, Yassine Maleh, & Wael

- Mohamed Shaher Yafooz (Eds.), *Combating Fake News with Computational Intelligence Techniques* (Vol. 1001, pp. 127–148). Springer. https://doi.org/10.1007/978-3-030-90087-8_6
149. Pattanayak, S. (2017). *Pro Deep Learning with TensorFlow: A Mathematical Approach to Advanced Artificial Intelligence in Python*. Apress. <https://doi.org/10.1007/978-1-4842-3096-1>
150. Philippe Jorion. (2007). *Value at Risk: The New Benchmark for Managing Financial Risk* (Third Edition). McGraw-Hill.
151. Philippe Jorion GARP. (2007). *Financial Risk Manager Handbook* (Fourth Edition). John Wiley & Sons.
152. Piccinini, G. (2004). The First Computational Theory of Mind and Brain: A Close Look at McCulloch and Pitts's "Logical Calculus of Ideas Immanent in Nervous Activity." *Synthese*, 141(2), 175–215. <https://doi.org/10.1023/B:SYNT.0000043018.52445.3e>
153. Pierre Vernimmen, Pascal Quiry, & Yann LE Fur. (2022). *Corporate Finance: Theory and Practice* (sixth Edition). John Wiley & Sons, Ltd.
154. Pradhan, R. P., & Kumar, R. (2010). Forecasting Exchange Rate in India: An Application of Artificial Neural Network Model. *Journal of Mathematics Research*, 2(4), 111–117. <https://doi.org/10.5539/jmr.v2n4p111>
155. Prince, S. J. D. (2023). *Understanding Deep Learning*. MIT Press. <http://udlbook.com>.
156. Pring Martin J. (2002). *Technical Analysis Explained, The Successful Investor's Guide to Spotting Investment Trends and Turning Points* (Fourth Edition). McGraw-Hill Education.
157. Ramachandran, P., Zoph, B., & Le, Q. V. (2017). *Searching for Activation Functions*.
158. Raoul Fokou. (2006). *Mesure du Risque de Marché d'un Portefeuille de Type Actions (Value-At-Risk, Value-At-Risk Conditionnelle)* [Mémoire de fin d'études présenté en vue de l'obtention du titre d'Actuaire]. Université de Bretagne Occidentale.
159. RiskMetrics Group. (2015). *Value at Risk: Parametric Method, Monte Carlo Simulation, Historical Simulation*. EliScholar – A Digital Platform for Scholarly Publishing at Yale, Yale School Management.
160. Robert J. Shiller. (2019). *Narrative economics, How Stories Go Viral & Drive Major Economic Events* Princeton. Copyright, Princeton University Press princeton & oxford.
161. Rockafellar, R. T., & Uryasev, S. (2000). Optimization of conditional value-at-risk. *The Journal of Risk*, 2(3), 21–41. <https://doi.org/10.21314/JOR.2000.038>
162. Rosa, J. P. S., Guerra, D. J. D., Horta, N. C. G., Martins, R. M. F., & Lourenço, N. C. C. (2020). *Using Artificial Neural Networks for Analog Integrated Circuit Design Automation* (First Edition). Springer International Publishing. <https://doi.org/10.1007/978-3-030-35743-6>
163. Ruder, S. (2016). *An overview of gradient descent optimization algorithms*.
164. Russell Stuart, & Norvig Peter. (2010). *Artificial Intelligence: A Modern Approach* (Third Edition). Prentice Hall.
165. Russom Philip. (2011). *Big Data Analytics* (Fourth Quarter). TDWI Best Practices Report.
166. Sarykalin, S., Serraino, G., & Uryasev, S. (2008). Value-at-Risk vs. Conditional Value-at-Risk in Risk Management and Optimization. In *State-of-the-Art Decision-Making Tools in the Information-Intensive Age* (pp. 270–294). INFORMS. <https://doi.org/10.1287/educ.1080.0052>
167. Sergio M. Focardi, & Frank J. Fabozzi. (2004). *The Mathematics of Financial Modeling and Investment Management*. John Wiley & Sons, Inc.

168. Sharma, S., Sharma, S., & Athaiya, A. (2020). ACTIVATION FUNCTIONS IN NEURAL NETWORKS. *International Journal of Engineering Applied Sciences and Technology*, 04(12), 310–316. <https://doi.org/10.33564/IJEAST.2020.v04i12.054>
169. Shiller, R. J. (2003). From Efficient Markets Theory to Behavioral Finance. *Journal of Economic Perspectives*, 17(1), 83–104. <https://doi.org/10.1257/089533003321164967>
170. Siddique, N., & Adeli, H. (2013). *Computational Intelligence: Synergies of Fuzzy Logic, Neural Networks and Evolutionary Computing* (First Edition). Wiley & Sons, Ltd. <https://doi.org/10.1002/9781118534823>
171. Silva, L. C. B. da, Aching Samatelo, J. L., Vieira Segatto, M. E., Bazzo, J. P., Cardozo da Silva, J. C., Martelli, C., & José Pontes, M. (2018). NARX neural network model for strong resolution improvement in a distributed temperature sensor. *Applied Optics*, 57(20), 5859. <https://doi.org/10.1364/AO.57.005859>
172. Simon Parienté. (2009). *Analyse Financière et évaluation d'entreprise* (2eme édition). Pearson Éducation.
173. Simone Manganello, & Robert F. Engel. (2001). *Value at Risk Models in Finance* (75).
174. Singh, H., & Lone, Y. A. (2020). *Deep Neuro-Fuzzy Systems with Python* (First Edition). Apress. <https://doi.org/10.1007/978-1-4842-5361-8>
175. Sophie Gaultier-Gaillard, & Jean-Paul Louisot. (2014). *Diagnostic des risques Identifier, analyser et cartographier les vulnérabilités* (2eme édition). AFNOR éditions.
176. Stephen A. Ross, Randolph W. Westerfield, & Bradford D. Jordan. (2018). *Fundamentals of Corporate Finance* (Eleventh Edition). McGraw-Hill.
177. Stephen A. Ross, Randolph W. Westerfield, & Bradford D. Jordan. (2011). *Fundamentals of Corporate Finance* (10th Edition). McGraw-Hill Irwin Edition.
178. Sutton, R. S., & Barto, A. G. (2015). *Reinforcement Learning: An Introduction*. in progress (Second edition,). MIT Press.
179. Sutton, R. S., & Barto, A. G. (2018). *Reinforcement Learning An Introduction* (second edition). MIT Press.
180. Ta, V.-D., Liu, C.-M., & Tadesse, D. A. (2020). Portfolio Optimization-Based Stock Prediction Using Long-Short Term Memory Network in Quantitative Trading. *Applied Sciences*, 10(2), 437. <https://doi.org/10.3390/app10020437>
181. Terence C. Mills. (2011). *The Foundations of Modern Time Series Analysis* (First published). PALGRAVE MACMILLAN.
182. Tipirisetty, A. (2018). *Stock Price Prediction using Deep Learning* [Master's thesis and Graduate Research, San Jose State University]. <https://doi.org/10.31979/etd.bzmm-36m7>
183. Tsang, P. M., Kwok, P., Choy, S. O., Kwan, R., Ng, S. C., Mak, J., Tsang, J., Koong, K., & Wong, T.-L. (2007). Design and implementation of NN5 for Hong Kong stock price forecasting. *Engineering Applications of Artificial Intelligence*, 20(4), 453–461. <https://doi.org/10.1016/j.engappai.2006.10.002>
184. Tsay, R. S. (2005). *Analysis of Financial Time Series* (Second Edition). John Wiley & Sons.
185. V. Gangadhar, & Ramesh G. Babu. (2006). *Investment Management*. Anmol Publications Pvt Ltd.
186. Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L., & Polosukhin, I. (2017). *Attention Is All You Need*.

187. Vijh, M., Chandola, D., Tikkiwal, V. A., & Kumar, A. (2020). Stock Closing Price Prediction using Machine Learning Techniques. *Procedia Computer Science*, 167, 599–606.
<https://doi.org/10.1016/j.procs.2020.03.326>
188. Vishal Rajput. (2023). *Ultimate Neural Network Programming with Python: Create Powerful Modern AI Systems by Harnessing Neural Networks with Python, Keras, and TensorFlow*. Orange Education Pvt Ltd.
189. Wang, H. (2020). An Insurance Sales Prediction Model Based on Deep Learning. *Revue d'Intelligence Artificielle*, 34(3), 315–321. <https://doi.org/10.18280/ria.340309>
190. Witten Ian H, Frank Eibe, & Hall Mark A. (2011). *Data Mining: Practical Machine Learning Tools and Techniques* (Third Edition). Morgan Kaufmann Publishers is an imprint of Elsevier.
<https://doi.org/10.1016/C2009-0-19715-5>
191. Xiong, R. (2020). *Battery Management Algorithm for Electric Vehicles* (First Edition). Springer Singapore. <https://doi.org/10.1007/978-981-15-0248-4>
192. YAMADA, Y., & PRIMBS, J. A. (2002). VALUE-AT-RISK ESTIMATION FOR DYNAMIC HEDGING. *International Journal of Theoretical and Applied Finance*, 05(04), 333–354.
<https://doi.org/10.1142/S0219024902001468>
193. Yao, J., & Lim Tan, C. (2002). Guidelines for Financial Forecasting with Neural Networks. *Proceedings of International Conference on Neural Information*, 757–761.
<https://www.researchgate.net/publication/2526217>
194. Yeung, D. S., Cloete, I., Shi, D., & Ng, W. W. Y. (2010). *Sensitivity Analysis for Neural Networks* (First Edition). Springer Berlin Heidelberg. <https://doi.org/10.1007/978-3-642-02532-7>
195. Yun Hsing Cheung, & Robert J. Powell. (2013). Anybody can do Value at Risk: A Teaching Study using Parametric Computation and Monte Carlo Simulation. *Australasian Accounting, Business and Finance Journal*, 6(5), 101–118.
196. Zenti, R., & Pallotta, M. (2001). Risk Analysis for Asset Managers: Historical Simulation, the Bootstrap Approach and Value at Risk Calculation. *SSRN Electronic Journal*.
<https://doi.org/10.2139/ssrn.251669>
197. Zvi Bodie, Alex Kane, & Alan J. Marcus. (2013). *Essentials of Investments* (Ninth Edition). McGraw-Hill.