

اختبار التعلم الآلي نموذج LSTM في تعزيز دقة التنبؤ بعوائد الأسهم العادية
 دراسة تحليلية لشركات مدرجة في سوق العراق للأوراق المالية للمدة (2016-2024)
 Testing the machine learning model LSTM in enhancing the
 accuracy of predicting returns of common stocks: An analytical
 study of companies listed on the Iraq Stock Exchange for the
 period(2016-2024)

أ.م.د حيدر حضير جوان
 A. M. Haider Hadhir Jwan
 hayder.jwan@uokerbala.edu.iq
 جامعة كربلاء/كلية الإدارة والاقتصاد
 Karbala University / College of
 Administration and Economics

حسين إسماعيل حسين حسن
 Hussein Ismail Hussein Hassan
 hussein.i@s.uokerbala.edu.iq
 جامعة كربلاء/كلية الإدارة والاقتصاد
 Karbala University / College of
 Administration and Economics

أ.د. حسام حسين شياح
 Prof. Dr. Hussam Hussein Shayaa
 hussam.h@uokerbala.edu.iq
 جامعة كربلاء/كلية الإدارة والاقتصاد
 Karbala University / College of Administration and Economics

المستخلص

يمثل التنبؤ بعوائد الأسهم أحد التحديات الأساسية في الأسواق المالية، خصوصاً في البيانات الناشئة التي تتسم بارتفاع مستوى التقلب وضعف الكفاءة مثل سوق العراق للأوراق المالية. تهدف هذه الدراسة إلى تقييم قدرة نموذج الشبكات العصبية طويلة الذاكرة LSTM على التنبؤ بالعائد الشهري لأسهم الشركات المدرجة في سوق العراق، استناداً إلى بيانات شهرية لعينة مكونة من 22 شركة تمثل قطاعات مختلفة للمدة 2016-2024. اعتمدت الدراسة المنهج الكمي التحليلي، الذي شمل معالجة البيانات وتجهيزها، وبناء وتدريب نموذج LSTM وفق متطلبات الشبكات العصبية العميقة، مع تقييم دقة التنبؤ باستخدام مؤشرات MAE و RMSE و MAPE و MSE. أظهرت النتائج أن نموذج LSTM يمتلك قدرة جيدة على التنبؤ بالعوائد الشهرية، إذ بلغ متوسط مربعات الخطأ MSE مقدار 0.0003588، وهي قيمة منخفضة تشير إلى قرب القيم المتنبأ بها من القيم الفعلية. كما بلغ الجذر التربيعي لمتوسط مربعات الخطأ RMSE قيمة 0.0189420، وهو ما يدل على أن متوسط الانحراف بين التنبؤات والعوائد الحقيقية لا يتجاوز نحو 1.9%، مما يعكس كفاءة النموذج في التقاط الأنماط الزمنية في سوق يتسم بقدر كبير من عدم الاستقرار. وتوصي الدراسة باعتماد نماذج الذكاء الاصطناعي، ولاسيما نماذج التعلم العميق مثل LSTM، كأدوات مساندة في تحليل المحافظ الاستثمارية واتخاذ القرارات المالية، إضافة إلى ضرورة توسيع استخدام هذه النماذج في أسواق المال العراقية لتعزيز جودة التنبؤ وإدارة المخاطر. الكلمات الرئيسية: التعلم العميق، نموذج LSTM، التنبؤ بعوائد الأسهم.

Abstract

Predicting stock returns represents one of the fundamental challenges in financial markets, particularly in emerging environments characterized by high volatility and low efficiency, such as the Iraqi Stock Exchange. This study aims to evaluate the ability of companies of the Long Short-Term Memory (LSTM) neural network to predict the monthly stock returns of companies listed on the Iraqi market, using monthly data for a sample of 22 from different sectors for the period 2016–2024. The study employed a quantitative analytical approach that included data preprocessing, model construction, and LSTM training according to deep learning requirements, while assessing predictive accuracy using MAE, RMSE, MAPE, and MSE metrics.

he results indicate that the LSTM model achieved solid predictive performance, with a Mean Squared Error (MSE) of 0.0003588, reflecting a small gap between actual and predicted values. The Root Mean Squared Error (RMSE) reached 0.0189420, suggesting that the average deviation between predictions

and actual returns does not exceed approximately 1.9%, demonstrating the model's ability to capture temporal patterns in a market characterized by instability.

The study recommends adopting artificial intelligence techniques, particularly deep learning models such as LSTM, as supportive tools for portfolio analysis and financial decision-making. It further emphasizes expanding the application of such models in the Iraqi financial markets to enhance forecasting quality and improve risk management.

Keywords: deep learning, LSTM model, stock return prediction.

1. المقدمة

يمثل التنبؤ بعوائد الأسهم إحدى القضايا المركزية في علم التمويل، لما له من أثر مباشر في قرارات بناء المحافظ الاستثمارية وإدارة المخاطر وتخصيص الموارد المالية. ومع تطور الأسواق المالية وازدياد درجة تعقيدها، أصبح السلوك السعري للأسهم أكثر تأثراً بعوامل متنوعة، اقتصادية ومالية وسلوكية، مما يجعل من الصعب التنبؤ بالعوائد باستخدام النماذج التقليدية التي غالباً ما تفترض خطية العلاقات واستقرارها عبر الزمن. ويزداد هذا التحدي في الأسواق الناشئة، ومنها سوق العراق للأوراق المالية، الذي يتسم بخصائص مميزة تشمل التذبذب العالي، في ظل هذه البيئة، برزت الحاجة إلى نماذج أكثر قدرة على التعامل مع الأنماط غير الخطية في البيانات، خصوصاً السلاسل الزمنية المالية التي تتأثر بعوامل قصيرة الأجل وطويلة الأجل. وهنا يأتي دور نماذج التعلم العميق، ولاسيما الشبكات العصبية طويلة الذاكرة (LSTM)، وهي نماذج مصممة للتعامل مع البيانات الزمنية بشكل فعال، من خلال القدرة على الاحتفاظ بالمعلومات المهمة عبر فترات طويلة، والتخلص من التشويش والضوضاء، وهي مشكلات تعجز النماذج التقليدية عن معالجتها بشكل كافٍ.

من هذا المنطلق، يهدف البحث إلى اختبار قدرة نموذج LSTM على التنبؤ بعوائد الأسهم الشهرية للشركات المدرجة في سوق العراق للأوراق المالية، وذلك من خلال بناء نموذج تطبيقي يعتمد على بيانات فعلية لـ 22 شركة موزعة على ستة قطاعات رئيسة للمدة (2016-2024). ويُعد هذا البحث مساهمة علمية مهمة في إثراء الأدبيات العربية المتعلقة بتطبيقات الذكاء الاصطناعي في الأسواق المالية، وتعزيز قدرة المستثمرين على اتخاذ قرارات مبنية على بيانات دقيقة ونماذج حديثة.

الفصل الأول

المبحث الأول

2 منهجية البحث

2-1 مشكلة البحث

تتبع مشكلة البحث من كون الأسواق المالية العراقية تتسم بدرجة عالية من عدم الاستقرار، إضافة إلى محدودية البيانات وغياب المعلومات الكاملة، مما يجعل عملية التنبؤ بعوائد الأسهم أكثر صعوبة. فضلاً عن ذلك، فإن النماذج الإحصائية التقليدية مثل الانحدار الخطي والنماذج المعتمدة على فرضيات ثبات العلاقات غالباً ما تفشل في تمثيل الأنماط العشوائية وغير الخطية للعوائد. من هنا تظهر الحاجة إلى نماذج بديلة ذات قدرات تحليلية أعلى تعتمد على الذكاء الاصطناعي. وبناءً عليه تتمثل مشكلة البحث بالسؤال الآتي: ما مدى فعالية نموذج LSTM في تحسين دقة التنبؤ بعوائد الأسهم للشركات المدرجة في سوق العراق للأوراق المالية؟

2-2 هدف البحث

1. بناء نموذج تطبيقي باستخدام LSTM للتنبؤ بعوائد الأسهم الشهرية.
2. قياس دقة النموذج باستخدام مؤشرات الأداء الإحصائي.

2-3 فرضية البحث

يُظهر نموذج LSTM قدرة تنبؤية عالية في تقدير العوائد الشهرية لأسهم الشركات العراقية المدرجة.

2-4 أهمية البحث

2-4-1 الأهمية العلمية

يسهم هذا البحث في تعزيز الأدبيات العربية المتعلقة بتطبيقات التعلم العميق في الأسواق المالية، كما يقدم نموذجاً تطبيقياً حديثاً يعتمد على خوارزمية LSTM التي ما تزال محدودة الاستخدام في البيئة العربية.

2-4-2- أهمية التطبيقية

يوفر هذا النموذج للمستثمرين أداة دقيقة وقابلة للاستخدام في التنبؤ بالعوائد، ولاسيما في الأسواق المتقلبة مثل السوق العراقي، كما يساعد المؤسسات المالية على رفع مستوى جودة القرارات الاستثمارية وتعزيز كفاءة إدارة المحافظ.

2-5 حدود البحث

تغطي الدراسة المدة الزمنية من 2016 إلى 2024، وتمثل سوق العراق للأوراق المالية المجال المكاني لها، بينما ينحصر مجالها الموضوعي في التنبؤ بعوائد الأسهم باستخدام نموذج LSTM. ويتكون مجتمع البحث من جميع الشركات المدرجة في سوق العراق للأوراق المالية، إلا أن اختلاف تواريخ الإدراج وتفاوت انتظام التداول استلزم الاقتصار على عينة مكونة من 22 شركة موزعة على ستة قطاعات رئيسية كما هو موضح في الجدول أدناه.

الجدول (1) الشركات المكونة لعينة الدراسة

ت	الشركة والقطاع	رمز الشركة	ت	الشركة والقطاع	رمز الشركة
	قطاع المصارف		11	العاب الكرخ السياحية	SKTA
1	مصرف بغداد	BBOB	12	المعمورة العقارية	SMRI
2	المصرف التجاري العراقي	BCOI	13	النخبة للمقاولات العامة	SNUC
3	مصرف الخليج	BGUC		قطاع الصناعة	
4	مصرف الاستثمار العراقي	BIBI	14	بغداد للمشروبات الغازية	IBSD
5	مصرف الشرق الأوسط	BIME	15	العراقية للسجاد والمفروشات	IITC
6	مصرف الموصل للاستثمار	BMFI	16	الكندي للقاحات البيطرية	IKLV
7	مصرف الأهلي العراقي	BNOI	17	المنصور للصناعات الدوائية	IMAP
8	مصرف سومر التجاري	BSUC	18	الخيطة الحديثة	IMOS
	قطاع التأمين			قطاع الفنادق	
9	شركة الأمين للتأمين	NAME	19	فندق بغداد	HBAG
	قطاع الخدمات		20	الوطنية للاستثمارات السياحية	HNTI
10	بغداد العراق للنقل العام	SBPT	21	اساسيل	TASC
			22	الخاتم للاتصالات	TZNI

المصدر: من إعداد الباحث.

وتم اختيار هذه الشركات وفق معايير تتعلق بتوفر البيانات واستمرار التداول خلال فترة البحث، الأمر الذي يضمن تكامل السلسلة الزمنية اللازمة لتدريب النموذج واختباره.

1-5-2-مدة الدراسة ومصادر البيانات

اعتمد البحث على البيانات الشهرية لأسعار الإغلاق للشركات من العينة للفترة الممتدة من: يناير 2016 إلى ديسمبر 2024 وهي فترة تمتاز بطولها الزمني، الأمر الذي يوفر سلسلة بيانات مناسبة لبناء نموذج LSTM الذي يحتاج إلى كمية كبيرة من البيانات والمعطيات التاريخية.

اعتمدت الدراسة على البيانات المالية وأسعار الأسهم الشهرية للشركات المدرجة، والتي جرى الحصول عليها من مجموعة مصادر رسمية وموثوقة. تمثل المصدر الرئيس للبيانات أسعار الإغلاق وتقارير التداول المنشورة في الموقع الرسمي لسوق العراق للأوراق المالية، إضافة إلى الإفصاحات الدورية والتقارير التنظيمية الصادرة عن هيئة الأوراق المالية العراقية. كما استعانت الدراسة بالقوائم المالية السنوية والفصلية الصادرة عن الشركات المدرجة والمتاحة عبر مواقعها الإلكترونية أو من خلال التقارير المدققة المنشورة للسوق.

وتم تحويل الأسعار إلى عوائد شهرية وفق المعادلة:

$$RI_t = \frac{P_t - P_{t-1}}{P_{t-1}}$$

بعدها تم طرح معدل العائد الخالي من المخاطر (RF) عند الحاجة لاشتقاق العائد الزائد Excess Return المستخدم كنتاج تنبؤ.

2-5-2- معالجة البيانات قبل إدخالها إلى النموذج قبل بناء نموذج LSTM ، خضعت البيانات لعدة مراحل من التحضير والمعالجة، وهي خطوات جوهرية في تحسين أداء النموذج، وتشمل:

1-تنظيف البيانات

- I. استبعاد القيم المفقودة
- II. معالجة الفترات التي توقف فيها التداول
- III. فحص القيم الشاذة Outliers والتأكد من عدم تشويبهها لطبيعة السلسلة الزمنية

2- تطبيع البيانات **Normalization** : تم استخدام Min-Max Scaling لجعل القيم بين 0 و 1 وهو أمر ضروري للشبكات العصبية.

3-تقسيم البيانات: جرى تقسيم البيانات إلى:

I. مجموعة تدريب Training Set بنسبة 70 %

II. مجموعة اختبار Testing Set بنسبة 30 %

3-5-3 هيكل السلاسل الزمنية وضع نافذة Sliding Window لسحب متغيرات الإدخال التي تمهد لتنبؤ الشهر اللاحق.

3-5-2 بيئة العمل تم تنفيذ النموذج باستخدام:

I. لغة Python

II. مكتبات Keras وTensorFlow

3-5-4 أدوات التحليل الإحصائي لضمان دقة تقييم أداء نموذج التنبؤ، استخدمت الدراسة أربع أدوات إحصائية قياسية:

1. متوسط مربع الأخطاء (MSE) يقيس المتوسط الكلي للأخطاء بين العوائد الفعلية والمنتبأ به.
2. الجذر التربيعي لمتوسط الأخطاء (RMSE) يتيح قراءة أسهل لنتائج الخطأ لأنها تكون بقيمة قريبة من بيانات المتغير نفسه.
3. توسط القيمة المطلقة للخطأ (MAE) يقيس حجم الانحراف دون المبالغة في قياس الأخطاء الكبيرة.
4. متوسط النسبة المئوية للخطأ (MAPE) يظهر نسبة الخطأ إلى القيمة الحقيقية، وهو مقياس مهم في التمويل.

2-5-5 منهج البحث

اعتمدت البحث المنهج الكمي التحليلي، واستخدمت أدوات التعلم العميق في معالجة وبناء نموذج LSTM، مع تقييم الأداء الإحصائي باستخدام MAE و RMSE و MAPE و MSE، ينتمي البحث إلى منهج الأساليب الكمية، وتحديدًا أسلوب تحليل السلاسل الزمنية، ضمن إطار نماذج التعلم العميق وقد جرى تبني نموذج LSTM نظرًا لملاءمته لخصائص البيانات المالية التي تتسم بالتقلب والعشوائية والاعتماد الذاتي. ويُعد هذا المنهج من الأساليب التطبيقية التي تعتمد على بناء نموذج تدريبي وتغذيته بالبيانات ثم اختبار قدرته التنبؤية.

المبحث الثاني

3- اختبار نموذج التعلم الآلي LSTM في تعزيز دقة التنبؤ بعوائد الأسهم العادية

شهدت السنوات الأخيرة تحولًا كبيرًا في أساليب تحليل الأسواق المالية، حيث أصبح استخدام التعلم العميق أحد أهم الاتجاهات العلمية الحديثة في مجال تحليل السلاسل الزمنية والتنبؤ بعوائد الأسهم. ويعود ذلك إلى قدرة هذه النماذج على تحليل العلاقات غير الخطية، واستخلاص الأنماط المخفية، والتعامل مع الضوضاء والتقلبات التي تميز الأسواق الناشئة مثل سوق العراق للأوراق المالية. وفي هذا الفصل سيتم تقديم إطار نظري موسع حول مفهوم التنبؤ المالي، وطبيعة السلاسل الزمنية للأسهم، والمرتكزات النظرية للتعلم العميق، مع التركيز على شبكة LSTM، وشرح كيفية عملها ودورها في التنبؤ المالي، بالإضافة إلى عرض موسع للدراسات السابقة العالمية والعربية والعراقية ذات العلاقة.

1-3 التنبؤ بعوائد الأسهم في السياق المالي

اكتسب تداول سوق الأسهم شعبية هائلة عالميًا، وأصبح جزءًا من روتين الكثيرين اليومي لتحقيق الأرباح. إلا أن التنبؤ بحركة أسعار الأسهم يُمثل تحديًا نظرًا لتعقيد بيانات سوق الأسهم. يُمكن تعريف التنبؤ بأنه التنبؤ ببعض الأحداث المستقبلية من خلال تحليل البيانات التاريخية. ويشمل هذا التنبؤ مجالات عديدة، بما في ذلك الصناعة والأعمال والاقتصاد والمالية. ومع ذلك، ومع تقدم التكنولوجيا، تتحسن فرص تحقيق ربح ثابت من سوق الأسهم، كما يُساعد الخبراء على إيجاد المؤشرات الأكثر فائدة لتحسين التنبؤات بشكل كبير. تتضمن العديد من مشاكل التنبؤ تحليل الوقت. يُساعد تحليل بيانات السلاسل الزمنية على التعرف على الأنماط والاتجاهات والمراحل أو الدورات الموجودة في البيانات. في حالة سوق الأسهم، تُساعد المعرفة المبكرة بالوضع الصعودي أو الهبوطي على استثمار رأس المال بحكمة. كما تُساعد دراسة الاتجاهات على تحديد أفضل الشركات أداءً خلال فترة زمنية محددة. (Fathali et al., 2022:3) وبناءً على ذلك، أصبح التنبؤ بالعوائد باستخدام النماذج التقليدية محدود الفاعلية، مما دفع الباحثين إلى تبني النماذج الحديثة القائمة على الذكاء الاصطناعي، ولاسيما الشبكات العصبية والتعلم العميق.

2-3 أهمية التنبؤات الدقيقة لسوق الأسهم: لا شك أن أهمية التنبؤات الدقيقة لسوق الأسهم لا تُضاهي في مجال التمويل والاستثمار. يوضح (Oyewole et al., 2024:553) الدور المحوري الذي تلعبه هذه التنبؤات للمستثمرين والمؤسسات المالية، إذ تُمكنهم من اتخاذ قرارات مدروسة، وإدارة المخاطر بفعالية، والمساهمة في استقرار النظام المالي. تُعد القدرة على التنبؤ الدقيق بحركات السوق أساسية في تعظيم العوائد وتقليل الخسائر، وهي حجر الزاوية للمستثمرين الأفراد والمؤسسات على حد سواء الذين يسعون إلى التعامل مع تعقيدات الأسواق المالية. يكمن تحدي التنبؤ بسوق الأسهم في التعقيد المتأصل في الأسواق المالية، والذي يتأثر بمجموعة لا حصر لها من العوامل، بما في ذلك المؤشرات الاقتصادية والأحداث السياسية

ومشاعر المستثمرين. تطبيق الذكاء الاصطناعي في التنبؤ بسوق الأسهم، مُشدد على إمكانات خوارزميات التعلم الآلي ومعالجة اللغة الطبيعية في غرلة مجموعات البيانات الضخمة وتحديد الاتجاهات التي قد تُشير إلى تحركات السوق المستقبلية. على الرغم من التقدم في التكنولوجيا، فإن طبيعة السوق غير المتوقعة، بالإضافة إلى الأحداث غير المتوقعة، تجعل التنبؤ بسوق الأوراق المالية مهمة شاقة. إن السعي وراء التوقعات الدقيقة يُعد التنبؤ بعوائد الأسهم من الموضوعات المحورية في علم التمويل، ويأخذ مكانة خاصة بسبب ارتباطه المباشر بسلوك المستثمرين وتوجهاتهم المستقبلية. وتنبع أهمية التنبؤ من طبيعة الأسواق المالية التي تقوم على تفاعل مستمر بين العرض والطلب، وبين عوامل اقتصادية وسلوكية وسياسية ومعلوماتية. ويُستخدم العائد، الذي يمثل التغير النسبي في سعر السهم، بوصفه مؤشرًا أساسيًا لقياس أداء الشركات وحركة السوق. وتتنوع عوائد الأسهم بخصائص تختلف عن العديد من الظواهر الاقتصادية الأخرى، فهي غالبًا (C. Wang, 2024:5):

1. عالية التقلب
2. تتبع أنماطاً غير خطية
3. تتأثر بعوامل قصيرة وطويلة الأجل
4. تتضمن قدرًا كبيرًا من العشوائية والوضوءاء

في الأسواق المستقرة، مثل الأسواق الأمريكية والأوروبية، يمكن أحيانًا تفسير العوائد عبر نماذج خطية أو شبه خطية، بينما في الأسواق الناشئة ذات السيولة المحدودة والشفافية الضعيفة تميل العوائد إلى التذبذب وعدم الانتظام. وينطبق ذلك بصورة واضحة على السوق العراقي الذي يتأثر بالأحداث الاقتصادية والسياسية، إضافة إلى تأثيره بمستوى التغطية الإعلامية وضعف كفاءة السوق.

2- السلاسل الزمنية المالية وخصائصها تتميز السلاسل الزمنية المالية، مثل أسعار الأسهم والعوائد ومؤشرات السوق، بخصائص فريدة تجعل من معالجتها عملية معقدة تحتاج إلى نماذج متقدمة، ومن أبرز هذه الخصائص: (Kim & Kang, 2019:2)

1. **عدم الخطية** لا تتبع الأسعار المالية خطًا مستقيمًا أو نمطًا رياضيًا ثابتًا، بل تتفاعل بطريقة غير منتظمة مع الأحداث والعوامل الاقتصادية.
2. **ارتباط القيم عبر الزمن** تحتوي البيانات المالية على ما يعرف بـ "الاعتماد الذاتي"، أي أن القيمة المستقبلية تتأثر بالقيم السابقة.
3. **وجود وضوءاء عالية** تتضمن أسعار الأسهم معلومات عشوائية وغير منتظمة تجعل التنبؤ الدقيق عملية صعبة.
4. **تقلبات النظام المالي** تظهر الأسواق الناشئة فروقات كبيرة في حجم التداول، والسيولة، ودرجة المخاطرة، مما يزيد من صعوبة نمذجة البيانات. وتفسر هذه الخصائص الحاجة الفعلية لاستخدام نماذج قادرة على اكتشاف الأنماط العميقة وتجنب الإفراط في التعميم، وهو ما توفره الشبكات العصبية خاصة LSTM.

3-2 الذكاء الاصطناعي والتعلم العميق في تحليل البيانات المالية

ظهر الذكاء الاصطناعي كمنهج جديد في تحليل البيانات المالية معتمدًا على قدرات التعلم الآلي في اكتشاف الأنماط الخفية داخل البيانات. وقد شهدت العقود الأخيرة اهتمامًا متزايدًا باستخدام الخوارزميات في التنبؤ بالأسعار وبناء المحافظ الاستثمارية وإدارة المخاطر. (Paramesha et al., 2024:68)

3-2-1 مفهوم التعلم العميق

التعلم العميق هو فرع من فروع التعلم الآلي يعتمد على بناء شبكات عصبية متعددة الطبقات قادرة على التعلم من البيانات بكميات كبيرة جداً. وتستطيع هذه الشبكات معالجة الأنماط المعقدة التي لا تتمكن النماذج التقليدية من اكتشافها. أما في نطاق الأسواق المالية، فقد أثبتت نماذج التعلم العميق قدرتها على التعامل مع البيانات الزمنية المعقدة والتقلبات السريعة. (Janiesch et al., 2021:656)

3-2-2 الشبكات العصبية كأداة للتنبؤ المالي

لقد غير الذكاء الاصطناعي (AI) الكثير في السنوات القليلة الماضية، والتنبؤ المالي ليس استثناءً. بدلاً من ذلك، يمكن للتحليلات التنبؤية الاستفادة من الخوارزميات المتطورة وتقنيات التعلم الآلي لتحليل كميات هائلة من البيانات التي لم تتمكن النماذج التقليدية من استيعابها. غالبًا ما تعتمد المناهج التقليدية على افتراضات محددة مسبقًا وعلاقات خطية، حيث يمكن لنماذج الذكاء الاصطناعي استخلاص أنماط وارتباطات معقدة من البيانات. جعلت الشبكات العصبية، وأشجار القرار، وأساليب التجميع رؤى البيانات أكثر مرونة وقابلية للتكيف. هذا يسمح للمؤسسات بالحصول على هذه الرؤى من مصادر بيانات غير متجانسة، بما في ذلك مشاعر وسائل التواصل الاجتماعي، وبيانات الاقتصاد الكلي، وبيانات المعاملات. بالإضافة إلى ذلك، يمكن للذكاء الاصطناعي أتمتة عملية التنبؤ، مما يقلل الوقت المستغرق في التحليل ويخفف الحاجة إلى التصحيحات اللاحقة مع ظهور المزيد من البيانات أو بيانات جديدة في عالم مالي سريع الخطى. تقوم الشبكات العصبية بمحاكاة طريقة عمل الدماغ البشري في استقبال البيانات ومعالجتها وتخزين أنماطها، مما يجعلها قادرة على اكتشاف العلاقات المخفية بين المتغيرات المالية. وتبرز أهمية هذه الشبكات حين تتعامل مع بيانات غير خطية وغير مستقرة، مثل أسعار الأسهم. (Faheem et al., 2024:223)

3-3 شبكة الذاكرة الطويلة قصيرة الأجل (LSTM)

3-3-1 مقدمة عن LSTM

تعتبر LSTM أحد أهم النماذج في مجال التعليم العميق، وقد تم تطويرها لمعالجة مشكلة "الاندثار" التي تظهر في النماذج التقليدية للشبكات العصبية منكررة الحلقات (RNN) وتمتاز LSTM بقدرتها على الاحتفاظ بالمعلومات طويلة الأجل بصورة فعالة، مما يجعلها مناسبة للغاية لمعالجة السلاسل الزمنية المالية التي تعتمد على السياق التاريخي (Zhang et al., 2018:920).

3-3-2 آلية عمل LSTM يتكون نموذج LSTM من وحدات تسمى خلايا الذاكرة، تحتوي كل خلية على (Landi et al., 2021:2):

1. بوابة الإدخال
2. بوابة النسيان
3. بوابة الإخراج

وتعمل هذه البوابات على إدارة تدفق المعلومات داخل النموذج، بحيث يتم الاحتفاظ بالمعلومات الضرورية والتخلص من المعلومات غير المفيدة، مما يتيح للنموذج معالجة البيانات المالية المتغيرة بدقة عالية.

3-3-3 أسباب ملائمة LSTM للتنبؤ المالي (Wang et al., 2024:3)

1. القدرة على التعامل مع البيانات الزمنية ذات العلاقات المعقدة
2. مرونة عالية في التعامل مع التقلبات الحادة
3. مقاومة جيدة للضوضاء والعشوائية
4. إمكانية التعلم من البيانات طويلة الأجل

المبحث الثالث

التحليل المالي وتطبيق النموذج

4- الجانب التحليلي لعوائد الأسهم

4-1 سلسلة بيانات العوائد

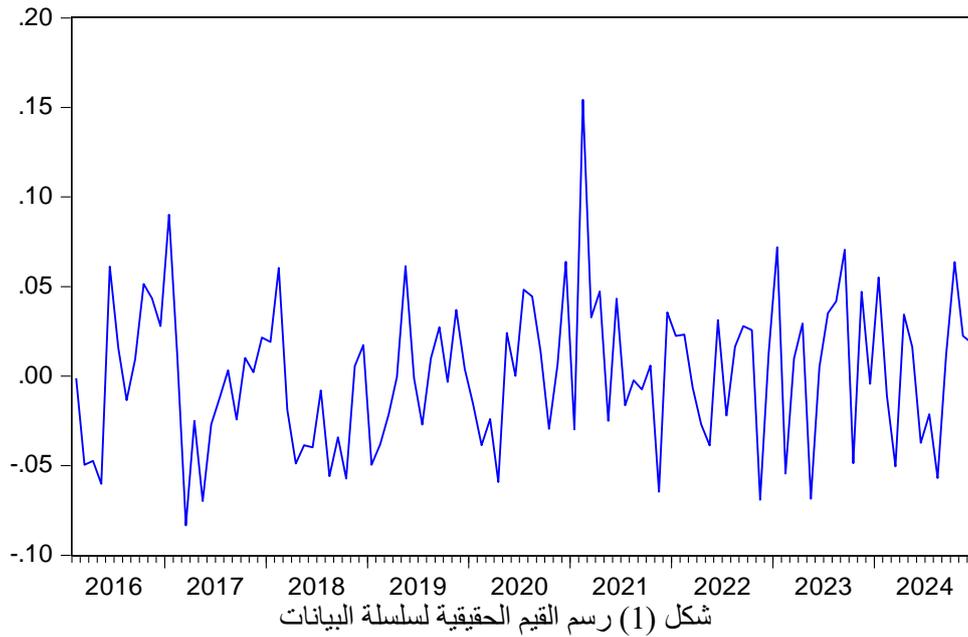
لتحديد بعض خصائص سلسلة البيانات المدروسة قام الباحث برسم البيانات الخاصة بالعوائد وكما في الشكل البياني التالي حيث تُظهر هذه السلسلة الزمنية عوائد الأسهم خلال الفترة الممتدة من عام 2016 حتى عام 2024 حيث يمثل المحور الأفقي الزمن، في حين يعكس المحور العمودي قيم العائد محسوبًا كفرق نسبي في السعر عن الفترة السابقة، مطروحًا منه العائد الخالي من المخاطر.

لقد أظهرت البيانات سلوكًا متقلبًا بطبيعته، وهو ما يُعرف بالتذبذب العالي (high volatility)، وهي سمة شائعة في البيانات المالية. إذ يلاحظ في بعض الفترات، مثلًا ما بين عامي 2020 و2021، وجود ارتفاعات يليها انخفاضات سريعة، وهذا السلوك على الأرجح هو انعكاس للتقلبات في الأسواق المالية. في المقابل، هناك فترات أخرى أكثر استقرارًا، حيث تنقلب العوائد ضمن نطاق ضيق نسبيًا، ما يشير إلى استقرار نسبي في السوق خلال تلك الفترات.

إضافة إلى ذلك لا يظهر الرسم اتجاهًا واضحًا للعوائد عبر الزمن، حيث أن البيانات تميل إلى التحرك حول المحور الأفقي للصفر دون ميل، مما يدل على أن العوائد لا تتبع اتجاهًا تصاعديًا أو تنازليًا طويل الأمد. هذا السلوك يتماشى مع ما هو معروف في الاقتصاد المالي، حيث أن أسعار الأصول المالية عادة ما تكون غير مستقرة (non-stationary)، بينما سلاسل العوائد تُعد مستقرة في معظم الحالات، وإن كانت تتسم بتقلبات مرتفعة وتغيرات مفاجئة.

بناءً على هذا السلوك المتقلب والمتغير باستمرار، فإن تحليل هذه السلسلة يتطلب استخدام نماذج مرنة قادرة على التقاط الأنماط والاعتماد الزمني بين القيم، وهو ما يجعل شبكات LSTM خيارًا مناسبًا، نظرًا لقدرتها على التعلم من البيانات المتسلسلة والتكيف مع ديناميكيات السوق غير المنتظمة:

RI_RF

**2- اختبار التوزيع الطبيعي والإحصاءات العامة للسلسلة الزمنية المدروسة**

قام الباحث هنا باحتساب بعض الإحصاءات العامة وهي الوسط الحسابي والوسيط وأدنى وأعلى قيمة والانحراف المعياري واختبار جارك-بيرا للتوزيع الطبيعي للبيانات لتحديد السلوك العام للسلسلة الزمنية وضمنت النتائج في الجدول أدناه:

جدول (2) الإحصاءات العامة لسلسلة بيانات

رمز البيانات	Mean	Median	Minimum	Maximum	Std. Dev.	Skewness	Kurtosis	Jarque-Bera	P-value
RI_RF	0.00111	0.00329	-0.08335	0.154314	0.04081	0.399137	3.63190	4.62124	0.09919

يعرض الجدول أعلاه مجموعة من المؤشرات الوصفية التي تساعد في فهم الخصائص العامة لسلسلة العوائد للأسهم RI_RF، حيث يُظهر المتوسط الحسابي للعوائد قيمة موجبة صغيرة تبلغ 0.0011، ما يشير إلى أن متوسط العائد الشهري للسهم فوق معدل العائد الخالي من المخاطر كان ضعيفاً ولكن موجباً خلال الفترة الزمنية المدروسة. يُعد هذا التوجه إيجابياً بشكل عام إلا أنه لا يعكس بالضرورة وجود نمط ربح منتظم بسبب التذبذب الواضح في البيانات.

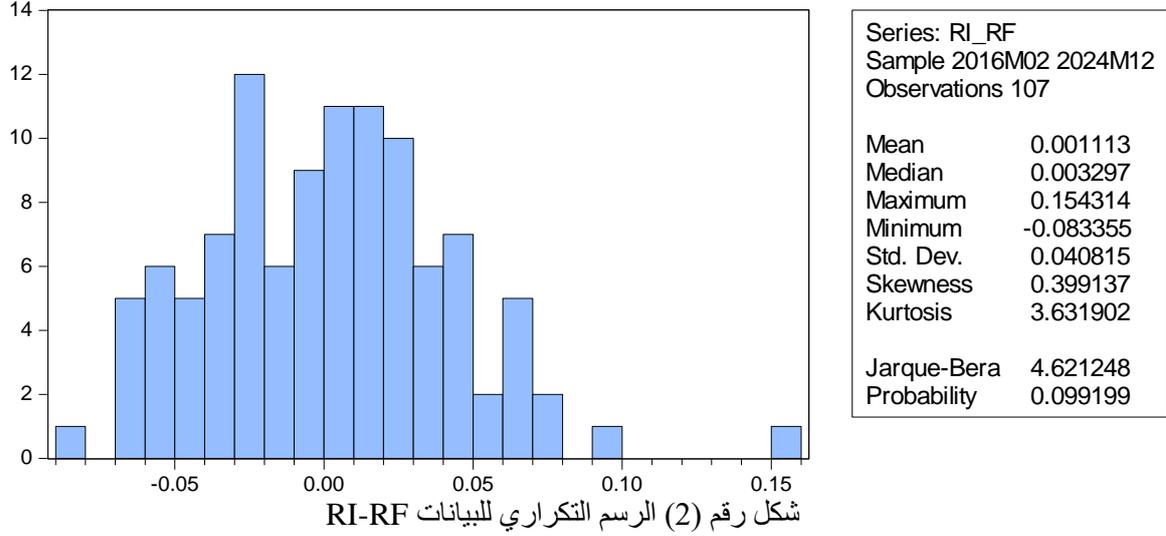
بالمقارنة، فإن الوسيط بلغ 0.0033، وهو أعلى من المتوسط، مما يشير إلى أن توزيع العوائد ليس متماثلاً تماماً، بل قد يميل قليلاً إلى القيم السالبة الكبيرة التي تؤثر في المتوسط وتدفعه للأسفل. هذا يتماشى مع النتيجة المتعلقة بمعامل الالتواء الذي سجل قيمة موجبة تبلغ 0.399، مما يدل على أن توزيع العوائد مائل نحو اليمين، أي أن هناك عدداً قليلاً من العوائد الموجبة العالية التي تؤثر في شكل التوزيع.

أما بالنسبة لأعلى وأدنى القيم، فإن الحد الأدنى في السلسلة وصل إلى -0.083، ما يعادل خسارة بنسبة 8.3%، بينما بلغ الحد الأقصى 0.154 أي تحقيق مكسب بنسبة 15.4% هذا الفرق الكبير بين الحد الأدنى والأقصى يعكس بوضوح مدى التذبذب الذي يميز الأسواق المالية، وهو ما تؤكد قيمة الانحراف المعياري البالغة 0.0408، حيث توضح هذه القيمة مقدار التشتت حول المتوسط.

عند النظر إلى التفرطح، نجد أن القيمة المسجلة هي 3.63، وهي أعلى من القيمة النظرية للتوزيع الطبيعي التي تبلغ 3 هذا يدل على أن توزيع العوائد يتميز بقيمة أكثر حدة ونهايات أكثر سمكاً مقارنة بالتوزيع الطبيعي، أي أن هناك احتمالاً أكبر لوقوع عوائد متطرفة سواء موجبة أو سالبة.

أخيراً، تم إجراء اختبار جارك-بيرا لقياس مدى انحراف السلسلة عن التوزيع الطبيعي، وسجلت القيمة الإحصائية للاختبار 4.62، مع قيمة احتمالية تبلغ 0.099. وبما أن هذه القيمة الاحتمالية أكبر من مستوى الدلالة 5%، فإننا لا نرفض الفرضية الصفرية القائلة بأن السلسلة تتبع توزيعاً طبيعياً. ومع ذلك، فإن قرب القيمة من الحد الفاصل يشير إلى احتمال وجود انحراف

طفيف عن التوزيع الطبيعي، وهو ما يجب أخذه بعين الاعتبار عند اختيار النموذج المناسب للتحليل أو التنبؤ. والشكل البياني التالي يوضح الرسم التكراري للبيانات والذي يتبين منه صحة ما ذهب إليه الباحث:



انطلاقاً من التحليل السابق، يتضح أن سلسلة العوائد تتميز بخصائص مالية نمطية تشمل تذبذباً مرتفعاً وتوزيعاً غير متمائل قليلاً، ووجود بعض القيم المتطرفة. ورغم أن اختبار جارك-بيرا اعطى دليلاً على قبول الفرضية الصفريّة المتعلقة باتّباع العوائد وفق توزيع طبيعي، فإن وجود التفرطح الزائد والانحراف الطفيف يشير إلى أن السلسلة قد لا تتّبع خصائص التوزيع المثالي بشكل دقيق. هذه الخصائص الإحصائية، بالإضافة إلى غياب اتجاه واضح للسلسلة، تجعل النماذج التقليدية أقل فعالية في التنبؤ بهذه العوائد، خاصة عند وجود علاقات زمنية غير خطية معقدة يصعب تمثيلها رياضياً. بناءً على ذلك، فإن اختيار نموذج الشبكة العصبية طويلة وقصيرة الأمد (LSTM) يبدو مناسباً نظراً لقدرتها على تمثيل الأنماط الزمنية المتغيرة والتفاعل مع حالات التذبذب الحادة والعلاقات غير الخطية في السلسلة. من المعروف أن نموذج LSTM يتميز بمرونة عالية في التعامل مع البيانات غير الخطية وغير المستقرة، لذلك يمكن اعتبار استخدام نموذج LSTM بمثابة استجابة مناسبة لطبيعة السلسلة المدروسة، من حيث خصائصها الإحصائية والتحديات المتضمنة في سلوكها.

4-3 نموذج LSTM

في ظل التطور المتسارع لتقنيات الذكاء الاصطناعي وتعلم الآلة، أصبحت النماذج العميقة مثل الشبكات العصبية المتكررة (Recurrent Neural Networks - RNNs)، وبشكل خاص نماذج الذاكرة طويلة وقصيرة المدى (Long Short-Term Memory - LSTM) من الأدوات المهمة في تحليل السلاسل الزمنية والتنبؤ بها. وتتميز نماذج LSTM بقدرتها على تمييز الأنماط الزمنية المعقدة والتعامل مع البيانات التي تتضمن اعتماداً على الماضي طويل الأمد، وهو ما يصعب تحقيقه باستخدام النماذج الخطية التقليدية. في هذا السياق، يهدف الباحث إلى استغلال خصائص LSTM لتقديم نموذج تنبؤي لعوائد الأسهم الشهرية للفترة الممتدة من عام 2016 إلى 2024، باستخدام بيانات تمثل العائد للسهم (RI_RF)، بعد معالجتها لتناسب متطلبات التدريب الشبكي. ويُعد هذا التطبيق خطوة متقدمة نحو تقييم فعالية النماذج غير الخطية مقارنة بالنماذج التقليدية مثل نموذج فاما-فرنش الثلاثي.

إن استخدام أسلوب LSTM يتطلب استخدام إحدى لغات البرمجة مثل R أو PYTHON بسبب عدم وجود برامج إحصائية جاهزة تدعم هذا الأسلوب لحد الآن (حسب علم الباحث) مما شكل تحدياً جديداً للباحث في إنجاز أهداف الدراسة الحالية، لقد تم اعتماد لغة البرمجة R في استخلاص النتائج لذلك تم إعداد البيانات بحيث يتم تعلم العلاقة بين القيم السابقة للعوائد والقيمة المستقبلية المستهدفة. حيث تم أولاً تنصيب البكجات الخاصة بالعمل. و تم بناء شبكة LSTM متعددة الطبقات، وجرى تدريبها باستخدام دالة متوسط مربعات الخطأ (MSE) مع خوارزمية التحسين (Adam Optimizer)، كما تم تقييم أداء النموذج باستخدام معايير MSE و RMSE و MAE و MAPE. حيث قام الباحث أولاً باستدعاء البيانات المدخلة على شكل اكسل من خلال استخدام الكود البرمجي التالي:

```
returns <- read.csv("C:\\Users\\DELL\\Desktop\\returns.csv")
returns <- returns$RI_RF

returns_scaled <- scale(returns)
```

تم بناء نموذج الشبكة العصبية من نوع LSTM لغرض التنبؤ بالعوائد الشهرية للأسهم اعتماداً على سلاسل زمنية تاريخية مكونة من 12 مشاهدة زمنية متتالية ($n_steps = 12$) ، أي أن النموذج يتلقى في كل مرة نافذة من 12 شهراً من القيم السابقة، ويُطلب منه التنبؤ بالعائد في الشهر الثالث عشر. وقد تم تصميم النموذج باستخدام بنية عميقة مكونة من ثلاث طبقات رئيسية: طبقتان من نوع LSTM، تليهما طبقة خطية كثيفة (Dense) لإنتاج القيمة التنبؤية النهائية وهي تهدف إلى تمثيل الأنماط الزمنية العميقة في سلسلة العوائد، والتنبؤ بالقيمة المستقبلية للعائد استناداً إلى قيمه السابقة. وبعد بناء النموذج تأتي فقرة التدريب والتنبؤ وفق كود برمجي. والجدول التالي يبين المكونات التفصيلية لبنية نموذج LSTM التي حصل عليها الباحث من خلال استخدام لغة البرمجة R:

جدول (3)

المكونات التفصيلية لبنية نموذج LSTM

Layer (type)	Output Shape	Param.
lstm_45 (LSTM)	(None, 12, 100)	40800
lstm_44 (LSTM)	(None, 50)	30200
dense_25 (Dense)	(None, 1)	51
Total params: 71051 (277.54 KB)		
Trainable params: 71051 (277.54 KB)		

من الجدول أعلاه يتضح ان البنية تبدأ بالطبقة الأولى وهي طبقة LSTM التي تحتوي على 100 وحدة عصبية هذه الطبقة تستقبل تسلسلاً زمنياً مكوناً من 12 فترة، حيث تحتوي كل فترة على متغير واحد فقط (عائد السهم في ذلك الشهر) وهذه الطبقة مصممة لإرجاع تسلسل مخرجات، أي أنها تحتفظ بالمخرجات الخاصة بكل فترة زمنية في السلسلة مما يسمح بتغذية الطبقة التالية. ان شكل المخرجات الناتج عن هذه الطبقة هو (None, 12, 100) ، حيث يشير الرقم 12 إلى عدد الفترات الزمنية في التسلسل، والعدد 100 إلى عدد الوحدات العصبية في الطبقة. أما القيمة "None" فتمثل حجم الدفعة التدريبية (batch size) والذي يظل مرناً وغير محدد أثناء بناء النموذج. ومن حيث دالة التنشيط، فقد استخدمت هذه الطبقة دوال التنشيط التالية:

- دالة sigmoid لتفعيل البوابات الثلاثة (بوابة النسيان، بوابة الإدخال، وبوابة الإخراج)، وهي دالة تحول القيم لتكون بين 0 و 1، مما يسمح بالتحكم في مقدار المعلومات التي يتم تمريرها أو نسيانها.

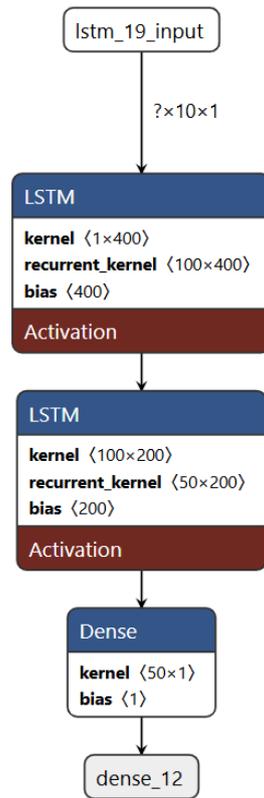
- دالة tanh لتحديث قيم الحالة الداخلية للخلية (cell state) ، حيث تُستخدم هذه الدالة لاحتساب القيم الجديدة التي ستُضاف إلى الذاكرة، مما يضمن وجود تمثيل غير خطي.

تحتوي هذه الطبقة على ما مجموعه 40,800 معامل قابل للتعلم، موزعة على أوزان المدخلات، أوزان الحالات السابقة، ومعاملات التحيز الخاصة بكل بوابة، ويُحسب هذا العدد وفقاً للبنية الداخلية لشبكات LSTM التي تتضمن أربع بوابات. بعد الطبقة الأولى تأتي الطبقة الثانية وهي طبقة LSTM إضافية تستخدم لغرض تقليل الأبعاد وتركيز المعلومات قبل تمريرها للطبقة الأخيرة، وهي تحتوي على 50 وحدة عصبية وان مخرجات برنامج R من هذه الطبقة تأخذ الشكل (None, 50)، وهو يشير الى أن كل تسلسل زمني مدخل يضمن في متجه واحد من 50 عنصرًا. تُستخدم في هذه الطبقة نفس دوال التنشيط السابقة وهي دالة التنشيط sigmoid للبوابات ودالة التنشيط tanh لتحديث الذاكرة وهي مسؤولة عن احتساب المخرجات غير الخطية داخل الوحدات العصبية. يبلغ عدد المعاملات في هذه الطبقة 30,200 معامل، بمدخلات من حجم 100 وخلايا من حجم 50.

اما الطبقة الثالثة وهي طبقة تسمى بطبقة الكثافة (Dense) التي تتكون من وحدة واحدة فقط، تُستخدم لاحتساب القيمة التنبؤية النهائية، أي العائد المتوقع للشهر التالي. هذه الطبقة تستخدم دالة تنشيط خطية (Linear Activation) بشكل افتراضي، أي لا يتم تطبيق أي دالة تحويل على القيمة الناتجة، وذلك لأن مهمة النموذج في هذه الحالة هي التنبؤ بقيمة عددية يبلغ عدد المعاملات في هذه الطبقة 51 فقط، وهي مكونة من 50 وزناً يمثلون العلاقة بين كل وحدة LSTM في الطبقة السابقة والإخراج، بالإضافة إلى معامل تحيز واحد.

أن مجمل النموذج يتضمن 71,051 معاملاً قابلاً للتعلم، وتحدث جميعها أثناء عملية التدريب باستخدام خوارزمية التحسين "Adam" وقد تم تصميم النموذج بدون أي طبقات مجمدة لا يتم فيها تدريب المعاملات (non-trainable) وهذا الامر يسمح للنموذج بالتكيف الكامل مع خصائص البيانات وتعلم الأنماط الزمنية الدقيقة الكامنة فيها. إن استخدام بنية متدرجة مكونة من طبقتي LSTM يسمح للنموذج بتعلم كل من العلاقات الزمنية القصيرة والطويلة الأمد، مما يمنحه قدرة تنبؤية قوية في تحليل السلاسل الزمنية المعقدة المتمثلة بعوائد الأسهم.

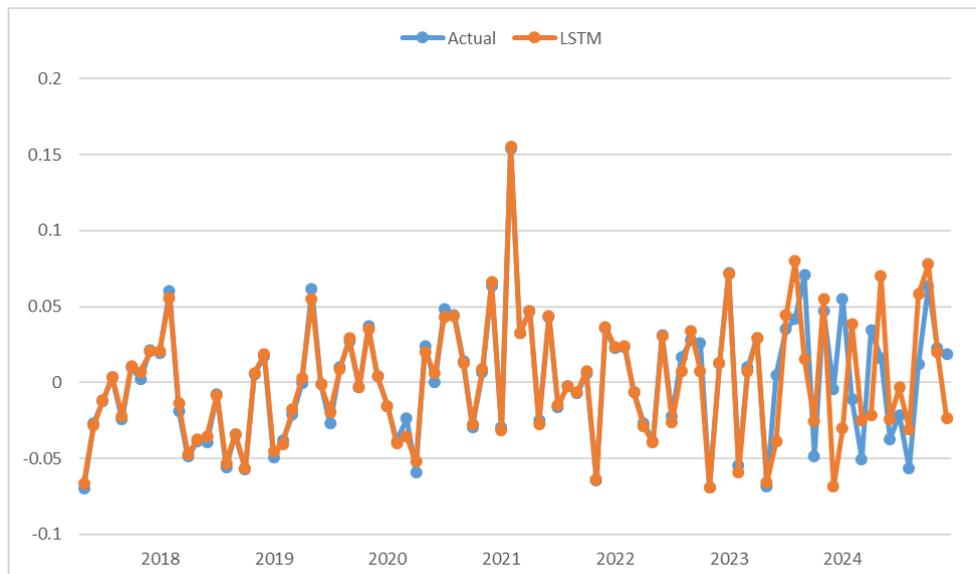
لقد كون الباحث معمارية شبكة LSTM المستخدمة في عملية التنبؤ بالعوائد الشهرية وكما وصفت أعلاه حيث ان الشكل البياني التالي يوضح هذه المعمارية:



شكل رقم (3) معمارية شبكة LSTM المستخدمة في عملية التنبؤ بالعوائد بعد تحديد المعمارية المناسبة لشبكة LSTM واحتساب وتدريب معاملاتهما واوزانها تم بعدها احتساب القيم التنبؤية للعوائد ورسمت هذه القيم مع القيم الحقيقية وفق الكود البرمجي التالي:

```
# رسم النتائج
plot(actual, type = "l", col = "blue", lwd = 2, main = "Actual vs Predicted", ylab =
lines(predicted, col = "red", lwd = 2)
legend("topleft", legend = c("Actual", "Predicted"), col = c("blue", "red"), lwd = 2
```

وضمنت الرسومات في الشكل التالي الذي يوضح القيم الحقيقية والتنبؤية باستخدام شبكة LSTM:



شكل رقم (4) القيم التنبؤية مع القيم الحقيقية للعوائد

بالاعتماد على الشكل البياني أعلاه، نلاحظ أن نموذج شبكة LSTM قدّم تنبؤات قريبة من القيم الفعلية لعوائد الأسهم، وهو ما يعكس قدرة هذا النموذج على التقاط الأنماط الزمنية الكامنة في البيانات بشكل فعال. يشير هذا التقارب إلى جودة التنبؤات التي يمكن أن تحققها شبكة LSTM، خاصة في بيئة مالية تتسم بالتقلب وعدم الاستقرار. ولغرض تقييم دقة النموذج بشكل كمي، تم احتساب متوسط مربعات الخطأ (MSE) بالإضافة إلى عدد من المعايير الإحصائية الأخرى وفق الكود البرمجي التالي:

```
mse <- mean((actual - predicted)^2)
rmse <- sqrt(mse)
mae <- mean(abs(actual - predicted))
cat("MSE:", mse, "\nRMSE:", rmse, "\nMAE:", mae)
write.csv(predicted, "C:\\Users\\DELL\\Desktop\\predict.csv")
mse
```

وكما هو موضح في الجدول التالي:

جدول رقم (4) معايير المقارنة ومقدراتها المحسوبة وفق طريقة LSTM

MAPE	MAE	RMSE	MSE	معايير المقارنة
1.0824558	0.0092887	0.0189420	0.0003588	القيمة المقدرّة

تشير القيم الموضحة في الجدول أعلاه إلى أن نموذج شبكة LSTM قد حقق أداءً جيدًا في التنبؤ بعوائد الأسهم الشهرية. إذ بلغ متوسط مربعات الخطأ MSE قيمة مقدارها 0.0003588، وهي قيمة منخفضة تعكس صغر الفجوة بين القيم الفعلية والقيم المتنبأ بها. كما أن الجذر التربيعي لمتوسط مربعات الخطأ RMSE بلغ 0.0189420، مما يشير إلى أن متوسط الانحراف بين التنبؤات والقيم الحقيقية لا يتجاوز 1.9% تقريبًا من قيمة العائد.

أما متوسط الخطأ المطلق MAE فقد بلغ 0.0092887، وهو أقل من 1%، مما يدل على أن معظم التنبؤات كانت قريبة جدًا من القيم الحقيقية دون تأثير كبير بالقيم الشاذة. كذلك، يُظهر متوسط النسبة المئوية للخطأ المطلق MAPE البالغ 1.0824%، أن النموذج أخطأ في توقعاته بنسبة صغيرة جدًا مقارنة بالقيم الفعلية، وهو مؤشر قوي على فعالية نموذج LSTM في التنبؤ. تعكس هذه النتائج أن نموذج LSTM لا يكتفي بالتعامل مع الاتجاه العام للسلسلة الزمنية، بل يقدم أيضًا تنبؤات دقيقة ومنخفضة الخطأ، ما يعزز من أهميته كأداة تنبؤية في مجال تحليل العوائد المالية.

المبحث الرابع

5- الاستنتاجات والتوصيات

5-1 الاستنتاجات

5.1.1 الاستنتاج الأول: كفاءة نموذج LSTM في التنبؤ بالعوائد الشهرية

أظهرت النتائج أن نموذج LSTM قادر على معالجة بيانات العوائد الشهرية للشركات العراقية والتنبؤ بسلوكها المستقبلي بدقة عالية. وقد عكست قيم المؤشرات الإحصائية مستوى أداء متقدمًا جدًا، إذ جاءت قيمة MAPE بحدود 1% تقريبًا، وهي قيمة تُعد غير مألوفة غالبًا في الأسواق الناشئة التي تشهد مستوى مرتفعًا من التقلب. وهذا يعكس قدرة النموذج على اكتشاف الأنماط المخفية خلف التقلبات، وهو ما يشير إلى أن البيانات المالية – رغم وضوحها – تحتوي على علاقات زمنية يمكن للنموذج تعلمها بكفاءة.

5.1.2 الاستنتاج الثاني: ملاءمة النموذج لبيئة السوق العراقي إذ على الرغم من التحديات الكبيرة في سوق العراق للأوراق المالية مثل انخفاض السيولة، وتوقف التداولات، والعوامل غير الاقتصادية المؤثرة على حركة الأسعار، إلا أن النموذج تمكن من التنبؤ بنمط العوائد الشهرية وقدم نتائج مستقرة. وهذا يعكس ملاءمة نموذج LSTM للأسواق التي تتصف بخصائص غير خطية وتقلبات حادة. وبذلك، يمكن اعتبار النموذج مناسبًا للسوق العراقي ومؤهلاً للتكيف مع طبيعة البيانات المتاحة.

5.1.3 الاستنتاج الثالث: قدرة النموذج على تجنب الإفراط في التعلّم إذ أظهر منحنى التدريب أن النموذج لم يقع في الإفراط في التعلّم. وهذا يعني أن النموذج لم يحفظ البيانات بل فهم العلاقات الزمنية بينها، وهي نقطة جوهرية في تقييم نماذج التنبؤ.

التوصيات

5-2 توصيات للمستثمرين

1. اعتماد النماذج الذكية في اتخاذ القرارات الاستثمارية. حيث يمكنها تقديم تقديرات أولية لاتجاه السهم من شأنها تحسين جودة القرارات وتقليل المخاطرة.

2. اعتبار نتائج النموذج جزءاً من عملية التحليل لا بديلاً عنها. فالنموذج يقدم تنبؤاً إحصائياً، لكن القرار يعتمد أيضاً على تحليل الأخبار، والإفصاح المالي، والعوامل الاقتصادية.
3. تحديث البيانات باستمرار قبل إجراء التنبؤ. لأن دقة النموذج تعتمد إلى حد كبير على البيانات الحديثة.
- 5-2-2 توصيات للمؤسسات المالية
 1. تبني نظم الذكاء الاصطناعي في إدارة المحافظ الاستثمارية. إذ أثبتت النتائج أن هذه النظم قادرة على تقديم رؤى أكثر دقة حول تقلبات العوائد.
 2. تطوير قواعد بيانات مالية متكاملة. لأن البيانات النظيفة والمتسلسلة تمثل حجر الأساس لأي نموذج تنبؤ فعال.
 3. تدريب الكوادر المالية على استخدام تقنيات التعلم الآلي. لتطوير بيئة تحليلية حديثة داخل المؤسسات.
- 5-2-3 توصيات لهيئة الأوراق المالية وسوق العراق للأوراق المالية
 1. تحسين شفافية البيانات وتسريع نشر الإفصاح المالي. لأن وفرة البيانات وجودتها ترتبط مباشرة بدقة النماذج التنبؤية.
 2. اعتماد منصات رقمية توفر البيانات التاريخية المنظمة للمستثمرين.
 3. تطوير بنى تحتية رقمية تشجع البحث العلمي في مجال التنبؤ المالي.

المصادر:

- 1 Faheem, M., Aslam, M., & Kakolu, S. (2024). Enhancing financial forecasting accuracy through AI-driven predictive analytics models. *Retrieved December, 11*.
- 2 Fathali, Z., Kodia, Z., & Ben Said, L. (2022). Stock market prediction of Nifty 50 index applying machine learning techniques. *Applied Artificial Intelligence, 36(1)*, 2111134.
- 3 Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning. *Electronic Markets, 31(3)*, 685–695.
- 4 Kim, S., & Kang, M. (2019). Financial series prediction using Attention LSTM. *ArXiv Preprint ArXiv:1902.10877*.
- 5 Landi, F., Baraldi, L., Cornia, M., & Cucchiara, R. (2021). Working memory connections for LSTM. *Neural Networks, 144*, 334–341.
- 6 Mehtab, S., & Sen, J. (2020). A time series analysis-based stock price prediction using machine learning and deep learning models. *International journal of business forecasting and marketing intelligence, 6(4)*, 272-335.
- 7 Oyewole, A. T., Adeoye, O. B., Addy, W. A., Okoye, C. C., Ofodile, O. C., & Ugochukwu, C. E. (2024). Predicting stock market movements using neural networks: A review and application study. *Computer Science & IT Research Journal, 5(3)*, 651–670.
- 8 Paramesha, M., Rane, N., & Rane, J. (2024). Artificial intelligence, machine learning, deep learning, and blockchain in financial and banking services: A comprehensive review. *Machine Learning, Deep Learning, and Blockchain in Financial and Banking Services: A Comprehensive Review (June 6, 2024)*.
- 9 Wang, C. (2024). Stock return prediction with multiple measures using neural network models. *Financial Innovation, 10(1)*, 72.
- 10 Wang, J., Hong, S., Dong, Y., Li, Z., & Hu, J. (2024). Predicting stock market trends using LSTM networks: overcoming RNN limitations for improved financial forecasting. *Journal of Computer Science and Software Applications, 4(3)*, 1–7.
- 11 Zhang, J., Zhu, Y., Zhang, X., Ye, M., & Yang, J. (2018). Developing a Long Short-Term Memory (LSTM) based model for predicting water table depth in agricultural areas. *Journal of Hydrology, 561*, 918–929.
- 12 Zhang, Z. (2023). Comparison of lstm and arima in price forecasting: evidence from five indexes. *2023 2nd International Conference on Economics, Smart Finance and Contemporary Trade (ESFCT 2023)*, 40–46.