



الجمهورية العربية السورية
وزارة التعليم والبحث العلمي
المعهد العالي لإدارة الأعمال
قسم: الإدارة المالية والمصرفية

التنبؤ بسيولة الأسهم في سوق عمان للأوراق المالية باستخدام أساليب التعلم الآلي
وإمكانية تطبيقها في سوق دمشق للأوراق المالية

Liquidity prediction on Amman stock market using learning machine system
and ability to applicable on Damascus Securities Exchange

رسالة لنيل درجة الماجستير في علوم الإدارة
اختصاص الإدارة المالية والمصرفية

إعداد الباحث:

محمد مؤمن الفرا

إشراف الدكتورة:

منال الموصلي

العام الدراسي: 2023 _ 2024

الإهداء

بسم الله الرحمن الرحيم

(يَرْفَعِ اللَّهُ الَّذِينَ آمَنُوا مِنْكُمْ وَالَّذِينَ أُوتُوا الْعِلْمَ دَرَجَاتٍ وَاللَّهُ بِمَا تَعْمَلُونَ خَبِيرٌ) صدق الله العظيم

إلى:

الروح التي تراني وتسمعني، نبض قلبي الطاهر، أنتِ التي من أجلها كنتُ أنا (روح أمي).

أبي الأستاذ محمد عامر الفراء، سرُّ الخير والأمل والمحبة والدي ووالدُ كل نجاح، أنتَ نعمة ورزقٌ من الله.

إخوتي هادي وسامح الذين قدموا الكثير والكثير ذوي القلب الأبيض النقي، أنتم سند وعز وفخر.
زوجتي، يا مسكني وسندي ودعمي الدائم يا من تعلمت منها أن العلم هو أساس النجاح وهو الحياة،
رفيقة الدرب بحلاوته ومره.

ابنتي تالية الفراء، سر سعادتي، أنتِ التي لأجلك يُبنى المستقبل

عائلتي عمي السيد ماجد عدي وزوجته، أنتم من كان له بصمته في هذا الدرب الطويل وأنتم من
خفف من صعوبته.

أصدقائي، كنتم خير صديق وخير أنيس.

المعلمة والمربية الفاضلة التي ذُكر بها الكثير ومهما ذُكر فهو قليل وكادت أن تكون رسولا...

الدكتورة الغالية منال الموصلي.

وإلى جميع أساتذتي الكرام.

المخلص:

هدف هذا البحث إلى استخدام التعلم الآلي للتوصل إلى نموذج للتنبؤ بسيولة أسهم البنوك المدرجة في سوق عمان للأوراق المالية مع دراسة إمكانية تطبيق هذا النموذج على سوق دمشق للأوراق المالية. ولتحقيق أهداف البحث تم تجميع البيانات اليومية اللازمة من موقع سوق عمان للأوراق المالية للمصارف المدرجة في السوق خلال الفترة من عام 2012 حتى بداية عام 2024، بالإضافة إلى بيانات المصارف المدرجة في سوق دمشق للأوراق المالية لعام 2023 وشهر أيلول وتشرين الأول وتشرين الثاني وكانون الأول من عام 2022 لدراسة إمكانية التنبؤ بالسيولة لهذه المصارف باستخدام النموذج ذاته. ولقياس السيولة تم استخدام كل من حجم التداول وقيمة التداول ونسبة التداول والفرق بين أفضل سعر وأقل سعر بالإضافة إلى مقياس أمهيود وهو يمثل عوائد الأسهم على قيمة التداول بالقيمة المطلقة والتي تشكل السمات أو الميزات التي يبني عليها النموذج. وباستخدام تقنيات التعلم الآلي المتمثلة بخوارزمية الذاكرة طويلة_قصيرة الأمد Long short Memory تم تطوير النموذج من حيث عدد النوافذ وعدد العصبونات اللازمة للدراسة وذلك على أساس النتائج التجريبية.

توصلت الدراسة إلى أن الشبكة العصبية المكونة من 6 نوافذ ومن طبقة مخفية مكونة من ثلاث طبقات، حيث تحتوي الطبقة الأولى على 16 خلية عصبية بينما تحتوي الطبقة الثالثة على 8 خلايا عصبية أعطت نتائج جيدة في التنبؤ بسيولة البنوك المدرجة في بورصة عمان حيث تراوحت دقة التنبؤ بين (93%-99%) في حين أن دقة التنبؤ للنموذج ذاته في سوق دمشق للأوراق المالية كانت تتراوح بين (84%-95%).

يمكن استخدام نتائج البحث لتطوير نماذج تصل الى دقة تنبؤ جيدة ويمكنها التنبؤ بأكثر من سوق مالي بالإضافة إلى إمكانية الاستدلال بها من أجل اتخاذ القرارات وخاصة الداعمة في أسواق الأسهم كما يمكن من خلال هذه الدراسة استخدام خوارزميات التعلم الآلي للتنبؤ في ربحية الأسهم وعوائدها وبالتالي تساعد المستثمرين في تلك الأسواق.

الكلمات المفتاحية: التعلم الآلي، التعلم العميق، الذاكرة طويلة الأمد، الخلايا العصبية، سيولة الأسهم.

Abstract:

This research aimed to use machine learning to come up with a model to predict the liquidity of bank shares listed on the Amman Stock Exchange, while studying the possibility of applying this model to the Damascus Stock Exchange. To achieve the research objectives, the necessary daily data () collected from the Amman Stock Exchange website for banks listed on the market during the period from 2012 until the beginning of 2024.

In addition to the data of banks listed on the Damascus Stock Exchange for the year 2023 and the months of September, October, November and December of 2022, to study the possibility of predicting the liquidity of these banks using the same model. To measure liquidity, trading volume, trading value, trading ratio, and the difference between the best price and the lowest price used, in addition to the Amhyud scale, which represents stock returns on trading value in absolute value, which constitute the characteristics or features on which the model is built. Using machine-learning techniques represented by the long short-term memory algorithm, the model developed in terms of the number of windows and the number of neurons needed for the study, based on the experimental results.

The study found that a neural network consisting of 6 windows and a hidden layer consisting of three layers, where the first layer contains 16 neurons while the third layer contains 8 neurons, gave good results in predicting the liquidity of banks listed on the Amman Stock Exchange, as the prediction accuracy ranged between (93%–99%), while the prediction

accuracy of the same model in the Damascus Stock Exchange ranged (%95-%84) between.

The research results can used to develop models that reach good forecasting accuracy and can predict more than one financial market, in addition to the possibility of inferring them in order to make decisions, especially supportive ones in the stock markets. Through this study, machine-learning algorithms can also used to predict the profitability and returns of stocks and thus help investors in those markets.

Keywords: machine learning, deep learning, long-term memory, neurons, stock liquidity.

الفصل التمهيدي.....	1
الإطار العام للبحث.....	1
أولاً: المقدمة.....	1
ثانياً: مشكلة البحث.....	2
ثالثاً: فرضيات البحث:.....	2
خامساً: مجتمع وعينة البحث.....	3
سادساً: منهج البحث.....	3
سابعاً: مصادر جمع البيانات وفترة الدراسة.....	3
الفصل الأول –مراجعة الأدبيات النظرية والتطبيقية.....	4
المبحث الأول: سيولة الأسهم وطرق قياسها.....	5
أولاً: مفهوم سيولة الأسهم:.....	5
ثانياً: أبعاد السيولة.....	5
ثالثاً: مستويات السيولة.....	7
رابعاً: مخاطر سيولة الأسهم:.....	7
مقاييس السيولة:.....	8
المبحث الثاني: أساليب التعلم الآلي.....	9
مقدمة.....	9
1. مفهوم التعلم الآلي:.....	9
2. أساليب التعلم الآلي:.....	10
4- Deep Learning –التعلم العميق:.....	13
3. آلية عمل العصبونات ذات الذكرة قصيرة وطويلة المدى:.....	17
4. "Machine Learning Pipeline" مسارات التعلم الآلي:.....	18
المبحث الثالث: مراجعة الأدبيات التطبيقية.....	21
الفصل الثاني: الدراسة التطبيقية.....	24
المبحث الأول: عينة ومتغيرات الدراسة.....	25

1- عينة الدراسة:	25
2- متغيرات الدراسة:	25
المبحث الثاني: اختبار الفرضية ومناقشة النتائج	26
أولاً: معالجة البيانات <i>Data processing</i>	26
ب- تقسيم البيانات	38
خامساً: نتائج اختبار النموذج	40
النتائج والتوصيات:	57
أولاً: النتائج	57
ثانياً: التوصيات	57

فهرس الجداول:

الصفحة	اسم الجدول	رقم الجدول
30	الدراسة الإحصائية لبنوك عمان	(1)
31	قياس التشتت للبنوك المدرجة في بورصة عمان للأوراق المالية	(2)
32	الدراسة الإحصائية لبنوك دمشق	(3)
34	قياس التشتت للبنوك المدرجة في سوق دمشق للأوراق المالية	(4)
46	تلخيص نتائج الدراسة على البنوك الأردنية	(5)
54	نتائج التنبؤ للبنوك في سوق دمشق للأوراق المالية	(6)

فهرس الأشكال:

رقم الشكل	اسم الشكل	الصفحة
1	الخلايا العصبية في شبكة التعلم العميق	14
2	طريقة مرور البيانات بين الطبقات في الشبكات العصبية	15
3	البوابات في الذاكرة طويلة-قصيرة الأمد	18
4	اعتماد التاريخ كفهرس للدراسة	27
5	الرسم البياني للمتغيرات	27
6	متغيرات الدراسة	28
7	الخريطة الحرارية للمتغيرات	29
8	النوافذ في الخلايا العصبية	37
9	تقسيم البيانات	38
10	التنبؤ بسيولة البنك الأردني	40
11	التنبؤ بسيولة البنك الأردني الكويتي	40
12	التنبؤ بسيولة البنك التجاري الأردني	41
13	التنبؤ بسيولة بنك الإسكان للتجارة والتمويل	41
14	التنبؤ بسيولة بنك الاتحاد	42
15	التنبؤ بسيولة المؤسسة العربية المصرفية الأردنية	43
16	التنبؤ بسيولة البنك الاستثماري	43
17	التنبؤ بسيولة بنك المال الأردني	44
18	التنبؤ بسيولة بنك القاهرة_عمان	44
19	التنبؤ بسيولة بنك الأردن	45
20	التنبؤ بسيولة البنك الأهلي الأردني	45
21	التنبؤ بسيولة البنك العربي الأردني	46
22	التنبؤ بسيولة البنك العربي سورية	47
23	التنبؤ بسيولة بنك الائتمان الأهلي	48
24	التنبؤ بسيولة بنك بيمو السعودي الفرنسي	48
25	التنبؤ بسيولة بنك سورية والمهجر	49
26	التنبؤ بسيولة المصرف الدولي للتجارة والتمويل	49
27	التنبؤ بسيولة بنك سورية الدولي الإسلامي	50

50	التنبؤ بسيولة بنك بيبلس-سورية	28
51	التنبؤ بسيولة بنك قطر الوطني-سورية	29
51	التنبؤ بسيولة بنك البركة-سورية	30
52	التنبؤ بسيولة بنك الشام	31
52	التنبؤ بسيولة فرنسا بنك- سورية	32
53	التنبؤ بسيولة بنك الشرق	33
53	التنبؤ بسيولة بنك سورية والخليج	34
55	حجم وقيمة التداول لبنك سورية والخليج	35

الفصل التمهيدي

الإطار العام للبحث

أولاً: المقدمة

تعتبر الأسهم السائلة من الأسهم المفضلة من قبل المستثمرين لسهولة تحويلها إلى نقد وبأفضل الأسعار المتاحة وبأقل تكلفة ممكنة، حيث تلعب دوراً هاماً في كفاءة الأسواق المالية، مما يؤثر على أسعار الأسهم وتكاليف المعاملات واستقرار السوق بشكل عام.

وفي الوقت الراهن، أصبح التنبؤ هو أساس بناء معايير مستقبلية واتخاذ القرارات الاستثمارية المناسبة. فالتنبؤ يعتمد بشكل أساسي على دراسة العوامل التاريخية لحدث ما ومن ثم توقع ما ستكون عليه تلك العوامل في المستقبل لذات الحدث.

ونتيجة لما سبق، أصبح التنبؤ بسيولة الأسهم أداة تستخدم لمساعدة كل من المستثمرين والشركات في اتخاذ القرارات المناسبة، وتساعد في التحوط من المخاطر المحتملة من خلال وضع الاستراتيجيات الملائمة لتلك المخاطر.

ومع تطور أنظمة التعلم، أصبح من الإمكان التنبؤ بالمخاطر المحيطة بأي سوق مالي ووضع العديد من الاحتمالات الممكن تنفيذها في اتخاذ القرار المناسب ومواجهة هذه المخاطر بدقة تنبؤ قد تصل إلى 99%.

من جانب آخر، تعتبر أنظمة التعلم الآلي مجموعة فرعية من الذكاء الاصطناعي الذي يركز على إنشاء الأنظمة التي تتعلم أو تحسن الأداء بناءً على البيانات والخوارزميات التي تستهلكها هذه الأنظمة، حيث تم استخدام خوارزميات التعلم العميق لجودة البيانات التي يتم التوصل إليها من خلال هذه الخوارزميات في عمليات التنبؤ وخاصة عند وجود عدد كبير من المشاهدات.

بالتالي جاء هذا البحث لبناء نموذج للتنبؤ بسيولة أسهم البنوك المدرجة في كل من سوق عمان وسوق دمشق للأوراق المالية.

ثانياً: مشكلة البحث

قامت العديد من الدراسات السابقة بالنتبؤ بسيولة الأسهم في البلدان النامية وخاصة البلدان العربية كدراسة (حمدان 2014) ودراسة (النايف 2014) ولكن لم يتم الاعتماد على أنظمة التعلم الآلي في عملية التنبؤ.

وبالتالي، تتلخص مشكلة الدراسة بالإجابة على الأسئلة التالية:

- 1- ما هو النموذج الذي يمكن أن نتوصل إليه للتنبؤ بسيولة أسهم المصارف المدرجة في سوق عمان للأوراق المالية، باستخدام أنظمة التعلم الآلي، وما دقة التنبؤ الذي تم الوصول إليه؟
- 2- ماهي دقة التنبؤ التي سيتم الوصول إليها عند تطبيق النموذج على سوق دمشق للأوراق المالية؟

ثالثاً: فرضيات البحث:

- 1- يمكن التنبؤ بسيولة أسهم المصارف المدرجة في سوق عمان باستخدام آليات التعلم الآلي.
- 2- إن خوارزميات التعلم العميق تعطي نتائج عالية الدقة في التنبؤ بالسيولة.
- 3- يمكن الوصول إلى نتائج ذات دقة جيدة بتطبيق النموذج الذي تم بناءه في سوق عمان للأوراق المالية على المصارف المدرجة في سوق دمشق للأوراق المالية.

رابعاً: أهمية وأهداف البحث:

تبرز أهمية البحث من أهمية التنبؤ بسيولة الأسهم في مساعدة متخذي القرار في اتخاذ القرار الاستثماري المناسب في الاستثمار في أسهم المصارف المدروسة وفي التحوط من مخاطر السيولة لتلك الأسهم، وبالتالي يهدف البحث إلى:

- 1- بناء نموذج قادر على التنبؤ بسيولة الأسهم لكل من سوق عمان وسوق دمشق للأوراق المالية.
- 2- تطوير البحث ليكون أداة لبناء نماذج قادرة على التنبؤ بأكثر من سوق مالي.

خامساً: مجتمع وعينة البحث

تم تقسيم مجتمع البحث إلى مجتمعين: الأول يتكون من جميع الشركات الأردنية المدرجة في بورصة عمان والتي عددها 83، بينما المجتمع الثاني فقد تكون من جميع الشركات المدرجة في سوق دمشق للأوراق المالية والتي عددها 28، بينما شملت عينة المجتمع الأول جميع المصارف الإسلامية والتقليدية الأردنية والتي عددها 12 مصرفاً، أما عينة المجتمع الثاني فقد شملت 14 مصرف إسلامي وتقليدي سوري، حيث تم استبعاد البنك الوطني الإسلامي نتيجة عدم توفر بيانات لحدثة تأسيس وإدراج هذا البنك.

سادساً: منهج البحث

تم اتباع منهج تحليلي وصفي من خلال الإلمام بالجوانب النظرية المتعلقة بالسيولة ومقاييسها وآلية التعلم الآلي والتعلم العميق وبناء نموذج من خلال خوارزميات التعلم العميق للتنبؤ بالسيولة في كل من سوق عمان وسوق دمشق للأوراق المالية وذلك باستخدام لغة البرمجة بايثون والتي تم تطبيقها على Google Colab

سابعاً: مصادر جمع البيانات وفترة الدراسة

سيتم الحصول على البيانات من كل من موقع سوق عمان للأوراق المالية وذلك بشكل يومي من 2012/1/1 إلى تاريخ 2024/1/1، وموقع سوق دمشق للأوراق المالية وذلك بشكل يومي من تاريخ 2022/9/1 حتى تاريخ 2024/1/1.

الفصل الأول -مراجعة الأدبيات النظرية والتطبيقية

ففي هذا الفصل سيتم عرض مراجعة الأدبيات النظرية والتطبيقية المتعلقة بكل من السيولة ومفاهيم التعلم الآلي والتعلم العميق والشبكة العصبونية ذات الذاكرة الطويلة وقصيرة المدى، وبالتالي ينقسم الفصل إلى المباحث الآتية:

المبحث الأول: سيولة الاسهم وطرق قياسها ومخاطرها

المبحث الثاني: أساليب التعلم الآلي مفهومه والخوارزميات المتبعة في عملية التنبؤ.

المبحث الثالث: مراجعة الأدبيات التطبيقية.

المبحث الأول: سيولة الأسهم وطرق قياسها

أولاً: مفهوم سيولة الأسهم:

يعتبر مفهوم السيولة من المفاهيم الهامة في عالم المال والاستثمار فالسيولة ركن أساسي تعكس نشاطات الأسواق المالية من جهة ونشاط المستثمرين في هذه الأسواق سواءً أكانوا الافراد أم الشركات من جهة أخرى.

ونتيجة لأزمة 2008، ازداد الاهتمام بشكل كبير في السيولة في الأوراق المالية بشكل عام وسيولة السهم بشكل خاص، وذلك لبيان إمكانية تبادل الأوراق المالية في تلك السوق بتكلفة قليلة.⁽¹⁾ من جانب آخر يهتم المستثمرون في التنبؤ بسيولة الأسهم المالية التي تتصف بالمخاطر العالية مما سبق يمكن تعريف سيولة الأسهم بوجود رغبة وموافقة لدى البائعين والمشتريين على تبادل حجم معين من تلك الأسهم بالسعر المعلن دون أي تأخير⁽²⁾

كما تعرف بأنها قدرة السوق لعلى تداول حجم ضخم من الأوراق المالية بسعر تكلفة تنفيذ قليل دون⁽³⁾ أن يكون لها تأثير كبير على أسعار الأوراق المالية

كما عرفت سيولة الأسهم بالقدرة على تداول الأسهم بتكلفة منخفضة ومع تأثير ضئيل على السعر⁽⁴⁾ فضلاً على أن السيولة تعطي المستثمرين المرونة لبيع ممتلكاتهم من الأسهم عند الحاجة.

ثانياً: أبعاد السيولة

تعد ابعاد السيولة مهمة لأغراض وضع مقاييس للسيولة إذ وضع Ivanchuk

أبعاد سيولة الأوراق المالية بالآتي:⁽⁵⁾

البعد الأول: هامش السعر وهو القدرة على الشراء والبيع دون فرق كبير في السعر

البعد الثاني: توقيت المعاملات القدرة على تنفيذ الصفقات التجارية في الأوقات اللازمة او بأقصر

فترة زمنية ممكنة ويتم قياسها بمعدل المعاملات لكل وحدة من الزمن.

¹ Hiransha Ma , Gopalakrishnan, Vijay Krishna Menonab, Soman , NSE Stock Market Prediction Using Deep-Learning Models, 2018,p2”

Amihud et al “Liquidity And Asset Prices” (2006),p18²

³ Brennan et al. Sell-order liquidity and the cross-section of expected stock returns (2012),p7

⁴ Ilmanen, Expected Returns: An Investor's Guide to Harvesting Market Rewards,2011:p360

⁵ Ivanchuk, Evaluating the Liquidity of Stocks using Transaction Data,2004:p3

البعد الثالث: عمق السوق ويشير الى القدرة على البيع او الشراء لحجم معين من الأسهم مع اقل تأثير ممكن على الأسعار ويمكن قياسها من كمية الأسهم المتاحة للتداول الفوري في السوق المالي يعد عمق السوق أحد الابعاد الرئيسية لسيولة الأوراق المالية ويعرف بقدرة السوق على استيعاب مستويات مختلفة من فعاليات التداول اذ يعتمد على كمية الأوامر الداخلة والتي غالبا ما تحركها الصفقات الأكثر نشاطا والتي تتداول في فترة الازدهار وان فرص تخفيض الكلفة يمكن ان ترتفع (6) بالتداول الأكثر نشاطا للصفقات.

حيث عرف Kuo عمق السوق بأنه الحجم اللازم لتدفق أمر معين ليحرك السعر وحدة واحدة وهذا يشير الى ان التغيرات في عمق السوق ترتبط بفعاليات التداول والسوق ذات العمق تساعد في إيجاد ظروف السوق التي تقلل من الضغوط على الأسعار عندما يكون الإفصاح عن معلومات التداول جيدة (7)

كما يؤثر عمق السوق بشكل مباشر على نتائج التداول وبالتالي على سيولة الأوراق، فالأسواق تكون ذات عمق جيد عندما تكون الفعاليات لعدد كبير من المشاركين في وحدة الزمن اما الأسواق ضعيفة التداول فتكون فعاليتها فقط مع عدد قليل من المشاركين ونتيجة لذلك لا يمكن للمستثمر القيام بتلبية الطلبات وتجهيزها بشكل كافي عند الشراء أو البيع بكميات كبيرة، إذ أن تنفيذ الطلبية الكبيرة قد يجعل من الضروري تغيير سعر السوق من اجل استيعاب التداول وبالتالي فان الطلبية لها تأثير كبير على تخفيض سيولة السوق ويزداد تأثير السعر مع حجم المعاملة (8) وبالتالي فإن لسيولة الأوراق المالية أهمية كبيرة بالنسبة للمتداولين لمساعدتهم على تحديد حجم عوائد الأسهم وبالتالي إمكانية وضعهم لاستراتيجيات تداول ملائمة.

البعد الرابع: التعقيد ويشير الى القدرة على شراء وبيع كميات كبيرة من دون تكبد تغييرات كبيرة في السعر وهو على عكس عمق السوق فيما يتعلق بحجم التداولات الكبيرة التي تتجاوز عمق السوق

⁶.(Frank&Garcia, Market Depth in Lean Hog and Live Cattle Futures Markets,2008,p20)

⁷ (Kuo et.al, Price Volatility Trading Activity and Market Depth: Evidence from Taiwan and Singapore Taiwan Stock Index Futures Marke:2005p13

⁸Morawski, " Investment Decisions on Illiquid Assets: A Search Theoretical Approach to Real Estate Liquidity"2008:p177

عند نقطة معينة من الزمن فهو يجسد سعر التبادل الفوري التي تكبدها عندما يكون الحجم ابعده من عمق السوق.

ثالثاً: مستويات السيولة

صنفت مستويات سيولة الأسهم كالآتي (9)

المستوى الأول: ويشير الى عدم القدرة على التداول وانعدام سيولة السهم اذ لا يمكن اجراء أي عملية تداول وفي السوق الضعيفة السيولة يجب ان يكون هناك محاولة واحدة على الأقل للشراء او البيع في الأوراق المالية.

المستوى الثاني: القدرة على شراء او بيع كمية معينة من الأوراق المالية مع وجود تأثير على السعر المعروف في السوق المالي.

المستوى الثالث: القدرة على شراء او بيع كمية معينة من الأوراق المالية مع وجود تأثير ضئيل على سعر السوق ولكن عند نقطة معينة في التداول بكميات كبيرة من الأوراق المالية يكون هناك تأثير أكبر على السعر.

المستوى الرابع: القدرة على شراء الأوراق المالية وبالأسعار المعروضة وفي الوقت ذاته.

المستوى الخامس: القدرة على تنفيذ الصفقات من المستوى الثاني الى المستوى الرابع بشكل فوري.

رابعاً: مخاطر سيولة الأسهم:

تنخفض سيولة السهم في الفترة التي تكمن بها معظم المخاطر، حيث تؤدي السيولة المنخفضة الى عدم استقرار الأسعار وانخفاض حجم التداول وبالتالي تدهور ظروف السوق المالي بشكل عام. وارتفاع السيولة بشكل مبالغ به يؤدي الى انخفاض عامل الربحية وعدم جذب كل من المحبين والمحايدين للمخاطر، أي سيصبح السوق جاذب للكاهين للمخاطر فقط.

وقد عرفت مخاطر السيولة: على انها مخاطر عدم القدرة على تصفية أصل ما في الوقت المناسب وبسعر معقول

وبالتالي يمكن تقسيم مخاطر السيولة الى:

⁹ Wyss, Measuring and Predicting Liquidity in the Stock Market,2004:p7

- 1-تباين تكلفة التنفيذ (تكلفة السرعة في بيع أصل ما): وهي تمثل الفروق بين أسعار العرض والطلب وهي ما تسمى بتكلفة المعاملة وتأثير السعر لنشاط التداول
- 2-تكلفة الفرصة البديلة (تكلفة تنفيذ عملية البيع): وهي تكلفة الاضطرار الى تأجيل التداول وتزداد تلك التكلفة بتأخير وقت التنفيذ
- 3⁽¹⁰⁾-ما يحتاجه المتداولون هو تحقيق التوازن بين هاتين التكلفةين وذلك لتقليل مخاطر السيولة
- مقاييس السيولة:**

للسيولة العديد من المقاييس، منها:

- 1- (Diff) فرق السعر: وهو الفرق بين أفضل سعر عرض وأفضل سعر طلب.
 - 2- (NO-of trade) عدد المعاملات: وهو عدد الأسهم المتداولة في كل سوق.
 - 3- (Volume) حجم التداول: وهو حجم التداول مضروباً بسعر السهم السوقي.
 - 4-(Trade rate) نسبة التداول: وهي قيمة التداول لكل بنك على قيمة التداول لكافة البنوك.
 - 5-(Amihud) اميهود: وهو نسبة عوائد الأسهم بالقيمة المطلقة على قيمة التداول
- وفي هذه الدراسة سنستخدم المقاييس الخمسة للسيولة خلال يوم تداول واحد.
- (Diff, Volume, Trade-rate, No-Of-trade, AMIHU)

¹⁰ Measurement of liquidity risk in the context of market risk calculation, Jun Muranaga and Makoto Ohsawa,1997,p195

المبحث الثاني: أساليب التعلم الآلي

مقدمة

عادةً ما يتم ادخال التعليمات أو ما يدعى بالكود إلى الحاسوب ليتم القيام بمهمة معينة ولكن هنالك اختلاف في تعقيد تلك التعليمات بناءً على المهمة المطلوبة كالتنبؤ بسيولة الأسهم. فالتعلم الآلي هو القيام بتدريب نموذج يتم التعامل به من قبل الحاسوب وهو آلي لأن الحاسوب من سيعمل العملية لوحده.

1. مفهوم التعلم الآلي:

فالتعلم الآلي: هو القيام بمهمة معينة من قبل الحاسب من خلال البيانات المتوفرة، بعيداً عن كل التخييلات العلمية فهو من إحدى مجالات التطبيق للذكاء الاصطناعي المعني بتطوير أنظمة قادرة على محاكاة الذكاء البشري، أي قادرة على التكيف مع البيئات المختلفة والتعلم منها واتخاذ القرارات المناسبة.⁽¹¹⁾

كما تم تعريف التعلم الآلي بأنه القدرة على جمع الخبرات عن طريق القيام بمهمة معينة وتحسين الأداء لهذه المهمة في المستقبل.⁽¹²⁾

كما يعرف بأنه شكل من أشكال الذكاء الاصطناعي، حيث يقوم بالتعلم من البيانات التاريخية المدخلة بدلاً من البرمجة الواضحة، حيث يستخدم التعلم الآلي مجموعة متنوعة من الخوارزميات التي تتعلم بشكل متكرر من البيانات، وذلك من أجل تحسين البيانات، وصفها والتنبؤ بالنتائج. ونظراً لأن الخوارزميات تستوعب بيانات التدريب، فمن الممكن بناء نماذج أكثر دقة بناءً على تلك البيانات.⁽¹³⁾

وبما أن المشاكل التي قد يواجهها التعلم الآلي كثيرة ومتغيرة، فهناك العديد من أنواع أساليب التعلم الآلي ليتم التعامل مع تلك الأنواع المختلفة من المشاكل.

¹¹ Andrew Wolf, machine learning simplified, 2022,p6

¹² Saikat Dutt, Subramanian Chandramouli, Amit Kumar Das, machine learning 2014, p.43

¹³ Hurwitz, Judith, Kirsch, Daniel, Machine Learning for dummies, John Wiley & Sons, Inc., Hoboken, 2018, P3

في هذا الفصل سيتم التعرف على أنواع التعلم الآلي وآلية عملها وكل من علم البيانات وتشغيل التعلم الآلي والذكاء الاصطناعي وطريقة تدريب التعلم المشرف وغير المشرف.

2. أساليب التعلم الآلي:

يوجد خمسة أساليب للتعلم الآلي، التعلم الآلي الخاضع للإشراف، التعلم غير الخاضع للإشراف، التعلم المعزز، التعلم العميق والتعلم العميق المعزز.

1- التعلم الآلي الخاضع للمشرف: Supervised Learning

العديد من المشاكل التي تمر في الواقع تأخذ هيكلية معينة وهي الحصول على هدف معين (التنبؤ) من خلال مشاهدات معروفة وواضحة للوصول الى مشاهدات او متغيرات مجهولة. حيث يبني التعلم الخاضع للإشراف نماذج باستخدام بيانات التدريب (المدخلات) مع المخرجات المطلوبة بهدف تعلم قاعدة عامة تحدد المدخلات إلى المخرجات. (14)

وهناك نوعين من المتغيرات يتم التعامل بهما من قبل التعلم الآلي المشرف:

النوع الأول: ما يعرف بالمتغيرات التصنيفية كالتنبؤ بكفاءة سوق ما استنادا الى عمليات البيع والشراء في هذا السوق

النوع الثاني: المتغيرات الرقمية كالتنبؤ بعائد سهم ما استنادا الى العوائد التاريخية لهذا السهم.

وبما انه يوجد نوعين من المتغيرات ليتم التعامل به بالتالي يوجد نوعين من المشاكل في التعلم الآلي المشرف:

أ-مشكلة التصنيف: Classification problems

أي المتغيرات نوعية ليست كمية وبالتالي يكون التنبؤ بشيء معين على سبيل المثال إذا كان الجواب لمشكلة معينة هو (نعم او لا) يدعى بالتصنيف الثنائي وإذا كان التصنيف يحمل أكثر من احتمالين يدعى بالتصنيف المتعدد وهذه بعض المشاكل التي يتم التعامل معها من خلال التعلم الآلي المشرف وهي ذات متغيرات نوعية.

هل سيقوم المستثمر بالاستثمار في هذا السوق ام لا؟ (تصنيف ثنائي فالإجابة نعم او لا)

¹⁴ Introduction to Machine Learning, The Wikipedia Guide, 2021, P1

هل سيرتفع عائد هذا السهم ام لا؟ (تصنيف ثنائي)

هل هذا السهم سيولته مرتفعة ام لا؟ (تصنيف ثنائي)

هل هذه السوق كفاءته مرتفعة ام متوسطة ام عديم الكفاءة؟ (تصنيف متعدد)

ب-مشكلة الانحدار: Regression problem

وهنا يتم التعرف على رقم مجهول بناء على متغيرات معلومة وكمثال على تلك المشاكل:

- ما هو عائد سهم ما ذو نمو متوقع في الأرباح خلال فترة زمنية معينة وتدفق نقدي وتوزيعات أرباح معروفة؟

- كم عدد المستثمرين المتوقعين للاستثمار في سوق معينة مع دراسة سيولة هذا السوق والمخاطر المحيطة به والعائد المتوقع من الاستثمار؟

يساعد كلا من التصنيف والانحدار على حل العديد من المشاكل التي قد تواجه المستثمر في بيئة الاعمال ولكن يجب علينا بداية وضع النموذج الملائم الذي يقوم بعملية التنبؤ بشكل تلقائي وبشكل دقيق قدر الإمكان ولعله يجب أن يكون هناك عدة قواعد يجب إدراجها في النموذج، فبمثال السهم الذي نريد التنبؤ بسيولته يمكن أن تكون الأسهم الموجودة في سوق مالي معين سيولتها مرتفعة وذلك لأن السوق المالي ذو كفاءة عالية وهذه إحدى القواعد التي يمكن إدراجها في النموذج ولكن هناك الكثير من القواعد التي تتفاعل وتتأثر ببعضها فيمكن أن تزيد من تأثير أخرى أو تلغيها. ماذا لو كان السهم ذو ربحية مرتفعة وذو معدل نمو متوقع مرتفع، بالطبع سيزيد من سعره ولكن لو كان هناك مخاطر مرتفعة محيطة بالسوق المالي هل سيخفض من سعره؟

وبالتالي عدد التفاعلات التي تحدث بين المتغيرات متتامة وسريعة ولكن في الواقع يوجد الكثير من التفاعلات بين المتغيرات والتي من المستحيل ادراكها جميعها او إدراك كيفية تفاعلها فيما بينها. فالهدف من التعلم الآلي المشرف هو التعلم التلقائي للقواعد الصحيحة وكيفية تفاعلها فيما بينها، وعند الانتهاء من تدريب النموذج يمكن استخدامه للتنبؤ، يمكن لهذا التنبؤ أن يكون دقيق أو غير ذلك، فالدقة تعتمد على عدة عوامل كصعوبة المشكلة التي تتم دراستها وجودة البيانات وجودة خوارزمية التعلم الآلي المتبعة.

إن خوارزمية التعلم الآلي هي من تقوم بتعليم تلك القواعد للنموذج وكيفية تفاعلها فيما بينها للقيام بعملية الانحدار أو التصنيف.

2-التعلم الآلي غير المشرف: Unsupervised Learning

في التعلم المشرف يقوم الانسان بالتزويد بما يسمى بالمتغيرات المستهدفة (المتغير التابع) وتقوم الالة بعملية تقليد للنموذج الموضوع.

فعند العمل بالتعلم الآلي المشرف يتم وضع متغيرات ككفاءة السوق المالي مثلا وربحية السهم ومعدل النمو المتوقع لهذا السهم ويتم بتزويد النموذج بعوائد تلك الأسهم (المتغير التابع) ومن ثم يتم إعطاء النموذج متغيرات مستقلة جديدة لأسهم جديدة ويقوم هو بالتنبؤ بعوائد هذه الأسهم، أي المتغير التابع الذي يجب إيجاده (أشبه بعملية تقليد للنموذج الذي درسه).

اما في التعلم غير المشرف لا يعطى المتغير التابع بل يحاول النموذج إيجاد عقد أو مجموعات مميزة ضمن المتغيرات المستقلة المدخلة ويحاول العمل من خلالها.

ومن الأمثلة على ذلك دراسة عينة من السوق، ولنفترض انه نريد دراسة نوع المستثمرين في سوق ما (هل محبين للمخاطر أم كارهين لها؟)

في هذا السيناريو لا يمكن للتعلم الآلي المشرف أن يقدم أي نموذج يساعد في ذلك لأنه يحتاج الى متغير تابع معروف ويقوم بتقليده بينما يقوم التعلم الآلي غير المشرف بتجميع بيانات من استبيانات تصف مواقف المستثمرين في عمليات البيع والشراء عند حدوث مخاطر في تلك السوق.

أقسام التعلم الآلي غير الخاضع للإشراف:

أ-التجميع العنقودي: يتم في هذا الأسلوب تجميع العناصر ذات المعلمات المتشابهة معاً في مجموعة ويعتبر التجميع نوع من التعلم غير الخاضع للإشراف لأن البيانات غير مصنفة، تقوم الخوارزمية بتفسير المعلمات التي يتكون منها كل عنصر ثم تقوم بتجميعها وفقاً لذلك. (15)

ب-تقسيم البعد: يساعد على استبعاد البيانات غير المفيدة للتحليل.

¹⁵ Hurwitz, Judith, Ibid, Counteracting Concept Drift in Natural Language Classifiers 2018, P15

تستخدم هذه المجموعة من الخوارزميات لاستبعاد كل من البيانات الزائدة، القيم المتطرفة وغيرها من البيانات غير المفيدة، ومن خلال استبعاد هذه البيانات يتحسن أداء نظام التعلم الآلي ويساعد على تصور البيانات.

3-التعلم بال تعزيز Reinforcement Learning

يتعلم من خلاله النموذج من كل إجراء يتم اتخاذه، حيث تتم مكافأة النموذج على أي قرار صحيح يتم اتخاذه ويتم معاقبته على أي قرار خاطئ، ويسمح له بمعرفة الأنماط واتخاذ قرارات أفضل دقة بشأن البيانات غير المعروفة. تتلقى الخوارزمية تغذية مرتدة من تحليل البيانات حيث يتم إرشاد المستخدم إلى أفضل نتيجة. يختلف التعليم المعزز عن الأنواع الأخرى من التعلم الخاضع للإشراف من حيث التدريب، باستخدام مجموعة من البيانات النموذجية فيتعلم النظام من خلال التجربة والخطأ، لذلك فإن سلسلة من القرارات الناجحة ستؤدي إلى تعزيز العملية لأنها تحل المشكلة المطروحة على أفضل وجه.⁽¹⁶⁾

4-التعلم العميق: Deep Learning

وهي نماذج معقدة من التعلم المشرف للقيام بمهام أكثر تعقيداً وصعوبة عندما يكون هناك تطلب لتحليل سريع ومتقدم في التعلم الآلي. وما يميز التعلم العميق خوارزميات الشبكات العصبونية كونها تدرس كيفية تفكير الانسان لتطبيقها على الآلة، لكن ليس من الضروري ان نقوم باستخدام التعلم العميق فهو يستخدم في المشاكل ذات الأحجام الضخمة من البيانات ويحتاج الى كلف حسابية ضخمة بالإضافة الى العديد من الجوانب السلبية الأخرى التي تجعلها غير مناسبة لبعض المشاكل.⁽¹⁷⁾ فالتعلم العميق هو مجموعة فرعية من التعلم الآلي، وهو في حد ذاته مجموعة فرعية من الذكاء الاصطناعي، بعبارات بسيطة يتضمن التعلم العميق تدريب خوارزميات تُعرف بالشبكات العصبية للتعلم من كميات كبيرة من البيانات لإجراء تنبؤات أو قرارات دون أن تتم برمجتها بشكل صريح للقيام بذلك.


¹⁶ Hurwitz, Judith, ibid, Counteracting Concept Drift in Natural Language Classifiers2018, P15

¹⁷ Andrew Wolf, machine learning simplified2022, P8

يبني نموذج التعلم العميق بالاستناد إلى:

1- الشبكات العصبية: هي نماذج حسابية مستوحاة من بنية ووظيفة الدماغ البشري فهي تشبه شبكة من العقد المترابطة أو "الخلايا العصبية"، كل منها يؤدي عملية رياضية بسيطة يتم تنظيم هذه الخلايا العصبية في طبقات: طبقة الإدخال، وطبقة مخفية واحدة أو أكثر، وطبقة الإخراج. (18)

الشكل رقم (1): الخلايا العصبية في شبكة التعلم العميق



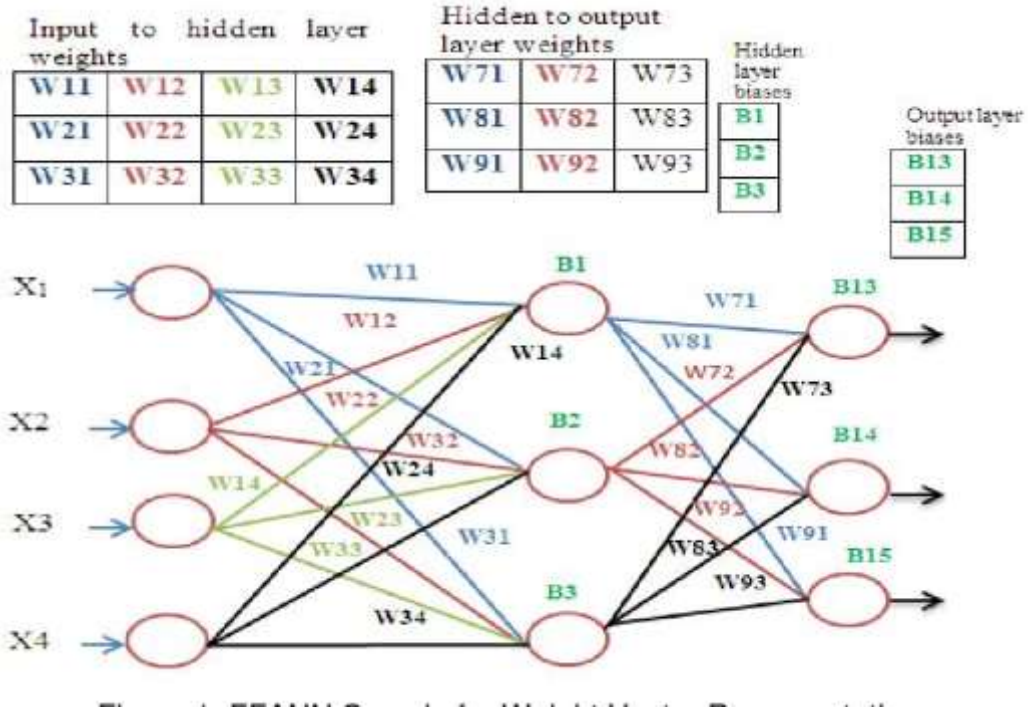
المصدر : Book: "Deep Learning" by Ian Goodfellow, Yoshua Bengio, and Aaron Courville

Chapter 6

2- التعلم من البيانات: تتعلم خوارزميات التعلم العميق من خلال ضبط قوة الاتصالات (الأوزان) بين الخلايا العصبية بناءً على الأمثلة الموجودة في البيانات.
من خلال عملية تسمى الانتشار العكسي، تحسب الخوارزمية مقدار مساهمة كل وزن في الخطأ في تنبؤه وتضبطه وفقاً لذلك لتقليل هذا الخطأ.

¹⁸ Deep Learning Ian Goodfellow, Yoshua Bengio, and Aaron Courville Chapter 6,p164

الشكل رقم (2): طريقة مرور البيانات بين الطبقات في الشبكة العصبية



المصدر: Y. "Gradient-based learning applied to document recognition"

LeCun, L. Bottou, Y. Bengio, and P. Haffner

3-التعلم التمثيلي: إحدى نقاط القوة الرئيسية للتعلم العميق هي قدرته على اكتشاف وتعلم تمثيلات البيانات تلقائيًا وهذا يعني أن الخوارزمية يمكنها تعلم استخراج الميزات ذات الصلة من البيانات الأولية، مثل الصور أو النصوص أو الصوت، دون الحاجة إلى تدخل بشري التسلسل الهرمي للميزات: تتعلم الشبكات العصبية العميقة التسلسل الهرمي للميزات المتزايدة التعقيد على سبيل المثال، في التعرف على الصور، قد تتعلم الطبقات السفلية اكتشاف ميزات بسيطة مثل الحواف أو الأنسجة، بينما تتعلم الطبقات العليا دمج هذه الميزات في مفاهيم أكثر تجريدها مثل الأشكال أو الكائنات

4-التعلم الشامل: غالبًا ما يمكن تدريب نماذج التعلم العميق بشكل شامل، مما يعني أنها تأخذ بيانات الإدخال الأولية وتنتج مباشرة التنبؤ أو القرار المطلوب، دون الحاجة إلى خطوات معالجة وسيطة أو هندسة الميزات.

وفي هذه الدراسة سيتم الاعتماد على التعلم العميق في اجراء عملية التنبؤ فقد تم استخدام التعلم العميق وخاصة الشبكات العصبية العميقة

Deep Neural Networks DNNs لها شعبية أكثر من طرق التعلم الالي التقليدية للتنبؤ

وذلك لعدة أسباب:

1- القدرة على التقاط الأنماط المعقدة: أظهرت نماذج التعلم العميق، وخاصة الشبكات العصبية والوحدات المتكررة ذات (LSTM) ومتغيراتها مثل شبكات الذاكرة طويلة المدى (RNNs) المتكررة (19) أداءً فائقاً في التقاط الأنماط الزمنية المعقدة في السلاسل الزمنية. (GRUs) البوابات 2-قابلية التوسع: إن نماذج التعلم العميق خاصة عند تنفيذها في اطر عمل مثل TensorFlow أو PyTorch فهي نماذج قابلة للتطوير بشكل كبير ويمكنها التعامل بكفاءة مع كميات كبيرة من بيانات السلاسل الزمنية.

3-المتانة في مواجهة البيانات ذات التقلبات الكبيرة: أثبتت نماذج التعلم العميق متانة بيانات السلاسل الزمنية الصاخبة وعالية الأبعاد تسمح الطبيعة الهرمية والموزعة للشبكات العصبية العميقة بتصنيف المعلومات غير ذات الصلة تلقائياً والتركيز على الميزات ذات الصلة، وبالتالي تحسين قوة البيانات ذات التقلبات الكبيرة.

في دراستنا سوف نعتمد على العصبونات ذات الذاكرة قصيرة وطويلة المدى في التعلم العميق

Long short-term memory “LSTM”

فإذا أراد المستثمر فهم ما يجري في السوق المالي من خلال قراءة البيانات المالية لهذه السوق من أسماء الشركات المدرجة وأسعار التداول الخاصة لكل سهم فهنا يقوم بالاحتفاظ بملاحظة ذهنية للتفاصيل المهمة وهكذا تعمل الذاكرة قصيرة وطويلة المدى.

فهي نوع من الشبكات العصبية المصممة للتعامل مع تسلسل البيانات وتذكر التبعات طويلة المدى داخل تلك البيانات فهي مفيدة بشكل خاص للتنبؤ بالسلاسل الزمنية ومعالجة اللغة والتعرف على الكلام.

¹⁹ Deep learning for time series classification Hassan Ismail Fawaz1 · Germain Forestier1,2 · Jonathan Weber1 · Lhassane Idoumghar1 · Pierre-Alain Muller · 2019 · 4

3. آلية عمل العصبونات ذات الذاكرة قصيرة وطويلة المدى:

أ- خلايا الذاكرة: توجد خلايا للذاكرة في قلب الشبكة يمكن لهذه الخلايا الاحتفاظ بالمعلومات على مدى فترات طويلة من الزمن وهو امر بالغ الأهمية للمهام التي تنطوي على تسلسل البيانات.

ب- بوابة النسيان: لدى هذه العصبونات آلية تسمى بوابة النسيان فهي تحدد المعلومات الواجب استبعادها من ذاكرة الخلية، كقيام المستثمر باستبعاد المعلومات المضللة او التي تبعده عن اتخاذ القرار المناسب في سوق ما.

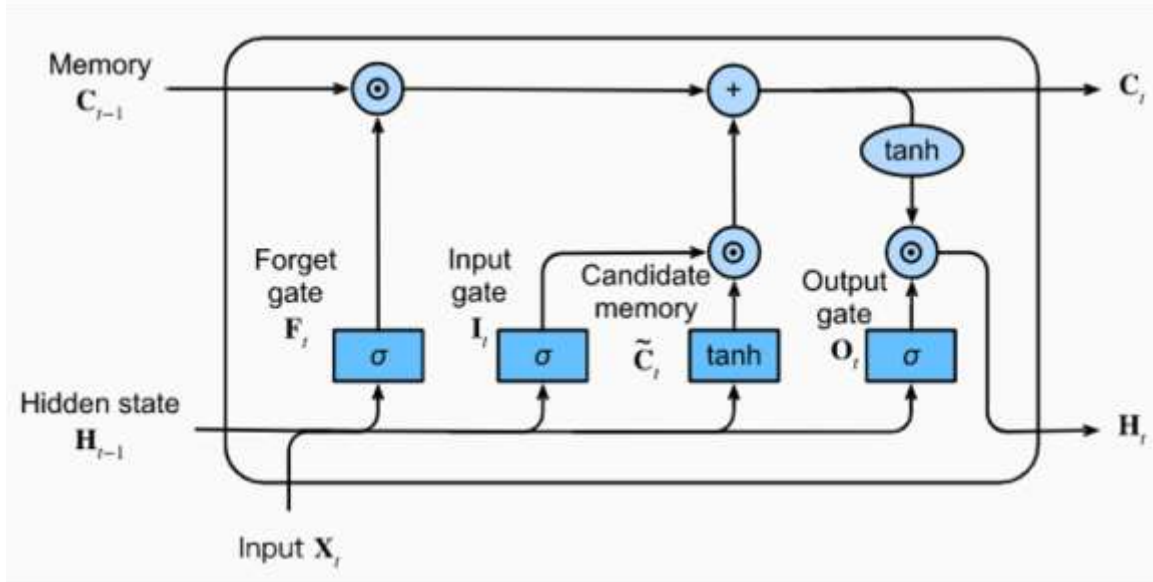
ج- بوابة الإدخال: تحدد هذه البوابة المعلومات الجديدة التي سيتم تخزينها في خلية الذاكرة، كإضافة تفاصيل أكثر الى ملخص المستثمر عن السوق المالي وذلك عند بحث هذا المستثمر أكثر عن هذا السوق.

د- بوابة الإخراج: وأخيرا تحدد هذه البوابة المعلومات التي سيتم إخراجها بناءً على الادخال الحالي وبناءً على ذاكرة الخلية، فهو كتوليد استنتاج او تنبؤ اعتماداً على الملخص الذي قام بوضعه عن هذا السوق المالي.

التقاط التبعيات طويلة LSTM ومن خلال التحكم الذكي لهذه البوابات يمكن لشبكات المدى وبشكل فعال في البيانات التسلسلية. (20)

²⁰ LONG SHORT-TERM MEMOR، Sepp Hochreiter، Jürgen Schmidhuber، 1997 ،p8

الشكل رقم (3): البوابات في الذاكرة طويلة-قصيرة الأمد



المصدر : Pattern Recognition and Machine Learning, Christopher M. Bishop, Chapter 10.

Deep Reinforcement Learning التعلم المعزز العميق

يجمع التعلم المعزز العميق بين تقنيات التعلم العميق والتعلم المعزز، حيث يتم دمج خوارزميات التعلم العميق مع التعلم المعزز لإنشاء نموذج قوي. (21)

4. مسارات التعلم الآلي: "Machine Learning Pipeline"

إن هدف التعلم الآلي هو تعليم كيفية التنبؤ وهو يعتمد عادة على نظافة المشكلة والمتمثلة بنظافة البيانات وطريقة علاجها.

في الواقع يوجد الكثير من المشاكل في البيانات مما يجعلها رديئة ولهذا السبب يتم اللجوء إلى مسار التعلم الآلي.

ولنفترض انه هنالك شركة ما تريد ان تفهم عادات الاستثمار للمستثمرين في سوق مالي معين لمعرفة المستثمر الذي من المرجح ان يقوم بعملية الاستثمار لديها.

²¹ Tutorials Points PVT LTD, ibid, 2019, P10

من ثم يتم بناء نموذج يتوقع ما هي سيولة السهم التي تجذب هؤلاء المستثمرين، عن طريق التعلم الآلي حيث يتم بدايةً، استخراج البيانات التي سيتم استخدامها في خوارزمية التدريب، فيتوجب تجميع بيانات ولتكن بيانات تاريخية عن هذا السوق والمستثمرين القدامى لفترات محددة.

ومن ثم يجب تحضير مجموعة البيانات لنموذج التعلم الآلي (المتغيرات المستقلة والمتغير التابع المعروف)، في الواقع يمكن ان يكون جزء من البيانات التي يتم تجميعها ليس لها علاقة بالموضوع الذي يتم التنبؤ لأجله (كإجمالي الأصول الثابتة في هذه الشركات) أو بيانات خاطئة (كمستثمر لم يقيم بالاستثمار بأسهم ذات سيولة عالية وتسجيل اسمه على أنه استثمر في هذه الأسهم).

غالبا إنها أخطاء بشرية في إدخال البيانات وعندما يتم تدريب النموذج على بيانات غير مرتبطة لن تساهم في الحصول على تنبؤ دقيق

ومن عملية تحضير الإجراءات هو استخدام الاحصائيات لضبط حجم البيانات المختارة.

ومن ثم سيتم بناء نموذج التعلم الآلي وتغذية خوارزمية التعلم الآلي بالبيانات المعدة، للتوصل إلى نموذج يقوم بالتنبؤ باحتمالية شخص معين بالاستثمار في أسهم هذه الشركة اعتماداً على معايير فردية، وأخيراً يتم تعميم هذا النموذج في السوق المالي لاستخدامه.

إذا كانت هذه الشركة صغيرة الحجم وبياناتها صغيرة يمكن لشخص واحد القيام بهذه التجربة، ولكن مع البيانات الضخمة التي تصبح أكثر انتشاراً من وقت لآخر لابد من تقسيم هذه العملية على عدة أجزاء والتي تنفذ من قبل عدة اشخاص مع عدة خبرات وتجارب، ومنهم مسؤول البيانات الذي يقوم بجمع البيانات والتأكد من خلوها من الأخطاء، بالإضافة الي مهندسي برمجيات التعلم الآلي وهم المسؤولون عن وضع النماذج وتدريبها وإطلاقها.

5. علم البيانات: "Data Science"

عادةً ما يدور مجال علم البيانات حول الحصول على البيانات من الماضي وتحليلها واستخراج المعلومات المهمة منها عادة ما يتضمن التحليل تصور وتفسير تلك البيانات وحساب احصائيات بسيطة مثل متوسط عوائد الأسهم في كل شهر او متوسط السيولة في هذا السوق لهذا الشهر ثم يقومون بتجميع هذه البيانات وتحليلها بشكل منطقي للوصول إلى نتائج معينة كأثر السيولة في عوائد الأسهم أما الآن يسعى علم البيانات لاستخدام التعلم الآلي لإعداد البيانات وبناء الخوارزميات وبناءً

على تلك البيانات يقومون بالتنبؤ بالمستقبل كما في بحثنا القيام بعملية التنبؤ بسيولة الأسهم للمساعدة في اتخاذ قرار ما .

وللقيام بهذا علينا استبعاد البيانات الغير مرتبطة ومن ثم فهم البيانات المجمعة وإنشاء الخوارزمية التي تعتمد على مميزات هذا النموذج فما يجب القيام به هو تحديد مصادر البيانات وطرق استخراجها لتكون هذه البيانات ذات فاعلية ومن ثم تحديد المهام التي يجب القيام بها لضمان جودة هذه البيانات وخلوها من البيانات الخاطئة وغير المرتبطة، وبعد ذلك معرفة طرق القياس التي سيتم اتباعها وماهي السمات الرئيسة التي تؤثر على المتغير المستهدف، ولا بد من وضع تصور للبيانات وكيف يمكن عرضها بأفضل الطرق وذلك بعد تحديد الغرض من النموذج المراد إعداده أو المشكلة التي يتوجب حلها، فعادةً ما يتم وضع طرق معينة لتقييم النموذج بناءً على الدقة المقبولة.⁽²²⁾

6. عمليات تعلم الآلة: "ML Operations"

الهدف الرئيسي للعمليات هو اخراج النماذج من التجربة وربطه مع الجهة التي تحتاج له وعلى الرغم من أن مهندسي العمليات يقومون ايضاً بعملية بناء نموذج كما هو الحال لدى عالم البيانات إلا أن تركيزهم الأساسي يكمن في تكامل ونشر هذه النماذج على البنية التحتية لتكنولوجيا المعلومات الخاصة بالعمل.

²² Andrew Wolf, 2022,p11, machine learning simplified

المبحث الثالث: مراجعة الأدبيات التطبيقية

توصلت نتائج الدراسات السابقة التي تناولت بناء نماذج للتنبؤ باستخدام التعلم الآلي إلى دقة نسبها جيدة بشكل عام، حيث تنوعت الأساليب المستخدمة في الدراسات للوصول إلى نماذج للتنبؤ من حيث أسلوب التعلم المستخدم لبناء النموذج، الفترة الزمنية التي تم تطبيقها ومن حيث السوق المالي الذي تم تطبيق تلك الدراسة عليه، فقد اعتمدت بعض الدراسات على كل من الإدراك الحسي متعدد الطبقات والذاكرة طويلة الأمد والانحدار الخطي، كدراسة (Pham Quoc Khanga2021) والتي توصلت بشكل عام إلى أن الذاكرة طويلة الأمد تعطي نتائج أكثر دقة للتنبؤ بسيولة الأسهم من الخوارزميات الأخرى المتبعة، حيث طبقت الدراسة على السوق الفيتنامي وكانت الفترة المدروسة منذ عام 2011 حتى عام 2019، في حين اعتمدت بعض الدراسات كدراسة (ppiahene, 2020) على نموذج شجرة القرارات والغابات العشوائية في بناء نموذج التنبؤ، بينما اعتمدت بعض الدراسات منهج ك-الجيران الأقرب، نموذج المتجهات الداعمة والانحدار اللوجستي، وكانت دقة هذه النماذج بشكل عام أقل من دقة نماذج التعلم الآلي الأخرى.

بينما توصل (Hiransha Ma,2018) إلى أن الشبكة العصبية ذات التلافيف تتفوق على غيرها من أنواع التعلم العميق في الوصول إلى نتائج عالية الدقة فقد استخدم كل من الإدراك الحسي متعدد الطبقات والشبكات العصبية المتكررة والذاكرة طويلة الأمد والشبكة العصبية ذات التلافيف وذلك للتنبؤ بسعر السهم على أساس الأسعار التاريخية المتاحة، حيث تم استخدام سعر الإغلاق اليومي لسوقين مختلفين للأوراق المالية وهما البورصة الوطنية في الهند وبورصة نيويورك، لقد تم تدريب النموذج على سعر السهم لشركة واحدة من بورصة الهند والتوقع لخمس شركات مختلفة من كلا السوقين، في حين أظهرت بعض الدراسات أن قدرة النموذج للتنبؤ تختلف اعتماداً على مصدر البيانات المراد دراستها

كما اثبتت دراسة (Pablo Luque Ray,2023) أن بيانات السيولة المتعلقة بالقطاع الخاص تساهم أكثر من بيانات السيولة المتعلقة بالقطاع العام في التنبؤ بالتقلبات الاقتصادية، كما توصلت الدراسة إلى أن السيولة هي أحد المتغيرات الرئيسية في السوق المالي ولكنها ليست محددة بشكل دقيق وغير موحدة في الأدبيات الأمر الذي يدعو إلى مزيد من الدراسات ولعل تقنيات التعلم

الآلي توفر منظورا جديداً للأسواق المالية، وللعصبونات ذات الذاكرة طويلة وقصيرة المدى صفات تميزها عن باقي الخوارزميات وهذا ما اثبتته دراسة (Sepp Hochreiter, 1997) حيث تناولت هذه الدراسة ميزات تلك العصبونات وكيفية اختصارها للجهد والوقت في عملية الاحتفاظ بالمعلومات من خلال ذاكرة الخلية الموجودة في داخلها فقد تبين ان هذه العصبونات تعمل على حل المهام المعقدة والغنية والمتأخرة لفترة طويلة.

وقد بينت العديد من الدراسات أهمية عامل السيولة في الأسواق المالية وهذا ما توصلت إليه دراسة (Wenyu Zhou, 2021) حيث هدفت إلى تسعير الأصول بشكل تجريبي في سوق الأسهم الصينية من خلال بناء وتحليل مجموعة شاملة من عوامل التنبؤ بالعوائد باستخدام خوارزميات التعلم العميق، وتوصلت الدراسة الى ان السيولة هي المؤشر الأكثر أهمية والأكثر تأثيراً على العوائد مما جعلهم يدرسون تكاليف المعاملات في تلك السوق عن كثب، بالإضافة إلى دراسة (Fang, 2009) التي توصلت إلى أن السيولة هي الأكثر تأثيراً على أداء الشركات، حيث قام الباحث إلى تطوير العلاقة بين سيولة الأسهم وأداء الشركات وتناولت الدراسة المفاهيم النظرية حول تأثير سيولة السوق والأداء التشغيلي للشركة وقد تضمن مجتمع الدراسة بورصة نيويورك وعينة تتكون من 8290 مشاهدة لشركة واحدة مع 2642 مشاهدة لمجموعة من الشركات.

بينما دراسة (Shrivastava, et, 2020) فقد استخدمت خوارزمية فرط عينات الأقليات الاصطناعية، وهي تقنية إحصائية لزيادة عدد الحالات في مجموعة البيانات الخاصة بالبحث بطريقة متوازنة، عن طريق اختبار المتغيرات الأقرب باستخدام نموذج ك-الجيران الأقرب بشكل عشوائي، ثم دراسة الانحدار لاختيار المتغيرات المهمة لفشل المصارف ولإستخدامها في نماذج التنبؤ وقد تم استخدام كل من الغابات العشوائية والانحدار اللوجستي والتعلم الجماعي، وقد توصلت دقة النموذج بالاعتماد على الغابات العشوائية إلى 98.8% وهي دقة عالية جداً، في حين دقة النموذج الذي اعتمد الانحدار اللوجستي وصلت إلى دقة أقل من 71.8%، فقد اعتمدت هذه الدراسة إلى عينة قليلة نسبياً تصل إلى 56 مصرفاً هندياً من القطاعين العام والخاص الفاشلة وغير الفاشلة، منها 44 مصرفاً غير فاشلاً و12 مصرفاً فاشلاً.

في حين أن دراسة ÖZDEMİR , 2011 هدفت إلى تحديد العوامل التي تلعب دوراً رئيسياً في تحديد سيولة سوق الأسهم التركية بشكل اجمالي ومناقشة ديناميكيات مشتركة لسيولة السوق بشكل واسع، حيث طبقت الدراسة لفترة تمتد من شهر نيسان 2005 الى كانون الأول 2010، ومن الأدوات المستخدمة للتحليل نموذج التباين لسلسلة العوائد كأحد المدخلات لتخمين نموذج السيولة، ومن اهم الاستنتاجات التي توصلت إليها هو تقلب سلسلة العوائد بسبب تأثير الرفع المالي وأسباب أخرى.

تتميز هذه الدراسة:

- أول دراسة على حد علم الباحث تستخدم وتطبق أساليب التعلم الآلي للتنبؤ بسيولة الأسهم في أسواق المال العربية.
- أول دراسة عربية تقوم ببناء نموذج للتنبؤ في سوقين ماليين مختلفين من حيث كفاءة هذين السوقين على حد علم الباحث، فقد تم دراسة قدرة النموذج في التنبؤ بكل من سوق عمان وسوق دمشق للأوراق المالية.

الفصل الثاني: الدراسة التطبيقية

سيتم في هذا الفصل عرض عينة الدراسة وهي المصارف الأردنية الخاصة والعامة التقليدية والإسلامية، والمصارف السورية الخاصة والعامة التقليدية والإسلامية، ومن ثم سيتم تحديد دقة التنبؤ للنموذج في كل مصرف من هذه المصارف من خلال حساب نسبة متوسط الخطأ بالقيمة المطلقة. mean absolute error وهو متوسط الفروق بالقيمة المطلقة بين القيم المتوقعة والقيم الفعلية. كما سيتم بناء نموذج التنبؤ من خلال أسلوب التعلم الآلي العميق عن طريق خوارزمية الذاكرة طويلة قصيرة المدى "Long short term memory".

المبحث الأول: عينة ومتغيرات الدراسة

1-عينة الدراسة:

اعتمدت الدراسة على عينة مكونة من 12 مصرف من المصارف الأردنية التقليدية والإسلامية، وهي تشكل جميع المصارف الأردنية المدرجة في بورصة عمان للأوراق المالية، وهي البنك الإسلامي الأردني، البنك الأردني الكويتي، البنك التجاري الأردني، بنك الإسكان للتجارة والتمويل، بنك الاتحاد، بنك المؤسسة العربية المصرفية -الأردن، البنك الاستثماري، بنك المال الأردني، بنك القاهرة-عمان، بنك الأردن، البنك الأهلي الأردني، البنك العربي.

كما أنه تم تجريب النموذج على عينة المصارف السورية التقليدية والإسلامية، وهي 15 مصرفاً، وهي بنك البركة-سورية، بنك الشام، فرنسا بنك، بنك الشرق، بنك سورية والخليج، بنك الأردن-سورية، بنك قطر الوطني-سورية، بنك بيلوس، بنك سورية الدولي الإسلامي، المصرف الدولي للتجارة والتمويل، بنك سورية والمهجر، بنك بيمو السعودي الفرنسي، بنك الائتمان الأهلي، والبنك العربي والبنك الوطني الإسلامي، حيث تم استبعاده لحدثة تأسيسه وإدراجه.

2-متغيرات الدراسة:

فيما يلي متغيرات الدراسة والتي تم اختيارها وفق مجموعة من الدراسات السابقة، كدراسة كل من

(Fang,2009)، (Pham Quoc Khanga2021)، (Pablo Luque Ray2023)

1-حجم التداول (volume)

2-عدد الصفقات (no_of_trades)

3-فرق السعر (Diff)

4-نسبة التداول (trade rate)

5-امهيود (Amihud)

المبحث الثاني: اختبار الفرضية ومناقشة النتائج

سيتم استخدام أسلوب التعلم الآلي العميق وعلى وجه الخصوص خوارزمية الذاكرة LSTM طويلة-قصيرة المدى وذلك بسبب قدرتها على التقاط الأنماط المعقدة، بالإضافة لقابليتها على التطوير للنموذج بشكل كبير ومتانتها في مواجهة البيانات ذات التشتت الكبير. ولبناء نموذج قادر على التنبؤ بسيولة الأسهم للبنوك المدرجة في سوق عمان للأوراق المالية، تم اتباع الخطوات التالية:

أولاً: معالجة البيانات Data processing

بعد تحميل البيانات من بورصة عمان للأوراق المالية لكل عام بشكل منفصل منذ عام 2012 حتى نهاية عام 2023، قمنا بدمج الأعوام ليصبح لدينا بيانات واحدة 2680 مشاهدة، وتم وضع ميزات (features) النموذج على شكل أعمدة وهي:

Date: التاريخ لكل قيمة

Name : اسم البنك

Volume : حجم التداول

No-Of Trades: عدد مرات التداول

High: أعلى سعر للسهم

Low : أقل سعر للسهم

Close Price : سعر الإغلاق

Best-Ask-price : أفضل طلب سعر

Best-bid-price : أفضل عرض سعر

Amihud : وهو مقياس أميهود

Percentage : وهي قيمة التداول لكل بنك على قيمة التداول لكافة البنوك


الشكل رقم (4): ترتيب المتغيرات واعتماد التاريخ كفهرس للدراسة

index	no_of_trades_x	name	volume	no_of_trades_y	high	low	close_price	best_ask_price	best_bid_price	volume_avg	volume_med	Anihud_illiquidity	percentage
2012-01-02	222	لج الإسلامي الأري	1869.00	5	2.76	2.74	2.76	2.76	2.75	1869.000000	1869.000	1.000000	2.252252
2012-01-03	217	لج الإسلامي الأري	203378.88	74	3.02	3.02	3.02	3.02	3.01	102623.940000	102623.940	1.000000	34.101382
2012-01-04	370	لج الإسلامي الأري	203289.31	75	3.03	3.02	3.02	3.02	3.01	136179.063333	203289.310	0.669878	20.278270
2012-01-05	327	لج الإسلامي الأري	65240.88	33	3.18	3.18	3.18	3.18	3.17	118444.517500	134265.095	0.882169	10.091743
2012-01-07	180	لج الإسلامي الأري	55586.37	45	2.41	2.39	2.40	2.41	2.40	105872.888000	65240.880	1.622800	25.000000
2012-01-08	264	لج الإسلامي الأري	18279.15	16	2.54	2.50	2.51	2.53	2.51	91273.931667	60413.625	1.510817	6.060606

المصدر: من إعداد الباحث

بعد تأكدنا من صياغة عامود التاريخ على شكل YYYY-MM-DD يتم اعتماد عامود التاريخ كأساس للقراءة أي يصبح عمود التاريخ هو الفهرس، ومن ثم نعرض قيمة من القيم المدروسة لأحد البنوك كالبنك الإسلامي الأري دنيا ولتكن مثلاً أمهود ومن ثم نعرض آخر 700 قيمة من البيانات للتأكد من الشكل وتسلسل القيم، ويكون الرسم البياني للقيم بالشكل الآتي:

الشكل رقم (5): الرسم البياني للقيم



المصدر: من إعداد الباحث

وبناءً على متطلبات الدراسة ووفقاً للدراسات السابقة سنقوم بأخذ المتغيرات التي ستعتمد دراستنا عليها والمتمثلة بكل من حجم التداول، عدد المعاملات، الفرق بين أكبر وأقل سعر، نسبة التداول وأمهود، وبالتالي سيصبح شكل البيانات كالتالي:

الشكل رقم (6): متغيرات الدراسة

index	volume	no_of_trades	diff	Amihud_illiquidity	trade_rate
2012-01-02	1869.00	5	0.01	1.000000	2.252252
2012-01-03	203378.88	74	0.01	1.000000	34.101382
2012-01-04	203289.31	75	0.01	0.669878	20.270270
2012-01-05	65240.88	33	0.01	0.882169	10.091743
2012-01-07	55586.37	45	0.01	1.622800	25.000000
...
2023-12-24	141473.01	39	0.01	1.549896	22.941176
2023-12-26	55470.62	21	0.01	1.547387	12.962963
2023-12-27	31095.66	20	0.01	1.547971	10.256410
2023-12-28	37259.19	19	0.02	1.548386	8.675799
2023-12-31	20118.45	14	0.01	1.544987	7.608696

2680 rows × 5 columns

المصدر: من إعداد الباحث ووفق الدراسات السابقة

من ثم يجب علينا دراسة العلاقة بين هذه المتغيرات الـ 5 لمعرفة ما إذا كان هناك ارتباط بينها، وتم استخدام مصفوفة الارتباط correlation matrix ومن ثم عرض المصفوفة عن طريق الخريطة الحرارية Heat map وهي تظهر قيم الارتباط بين هذه المتغيرات الـ 5 على الشكل الآتي:

الشكل رقم (7): الخريطة الحرارية للمتغيرات



المصدر: من إعداد الباحث باستخدام لغة بايثون

ومن الشكل السابق نلاحظ وجود علاقة ارتباط قوية بين كل من حجم التداول وعدد المعاملات وبين نسبة التداول وعدد المعاملات ايضاً. وبالتالي سيتم استبعاد متغير عدد المعاملات No-of trades وبذلك أصبحت متغيرات البحث هي:

name	feature	Kurtosis	skewness	Avg	min	Max	std_value	Jarque-Bera
البنك الإسلامي الأردني	trade_rate	1.9210	1.2377	16.0806	0.4878	66.0920	9.3777	1095.8868
	Amihud	3.1370	1.7114	0.0000	0.0000	0.0000	0.0000	2406.1994
	diff	77.8940	5.8749	0.0161	0.0100	0.2400	0.0114	692692.0523
	volume	160.1036	9.1795	119069.9914	272.8000	4644574.5900	186346.9085	2898924.8596
البنك الاردني الكويتي	trade_rate	20.3706	3.3593	3.9702	0.1715	48.2301	3.9178	48349.0579
	Amihud	1.4177	1.7254	0.0000	0.0000	0.0001	0.0000	1462.6024
	diff	330.6243	-5.3999	0.0328	-2.7500	2.3900	0.1333	11499171.0398
	volume	901.0174	27.9903	24252.0262	1.6300	5517489.6800	153436.0619	85639357.3680
البنك التجاري الأردني	trade_rate	58.1424	5.5522	1.8334	0.0845	42.8571	2.5360	208187.0731
	Amihud	-0.8968	0.3547	0.0002	0.0000	0.0005	0.0001	77.6872
	diff	81.7971	1.0456	0.0286	-1.0900	1.2800	0.1025	397802.3762
	volume	1011.3398	30.4307	22230.1456	0.8000	11949358.7800	345275.1843	60991945.2523
بنك الاسكان للتجارة والتمويل	trade_rate	18.2893	3.4555	2.4427	0.1172	30.6620	3.0305	31855.1594
	Amihud	-0.4721	0.9041	0.0000	0.0000	0.0001	0.0000	291.0622
	diff	42.5364	0.0026	0.1239	-9.1000	8.3700	1.2437	150778.6616
	volume	621.9839	22.9559	33338.0171	4.0800	8560174.6600	266539.7892	32414326.7882
بنك الإتحاد	trade_rate	13.6498	3.0455	4.3667	0.1227	47.1831	4.8157	22434.9727
	Amihud	395.5840	14.9955	0.0000	0.0000	0.0003	0.0000	15804192.3432
	diff	59.1664	5.2618	0.0199	0.0100	0.2600	0.0149	362645.9734
	volume	1752.0425	39.9943	62312.4381	6.2400	35212935.8300	777829.0282	308886811.5971
بنك المؤسسة العربية المصرفية/الاردن	trade_rate	19.0923	3.2990	2.8437	0.0947	35.0000	2.9277	37557.6766
	Amihud	3.6259	1.6715	0.0001	0.0000	0.0004	0.0001	2238.7101
	diff	834.2761	27.1141	0.0152	0.0100	0.7100	0.0222	64333197.2825
	volume	269.4928	13.9850	13241.8616	0.7700	1254495.0900	49987.6858	6756656.3928
البنك الاستثماري	trade_rate	12.0130	2.9079	2.3459	0.0709	24.0506	2.6496	13545.7648
	Amihud	1.2168	1.2676	0.0001	0.0000	0.0003	0.0001	601.3382
	diff	282.4691	2.4685	0.0255	-1.4800	1.5000	0.0809	6069124.1968
	volume	421.4561	19.1515	22148.8303	1.4700	4428590.3200	165604.4896	13618480.4491
بنك المال الأردني	trade_rate	3.5459	1.6379	11.0397	0.1305	66.9027	9.8003	2495.4532
	Amihud	189.8984	12.0356	0.0003	0.0000	0.0331	0.0015	3923620.8346
	diff	702.0833	25.3506	0.0160	0.0100	0.9100	0.0314	53058886.0233
	volume	523.2843	19.6309	119655.6973	1.3000	12484806.6900	412030.6854	29487321.4912
بنك القاهرة عمان	trade_rate	5.9114	1.8470	6.9243	0.2137	51.6234	5.6381	5180.9206
	Amihud	59.6599	5.7912	0.0000	0.0000	0.0005	0.0000	393814.6496
	diff	412.4851	18.5392	0.0212	0.0100	0.9800	0.0410	18288184.0987
	volume	686.8538	24.4173	61206.7989	5.3400	8207134.4900	260118.7034	50556553.7183
بنك الاردن	trade_rate	7.8484	2.2017	7.0935	0.2045	58.0547	5.9418	8898.4288
	Amihud	2.1218	1.9188	0.0000	0.0000	0.0000	0.0000	2112.7343
	diff	602.7682	24.1112	0.0226	0.0100	2.2000	0.0805	40176326.5462
	volume	2617.0367	51.1064	137874.5096	10.0500	202912794.1600	3955122.9945	753668729.2337
البنك الاهلي الأردني	trade_rate	5.6565	1.7601	10.4411	0.2793	69.0566	7.2021	4941.9390
	Amihud	-0.5723	0.8698	0.0000	0.0000	0.0000	0.0000	373.4151

	diff	833.2878	28.4844	0.0125	0.0100	0.8200	0.0268	77667695.6000
	volume	44.6563	5.6265	75908.3774	18.8000	1769129.4600	133110.4320	236117.7541
البنك العربي	trade_rate	0.1090	0.6099	32.0082	4.4444	80.4781	13.1930	167.6537
	Amihud	-1.1525	0.2359	0.0000	0.0000	0.0000	0.0000	173.3795
	diff	64.1238	5.2581	0.0254	0.0100	0.4800	0.0241	472034.8829
	volume	265.8674	11.9116	505494.0965	4629.6000	25172347.8000	867635.1589	7965495.1322

نسبة التداول Trade-rate, الفرق بين أعلى سعر وأقل سعر Diff, حجم التداول Volume, وAmihud.

ثانياً: الدراسة الإحصائية للمتغيرات

سنقوم بدراسة كل من الالتواء والتقلطح وأصغر وأكبر قيمة والانحراف المعياري بالإضافة إلى المتوسط الحسابي والتوزيع الطبيعي باستخدام جاركو بيررا لمتغيرات الدراسة في كل من المصارف المدرجة في بورصة عمان وسوق دمشق للأوراق المالية، وذلك لتفسير التغير في درجة التنبؤ بين هذه المصارف.

يبين كل من الجدول رقم (1) و(3) التوصيف الإحصائي لمتغيرات الدراسة لكل من البنوك المدرجة في بورصة عمان وفي سوق دمشق للأوراق المالية.

الجدول رقم (1): الدراسة الإحصائية للمتغيرات للبنوك المدرجة في سوق عمان للأوراق المالية

المصدر: من إعداد الباحث باستخدام برنامج الإكسل

نلاحظ من خلال الدراسة الإحصائية للبنوك المدرجة في بورصة عمان للأوراق المالية ما يلي:

1- أن متغير أمهيود متقلطح في كل من البنك الإسلامي الأردني، بنك الاتحاد، المؤسسة العربية المصرفية الأردنية، بنك المال الأردني، بنك القاهرة.

2- إن أكبر متوسط حسابي لمتغير أمهيود في بنك المال الأردني 0.0003

3- إن جميع البنوك ملتوية نحو اليمين.

4- إن بقسمة الانحراف المعياري على المتوسط الحسابي لجميع البنوك نلاحظ أن جميع البيانات

تتصف بالتشتت لكون الناتج أكبر من 25%، كما هو موضح بالجدول الآتي:

الجدول رقم (2): قياس التشتت للبنوك المدرجة في بورصة عمان للأوراق المالية

اسم البنك	Amihud	Diff	trade_rate	Volume
البنك الإسلامي الأردني	67.86926587	71.01734948	58.31669895	156.5019921

البنك الأردني الكويتي	88.8516972	406.7553338	98.68242242	632.6731662
البنك التجاري الأردني	57.01663151	357.674995	138.3201393	1553.184538
بنك الإسكان للتجارة والتمويل	85.9936575	1004.181192	124.0655587	799.5070276
بنك الاتحاد	64.27945492	75.22977581	110.282554	1248.272499
المؤسسة العربية المصرفية الأردنية	83.89073697	146.218916	102.9559883	377.4974183
البنك الاستثماري	76.05283567	317.1529261	112.9447029	747.6895503
بنك المال الأردني	512.9601779	196.4431298	88.77299936	344.3469009
بنك القاهرة عمان	185.0193477	192.9288841	81.42438881	424.9833485
بنك الأردن	116.3719126	356.6729848	83.76402221	2868.639755
البنك الأهلي الأردني	77.42386696	213.8803146	68.97839972	175.3567085
البنك العربي	58.31956215	95.09819366	41.21759614	171.6410073

المصدر: من إعداد الباحث

5- إن أكبر قيمة لمتغير أمهيوذ كانت في بنك المال الأردني 0.0331

6- إن أكبر قيمة للانحراف المعياري لمتغير أمهيوذ في المؤسسة المصرفية الأردنية 0.0222

name	Feature	Kurtosis	Avg	Min	Max	std_value	Jarque-Bera	Skewness
البنك العربي - سورية	trade_rate	29.23400889	3.313871384	0.303951383	40.40404129	4.258293152	8638.20077	4.450625428
	Amihud	65.62497749	5.25997E-06	0	1.58549E-05	9.71005E-07	40784.85854	5.06300864
	Diff	2.234480082	67.38739014	-2963	2588	922.468689	60.91495977	-0.63097
	Volume	62.99968085	10789.33789	1	458929	46360.68359	38898.46977	7.68570407
بنك الائتمان الأهلي	trade_rate	8.532059471	3.30725646	0.303951383	23.74100685	3.983445406	910.4541688	2.72902644
	Amihud	69.43052275	4.89364E-06	0	1.90439E-05	1.28137E-06	44211.92814	6.3448190
	Diff	1.248641231	371.3333435	-5513	5195	1867.192017	25.44898158	-0.57192
	Volume	129.106229	32889.51563	1	3599000	281991	152373.3109	11.184871
بنك بيمو السعودي الفرنسي	trade_rate	7.18780985	4.198462963	0.358422935	23.20000076	3.542711258	720.4257397	2.257096
	Amihud	0.370587351	8.28527E-06	0	1.56473E-05	3.10337E-06	4.025821382	-0.257510
	Diff	2.270568003	384.6291809	-6829	6725	2036.632813	70.99318521	-0.697108
	Volume	229.7032349	8879.354492	2	1323736	85532.38281	536811.2083	15.1455002
بنك سورية والمهجر	trade_rate	7.149798012	3.617709398	0.275482088	24.13793182	3.733725071	658.4379237	2.3653997
	Amihud	106.7071029	4.72318E-06	0	2.2308E-05	1.42864E-06	104977.7365	9.1109714
	Diff	1.870906601	127.8139572	-1925	2000	700.8023682	31.40521108	-0.036764
	Volume	108.4648777	16174.01855	1	930864	76469.97656	109043.1562	10.0949196
المصرف الدولي للتجارة والتمويل	trade_rate	0.846417181	10.73445988	0.59523809	35.5263176	6.984830856	50.60648619	0.99435229
	Amihud	12.02057141	3.31817E-06	0	5.77936E-06	5.0602E-07	1599.133073	0.88291504
	Diff	6.531115005	50.11153793	-3893	3696	997.6455078	494.8679079	-0.8695762
	Volume	117.1459839	20692.40039	5	906700	71939.21094	153472.7058	10.5300732
بنك سورية الدولي الإسلامي	trade_rate	1.917883621	14.43018436	0.732600749	47.22222137	6.850883961	84.36182895	0.98444334
	Amihud	2.421962951	1.41857E-06	0	2.04768E-06	2.63708E-07	135.8211983	-1.2547132
	Diff	8.201674686	22.97014999	-3167	3013	793.538269	754.0891365	-0.2563702
	Volume	8.119346867	22115.47461	195	142654	23439.66797	1026.797018	2.55089093
بنك بيبيلوس- سورية	trade_rate	45.91115365	3.000030279	0.259740263	44.21487427	4.248182297	17876.78186	5.62946942
	Amihud	5.148252329	4.35622E-06	0	7.08873E-06	8.55108E-07	313.7843211	-1.7831545
	Diff	0.989855811	-350.40625	-3900	3999	1180.283813	21.70209089	-0.6582072
	Volume	105.2388112	12306.40137	1	892396	74596.73438	91712.96823	9.8604467
بنك قطر الوطني- سورية	trade_rate	11.403058	9.227440834	0.425531924	61.41732407	7.986000061	1789.110159	2.82855445
	Amihud	26.94855813	2.58171E-06	0	4.55234E-06	3.00032E-07	8203.32239	-2.0443815
	Diff	7.903282522	72.44905853	-5023	4899	1201.675781	701.5572873	-0.5185049
	Volume	110.8608349	40423.58203	33	2601392	205285.2969	140247.97	10.1436954
بنك الأردن - سورية	trade_rate	15.88562196	3.072011948	0.25	29.10798073	4.009040356	2088.605926	3.4570923
	Amihud	1.028374022	2.83633E-05	0	9.52046E-05	3.66751E-05	32.22541169	0.9452041
	Diff	1.087726732	875.4910278	-8016	3599	2149.183105	23.09654493	-0.7307726
	Volume	53.18572769	3354.586914	1	75000	7434.588379	20841.32132	6.4505488
بنك سورية و الخليج	trade_rate	13.55407533	1.977837086	0.257731944	16.92307663	2.304294348	1271.41216	3.18801998
	Amihud	3.073312804	9.21525E-06	0	1.27759E-05	1.91488E-06	67.75353246	-0.7923469
	Diff	1.171477975	1735.977905	-6350	6475	3610.16748	9.52136173	-0.2774347
	Volume	121.4099005	14148.19141	1	1281251	111108.0938	86239.84399	10.936545
بنك الشرق	trade_rate	6.183078575	2.432015896	0.234741777	14.10256386	2.469985962	450.5213698	2.28332593
	Amihud	3.742699347	4.86108E-06	0	8.04765E-06	1.38638E-06	128.5057227	-0.8434165

	Diff	2.485540668	800.7267456	-	-9256	6700	2411.161133	109.5354894	-1.4306816
	Volume	82.04246062	5843.437012	1	290000	26629.38672	53668.93628	8.76903181	
فرنسبنك - سورية	trade_rate	12.27439908	5.034450054	0.375939846	40.6593399	4.954430103	1791.923718	2.77487644	
	Amihud	9.776408397	3.55896E-06	2.46246E-06	5.21219E-06	2.61033E-07	945.1639943	-0.183509	
	Diff	1.93377646	27.51054764	-2138	1917	690.8463745	44.79090604	-0.4461773	
	Volume	115.0760886	12110.91992	1	560666	43306.94922	134782.3977	10.078943	
بنك الشام	trade_rate	3.515455152	10.42714882	0.628930807	36.76470566	6.140825272	229.5353716	1.44495085	
	Amihud	-0.46503448	1.94034E-06	0	2.6467E-06	4.68781E-07	2.397665956	0.00429108	
	Diff	6.791584456	137.6804504	-4068	3521	1024.8302	602.9948006	-1.4387431	
	Volume	185.8222118	17333.95117	29	807185	52804.19141	390004.5009	12.8304484	
بنك البركة - سورية	trade_rate	0.293728683	32.62399292	4.166666508	65.35087585	10.73052406	1.019685323	0.0366758	
	Amihud	2.093543846	8.38765E-07	0	1.7262E-06	2.06489E-07	53.45803762	0.32491957	
	Diff	7.760723226	277.9176025	-7767	8245	1923.517944	683.0187329	-0.5399346	
	Volume	102.6419372	50837.63672	1145	1229745	107231.7266	121429.0854	9.74174906	

الجدول رقم (3): الدراسة الإحصائية للمتغيرات في سوق دمشق للأوراق المالية

المصدر: من إعداد الباحث باستخدام برنامج الإكسل

نلاحظ من خلال الدراسة الإحصائية للبنوك المدرجة في سوق دمشق للأوراق المالية مايلي:

1- أن متغير أمهيود متطوح في كل البنوك باستثناء بنك العربي سورية وبنك الائتمان الأهلي وبنك سورية والمهجر .

2- إن أكبر متوسط حسابي لمتغير أمهيود في بنك سورية والخليج، بينما أصغر متوسط حسابي لمتغير أمهيود في البنك الدولي الإسلامي .

3- إن منحنيات جميع البنوك ملتوية نحو اليمين، باستثناء بنك الشام فهو ملتوي نحو اليسار .

4- إن بقسمة الانحراف المعياري على المتوسط الحسابي لجميع البنوك نلاحظ أن متغير أمهيود في كل من بنك الائتمان الأهلي وبنك بيمو وبنك سورية والمهجر وبنك الأردن وبنك الشرق تتصف بالتشتت فقط لكون الناتج أكبر من 25% كما هو موضح في الجدول الآتي:

الجدول رقم (4): قياس التشتت للبنوك المدرجة في سوق دمشق للأوراق المالية

اسم البنك	Amihud	Diff	trade_rate	volume
البنك العربي	18.460273	-1368.904015	128.4990472	429.6897925
بنك الائتمان الأهلي	26.18444816	-502.8344611	120.4456157	857.388729
بينك بيمو	37.45653009	-529.5055377	84.38114827	963.2725317
بنك سورية والمهجر	30.24746755	548.2987801	103.206882	472.7951579
التجارة والتمويل	15.24996111	-1990.84991	65.06923438	347.6600567
الدولي الإسلامي	18.58968199	3454.649923	47.47606675	105.9876326
بيبلوس	19.62956993	-336.8329799	141.6046473	606.1620465
قطر	11.62144329	-1658.649271	86.54620717	507.8354925
الأردن	129.3047573	-245.4831674	130.5021082	221.6245567
سورية والخليج	20.77944076	207.9616031	116.5057711	785.3165861
الشرق	28.52003194	-301.1215931	101.561259	455.7144479
فرنسا بنك	7.334536861	-2511.205461	98.41055229	357.5859596
الشام	24.15971268	-744.3541889	58.89265971	304.6287075
البركة	24.61821035	-692.1180691	32.89151052	210.9298022

المصدر: من إعداد الباحث

5- إن أكبر قيمة لمتغير أمهيود كانت في بنك الأردن سورية.

6- إن أكبر قيمة للانحراف المعياري لمتغير أمهيود في البنك العربي سورية.

ثالثاً: تقييس البيانات (Scaling):

وهو التقدير الكمي للبيانات، حيث يعمل على توليد سلسلة متصلة من القيم وربط الأحداث التي يتم قياسها بتلك القيم.

ويتم استخدامه للأسباب التالية:

- 1- تعزيز سرعة التقارب: يؤدي تطبيع ميزات الإدخال لمقياس مماثل إلى منع ميزات معينة من السيطرة على عملية التعلم نظراً لحجم هذه الميزات الكبير، ونتيجة لذلك تتقارب تقنيات تحسين النسب المتدرجة بسرعة أكبر، مما يؤدي إلى تدريب نموذجي أسرع.⁽²³⁾
 - 2- تحسين متانة النموذج: تساهم بيانات الإدخال التي تم قياسها بشكل صحيح في قوة نماذج التعلم العميق، فهو يقلل من حساسية النموذج للمتغيرات في ميزات الإدخال، مما يجعل الشبكة أكثر مرونة اتجاه المعلومات الغير دقيقة أو التي لا ترتبط بالدراسة، تعد هذه العملية ضرورية لإمكانية تطبيق نماذج التعلم العميق على البيانات المختلفة التي تحمل الكثير من الأخطاء.⁽²⁴⁾
 - 3- تسهيل ضبط المعلمة الفائقة: حيث يعمل قياس البيانات على تبسيط عملية ضبط المعلمة الفائقة او الاستثنائية في نماذج التعلم العميق، مما يضمن ان تكون هذه النماذج اقل حساسية اتجاه تلك المعلمات مما يؤدي إلى تدريب نموذجي أكثر استقراراً وموثوقية.⁽²⁵⁾
- (مقياس الحد الأدنى والأعظم) minmax scaller لتقييس البيانات قمنا باستخدام خوارزمية حيث تعتمد على قياس قيم المعالم إلى نطاق محدد مسبقاً، عادةً يكون بين 0 و 1 وتحافظ هذه الطريقة على شكل التوزيع الأصلي للبيانات مع ضبط قيمها لتتناسب مع نطاق محدد وهو مثالي للبيانات التي لا تعتمد التوزيع الغوسي او التي لا تحتوي على انحراف معياري صغير جداً.

²³ LeCun et al., deep learning,2015,p440

²⁴ Chollet, Deep Learning with Python,2017,p129

²⁵ ; Bergstra & Bengio, Random Search for Hyper-Parameter Optimization,2012,p80

وتكون معادلته من الشكل:

المعادلة رقم (1): معادلة التقييس للمتغيرات

$$x_{scaled} = \frac{x - x_{min}}{x_{max} - x_{min}} \times (max - min) + min$$

حيث :

X min اصغر قيمة في البيانات

X-max اكبر قيمة في البيانات

X القيمة الحالية المراد قياسها

X-norm القيمة بعد التقييس

Max الحد الأعلى للمجال الجديد

Min الحد الأدنى للمجال الجديد

رابعاً: بناء النموذج باستخدام خوارزمية الذاكرة طويلة وقصيرة المدى:

أ-بناء النوافذ

نقوم بعمل ما يسمى بالنوافذ أي جعل البيانات على شكل نوافذ، إن البيانات الموجودة لدينا هي عبارة عن مصفوفة متسلسلة من التواريخ ولا يمكننا إدخالها كما أو تدريب النموذج عليها إذ يفترض بنا وضعها على شكل نوافذ ليتم فهمها ولتكون قابلة للتدريب.

حيث قمنا بجعل كل نافذة عبارة عن 6 أيام ونقوم في كل مرة بالتقدم ليوم واحد أي لليوم السابع، فتكون هذه النافذة هي المدخلات بالنسبة للنموذج ويكون الإخراج هو التنبؤ بقيمة اليوم السابع. فيما يلي توضيح للآلية المتبعة:

النافذة الأولى: تبدأ من العنصر السادس وهو الفهرس 5 وتشمل العناصر الستة التي قبلها "1,2,3,4,5,6" والإخراج هو اليوم السابع.


النافذة الثانية: تبدأ من العنصر السابع وهو الفهرس 6 وتتضمن العناصر الستة التي قبلها "2,3,4,5,6,7" والإخراج هو اليوم الثامن.

النافذة الثالثة: تبدأ من العنصر الثامن وهو الفهرس 7 وتتضمن العناصر الستة التي قبلها
"3,4,5,6,7,8" والإخراج هو العنصر التاسع.

النافذة الرابعة: تبدأ من العنصر التاسع وهو الفهرس 8 وتتضمن العناصر الستة التي قبلها
"4,5,6,7,8,9" والإخراج هو العنصر العاشر.

النافذة الخامسة: تبدأ من العنصر العاشر وهو الفهرس 9 وتتضمن العناصر الستة التي قبلها
"5,6,7,8,9,10" والإخراج هو العنصر الحادي عشر.

الشكل رقم (8): النوافذ في الخلايا العصبية



ب- تقسيم البيانات

نقوم بتقسيم البيانات الجديدة إلى ثلاثة أقسام :

أ- Train قسم التدريب وهو القسم الأكبر حيث يشكل 80% من البيانات.

ب- Validation قسم التحقق ويشكل 10% من البيانات ولهذا القسم العديد من الوظائف:

1- مساعدة النموذج أثناء التدريب على التحقق من سير عملية التدريب بشكل صحيح وعدم قيام الشبكة عن الانحراف عن مسارها.


2- منع Over fitting ويحدث عندما يتعلم النموذج البيانات بشكل جيد للغاية، بما في ذلك القيم

المتطرفة، مما يجعله يؤدي بشكل سيء على البيانات الجديدة غير المرئية، حيث تساعد بيانات التحقق من الصحة في تحديد المطابقة، لأنها مجموعة منفصلة من البيانات التي لم يراها النموذج أثناء التدريب.

3-يقوم بعملية ضبط للمعلمات الفائقة التي تؤثر على كيفية تعلم النموذج من البيانات، حيث تعمل بيانات التحقق على اختبار أفضل المعلمات الفائقة بالنسبة للنموذج.

ج-قسم الاختبار Test وهو يشكل نسبة 10% من البيانات ونقوم بالعمل عليه بعد الانتهاء من تدريب الشبكة العصبية لاختبار أدائها نظراً لأن هذا القسم لا يدخل عملية التدريب ويكون مجهولاً بالنسبة للشبكة العصبية المدربة لدينا.

الشكل رقم (9): تقسيم البيانات إلى ثلاثة أقسام



ج-تحضير الشبكة العصبية

تكون الشبكة العصبية مكونة من ثلاث طبقات:

أولاً: طبقة الإدخال

ثانياً: الطبقة المخفية وستكون مكونة من ثلاث طبقات أيضاً

الطبقة الأولى: هي طبقة LSTM تتكون من 16 خلية عصبية.

الطبقة الثانية: هي طبقة الإسقاط Droup out حيث تقوم بإسقاط بعض المعلمات التدريبية في حالتنا لا تقوم بتمرير معلمات قسم التدريب إلى الطبقة التالية والتي تشكل 10% من البيانات وذلك لتجنب وجود Over-fitting ولضمان تعميم النموذج أثناء التدريب وعدم انحيازه لقيم معينة.

الطبقة الثالثة: وهي طبقة ثانية من LSTM مكونة من 8 خلايا عصبية.

ثالثاً: طبقة الإخراج فهي مكونة من عصبون وحيد وذلك لان التوقع سيكون بقيمة واحدة فقط (اليوم واحد).

لقد قمنا بالعديد من التجارب لاختيار عدد النوافذ 6 وعدد الخلايا العصبية 16، حيث بدايةً قمنا بإطالة طول النافذة لتكون 13 ثم 20 ثم 50 يوم فلاحظنا من خلالها أن الشبكة العصبية كانت تدخل في حالة من التشويش وذلك بسبب حجم البيانات الكبير وأصبح هناك صعوبة في اكتشاف أنماط للتعلم.

كما قمنا بزيادة عدد الخلايا العصبية حيث قمنا بوضع 32 عصبون في أول طبقة و16 في الطبقة الثانية كما قمنا بزيادة عدد الطبقات المخفية مما أدى إلى حدوث حفظ لبيانات التدريب فأصبح يعطي نتائج على تلك البيانات بمعدل خطأ يساوي الصفر ولكن عند عرض بيانات الاختبار تكون النتائج سيئة وبالتالي هو قام بالحفظ وليس التعلم.

خامساً: نتائج اختبار النموذج

قمنا بدراسة نسبة الخطأ وهي متوسط الفروق بالقيمة المطلقة بين القيم المتوقعة والقيم الفعلية.

Mean absolute percentage error(MAPE)

المعادلة رقم (2): كيفية حساب متوسط الخطأ بالقيمة المطلقة

$$MAPE = \frac{\sum \frac{|A - F|}{A} \times 100}{N}$$

حيث أن N هو حجم العينة


A هو القيمة الفعلية للبيانات .

F هو القيمة المتوقعة من النموذج.

يستخدم متوسط نسبة الخطأ في قياس دقة التنبؤ في أسواق الأسهم ومشاكل السلاسل الزمنية لأنه يسمح بمقارنة أداء نماذج مختلفة، ويمكن استخدامه لتحديد أي نموذج يتنبأ بشكل أدق بالقيم المستقبلية، فإذا كان لدينا ثلاثة نماذج مختلفة يمكننا مقارنة متوسط الخطأ لتحديد أي نموذج يعطي أفضل تنبؤ.

وقد ظهرت نتائج التنبؤ في سيولة الأسهم لبنوك سوق عمان للأوراق المالية على الشكل الآتي:


الشكل رقم (10): التنبؤ بسيولة البنك الإسلامي الأردني



المصدر: من إعداد الباحث باستخدام لغة البرمجة بايثون و Google Colab

نلاحظ أن في البنك الإسلامي الأردني قد قاربت القيم المتوقعة القيم الفعلية بمعدل خطأ 1.03% أي بدقة تنبؤ 98.97%.


الشكل رقم (11): التنبؤ بسيولة البنك الأردني الكويتي



المصدر: من إعداد الباحث باستخدام لغة البرمجة بايثون و Google Colab

بينما نلاحظ أنه في البنك الأردني الكويتي، فقد وصلت نسبة الخطأ إلى 3.4% تقريباً، أي أن دقة التنبؤ وصلت لحدود 96.6%.


الشكل رقم (12): التنبؤ بسيولة البنك التجاري الأردني



المصدر: من إعداد الباحث باستخدام لغة البرمجة بايثون و Google Colab

في حين وصلت نسبة الخطأ في البنك التجاري الأردني إلى 5.8% تقريباً، أي أن دقة التنبؤ وصلت لحدود 94.2%.


الشكل رقم (13): التنبؤ بسيولة بنك الإسكان للتجارة والتمويل



المصدر: من إعداد الباحث باستخدام لغة البرمجة بايثون و Google Colab

في بنك الإسكان للتجارة والتمويل فقد وصلت نسبة الخطأ إلى 2% تقريباً، أي أن دقة التنبؤ تصل إلى 98% تقريباً.


الشكل رقم (14): التنبؤ بسيولة بنك الاتحاد



المصدر: من إعداد الباحث باستخدام لغة البرمجة بايثون و Google Colab

ومن الملاحظ أن في بنك الاتحاد وصلت نسبة الخطأ إلى 1.8% تقريباً وبالتالي إلى دقة نموذج تتجاوز حدود 98%.

الشكل رقم (15): التنبؤ بسيولة بنك العربية المصرفية الأردنية



المصدر: من إعداد الباحث باستخدام لغة البرمجة بايثون و Google Colab

ونجد في بنك المؤسسة العربية المصرفية/الأردن أن نسبة الخطأ تصل إلى 2% تقريباً، أي بدقة نموذج تصل إلى 98%.


الشكل رقم (16): التنبؤ بسيولة البنك الاستثماري



المصدر: من إعداد الباحث باستخدام لغة البرمجة بايثون و Google Colab

ينما في البنك الاستثماري فقد كانت أعلى نسبة خطأ بين البنوك الأردنية حيث وصلت إلى 7% أي بدقة تنبؤ تصل إلى 93%.


الشكل رقم (17): التنبؤ بسيولة بنك المال الأردني



المصدر: من إعداد الباحث باستخدام لغة البرمجة بايثون و Google Colab

في بنك المال الأردني وصلت نسبة الخطأ إلى 2.8% تقريباً، أي بدقة تنبؤ تصل إلى 93%.


الشكل رقم (18): التنبؤ بسيولة بنك القاهرة عمان



المصدر: من إعداد الباحث باستخدام لغة البرمجة بايثون و Google Colab

في حين أن في بنك القاهرة-عمان وصلت نسبة الخطأ إلى 1.6% وسطياً، أي بدقة تتبؤ تصل إلى 98.4%.


الشكل رقم (19): التنبؤ بسيولة الأسهم في بنك الأردن



المصدر: من إعداد الباحث باستخدام لغة البرمجة بايثون و Google Colab


نجد في بنك الأردن أن نسبة الخطأ تتجاوز إلى 3% أي أن دقة التنبؤ تصل إلى 97%.

الشكل رقم (20): التنبؤ بسيولة البنك الأهلي الأردني



المصدر: من إعداد الباحث باستخدام لغة البرمجة بايثون و Google Colab

في حين أن نسبة الخطأ في البنك الأهلي الأردني تتجاوز 1% أي بدقة تتبؤ نصل إلى 99%.
الشكل رقم (21): التنبؤ بسيولة البنك العربي الأردني



المصدر: من إعداد الباحث باستخدام لغة البرمجة بايثون و Google Colab وكذلك الأمر بالنسبة للبنك العربي، حيث أن نسبة الخطأ هي 1.3% أي بدقة نموذج 98.7%. نلاحظ من النتائج السابقة أن الشبكة العصبية المدربة أعطت نتائج دقة تتبؤ بين 93% و 99% وبالتالي يمكننا استخدام هذا النموذج في التنبؤ بسيولة الأسهم للبنوك المدرجة في سوق عمان للأوراق المالية.

الجدول رقم (5): تلخيص نتائج الدراسة على البنوك الأردنية


اسم البنك	نسبة الخطأ
البنك الإسلامي الأردني	1.03%
البنك الأردني الكويتي	3.44%
البنك التجاري الأردني	5.85%
بنك الإسكان للتجارة والتمويل	2.10%
بنك الاتحاد	1.87%
بنك المؤسسة المصرفية الأردنية	2.11%
البنك الاستثماري	7.04%

%2.83	بنك المال الأردني
%1.66	بنك القاهرة عمان
%3.21	بنك الأردن
%1.29	البنك الأهلي الأردني
%1.30	البنك العربي-الأردن

المصدر: من إعداد الباحث

ولقد قمنا بتطبيق هذا النموذج على سوق دمشق للأوراق المالية لمعرفة مدى قدرته على التنبؤ بسيولة البنوك المدرجة، وكانت نتائج التنبؤ كالتالي:

الشكل رقم (22): التنبؤ بسيولة البنك العربي_سورية



المصدر: من إعداد الباحث باستخدام لغة البرمجة بايثون و Google Colab

يظهر البنك العربي-سورية نسبة خطأ 17.4% أي دقة تنبؤ 95.83%.


الشكل رقم (23): التنبؤ بسيولة بنك الائتمان الأهلي



المصدر: من إعداد الباحث باستخدام لغة البرمجة بايثون و Google Colab

بينما أظهر بنك الائتمان الأهلي نسبة خطأ 7.07% أي دقة التنبؤ 92.93%.

الشكل رقم (24): التنبؤ بسيولة بنك بيمو السعودي الفرنسي




المصدر: من إعداد الباحث باستخدام لغة البرمجة بايثون و Google Colab

ونلاحظ أن دقة التنبؤ في بنك بيمو السعودي الفرنسي 91% بنسبة خطأ 8.48%

الشكل رقم (25): التنبؤ بسيولة بنك سورية والمهجر

MAPE: 6.322222948074341%

the bank name: بنك سورية والمهجر




المصدر: من إعداد الباحث باستخدام لغة البرمجة بايثون و Google Colab

وفي بنك سورية والمهجر نسبة الخطأ 6.32% أي أن دقة التنبؤ وصلت إلى 93.68%.

الشكل رقم (26): التنبؤ بسيولة المصرف الدولي للتجارة والتمويل

MAPE: 5.037935823202133%


the bank name: المصرف الدولي للتجارة والتمويل



المصدر: من إعداد الباحث باستخدام لغة البرمجة بايثون و Google Colab

وفي المصرف الدولي للتجارة والتمويل كانت دقة التنبؤ 94.97% أي بنسبة خطأ 5.03%.

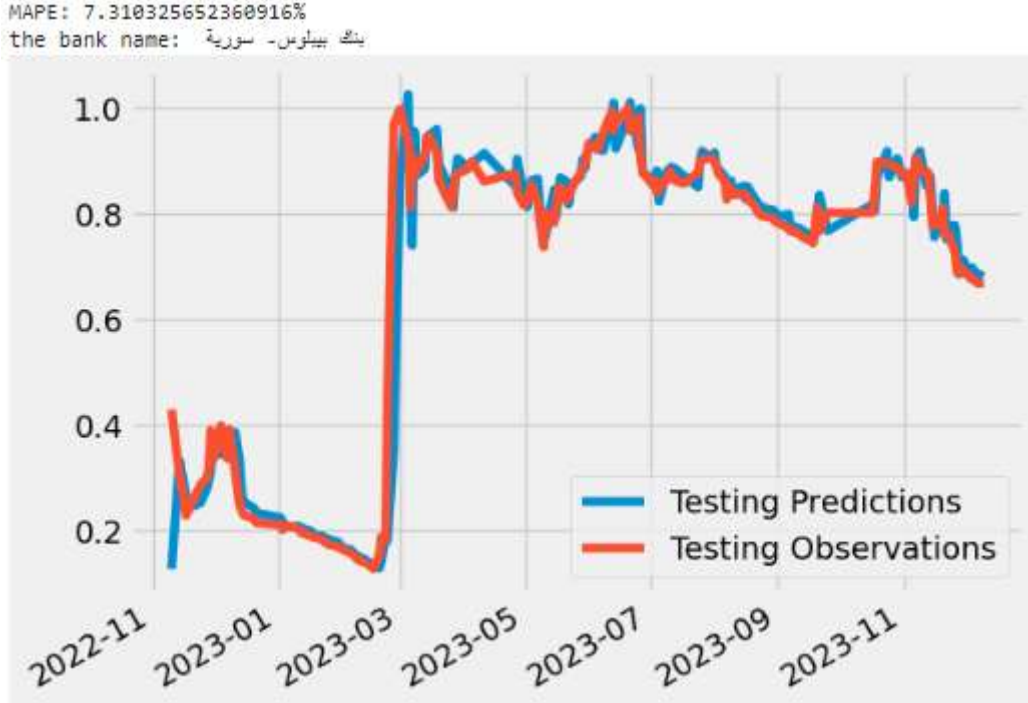
الشكل رقم (27): التنبؤ بسيولة بنك سورية الدولي الإسلامي



المصدر: من إعداد الباحث باستخدام لغة البرمجة بايثون و Google Colab

ومن الملاحظ أن في بنك سورية الدولي الإسلامي كانت دقة التنبؤ 90.31% بنسبة خطأ 9.69%


الشكل رقم (28): التنبؤ بسيولة بنك بيبيلوس سورية



المصدر: من إعداد الباحث باستخدام لغة البرمجة بايثون و Google Colab

في حين أن نسبة الخطأ في بنك بيبيلوس 7.31% أي بدقة تنبؤ تصل إلى 92.69%.


الشكل رقم (29): التنبؤ بسيولة بنك قطر الوطني_سورية



المصدر: من إعداد الباحث باستخدام لغة البرمجة بايثون و Google Colab

وكانت دقة التنبؤ في بنك قطر-سورية 93.54% أي بنسبة خطأ 6.46%

الشكل رقم (30): التنبؤ بسيولة بنك البركة_سورية




المصدر: من إعداد الباحث باستخدام لغة البرمجة بايثون و Google Colab

ونلاحظ أن نسبة الخطأ في بنك البركة-سورية 6.73% أي ان دقة التنبؤ 93.27%.

الشكل رقم (31): التنبؤ بسيولة بنك الشام

MAPE: 11.396897584199905%
the bank name: بنك الشام

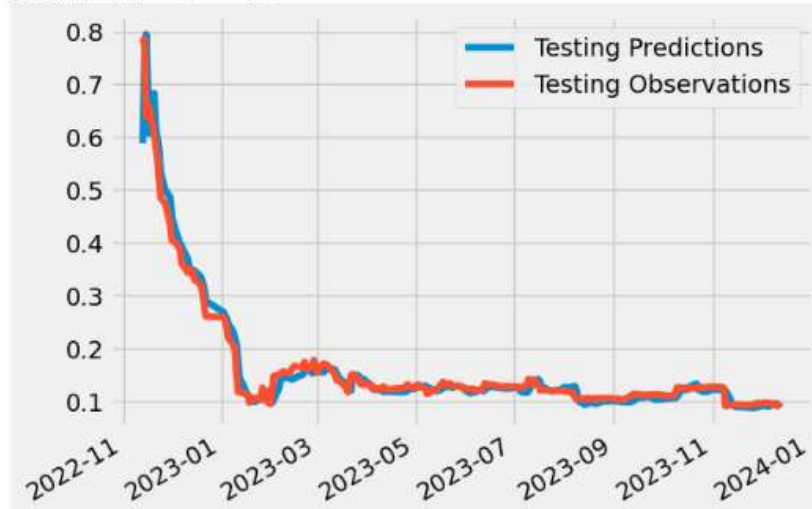


المصدر: من إعداد الباحث باستخدام لغة البرمجة بايثون و Google Colab

وإن نسبة الخطأ في بنك الشام هي 11.39% أي بدقة تنبؤ تصل إلى 88.61%.

الشكل رقم (32): التنبؤ بسيولة فرنسا بنك سورية

MAPE: 6.789599359035492%
the bank name: فرنسبنك - سورية




المصدر: من إعداد الباحث باستخدام لغة البرمجة بايثون و Google Colab

ويظهر فرنسا بنك سورية نسبة خطأ 6.78% أي بدقة تنبؤ تصل إلى 93.22%.

الشكل رقم(33): التنبؤ بسيولة بنك الشرق

MAPE: 16.199347376823425%
the bank name: بنك الشرق




المصدر: من إعداد الباحث باستخدام لغة البرمجة بايثون و Google Colab

تظهر نتيجة التنبؤ في بنك الشرق خطأ في التنبؤ وقدره 16.19% أي بقيمة تنبؤية 83.81%

الشكل رقم (34): التنبؤ بسيولة بنك سورية والخليج

MAPE: 46.84872136878967%
the bank name: بنك سورية و الخليج



المصدر: من إعداد الباحث باستخدام لغة البرمجة بايثون و Google Colab

بينما ظهرت نسبة الخطأ في بنك سورية والخليج ب مقدار 46.84% أي بقيمة تتبؤيه 53.16%

نلاحظ أن دقة التنبؤ في هذه البنوك تراوحت بين 84% و 95% أي بنسبة خطأ بين 16% و 5%. وهي دقة تتبؤ جيدة كوننا نستخدم نموذج تم تدريبه على سوق مالي آخر. في حين كانت نسبة الخطأ في بنك سورية والخليج مرتفعة، وبالرجوع إلى البيانات تبين التباين الكبير في بيانات هذا البنك من حيث قيمة التداول وبالتالي في حساب أمهيود، كما هو مبين في الشكل رقم (35).

الشكل رقم (35): حجم وقيمة التداول لبنك سورية والخليج

اسم الشركة	no_of_trades_y	حجم تداول	قيمة لتداول
بنك سورية و الخليج	4	2734800.0	1150
بنك سورية و الخليج	9	7294278.0	2973
بنك سورية و الخليج	4	2060600.0	800
بنك سورية و الخليج	8	7341600.0	2850
بنك سورية و الخليج	1	258000.0	100
...
بنك سورية و الخليج	0	0.0	0
بنك سورية و الخليج	3	1020438.0	244
بنك سورية و الخليج	2	660013800.0	150003
بنك سورية و الخليج	1	577500.0	125
بنك سورية و الخليج	9	2347973.0	529

المصدر: سوق دمشق للأوراق المالية

نلاحظ في بنك سورية والخليج فإن حجم التداول يتراوح بين 0 و 150,000

الجدول رقم (6): نتائج التنبؤ للبنوك في سوق دمشق للأوراق المالية

اسم البنك	نسبة الخطأ
البنك العربي-سورية	4.17%
بنك الائتمان الأهلي	7.07%
بنك بيمو السعودي الفرنسي	8.48%
بنك سورية والمهجر	6.32%
المصرف الدولي للتجارة والتمويل	5.03%
بنك سورية الدولي الإسلامي	9.69%
بنك بيبيلوس سورية	7.31%
بنك قطر الوطني-سورية	6.46%

%13.63	بنك الأردن-سورية
%46.84	بنك سورية والخليج
%16.19	بنك الشرق
%6.78	فرنسا بنك سورية
%11.39	بنك الشام
%6.73	بنك البركة

المصدر: من إعداد الباحث

النتائج والتوصيات:

أولاً: النتائج

-إن أساليب التعلم الآلي قادرة على التنبؤ بسيولة الأسهم للبنوك المدرجة في سوق عمان للأوراق المالية.

-إن الشبكات العصبية أعطت دقة تنبؤ في سوق عمان للأوراق المالية تتراوح بين 93% و99% وهي نسبة جيدة.

-إن النموذج الذي تم الوصول إليه قادر على التنبؤ في سوق مالي آخر مختلف من حيث السيولة والكفاءة.

-لقد كانت دقة التنبؤ في سوق دمشق للأوراق المالية تتراوح بين 84% و95% باستثناء بنك سورية والخليج وهي نسبة جيدة بالنسبة لنموذج تم بناءه في سوق آخر.

ثانياً: التوصيات

-اعتماد أساليب التعلم الآلي عند القيام بالتنبؤ بالسيولة في الأسواق المالية، حيث أنها نماذج قادرة على تحقيق دقة تنبؤيه عالية.

-تطوير نماذج قادرة على التنبؤ بعوائد الأسهم للأسواق المالية مع إمكانية تنبؤ تلك النماذج بأكثر من سوق مالي واحد.

- 1–Hiransha Ma, Gopalakrishnan, Vijay Krishna Menonab, Soman , “NSE Stock Market Prediction Using Deep–Learning Models”, (2018,p2).
- 2– Amihud et al “Liquidity And Asset Prices” (2006, p18).
- 3– Brennan et al. “Sell–order liquidity and the cross–section of expected stock returns” (2012, p7).
- 4– Ilmanen, “Expected Returns: An Investor's Guide to Harvesting Market Rewards”, (2011, p360).
- 5–Ivanchuk, “Evaluating the Liquidity of Stocks using Transaction Data”, (2004, p3).
- 6–Frank&Garcia, “Market Depth in Lean Hog and Live Cattle Futures Markets”, (2008, p20).
- 7–Kuo et.al, “Price Volatility Trading Activity and Market Depth: Evidence from Taiwan and Singapore”, (2005, p13).
- 8– Morawski, " Investment Decisions on Illiquid Assets: A Search Theoretical Approach to Real Estate Liquidity", (2008, p177).
- 9– Wyss, “Measuring and Predicting Liquidity in the Stock Market”, (2004, p7).
- 10– Jun Muranaga and Makoto Ohsawa, “Measurement of liquidity risk in the context of market risk calculation”, (1997, p195).
- 11– Andrew Wolf, “machine learning simplified”, (2022, p6).
- 12– Saikat Dutt, Subramanian Chandramouli, Amit Kumar Das, “machine learning”, (2014, p43).

- 13– Hurwitz, Judith, Kirsch, Daniel, “Machine Learning for dummies”, (2018, P3).
- 14– Hurwitz, Judith, Ibid, “Counteracting Concept Drift in Natural Language Classifiers” (2018, P15).
- 15– Ian Goodfellow, Yoshua Bengio, and Aaron Courville, “Deep Learning” (Chapter 6, p164).
- 16– Hassan Ismail Fawaz, Germain Forestier, Jonathan Weber, Lhassane Idoumghar, Pierre–Alain Muller, “Deep learning for time series classification”, (2019 , p4).
- 17– Sepp Hochreiter, Jurgen Schmidhuber, “LONG SHORT–TERM MEMORY, (1997, p8).
- 18– ibid, “Tutorials Points PVT LTD”, (2019, P10)