التنبؤ بأسعار الأسهم باستخدام تقنيات تعلم الآلة دراسة لعينة من الشركات المدرجة في سوق العراق للأوراق المالية

أ.م.د. محمد جاسم محمد
كلية الادارة والاقتصاد/ قسم العلوم المالية والمصرفية/ جامعة البصرة
mohammed.jassim@uobasrah.edu.iq

المستخلص :

تهدف الدراسة إلى استخدام إحدى تقنيات الذكاء الاصطناعي وهي تعلم الآلة للتنبؤ بأسعار الأسهم لعينة من الشركات، ولكل من قطاع المصارف وقطاع الفنادق والسياحة وقطاع الصناعة في سوق العراق للأوراق المالية باعتماد مدتين للدراسة الأولى من شهر3 لعام 2015 ولغاية شهر3 من عام 2025، والمدة الثانية للمدة من شهر 4 عام 2025 ولغاية شهر 12 عام 2027، وقد تبنت الدراسة فرضية رئيسة، وهي دقة التنبؤ بأسعار الأسهم باعتماد تقنية تعلم الآلة، وقد تم ذلك باعتماد البرنامج الإحصائي المتخصص MATLAB، وقد توصلت الدراسة إلى استنتاجات عدة من أهمها دقة تقنية تعلم الآلة للتنبؤ بأسعار أسهم الشركات عينة الدراسة؛ وذلك بالاعتماد على MSE، فقد تم اختبار نوعين من نماذج تعلم الآلة بنسب تدريب 60% واختبار 40%، وتدريب 70% واختبار 30%، وأهم استنتاج توصلت إليه الدراسة أنه قد تم تشخيص قدرة متباينة لنموذج التنبؤ بين النموذجين ولكل شركة بشكل خاص، وقد تم التنبؤ بأسعار الإغلاق لأسهم الشركات للمدة 33 شهر، أما أهم توصية خرجت بها الدراسة فهي على المهتمين والمختصين اعتماد النماذج الحديثة للاختبار والتنبؤ، وبالأخص تلك التي تستخدم تقنيات الذكاء الاصطناعي.

الكلمات المفتاحية: الذكاء الاصطناعي، التعلم الآلي، التعلم العميق، التقنيات، أسعار الأسهم..

Predicting stock prices using machine learning techniques

A Study of a Sample of Industrial and Financial Companies Listed on the Iraq Stock Exchange

Asst. Prof. Dr. Mohammed Jasim Mohammed
University of Basrah, College of Administration and Economics ,
Department of Banking and Financial Sciences
email: mohammed.jassim@uobasrah.edu.iq

Abstract :

This study aims to use artificial intelligence techniques, specifically machine learning, to predict stock prices for a sample of companies in the banking, hotel and tourism, and industrial sectors of the Iraq Stock Exchange. The study will be conducted over two timeframes: the first from March 2015 to March 2025, and the second from April 2025 to December 2027. The study's primary hypothesis is the accuracy of stock price predictions using machine learning. This was achieved using specialized statistical software MATLAB. The study reached several conclusions, most notably the accuracy of machine learning in predicting the stock prices of the companies in the sample, based on the MSE model. Two types of machine learning models were tested with training percentages of 60% and 40%, and 70% and 30%. The study's key finding was the identification of varying prediction capabilities between the two models and for each company individually. The closing stock prices of the companies were predicted for a 33-month period. The study's main recommendation is that interested parties and specialists should adopt this approach. Modern models for testing and prediction, especially those that utilize artificial intelligence techniques .

Keywords: **Artificial intelligence, machine learning, deep learning, technology, stock prices.**

مقدمة :

يعد تطور الأسواق المالية مؤشراً اقتصادياً ومالياً مهم لأي بلد، كما أنه يعكس العمق والأداء المالي للشركات، فمع نمو الشركات وتوسع الاقتصادات يتجه المستثمرون إما إلى المصارف أو الأسواق المالية؛ وذلك بحسب توجه النظام المالي في البلد (متوجه نحو المصارف كما في المانيا واليابان، أو متوجه نحو الأسواق المالية كما في الولايات المتحدة والمملكة المتحدة)، بشكل متزايد إلى لتمويل احتياجاتهم المالية مما يُحفز الطلب المتزايد على نماذج التنبؤ الدقيقة، إذ يُعدّ التنبؤ بأسعار الأسهم مهمة معقدة وديناميكية تتأثر بعوامل عديدة بما في ذلك اتجاهات السوق والمؤشرات المالية والأخبار الاقتصادية وسلوك المستثمرين، وللقدرة على التنبؤ بدقة آثار بعيدة المدى إذ تُمكّن المستثمرين من اتخاذ قرارات مدروسة، لذا تعد العمليات التي تتعلق بالبيع أو الشراء أو حتى الاحتفاظ بالسهم من أهم ما يواجه المتعاملون في السوق المالي أو ذوي العلاقة سواء الشركات المصدرة للأسهم أو الرغبة في الشراء، وقد عملت العديد من البرامج والنماذج على تقييم سعر السهم أو حتى التنبؤ بهذه الأسعار، إذ واجهة العديد منها بعض القصور ووجهة إليها انتقادات أو لافتراضاتها غير الواقعية، لذا تم الاعتماد وتبني مداخل جديدة، ومنها المداخل التي تعتمد التطورات المالية، فقد أدت التطورات التي شهدتها الساحة المالية في جوانب الابتكارات المالية من خدمات وأدوات ونماذج ومقايس ثورة كبيرة وانتقال من الجانب التقليدي إلى جانب الحداثة والأتمتة، ويأتي في مقدمة هذا التحول اعتماد البرامج الحديثة في الجوانب المالية، ومنها تقنيات الذكاء الاصطناعي وفي مقدمتها تعلم الآلة الذي شكل ثورة مع التقنيات الأخرى، فقد كان للظروف التنافسية والتسارع على تبني واعتماد هذه التقنيات حافز للعديد من الدراسات التجريبية في مختلف المجالات، ومنها جانب التنبؤ بأسعار أسهم الشركات، وعن طريق متابعة نتائج عينة من الشركات المدرجة في سوق العراق للأوراق المالية تم ملاحظة عدم الترابط بين الأداء المالي لبعض الشركات وأسعار أسهمها، لذا فإن الاعتماد على متغيرات أو مؤشرات الأداء للتنبؤ أو تقدير هذه الأسعار لا تعطي نتائج دقيقة وذلك لفشل النظرية المالية في تفسير حالة سوق العراق للأوراق المالية او لعدم كفاءة السوق المالي ليعكس المعلومات في الأسعار، لذا كان لابد من تبني النماذج الحديثة ومنها تعلم الآلة للتنبؤ بأسعار الأسهم باعتماد الأسعار التاريخية الشهرية للتنبؤ بالمستقبل، وهذا يمثل جوهر الفجوة البحثة للدراسة، فضلاً عن ذلك يعد تطبيق التعلم الآلي للتنبؤ بأسعار الأسهم مجالًا رئيسًا للاستكشاف في التحليلات المالية، وبالتالي جاءت الدراسة على وفق مجموعة من الفقرات وكالآتي:

1. المنهجية العلمية للدراسة

1.1. مشكلة الدراسة:

يُعد سوق الأواق المالية جزءًا مهمًا من النظام المالي، والقدرة على تحديد اتجاهات أسعار الأسهم ضرورية لاتخاذ قرارات استثمارية سليمة، ونظرًا لسرعة تقلبات أسواق الأسهم وتعقيدها غالبًا ما تعجز الطرق التقليدية عن تقديم تنبؤات دقيقة، وكون أسعار الأسهم تعد من أهم أسعار الأدوات المالية، ومن أهم المؤشرات المالي التي يتم الاعتماد عليها في معرفة وضع الشركة في السوق المالي من جانب، ومؤشر السوق بشكل عام من جانب آخر، لذا عملية التنبؤ بالأسعار باعتماد النماذج التقليدية لم يعد يفي بالغرض نتيجة جملة الانتقادات التي رافقت

هذه النماذج، ولهذا تعد التقنيات التي تعتمد الذكاء الاصطناعي البديل الأفضل والناجح في الكثير من التطبيقات والمجالات ولا سيما في الجوانب المالية، ومنها عملية التقدير والتنبؤ وبيان مقدار أهمية كل متغير فرعي من متغيرات المتغير المستقل بالنسبة للمتغير التابع، لذا جاءت هذه الدراسة والتي تتمحور مشكلتها حول التساؤل الآتي: هل بالإمكان التنبؤ بأسعار الأسهم عن طريق تعلم الآلة للتنبؤ للشركات عينة الدراسة وما مدى دقة هذا التنبؤ ؟

2.1. **أهداف الدراسة**: تتمثل أهداف الدراسة في النقاط الآتية:

1. اعتمدت الدراسة في إطارها الفكري والتحليل على أهم التقنيات التي تعتمد الذكاء الاصطناعي التي تم التوصل إليها، وتم تبني بعضها في الفكر المالي الحديث.
2. تقديم إطار فكري ومعرفي يبن المفاهيم النظرية لمتغيرات الدراسة الأساسية والمتمثلة بـ (بتقنيات الذكاء الاصطناعي وتعلم الآلة)، وما تقدمة هذه التقنيات من تطور في الجانب المالية.
3. الوصول إلى استنتاجات علمية مدعومة بنتائج اختبارات فعلية معززه بتوصيات لذوي العلاقة.

3.1. **فرضيات الدراسة**: وفقاً لمسوغات وإجراءات الدراسة تم الاعتماد على فرضية رئيسة بوصفها إجابة أولية للتساؤل المطروح في مشكلة الدراسة، والتي يسعى الباحث لا ثباتها أو نفيها وهي عدم قدرة تقنية تعلم الآلة على التنبؤ بأسعار الأسهم للشركات عينة الدراسة.

4.1. **أهمية الدراسة**: تتمثل أهمية الدراسة في الآتية:

1- تعمل الدراسة على تبني واستخدام تقنية تعد من أهم تقنيات الذكاء الاصطناعي.

2- تعمل الدراسة على معالجة فجوة بحثية غاية في الأهمية.

3- تسعى الدراسة التنبؤ بأسعار الأسهم بدون المتغيرات الجزئية أو الكلية عن طريق أسعار الأسهم التاريخية، لما تتمتع فيها المؤشرات المالية من عدم استقرار.

5.1. **مدة الدراسة**: تم تقسيم مدة الدراسة على قسمين القسم الأول، وهي المدة التي تمتد من شهر3عام 2015 ولغاية شهر3 عام 2025، وهي المدة التي تم اعتماد بياناتها كمدخلات للتنبؤ لمدة أخرى وهي المدة الثانية والتي تمتد من شهر 4 عام 2025 ولغاية شهر 12 عام 2027.

6.1. **مجتمع وعينة الدراسة**: يتكون مجتمع الدراسة من مجموعة من الشركات المدرجة في سوق الأواق المالية للمدة، وقد تم اختيار 25 شركة لثلاثة قطاعات رئيسة في السوق، وهي قطاع المصارف وقطاع الفنادق والسياحة وقطاع الصناعة، دون غيرها نظراً لتوافر البيانات التي تحتاجها الدراسة، كما أنها تمتاز بالاستمرارية في التداول ولم تشهد عمليات اندماج أو اكتساب خلال مدة الدراسة، كما يجب ملاحظ أنه لاوجود لأي مانع بأن تكون عينة مصارف وشركات خدمات وشركات صناعية؛ وذلك لأننا لا نتعامل مع مؤشرات مالية من سيولة ورافعة مالية وغيرة وضرورية خصوصية المتغيرات والعينة، وإنما هي عملية تنبؤ بأسعار مستقبلية بناءً على أسعار تأريخيه وباعتماد تقنية تعلم الآلة، كما أن الدراسة قامت ببناء نموذج خاص لكل شركة أو مصرف،

والجدول الآتي يوضح الشركات عينة الدراسة والرمز الخاص بكل شركة وتاريخ الإدراج في سوق العراق للأوراق المالية.

الجدول (1) قطاع الشركات عينة الدراسة مع رمز الشركة وتاريخ الإدراج

ت	القطاع	اسم الشركة	رمز الشركة	تأريخ الإدراج
1	المصارف	مصرف بغداد التجاري	BBOB	2004-6-15
2	المصارف	المصرف التجاري العراقي	BCOI	2004-7-25
3	المصارف	مصرف إيلاف الإسلامي	BELF	2007-6-28
4	المصارف	مصرف الخليج التجاري	BGUC	2004-7-25
5	المصارف	مصرف الاستثمار العراقي	BIBI	2004-6-15
6	المصارف	المصرف العراقي الإسلامي	BIIB	2004-7-25
7	المصارف	مصرف الشرق الأوسط	BIME	2004-8-7
8	المصارف	مصرف الموصل التجاري	BMFI	2005-9-1
9	المصارف	مصرف المنصور التجاري	BMNS	2008-7-1
10	المصارف	المصرف الوطني الإسلامي	BNAI	2015-1-28
11	المصارف	المصرف الأهلي العراقي	BNOI	2004-7-8
12	المصارف	مصرف الائتمان التجاري	BROI	2004-8-7
13	الفنادق والسياحة	فندق المنصور السياحي	HMAN	2006-9-25
14	الفنادق والسياحة	فندق بابل السياحي	HBAY	2004-9-4
15	الفنادق والسياحة	فندق بغداد السياحي	HBAG	2004-7-8
16	الفنادق والسياحة	فندق رحاب كربلاء السياحي	HKAR	2004-7-25
17	الفنادق والسياحة	فندق فلسطين السياحي	HPAL	2004-7-25
18	الفنادق والسياحة	الشركة الوطنية للسياحة	HNTI	2004-7-8
19	الصناعة	شركة بغداد للمشروبات الغازية	IBPM	2004-7-25
20	الصناعة	الشركة العر اقية لتصنيع وتغليف التمور	IIDP	2004-9-4
21	الصناعة	الشركة العر اقية للسجاد والمفروشات	IITC	2004-7-25
22	الصناعة	شركة الكندي لإنتاج اللقاحات البيطرية	IKLV	2004-7-25
23	الصناعة	شركة المنصور للصناعات الدو ائية	IMAP	2004-11-17
24	الصناعة	شركة الخياطة الحديثة	IMOS	2004-7-8
25	الصناعة	شركة إنتاج الألبسة الجاهزة	IRMC	2004-7-25

المصدر: من إعداد الباحث بالاعتماد على بيانات سوق العراق للأوراق المالية.

2- **الدراسات المرجعية**: ضمن هذه الفقرة سوف يتم إعطاء صورة بسيطة لعملية التنبؤ بالأسعار وبالأخص أسعار الأسهم على وفق نتائج الدراسات التجريبية، إذ يعد التنبؤ بأسعار الأسهم من أكثر المواضيع بحثًا ويحظى باهتمام واسع من الأوساط الأكاديمية على حد سواء ومع ظهور الذكاء الاصطناعي تمّ توظيف العديد من الخوارزميات للتنبؤ بأسعار الأسهم، وقد صُمّمت تطبيقات مُدمجة تجمع بين الإحصاءات

وخوارزميات التعلّم الآلي إما للتنبؤ بسعر افتتاح السهم في اليوم التالي مباشرةً أو لفهم السوق على المدى الطويل في المستقبل، فقد قام Xie بدراسة تهدف إلى تطبيق الأساليب الإحصائية وأساليب التعلم الآلي للتنبؤ بأسعار الأسهم لمساعدة المستخدمين في اتخاذ القرارات في مجموعة متنوعة من التطبيقات العملية، وتم اعتماد 50 سعرًا سابق للأسهم للتنبؤ بأسعار الأسهم المستقبلية، وقد تم اعتماد كل من نموذجي ARIMA وLSTM للتنبؤ بالأسعار، وتم تقييم أداء النموذجين باستخدام MAE وMSE وRMSE بعد تشغيلهما وأظهرت النتائج أن كلاً من نموذج LSTM ونموذج ARIMA يتنبآن بسعر السهم بشكل جيد (Xie,2023:p740).

وفي دراسة تحليلية مقارنة بين نماذج التعلم العميق والأساليب الإحصائية التقليدية للتنبؤ بأسعار الأسهم وباستخدام البيانات التاريخية بما في ذلك الأسعار اليومية وأحجام التداول لتطبيق نماذج مثل شبكات الذاكرة طويلة المدى (LSTM) ووحدات التكرار (GRUs)، ونموذج المتوسط المتحرك المتكامل التلقائي (ARIMA)، ونموذج المتوسط المتحرك التلقائي (ARMA)، إذ تم تقييم هذه النماذج على مدى ثلاثة آفاق زمنية وهي قصيرة الأجل (سنة واحدة) ومتوسطة الأجل (سنتان ونصف) وطويلة الأجل (خمس سنوات)، وتم اعتماد متوسط مربع الخطأ (MSE) ومتوسط الخطأ المطلق (MAE)، واتضح أن نماذج التعلم العميق وبخاصة LSTM تتفوق على الأساليب التقليدية عن طريق قدرتها على رصد الأنماط المعقدة وغير الخطية في البيانات مما يؤدي إلى تنبؤات أكثر دقة (Alamu&Saim,2024:p363).

كما بحثت دراسة Zhang في الطرق المبتكرة لتحديد اتجاهات أسعار الأسهم، وتم التركيز على استراتيجيات عدة منها نموذج المتوسط المتحرك المتكامل التلقائي (ARIMA) والأشجار العشوائية وشبكات التخزين العصبي الطويلة والقصيرة (LSTM)، وباعتماد البيانات التاريخية للأسهم للتحقق من مدى فعاليتها من خلال اختبارات مقاييس الدقة مثل جذر متوسط مربع الخطأ (RMSE) ومتوسط النسبة المئوية للخطأ المطلق (MAPE)، وقد تم تشخيص مدى كفاءتها في فهم الأنماط المعقدة في أسعار الأسهم، وأظهرت النتائج أن نموذج LSTM وهو نوع من نماذج التعلم العميق الذي يتفوق على الطرق الكمية التقليدية، إذ يتميز بقدرته الفائقة على فهم العلاقات طويلة الأجل والتعامل مع العلاقات المعقدة في الأسواق، وتعد نماذج التعلّم الآلي مثل الغابات العشوائية ممتازة في رصد الاتجاهات قصيرة الأجل بينما يُناسب نموذج ARIMA مع البيانات المستقرة أو التي تتبع نمطًا معينًا، مع ذلك لا تزال هناك بعض التحديات مثل تغيّر ظروف السوق وخطر اعتماد المفاهيم بشكل مفرط على المعلومات السابقة والحاجة إلى معلومات عالية الجودة في جميع الطرق، كما تُشير النتائج التجريبية إلى أن استخدام طرق متنوعة يُمكن أن يزيد من دقة تقدير تغيرات أسعار الأسهم مما يُساعد المتداولين على اتخاذ قرارات أفضل في ظل تغير ظروف السوق(Zhang,2025:p209).

وفي دراسة تكتشف منهجًا قائمًا على البيانات للتنبؤ بأسعار الأسهم باستخدام بيانات السوق التاريخية، بما في ذلك أسعار الافتتاح والإغلاق وأعلى وأدنى الأسعار وحجم التداول، إذ تضمنت العينة سلاسل زمنية لبيانات شركات مدرجة في السوق المالي، مما يُتيح تحليل الاتجاهات وتحركات الأسعار عبر فترات زمنية مختلفة، وقد تم تطبيق وتقييم مجموعة من نماذج التعلم الآلي بما في ذلك الانحدار الخطي وأشجار القرار والغابات العشوائية، وAdaBoosting، وXGBoost، وخوارزمية أقرب الجيران ومُنحدر متجه الدعم والذاكرة طويلة المدى

(LSTM)، وقد تم تقييم هذه النماذج باستخدام جذر متوسط مربع الخطأ (RMSE) ومتوسط الخطأ المطلق (MAE) ودرجات ME لتحديد دقتها واتساقها، ومن بين النماذج التي تم اختبارها أظهر نموذج LSTM أداءً قويًا مما يجعله مناسبًا تمامًا لبيانات السلاسل الزمنية المالية، كما قدمت خوارزميات الغابات العشوائية وتعزيز، التدرج نتائج قوية مع تباين منخفض نسبيًا، بينما تميزت نماذج الانحدار التقليدية بالبساطة وسهولة التفسير وقد تم دمج مؤشرات فنية مثل المتوسطات المتحركة ومؤشر القوة النسبية (RSI) لتحسين حساسية النموذج لسلوك السوق، كما اتضح قدرة التعلم الآلي للتنبؤ(Jonathan etal.,2025:p12).

3. تغطية نظرية لتعلم الآلة

قبل الدخول في التعلم الآلة كان لابد علينا من التعرف على أول ظهور حقيقي لهذا المجال والاستخدام لهذه التقنيات، ففي منتصف القرن العشرين أخذ المختصون بالبحث عن مداخل جديدة في المجالات الإلكترونية، ورافق هذا البحث اكتشافات جديدة في علم الأعصاب من جانب، والتحكم بالآلات عن طريق الحاسوب من جانب أخر، وبالتالي طورت تقنيات يمكن من خلالها محاكاة عمل العقل البشري أطلق عليه مصطلح الذكاء الاصطناعي هذا كان في عام 1956من قبل جون مكارثي، وكان من أحد أهم مجالات الذكاء الاصطناعي هو التعليم الآلي،(Machine Learning) فالذكاء الاصطناعي هو علم وهندسة صناعة الآلات الذكية وبخاصة برامج الحاسوب الذكية والذي يرتبط بمهمة تتمثل في استخدام الحواسيب لفهم الذكاء البشري، ولكن الذكاء الاصطناعي لا يقتصر على الأساليب التي يمكن ملاحظتها بيولوجيًا، ورغم عدم وجود تعريف متفق عليه للذكاء الاصطناعي، إلا أنه يُوصف بشكل عام بأنه دراسة العمليات الحسابية التي تُتيح الإدراك والتفكير والتصرف، فاليوم يتجاوز حجم البيانات المُولّدة سواء من قِبل البشر أو الآلات قدرة البشر على استيعابها وتفسيرها واتخاذ قرارات معقدة بناءً عليها؛ لذلك يشكل الذكاء الاصطناعي أساسًا لجميع عمليات تعلم الحاسوب وهو مستقبل اتخاذ القرارات (Saini,2023:p256).

يعد تعلم الآلة أحد فروع الذكاء الاصطناعي الذي يشير إلى منح الآلات القدرة على التعلم واتخاذ القرارات بالاعتماد على نفسها دون الحاجة إلى برمجيات من قبل الانسان، إذ يمكن التعلم عن طريق الإجراءات السابقة والاحتفاظ بالبيانات للاستفادة منها في تطوير الأداء في المستقبل، يتم ذلك عن طريق برمجة محددة يتم تصميمها للوصول إلى الأفكار بواسطة هذه البيانات واستخدامها في اتخاذ القرارات، يشكل تعلم الآلة جزء مهم من الذكاء الاصطناعي واحد فروعة الذي يهتم بجعل الحاسوب قادر على التعلم من تلقاء نفسة من أي خبرات أو تجارب سابقة، مما يجعله قادر على التنبؤ واتخاذ القرارات المناسبة وبوقت أقل(Janiesch et al.,2021:p686)، وينظر العديد من الباحثين إلى التعلم الآلي كجزء (حصري) من الذكاء الاصطناعي، وبشكل عام يُعدّ التعلم جانبًا أساسيًا من جوانب الإدراك البشري يُعالج كميات هائلة من المعلومات باستخدام المعرفة المجردة التي تُساعدهم على فهم المدخلات الواردة بشكل أفضل، وبفضل طبيعتها التكيفية تستطيع نماذج التعلم الآلي محاكاة القدرات الإدراكية للإنسان، ويصف التعلم الآلي مجموعة من الأساليب الشائعة الاستخدام لحل مجموعة متنوعة من المشكلات الواقعية بمساعدة أنظمة الحاسوب التي يُمكنها تعلم حل المشكلة بدلًا من برمجتها بشكل صريح (Kühl

etal.,2020:p3)، أصبح تعلم الآلة تقنية مهمة للتنبؤ بالمتغيرات المالية مثل عوائد وأسعار الأسهم بسبب القدرة على التعامل مع حالات عدم التأكد التي تصاحب المعلومات، فضلاً عن تعاملها الجيد مع تقلبات أسعار الأسهم خلال الأجل القصير والقصير جداً، وقدرتها على فك تعقيدات بيانات السلاسل الزمنية غير الخطية التي تمثل السمة السائدة في أسعار الأسهم (Chararnakul&Enke,2008:p1005).

1.3. أنواع تعلم الآلة

هنالك أكثر من نوع من التعلم هي التعلم الآلي غير الخاضع للإشراف، والتعلم الآلي الخاضع للإشراف، والتعلم الآلي المعزز يشمل التعلم الآلي غير الخاضع للإشراف أساليب تكشف أنماطًا غير معروفة سابقًا في البيانات(Berry et al.,2020:p4) ، وبالتالي لا تمتلك مهام التعلم غير الخاضع للإشراف بالضرورة حلًا صحيحًا لعدم وجود حقيقة مطلقة، ويشير التعلم الآلي الخاضع للإشراف إلى الأساليب التي تسمح ببناء معرفة حول مهمة معينة من سلسلة من الأمثلة التي تمثل الخبرة السابقة، في عملية التعلم لا يتطلب الأمر أي تعديل يدوي أو برمجة للقواعد أو الاستراتيجيات لحل مشكلة ما، أي أن النموذج قادر على التعلم بذاته، وبتفصيل أكثر تهدف أساليب التعلم الآلي الخاضع للإشراف دائمًا إلى بناء نموذج عن طريق تطبيق خوارزمية على مجموعة من نقاط البيانات المعروفة لاكتساب فهم أعمق لمجموعة بيانات غير معروفة، تُصنف نقاط البيانات المعروفة دليلاً لإنشاء هدف لنموذج التعلم الآلي، يجمع ما يُسمى بالتعلم شبه الموجه بين عناصر التعلم الموجه وغير الموجه (الخاضع للأشراف وغير الخاضع للأشراف) (Aggarwal,2018:p44)؛ وذلك باستخدام بيانات مصنفة وغير مصنفة معًا، ويشير التعلم المعزز إلى الأساليب التي تُعنى بتعليم الأنظمة الذكية اتخاذ الإجراءات التي تزيد من مكافآتها التراكمية ويختلف عن التعلم الموجه في أنه لا يتطلب مطابقة السمات والأهداف بشكل صحيح للتدريب، فبدلاً من ذلك تسمح المكافآت وغيرها للنموذج بالتعلم المستمر بمرور الوقت، وينصب التركيز على المفاضلة بين استكشاف البيئة غير المعروفة واستغلال القاعدة المعرفة والموجودة (Kühl etal.,2020:p3)، كما يجب أن نميز بين التعلم الآلة والتعلم العميق.

فالتعلم العميق يعد فرع من فروع تعلم الآلة الذي يهتم في عمله على محاكات الخلايا العصبية الموجودة في العقل البشري بواسطة ابتكار شبكة عصبية اصطناعية التي تستطيع تحليل كميات كبيرة من البيانات، والتعلم العميق موجود منذ زمن طويل ومع ذلك في السنوات الأخيرة شهدت هذه التقنية ثورةً بفضل توافر البيانات الضخمة والتقدم في القدرة الحاسوبية (Sharifani&Amini,2023:p3898-3899)، كما أن التعلم العميق هو مجموعة من خوارزميات التعلم الآلي التي تستخدم طبقات متعددة تتوافق مع مستويات مختلفة من التجريد لكل مستوى يتكون من طبقة إدخال وطبقة إخراج وطبقات مخفية متعددة يُستخدم في توليف الصوت ومعالجة الصور والتعرف على الكتابة اليدوية واكتشاف الأشياء والتنبؤ والتحليل واتخاذ القرارات (Chahal & Gulia,2019:p4912)، فضلاً عن ذلك يعده بعضهم طريقة جديدة في بناء وتدريب واستخدام الشبكات العصبية.

وبالتالي فإن الذكاء الاصطناعي هو المجال الأوسع، أما التعلم العميق وتعلم الآلة فهما مجلات من الذكاء الاصطناعي يتم توظيفهما لتحقيق هدف محدد، كما أن مجال الذكاء الاصطناعي (AI) يستخدم عدة مصطلحات وهي التعلم الآلي (ML)، والتعلم العميق (DL)، وعلم البيانات (DS)، وعلى الرغم من أنها تبدو في كثير من الأحيان

غير قابلة للتمييز نظرًا لتشابه تطبيقاتها وعدم وجود تعريف محدد يميزها بوضوح، إلا أن هذه المصطلحات متداخلة ومن الضروري فهم كيفية اختلاف بعضها ببعضها الآخر، ويُعد الذكاء الاصطناعي والتعلم الآلي والتعلم العميق وعلم البيانات من أكثر المصطلحات شيوعًا بين العلماء والباحثين والتقنيين الذين يعملون في مجال الذكاء الاصطناعي، ويمكن فهم الفرق بين هذه المصطلحات من خلال الشكل رقم (1)، فالذكاء الاصطناعي هو التقنية المعنية بأتمتة السلوك الذكي ومحاولة بناء كيانات ذكية، ويمكن وصف الذكاء الاصطناعي مظلة واسعة تندرج تحتها تقنيات التعلم الآلي والتعلم العميق لتحقيق أهداف الذكاء الاصطناعي، فالتعلم الآلي كما تم توضيحه هو فرع من فروع الذكاء الاصطناعي، إذ نُعلّم الآلة كيفية اتخاذ القرارات باستخدام بيانات الإدخال من خلال الأدوات الإحصائية، بعبارة أخرى يمكننا القول إن طريقة تدريب أجهزة الكمبيوتر على تعلم الأنماط من مجموعة بيانات والتي تُستخدم عادةً لاتخاذ القرارات أو التنبؤات باسم التعلم الآلي(Works,2020:p24-25).

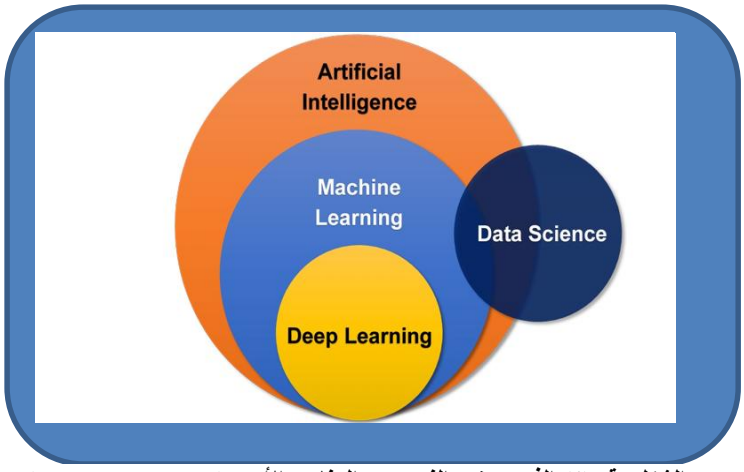

الشكل رقم (1) الذي يوضح الفرق بين المفاهيم الأربع (AI, ML, DL, DS)

Refrains: Works,(2020). Introduction to Artificial Intelligence and Machine Learning, 1st Edition.

2.3. خطوات تعلم الآلة

هنالك مجموعة من الخطوات المهمة التي يعتمد عليها تعلم الآلة من منها الآتي:- (عبد الوهاب وسلمان،2024:ص89-90).

1.2.3. اختيار النموذج: هنالك عدد من النماذج ضمن تعلم الآلة، وبالتالي يتطلب الأمر اختيار النموذج المناسب.

2.2.3. تدريب النموذج: أثناء عملية التدريب يتم تغذية النموذج المحدد بالبيانات المعدة ويقوم النموذج بضبط معلماته الداخلية بشكل متكرر؛ لتقليل الفرق بين تنبؤاته والقيم الفعلية في بيانات التدريب، وتتم هذه العملية باستخدام خوارزميات التحسين.

3.2.3. تقييم النموذج: بمجرد تدريب النموذج يجب تقييمه لتقييم أدائه على البيانات المتاحة إلى مجموعات تدريب واختبار، وتعتمد مقاييس التقييم المعتمدة على المشكلة المطروحة لغرض حلها مثل الدقة أو الاستدعاء أو درجة F1 للتصنيف أو متوسط الخطأ التربيعي أو R2 للانحدار.

4.2.3. ضبط النموذج: من خلال أداء النموذج ربما يتم إعادة ضبط دقيق عن طريق ضبط المعلمات أو حتى عن طريق تحديد خوارزميات مختلفة، والتي تسمى ضبط المعلمة والتي يتم إجرائها في الغالب بواسطة تقنيات تحديد.

4.استخدامات تقنية تعلم الآلة:

تعددت مجالات الاستخدامات لهذه التقنيات والتي كانت وليدة الحاجه لها في مختلف الجوانب الاقتصادية والمحاسبية والإدارية والإحصائية والمالية وغيرها، فعلى سبيل المثال كان لهذه التقنيات ثلاثة مجالات رئيسة للاستخدام وهي في مجالات التقدير والتنبؤ وتوضيح التأثير (تصنيف المتغيرات)، فمن ضمن المجالات المالية عملت الدراسات التجريبية على استخدام وتوظيف هذه التقنيات في كل من تحسين القرارات المالية وحوكمة الشركات وفي إدارة الائتمان ومخاطر الائتمان، وكان الأبرز هو مجال تقدير والتنبؤ بكل من العوائد والأسعار وبالأخص الأدوات المالية ومنها الأسهم،

إن ما تمتاز فيها اسوق الأسهم في مختلف الأنظمة من ديناميكية غير مستقرة وغير منتظمة بطبيعتها وتأثرها بعوامل عديدة منها الاقتصادي والسياسية وعدم اليقين بالعوامل الخاصة بالقطاع والشركة، لذا يتطلب الأمر تقييم إمكانية التنبؤ بأسعار الأسهم وصياغة توقعات علاوة عوائد الأسهم بناءً على مجموعات كبيرة من المعلومات المشروطة، ومع ذلك تفشل الأساليب التقليدية في مثل هذه الظروف إلا أن الأساليب الحديثة استطاعت تحقيق ذلك (Reyes & González,2023:p255)؛ وذلك لما لهذه التقنيات من لقدرة في التعامل مع البيانات الخطية وغير الخطية (Bahramianfar2013:20) التي تعاني من مشكلة عدم التجانس وهو ما تتميز بها البيانات المالية فقد استطاعت هذه التقنيات أن تتفوق على النماذج التقليدية التي عانت كثيراً أمام هذه المشاكل وطرق معالجتها المختلفة، ومن أبرز هذه التقنيات هي تعلم الآلة، كما أن دمج مؤشرات فنية متعددة مع نماذج التعلم الآلي للتنبؤ بحركة أسعار الأسهم يعد مجال ذو أهمية بالغة في مجال التداول والتحليلات المالية، وتستطيع النماذج رصد الاتجاهات وأنماط الزخم التي غالبًا ما تسبق تحولات الأسعار باستخدام مؤشرات، مثل مؤشر القوة النسبية (RSI) ومؤشر تقارب وتباعد المتوسطات المتحركة (MACD)، فضلاً عن بيانات الأسعار التاريخية (Jonathan etal.,2025:p22).

5. نماذج التعلم الآلي

هنالك العديد من التقنيات المتطورة مثل التحليل الفني والأساسي والإحصائي وتحليل السلاسل الزمنية التي تساعدنا في محاولة التنبؤ، ولكن لم تثبت أي من هذه الطرق موثوقيتها ودقتها كأداة موثوقة للتقدير(Polamuri et al,2019:p1224)، إلا أن كل من خوارزميات الانحدار اللوجستي والغابة العشوائية والشبكة العصبية متعددة الطبقات والذاكرة طويلة المدى تمثل أهم مناهج لتصنيف تعلم الآلة، والتي استطاعت أن تقدم تقديرات وتنبؤات دقيقة ووفق الاتي:- (Kamalov et al.,2021:p253-254).

1.5. الانحدار اللوجستي (LR): هو مصنف خطي بسيط يتميز الانحدار اللوجستي بدالة تكلفة محدبة تضمن وجود حد أدنى عالمي فريد، ولأنه مصنف خطي فهو مقاوم لظاهرة التخصيص الزائد، من جانب أخر لا يستطيع الانحدار اللوجستي التعامل مع الأنماط غير الخطية، وإحدى طرق معالجة هذه المشكلة هي توليد ميزات غير

خطية من الميزات الأصلية، وعلى الرغم من وجود خوارزميات تصنيف أكثر تطورًا إلا أن الانحدار اللوجستي لا يزال يُعد معيارًا قياسيًا، ويمثل ارتباط المشاهدات الحالية للسلسلة الزمنية مع مشاهدات سابقة لنفس السنة (Box atel,2008:9).

2.5. الغابة العشوائية (RF): هي تقنية تعلم آلي خاضعة للإشراف تعتمد على التجميع، وتُستخدم تقنيات التعلم الآلي في مجال استخراج البيانات، وتتمتع الغابة العشوائية بإمكانات هائلة في معالجة البيانات والوصول إلى نتائج (Sinha& Kulkarni,2013:p1144)، وهي مُقدِّر تجميعي يُطبِّق عددًا من مصنفات أشجار القرار على عينات فرعية مختلفة من مجموعة البيانات حجم العينة الفرعية هو نفسه حجم مجموعة بيانات الإدخال الأصلية، ويتم سحب العينات الفرعية مع الإحلال من البيانات الأصلية، ويتم تحديد مخرجات الغابة العشوائية بأخذ نمط أشجار القرار المستخدمة في التجميع، وتتمثل الميزة الرئيسة لخوارزمية الغابات العشوائية (RF) في بساطتها وكفاءتها، فضلاً عن ذلك تساعد عملية حساب المتوسطات في تقليل التجاوز في التدريب، كما تُعد خوارزمية الغابات العشوائية خوارزمية سريعة حسابيًا وتُعتبر مصنفًا جاهزًا ممتازًا للاستخدام.

3.5.الشبكة العصبية متعددة الطبقات (MLP): هي مصنف مستوحى من البنية العصبية للدماغ البشري، فقد حققت الشبكة العصبية متعددة الطبقات (MLP) ومشتقاتها نجاحًا باهرًا مؤخرًا في مجال التعرف على الصور والكلام، مما شجع على استخدامها في النمذجة المالية، وتتكون بنية الشبكة العصبية متعددة الطبقات (MLP) من ثلاث طبقات وهي طبقة الإدخال والطبقة المخفية وطبقة الإخراج، وتُعد الشبكة العصبية متعددة الطبقات (MLP) نموذجًا قويًا قادرًا على تقريب أي نمط (Ozturk,2020:p14) .

4.5.نماذج الذاكرة طويلة المدى (LSTM): هي شبكات عصبية متكررة (RNN) مُصممة لمعالجة البيانات المتسلسلة، ولا تستطيع نماذج الشبكات العصبية التقليدية الاستفادة من البنية الزمنية في البيانات المتسلسلة لذا تستخدم الشبكات العصبية المتكررة بنية شبكية خاصة، وتعتمد النتائج في كل خطوة زمنية على كلٍ من المدخلات في تلك الخطوة الزمنية والحالة في الخطوة الزمنية السابقة، مع ذلك فإن الشبكات العصبية المتكررة التقليدية عرضة لمشكلة تلاشي التدرج، إذ تتناقص قيمة التدرج بشكل أساس أثناء انتشارها عبر الشبكة، وقد طُرحت شبكات الذاكرة طويلة المدى (LSTM) لحل هذه المشكلة، وتستخدم LSTM بوابات خاصة تتحكم في التدفق التدريجي عبر الشبكة بطريقة تحافظ على إشارة التدرج، وتتكون خلية LSTM من عناصر أساسية هي حالة الخلية وبوابة النسيان وبوابة الإدخال وبوابة الإخراج، وتنقل حالة الخلية المعلومات عبر الشبكة رابطةً الخلايا البعيدة وتتحكم البوابات الثلاث في تدفق المعلومات داخل الخلية إذ تنظم بوابة النسيان كمية المعلومات المتبقية في الخلية، بينما تتحكم بوابة الإدخال في كمية المعلومات الجديدة المتدفقة إليها، وتحدد بوابة الإخراج الحالة المخفية التالية، ونظرًا لاحتواء شبكات الذاكرة طويلة المدى (LSTM) على عدد كبير من المعاملات فإنها أكثر عرضة للتخصيص الزائد لبيانات التدريب.

6. الجانب التحليلي واختبار فرضيات الدراسة

قبل الولوج في اختبار التنبؤ كان لابد من إجراء اختبار Mean Bias الخاص بتطابق نتائج تقدير قيم أسعار الأسهم؛ وذلك لمعرفة مدى تطابق القيمة الفعلية لأسعار أسهم مع القيمة المقدرة، وهو ما يسمى متوسط الفرق البسيط، ويتم ذلك على وفق المعادلة الآتية (Steurer et al.,2021;p103).

$$MAB=\frac{1}{N}\sum_{I=1}^{N}(\hat{y}i - yi)..... 1$$

1.6. متوسط الفرق البسيط للشركات عينة الدراسة

الجدول (2) يعرض نتائج اختبار Mean Bias للشركات عينة الدراسة للمدة من شهر 3-2015 ولغاية شهر 3-2025

قطاع المصارف	مصرف بغداد التجاري	المصرف التجاري العراقي	مصرف إيلاف الإسلامي	مصرف الخليج التجاري	مصرف الاستثمار التجاري	مصرف العراقي الإسلامي
	-0.016	0.546	0.368	0.299	0.382	0.580
قطاع المصارف	مصرف الشرق الأوسط	مصرف الموصل التجاري	مصرف المنصور التجاري	المصرف الوطني الإسلامي	المصرف الأهلي العراقي	مصرف الائتمان التجاري
	0.229	0.223	0.842	0.899	1.081	0.568
قطاع الفنادق والسياحة	فندق المنصور	فندق بابل	فندق بغداد	فندق كربلاء	فندق فلسطين	الوطنية للسياحة
	0.026	0.111	-0.061	-0.003	0.107	-0.040
قطاع الشركات الصناعية	بغداد للمشروبات	العراقية لتصنيع التمور	العراقية للسجاد والمفروشات	الكندية لإنتاج اللقاحات	المنصور للصناعات الدوائية	الخياطة الحديثة
	0.012	0.022	-0.065	-0.026	0.001	-0.050
قطاع الشركات الصناعية	صناعات الألبسة الجاهزة					
	0.076					

المصدر: من إعداد الباحث باستخدام Excel .

1.1.6. قطاع المصارف: من خلال بيانات الجدول رقم (2) وباعتماد معادلة متوسط الفرق البسيط اتضح أن هنالك تباين كبير في المصارف، فقد أوضح أن المصرف الأهلي العراقي قد حقق متوسط فرق بسيط أكبر من الواحدة الصحيح، وبالتالي هنالك انحياز ولكن هذا الانحياز ليس مبالغ فيه، أما مصرف بغداد التجاري فقد كانت القيمة منخفضة وسالبة، وبالتالي الانحياز جداً بسيط أي أن تقليل انحياز التنبؤ أكبر، أما بقية المصارف فهي قيم تراوحت ما بين 0.223 و 0.899، وبالتالي وبشكل عام كخلاصة اختبار متوسط الفرق البسيط لقطاع المصارف أتضح أن المتوسطات صغيرة والنموذج قريب من القيم الحقيقية والانحياز ضعيف.

2.1.6. قطاع الفنادق والسياحة: كما يعرض الجدول رقم (2) كذلك نتائج قطاع الفنادق والسياحة، فقد حقق فندق بابل السياحي أكبر متوسط الفرق البسيط والبالغ 0.111 مقارنة مع أقل متوسط الفرق الذي كان من نصيب الشركة الوطنية للسياحة والبالغ 0.040-، وبالتالي فإن المتوسطات صغيرة والنموذج قريب من القيم الحقيقة والانحياز ضعيف.

3.1.6. قطاع الشركات الصناعية: يعرض الجدول رقم (2) نتائج Mean Bias الخاصة بالشركات الصناعية العراقية عينة الدراسة، إذ اتضح أن اكبر Mean Bias كان من نصيب شركة صناعات الألبسة الجاهزة، إذ بلغ 0.076 ، أما أقل قيمة فقد طانت من نصيب الشركة العراقية لصناعة المفروشات، إذ بلغ -0.065، وأتضح أن المتوسطات صغير والنموذج قريب من القيم الحقيقية والانحياز ضعيف.

7. الجانب التحليلي واختبار فرضيات الدراسة

من أجل إثبات أو نفي الفرضية الرئيسة الخاصة بالدراسة ووفقاً لما طرح في منهجية الدراسة، فقد تم اختبار نوعين من النماذج وباعتماد البرنامج MATLAB أحدهم بعينة تدريب بلغت 60% واختبار 40%، والنموذج الثاني فقد كان بعينة تدريب 70% واختبار30%، أي أن حجم العينة موزع وفق 73 و 48 مشاهدة ضمن النموذج الأول و85 و36 ضمن النموذج الثاني، وبالتالي نحن ضمن عدد مشاهدات الاختبار لا تقل عن 36 مشاهدة ضمن أقل النماذج وهو عدد مقبول وصالح للاختبار لا سيما وإن عدد المشاهدات الكلية 121 مشاهدة لكل مصرف أو شركة ، أما دقة النموذج فقد تباينت بحسب كل مصرف وشركة وفقاً لـ MSE.

1.7. تحليل القيم المتنبئ بها لقطاع المصارف

من خلال بيانات الجدول (3) اتضح أن أكبر متوسط قيمة متنبئ بها لأسعار قطاع المصارف عينة الدراسة خلال المدة المدروسة كان من نصيب المصرف التجاري العراقي، إذ بلغت 5.907 دينار بانحراف معياري بلغ0.620؛ وذلك يعود إلى سعر السهم المرتفع خلال المدة التي تم الاعتماد عليها، وباعتماد تقنية تعلم الآلة فقد حقق نموذج التدريب 60% واختبار 40% اقل MSE بلغ 0.1791 ؛ وذلك بحسب بيانات الجدول رقم (4) الذي يعرض MSEبالمقارنة مع نموذج تدريب 70% واختبار30% إذ بلغ MSE 0.1833، أما أقل قيمة متنبئ بها فقد كانت من نصيب مصرف الشرق الأوسط إذ بلغت 0.121 بانحراف معياري منخفض جداً بلغ 0.001، وذلك على وفق نموذج تعلم الآلة المعتمد بعينة تدريب بلغت 60% واختبار 40% إذ بلغ MSE 0.0959 بالمقارنة مع نموذج يعتمد تدريب 70% واختبار30 إذ بلغ MSE 0.0971 ، وهذا يعود إلى استقرار مدخلات التنبؤ والتي تتمثل هنا بأسعار أسهم مصرف الشرق الأوسط خلال مدة الدراسة، أما بقية المصارف فهي متاحة ضمن الجدول رقم (3).

الجدول (3) القيمة المتنبئ بها على وفق تقنية تعلم الآلة للمدة من (4-2025 ولغاية 12-2027) لقطاع المصارف

التاريخ/الـ مصرف	مصرف بغداد	المصرف التجاري	إيلاف الإسلامي	الخليج التجاري	مصرف الاستثمار	العراقي الإسلامي	الشرق الأوسط	مصرف الموصل	مصرف المنصور	الوطني الإسلامي	الأهلي العراقي	الائتمان العراقي
Apr-25	4.158	0.967	0.967	0.313	0.327	1.581	0.119	0.205	2.098	0.676	3.851	0.939
May-25	4.203	0.984	0.984	0.316	0.328	1.616	0.120	0.205	2.153	0.674	3.948	0.953
Jun-25	4.244	1.002	1.002	0.319	0.329	1.647	0.120	0.205	2.204	0.673	4.043	0.967
Jul-25	4.283	1.019	1.019	0.322	0.330	1.675	0.120	0.205	2.252	0.671	4.137	0.980
Aug-25	4.319	1.036	1.036	0.325	0.332	1.701	0.120	0.206	2.295	0.670	4.230	0.993
Sep-25	4.353	1.052	1.052	0.328	0.333	1.724	0.120	0.206	2.334	0.668	4.321	1.006
Oct-25	4.384	1.069	1.069	0.331	0.334	1.745	0.120	0.206	2.369	0.667	4.410	1.019
Nov-25	4.413	1.085	1.085	0.334	0.335	1.763	0.120	0.206	2.401	0.666	4.498	1.031
Dec-25	4.439	1.100	1.100	0.337	0.336	1.780	0.120	0.207	2.429	0.664	4.583	1.043
Jan-26	4.464	1.115	1.115	0.340	0.337	1.794	0.120	0.207	2.454	0.663	4.666	1.054
Feb-26	4.487	1.130	1.130	0.343	0.338	1.807	0.120	0.207	2.476	0.662	4.746	1.065

1.076	4.825	0.661	2.496	0.207	0.120	1.818	0.339	0.345	1.144	1.144	4.508	Mar-26
1.087	4.900	0.660	2.513	0.207	0.120	1.828	0.340	0.348	1.158	1.158	4.527	Apr-26
1.097	4.974	0.658	2.528	0.208	0.120	1.837	0.341	0.351	1.171	1.171	4.545	May-26
1.107	5.044	0.657	2.541	0.208	0.120	1.844	0.342	0.354	1.183	1.183	4.562	Jun-26
1.117	5.113	0.656	2.552	0.208	0.121	1.851	0.343	0.357	1.196	1.196	4.577	Jul-26
1.126	5.178	0.655	2.562	0.208	0.121	1.856	0.344	0.359	1.207	1.207	4.591	Aug-26
1.135	5.241	0.654	2.571	0.208	0.121	1.861	0.345	0.362	1.218	1.218	4.604	Sep-26
1.143	5.302	0.653	2.578	0.208	0.121	1.866	0.346	0.365	1.229	1.229	4.616	Oct-26
1.152	5.360	0.652	2.584	0.209	0.121	1.870	0.347	0.368	1.239	1.239	4.627	Nov-26
1.160	5.416	0.651	2.589	0.209	0.121	1.873	0.348	0.370	1.248	1.248	4.636	Dec-26
1.168	5.469	0.650	2.594	0.209	0.121	1.876	0.349	0.373	1.257	1.257	4.646	Jan-27
1.175	5.519	0.649	2.597	0.209	0.121	1.878	0.350	0.376	1.266	1.266	4.654	Feb-27
1.182	5.568	0.648	2.601	0.209	0.121	1.880	0.351	0.378	1.274	1.274	4.662	Mar-27
1.189	5.614	0.648	2.603	0.209	0.121	1.882	0.352	0.381	1.282	1.282	4.669	Apr-27
1.196	5.657	0.647	2.605	0.209	0.122	1.884	0.352	0.383	1.289	1.289	4.675	May-27
1.202	5.699	0.646	2.607	0.210	0.122	1.885	0.353	0.386	1.296	1.296	4.681	Jun-27
1.208	5.738	0.645	2.608	0.210	0.122	1.886	0.354	0.388	1.302	1.302	4.687	Jul-27
1.214	5.776	0.644	2.609	0.210	0.122	1.887	0.355	0.391	1.308	1.308	4.692	Aug-27
1.220	5.812	0.644	2.610	0.210	0.122	1.888	0.356	0.393	1.314	1.314	4.696	Sep-27
1.226	5.845	0.643	2.610	0.210	0.122	1.889	0.357	0.396	1.319	1.319	4.701	Oct-27
1.231	5.877	0.642	2.611	0.210	0.122	1.890	0.358	0.398	1.324	1.324	4.704	Nov-27
1.236	5.907	0.641	2.611	0.210	0.122	1.890	0.358	0.400	1.328	1.328	4.708	Dec-27
1.112	5.069	0.656	2.492	0.208	0.121	1.817	0.344	0.358	1.185	1.185	4.537	المتوسط
0.939	3.851	0.641	2.098	0.205	0.119	1.581	0.327	0.313	0.967	0.967	4.158	أقل قيمة
1.236	5.907	0.676	2.611	0.210	0.122	1.890	0.358	0.400	1.328	1.328	4.708	أكبر قيمة
0.089	0.620	0.010	0.146	0.002	0.001	0.086	0.009	0.026	0.110	0.110	0.159	SD

المصدر: من إعداد الباحث بالاعتماد على نتائج اختبارات تقنية تعلم الآلة وباستخدام برنامج MATLAB

الجدول (4) عينة الاختبار والتدريب و MSE على وفق تقنيات تعلم الآلة للمدة من (4-2025 ولغاية 12-2027) لقطاع المصارف

ت	اسم المصرف	نسبة التدريب	نسبة الاختبار	حجم التدريب	حجم الاختبار	MSE
1	مصرف بغداد التجاري	**0.60**	**0.40**	**73**	**48**	**0.0277**
		0.70	0.30	85	36	0.0321
2	المصرف التجاري العراقي	**0.60**	**0.40**	**73**	**48**	**0.1791**
		0.70	0.30	85	36	0.1833
3	مصرف إيلاف الإسلامي	0.60	0.40	73	48	0.7270
		0.70	**0.30**	**85**	**36**	**0.5690**
4	مصرف الخليج التجاري	0.60	0.40	73	48	0.0866
		0.70	**0.30**	**85**	**36**	**0.0577**
5	مصرف الاستثمار التجاري	0.60	0.40	73	48	0.1110
		0.70	**0.30**	**85**	**36**	**0.0755**
6	المصرف العراقي الإسلامي	**0.60**	**0.40**	**73**	**48**	**0.0557**
		0.70	0.30	85	36	0.0612
7	مصرف الشرق الأوسط	**0.60**	**0.40**	**73**	**48**	**0.0959**
		0.70	0.30	85	36	0.0971
8	مصرف الموصل التجاري	0.60	0.40	73	48	0.0925
		0.70	**0.30**	**85**	**36**	**0.0668**

9	مصرف المنصور التجاري	**0.60**	**0.40**	**73**	**48**	**0.0701**
		0.70	0.30	85	36	0.0908
10	المصرف الوطني الإسلامي	**0.60**	**0.40**	**73**	**48**	**0.3515**
		0.70	0.30	85	36	0.4161
11	المصرف الأهلي العراقي	**0.60**	**0.40**	**73**	**48**	**0.0625**
		0.70	0.30	85	36	0.0725
12	مصرف الائتمان العراقي	**0.60**	**0.40**	**73**	**48**	**0.1426**
		0.70	0.30	85	36	0.1657

المصدر: من إعداد الباحث بالاعتماد على نتائج اختبارات تقنية تعلم الآلة وباستخدام برنامج MATLAB

2.7. تحليل القيم المتنبئ بها لقطاع الفنادق والسياحة

من خلال بيانات الجدول 5 اتضح أن أكبر متوسط قيمة متنبئ بها لأسعار قطاع الفنادق والسياحة عينة الدراسة خلال المدة المدروسة كان من نصيب فندق بابل إذ بلغ 106.238 دينار بانحراف معياري بلغ0.920؛ وذلك يعود إلى سعر السهم المرتفع خلال المدة التي تم الاعتماد عليها، وباعتماد تقنية تعلم الآلة فقد حقق نموذج التدريب70% واختبار 30% اقل MSE بلغ 0.0298؛ وذلك بحسب بيانات الجدول رقم (6) بالمقارنة مع نموذج تدريب 60% واختبار40% إذ بلغ MSE 0.0915، أما أقل قيمة متنبئ بها فقد كانت من نصيب فندق كربلاء إذ بلغت 0.898 بانحراف معياري منخفض جداً بلغ 0.011، وذلك على وفق نموذج تعلم الآلة المعتمد بعينة تدريب بلغت 60% واختبار 40% إذ بلغ MSE 0.1239 بالمقارنة مع نموذج يعتمد تدريب 70% واختبار30 إذ بلغ MSE 0.1592 ، وهذا يعود إلى استقرار مدخلات التنبؤ والتي تتمثل هنا بأسعار أسهم فندق كربلاء خلال مدة الدراسة، أما بقية الشركات فهي متاحة ضمن الجدول رقم (6).

الجدول (5) القيمة المتنبئ بها على وفق تقنية تعلم الآلة للمدة من (4-2025 ولغاية 12-2027) لقطاع الفنادق والسياحة

التاريخ	فندق المنصور	فندق بابل	فندق بغداد	فندق كربلاء	الوطنية للسياحة
Apr-25	42.479	104.376	12.201	0.879	10.6516
May-25	42.512	104.542	12.325	0.880	10.6653
Jun-25	42.538	104.703	12.449	0.881	10.6785
Jul-25	42.558	104.857	12.571	0.882	10.6913
Aug-25	42.573	105.005	12.692	0.884	10.7037
Sep-25	42.584	105.147	12.811	0.885	10.7156
Oct-25	42.591	105.284	12.928	0.886	10.7272
Nov-25	42.594	105.416	13.044	0.887	10.7384
Dec-25	42.596	105.542	13.157	0.888	10.7492
Jan-26	42.595	105.664	13.268	0.890	10.7597
Feb-26	42.592	105.782	13.376	0.891	10.7699
Mar-26	42.587	105.895	13.482	0.892	10.7797
Apr-26	42.582	106.003	13.585	0.893	10.7893
May-26	42.575	106.108	13.685	0.894	10.7985
Jun-26	42.567	106.208	13.782	0.895	10.8075
Jul-26	42.559	106.305	13.876	0.897	10.8162

10.8246	0.898	13.967	106.398	42.551	**Aug-26**
10.8328	0.899	14.055	106.488	42.541	**Sep-26**
10.8407	0.900	14.140	106.574	42.532	**Oct-26**
10.8485	0.901	14.222	106.657	42.522	**Nov-26**
10.8560	0.903	14.301	106.738	42.512	**Dec-26**
10.8632	0.904	14.376	106.815	42.502	**Jan-27**
10.8703	0.905	14.449	106.889	42.492	**Feb-27**
10.8772	0.906	14.518	106.961	42.482	**Mar-27**
10.8839	0.907	14.584	107.030	42.472	**Apr-27**
10.8904	0.908	14.648	107.097	42.462	**May-27**
10.8968	0.910	14.708	107.161	42.452	**Jun-27**
10.9030	0.911	14.766	107.223	42.442	**Jul-27**
10.9090	0.912	14.821	107.283	42.432	**Aug-27**
10.9148	0.913	14.873	107.341	42.422	**Sep-27**
10.9206	0.914	14.922	107.396	42.413	**Oct-27**
10.9261	0.915	14.969	107.450	42.403	**Nov-27**
10.9316	0.916	15.014	107.502	42.394	**Dec-27**
10.8131	0.898	13.835	106.238	42.518	**المتوسط**
10.6516	0.879	12.201	104.376	42.394	**أقل قيمة**
10.9316	0.916	15.014	107.502	42.596	**أكبر قيمة**
0.0824	0.011	0.851	0.920	0.063	**SD**

المصدر: من إعداد الباحث بالاعتماد على نتائج اختبارات تقنية تعلم الآلة وباستخدام برنامج MATLAB

الجدول (6) عينة الاختبار والتدريب و MSE على وفق تقنيات تعلم الآلة للمدة من (4-2025 ولغاية 12-2027) لقطاع الفنادق والسياحة

ت	اسم الفندق	نسبة التدريب	نسبة الاختبار	حجم التدريب	حجم الاختبار	MSE
1	فندق المنصور السياحي	**0.60**	**0.40**	**73**	**48**	**0.0434**
		0.70	0.30	85	36	0.0598
2	فندق بابل السياحي	0.60	0.40	73	48	0.0915
		0.70	**0.30**	**85**	**36**	**0.0298**
3	فندق بغداد السياحي	0.60	0.40	73	48	0.1681
		0.70	**0.30**	**85**	**36**	**0.1137**
4	فندق كربلاء السياحي	**0.60**	**0.40**	**73**	**48**	**0.1239**
		0.70	0.30	85	36	0.1592
5	فندق فلسطين السياحي	0.60	0.40	73	48	0.0595
		0.70	0.30	85	36	0.0632
6	الشركة الوطنية للسياحة	0.60	0.40	73	48	0.1377
		0.70	**0.30**	**85**	**36**	**0.1005**

المصدر: من إعداد الباحث بالاعتماد على نتائج اختبارات تقنية تعلم الآلة وباستخدام برنامج MATLAB

3.7. تحليل القيم المتنبئ بها لقطاع الصناعة

من خلال بيانات الجدول (7) اتضح أن أكبر متوسط قيمة متنبئ بها لأسعار قطاع الصناعة عينة الدراسة خلال المدة المدروسة كان من نصيب الشركة العراقية للسجاد والمفروشات إذ بلغ 15.296 دينار بانحراف معياري بلغ0.084، وذلك يعود إلى سعر السهم المرتفع خلال المدة التي تم الاعتماد عليها، وباعتماد تقنية تعلم الآلة فقد حقق نموذج التدريب60% واختبار 40% اقل MSE بلغ 0.0158 ، وذلك بحسب بيانات الجدول رقم (8) بالمقارنة مع نموذج تدريب 70% واختبار30% إذ بلغ MSE 0.0398، أما أقل قيمة متنبئ بها فقد كانت من نصيب شركة الكندي لإنتاج اللقاحات البيطرية إذ بلغت 1.888 بانحراف معياري منخفض جداً بلغ 0.035، وذلك على وفق نموذج تعلم الآلة المعتمد بعينة تدريب بلغت 60% واختبار 40% إذ بلغ MSE 0.2063 بالمقارنة مع نموذج يعتمد تدريب 70% واختبار30% إذ بلغ MSE 0.2617، وهذا يعود إلى استقرار مدخلات التنبؤ والتي تتمثل هنا بأسعار أسهم فندق شركة الكندي لإنتاج اللقاحات البيطرية خلال مدة الدراسة، أما بقية الشركات فهي متاحة ضمن الجدول رقم7.

الجدول (7) القيمة المتنبئ بها على وفق تقنية تعلم الآلة للمدة من (4-2025 ولغاية 12-2027) لقطاع الصناعة

التاريخ/ الشركة	بغداد للمشروبات	العراقية للتمور	العراقية للسجاد	الكندي للقاحات	المنصور الدوائية	الخياطة الحديثة	الألبسة الجاهزة
Apr-25	3.981	3.621	15.440	1.825	2.013	9.259	4.176
May-25	3.982	3.799	15.431	1.830	2.007	9.307	4.203
Jun-25	3.984	3.968	15.422	1.834	2.001	9.355	4.230
Jul-25	3.985	4.126	15.412	1.838	1.995	9.402	4.256
Aug-25	3.986	4.272	15.403	1.843	1.989	9.449	4.283
Sep-25	3.987	4.404	15.394	1.847	1.983	9.495	4.308
Oct-25	3.988	4.524	15.384	1.851	1.977	9.541	4.334
Nov-25	3.989	4.630	15.375	1.855	1.971	9.587	4.358
Dec-25	3.990	4.724	15.366	1.859	1.965	9.632	4.383
Jan-26	3.991	4.806	15.357	1.863	1.959	9.677	4.407
Feb-26	3.992	4.877	15.347	1.867	1.953	9.722	4.431
Mar-26	3.993	4.938	15.338	1.871	1.948	9.766	4.454
Apr-26	3.994	4.990	15.329	1.875	1.942	9.809	4.477
May-26	3.995	5.035	15.320	1.879	1.936	9.852	4.499
Jun-26	3.995	5.072	15.311	1.883	1.931	9.895	4.521
Jul-26	3.996	5.104	15.302	1.886	1.925	9.938	4.543
Aug-26	3.997	5.130	15.294	1.890	1.919	9.979	4.564
Sep-26	3.997	5.151	15.285	1.894	1.914	10.021	4.585
Oct-26	3.998	5.169	15.276	1.897	1.908	10.062	4.606
Nov-26	3.999	5.184	15.267	1.901	1.903	10.103	4.626
Dec-26	3.999	5.195	15.259	1.904	1.897	10.143	4.646
Jan-27	4.000	5.204	15.250	1.907	1.892	10.183	4.665
Feb-27	4.000	5.212	15.241	1.911	1.886	10.222	4.684
Mar-27	4.001	5.217	15.233	1.914	1.881	10.261	4.703
Apr-27	4.001	5.221	15.224	1.917	1.875	10.300	4.721
May-27	4.002	5.224	15.216	1.921	1.870	10.338	4.739

Jun-27	4.002	5.226	15.208	1.924	1.865	10.376	4.757
Jul-27	4.003	5.227	15.199	1.927	1.860	10.413	4.774
Aug-27	4.003	5.227	15.191	1.930	1.854	10.450	4.791
Sep-27	4.003	5.227	15.183	1.933	1.849	10.487	4.808
Oct-27	4.004	5.226	15.175	1.936	1.844	10.523	4.824
Nov-27	4.004	5.225	15.166	1.939	1.839	10.558	4.840
Dec-27	4.005	5.223	15.158	1.942	1.834	10.594	4.856
المتوسط	3.995	4.890	15.296	1.888	1.921	9.961	4.547
اقل قيمة	3.981	3.621	15.158	1.825	1.834	9.259	4.176
اكبر قيمة	4.005	5.227	15.440	1.942	2.013	10.594	4.856
SD	0.007	0.457	0.084	0.035	0.053	0.398	0.203

المصدر: من إعداد الباحث بالاعتماد على نتائج اختبارات تقنية تعلم الآلة وباستخدام برنامج MATLAB

جدول (8) عينة الاختبار والتدريب و MSE على وفق تقنيات تعلم الآلة للمدة من (4-2025 ولغاية 12-2027) لقطاع الصناعة

ت	اسم الشركة	نسبة التدريب	نسبة الاختبار	حجم التدريب	حجم الاختبار	MSE
1	شركة بغداد للمشروبات الغازية	0.60	0.40	73	48	0.1726
		0.70	**0.30**	**85**	**36**	0.1612
2	الشركة العراقية لتصنيع التمور	**0.60**	**0.40**	**73**	**48**	**0.6246**
		0.70	0.30	85	36	0.8964
3	الشركة العراقية للسجاد والمفروشات	**0.60**	**0.40**	**73**	**48**	**0.0158**
		0.70	0.30	85	36	0.0398
4	الكندي لصناعات اللقاحات البيطرية	**0.60**	**0.40**	**73**	**48**	**0.2063**
		0.70	0.30	85	36	0.2617
5	شركة المنصور لصناعات الدوائية	**0.60**	**0.40**	**73**	**48**	**0.0908**
		0.70	0.30	85	36	0.1149
6	شركة الخياطة الحديثة	**0.60**	**0.40**	**73**	**48**	**0.1731**
		0.70	0.30	85	36	0.2146
7	شركة الألبسة الجاهزة	0.60	0.40	73	48	0.1708
		0.70	**0.30**	**85**	**36**	**0.1323**

المصدر: من إعداد الباحث بالاعتماد على نتائج اختبارات تقنية تعلم الآلة وباستخدام برنامج MATLAB

من خلال نتائج الجداول 3,4,5,6,7,8 وما أفرزته تفسيرات كل من متوسط الفرق البسيط و MSE، وبالعودة إلى فرضية الدراسة الرئيسة والتي تنص على عدم قدرة تقنية تعلم الآلة على التنبؤ بأسعار الأسهم للشركات عينة الدراسة، وبعد تحليل الشركة الخمس والعشرون للقطاعات الثلاثة الرئيسة في سوق العراق للأوراق المالية، تم رفض الفرضية الرئيسة وقبول الفرضية البديلة، وبالتالي هنالك قدرة لتقنية تعلم الآلة على التنبؤ بأسعار الأسهم للشركات عينة الدراسة في القطاعات الثلاثة الرئيسة.

الاستنتاجات

1- هنالك قصور في الكثير من برامج التنبؤ التقليدية، وبالأخص في ما يتعلق بافتراضات النماذج غير الواقعية.

2- أوجه القصور والافتراضات غير الواقعية للنماذج التقليدية كانت بيئة وليدة لوجود واستخدام النماذج الحديثة.

3- يعد كل من التقدير والتنبؤ والقوة التأثيرية من أهم استخدامات تقنية تعلم الآلة.

4- هنالك أكثر من نوع من تعلم الآلة، ويعتمد التقسيم على مدى الإشراف على هذا التعلم من عدمه.

5- قدرة مؤشر متوسط الفرق البسيط على تحديد وجود من عدم وجود فروقات بين القيم المقدرة مع القيم الفعلية لأسعار الأسهم.

6- اعتماد سلسلة أسعار تأريخيه تعطي تقديرات وتنبؤات أفضل من اعتماد متغيرات جزئية أو كلية قد تكون غير ذات أثر كبير في هذه القيم ولاسيما في البيئة العراقية (شركات سوق العراق للأوراق المالية).

7- هنالك تباين في تفوق نموذج دون آخر من النماذج المعتمدة في الاختبار، وذلك على وفق MSE بين الشركات عينة الدراسة.

8- قدرة تقنية تعلم الآلة على التنبؤ بأسعار الأسهم للشركات عينة الدراسة.

التوصيات

1- على المهتمين تبني التقنيات الحديثة في المجالات المالية ولاسيما تقنية تعلم الآلة.

2- إجراء اختبارات مقارنة لهذه التقنية (تعلم الآلة) وغيرها من التقنيات أو النماذج الأخرى للوقوف على مدى التباين في النتائج.

3- ضرورة اعتماد خطوات اختيار النموذج المناسب.

4- اعتماد تقنية تعلم الآلة في التنبؤ بعائد الأسهم مع الأخذ بنظر الاعتبار العوامل المؤثرة في هذا العائد، وبالتالي بالإمكان تضمينها ضمن هذه التقنية.

5- إجراء اختبارات أوسع على مددة وقطاعات أخرى لم يتم تضمينها ضمن الدراسة.

6- إدخال وتبني أدوات الذكاء الاصطناعي في بناء مكونات وكلف الهيكل التمويلي للشركات.

7- على المختصين الأخذ بمؤشرات نتائج الدراسة؛ كونها دراسة مبنية على بيانات فعلية تتمثل بالأسعار الفعلية للأسهم.

المصادر:

1- عبد الوهاب ، عمر محمد وسلمان، مريم محمد،(2024)، استعمال تعلم الآلة في النماذج الإحصائية للتنبؤ السكاني في العراق، مجلة كلية الرافدين الجامعة للعلوم.

2- Alamu, O. S., & Siam, M. K. (2024). Stock price prediction and traditional models: An approach to achieve short-, medium-and long-term goals. arXiv preprint arXiv:2410.07220.

3- Aggarwal, Charu C.,(2018) Neural Networks and Deep Learning, Springer, Yorktown Heights, NY, USA.

4- Bahramianfar, P. (2013). Forecasting US home prices with artificial neural networks and fuzzy methods combination and single forecasts (Doctoral dissertation, Eastern Mediterranean University (EMU)-Doğu Akdeniz Üniversitesi (DAÜ).
5- Berry, M. W., Mohamed, A., & Yap, B. W. (Eds.). (2019). Supervised and unsupervised learning for data science. Springer Nature.
6- Box, G. E., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2008). Time series analysis: forecasting and control, 4th Edition, John Wiley & Sons, Inc., Hoboken, New Jersey.
7- Chahal, A., & Gulia, P. (2019). Machine learning and deep learning. International Journal of Innovative Technology and Exploring Engineering, 8(12), 4910-4914.
8- Chavarnakul, Thira, & Enke, David, Intelligent Technical Analysis Based Equivoque Charting for Stock Trading Using Neural Networks, Expert Systems with Applications, 34, 2008, pp. 1004–1017.
9- Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning: C. Janiesch et al. Electronic markets, 31(3), 685-695.
10- Jonathan, D., Burugupalli, S., Uggina, M., Kancherala, H., Chilukuri, G. S. P., Nwanegbo, I. M., & Chiobi, N. F. (2025). Stock price prediction using machine learning. International Journal of Engineering Processing & Safety Research, 8(5). https://doi.org/10.70382/caijepsr.v8i5.008
11- Kamalov, F., Gurrib, I., & Rajab, K. (2021). Financial forecasting with machine learning: price vs return. Kamalov, F., Gurrib, I. & Rajab, K.(2021). Financial Forecasting with Machine Learning: Price Vs Return. Journal of Computer Science, 17(3), 251-264.
12- Kühl, N., Schemmer, M., Goutier, M., & Satzger, G. (2022). Artificial intelligence and machine learning. Electronic Markets, 32(4), 2235-2244.
13- Kulkarni, Vrushali Y and Sinha, Pradeep K (2013), Random Forest Classifiers :A Survey and Future Research Direction, International Journal of Advanced Computing, ISSN:2051-0845, Vol.36, Issue 1.
14- Ozturk, B. (2020). Electricity Consumption Forecasting in Chicago Area Using Artificial Neural Network (ANN) with the Nonlinear Autoregressive Network with Exogenous Inputs (NARX) Approach. Southern Illinois University at Edwardsville.
15- Polamuri, S. R., Srinivas, K., & Mohan, A. K. (2019). Stock market prices prediction using random forest and extra tree regression. Int. J. Recent Technol. Eng, 8(1), 1224-1228.
16- Reyes Santiago, A., & González Maíz Jiménez, J. (2024). Machine learning portfolios for US stock prices: Directional forecasting before and during the COVID-19 pandemic. Contaduría y administración, 69(4).
17- Saini, N. (2023). Research paper on artificial intelligence & its applications. International Journal for Research Trends and Innovation, 8(4), 356-360.
18- Sharifani, K., & Amini, M. (2023). Machine learning and deep learning: A review of methods and applications. World Information Technology and Engineering Journal, 10(07), 3897-3904.

19- Steurer, M., Hill, R. J., & Pfeifer, N. (2021). Metrics for evaluating the performance of machine learning based automated valuation models. Journal of Property Research, 38(2), 99-129.
20- Works,(2020). Introduction to Artificial Intelligence and Machine Learning, 1st Edition.
21- Xie, Yihui.(2023). Stock Price Forecasting: Traditional Statistical Methods and Deep Learning Methods. Journal of Highlights in Business, Economics and Management. Volume 21.
22- Zhang, R. (2025). Research of the Prediction of Stock Market Price Trends Based on Several Models. In 2025 International Conference on Financial Risk and Investment Management (ICFRIM 2025) (pp. 209-217). Atlantis Press.