

## التنبؤ في سوق الأسهم باستخدام نماذج الذكاء الاصطناعي

### Forecasting in Stock Exchanges using AI Models

(دراسة تطبيقية في سوق دمشق للأوراق المالية باستخدام الشبكات العصبية الصناعية ANN)

إعداد الطالب:

عبد اللطيف الصواف

بإشراف:

د. منال الموصلي

2023

## المخلص:

هدفت هذه الدراسة إلى التنبؤ بأسعار الأسهم واتجاهات حركة الأسعار باستخدام نماذج الذكاء الاصطناعي. ولتحقيق هذا الهدف تم توظيف مجموعتين من المتغيرات، الأولى هي قيمة الإغلاق وقيمة الافتتاح ومؤشري EMA القصير والطويل وذلك للتنبؤ بسعر السهم في اليوم التالي؛ والثانية هي مؤشر MACD للتنبؤ باتجاه حركة سعر السهم في اليوم التالي. وتم تطبيق الدراسة على مؤشر DWX كممثلٍ عن كامل مجتمع الدراسة (سوق دمشق للأوراق المالية)، بالاعتماد على بيانات الفترة الممتدة من 2019-2022. وخلصت الدراسة إلى النتائج التالية:

❖ حقق التنبؤ باستخدام نموذج LSTM نتائج تنبؤ قريبة جداً من الواقع حيث كانت المتوسطات الحسابية للقيم التي تنبأ بها النموذج (قيم إغلاق مؤشر DWX وقيم مؤشر MACD لفترة الاختبار) قريبة جداً من المتوسطات الحسابية للقيم التي تحققت بالواقع.

❖ لا يوجد فارق جوهري بين أسعار الأسهم التي يتنبأ بها نموذج الذكاء الاصطناعي للمستقبل والأسعار التي ستتحقق بالفعل.

❖ لا يوجد فارق جوهري بين اتجاه حركة أسعار الأسهم الذي تنبأ به نموذج الذكاء الاصطناعي للمستقبل والاتجاه الذي ستسلكه بالفعل.

وأخيراً، نصح الباحث المتداولون في الأسواق المالية باستخدام نماذج الذكاء الاصطناعي كأداة مساعدة لهم في التنبؤ في هذه الأسواق، لكن لا ينصح بالاعتماد عليها بشكلٍ كامل فلا زالت النتائج غير دقيقة بما فيه الكفاية.

## **Abstract:**

This study aims to predict stock prices and price trends using artificial intelligence models. To achieve this goal, two sets of variables were employed, the first is Close Value, Open Value, Short EMA and Long EMA, in order to predict the price of the stock on the next day, and the second is MACD indicator to predict the direction of the stock price trend in the next day. The study was applied to the DWX index as a representative of the entire study population (Damascus Stock Exchange) from 2019–2022. And the results were the following:

- ❖ Predicting using LSTM model achieved results that are very close to reality, as the arithmetic averages of the values predicted by the model (Close Values of DWX indicator and MACD indicator values for the testing period) were very close to the arithmetic averages of the observed values.
- ❖ There is no significant difference between stock prices predicted by the AI model and the prices that will actually be observed.
- ❖ There is no significant difference between the trend of stock price predicted by the AI model of the future and the trend it will actually take.

Finally, the researcher advised traders in the financial markets to use artificial intelligence models as a tool to assist them in making predictions in these markets, but it is not recommended to rely on them completely, as the results are still not accurate enough.

## فهارس المحتويات

| فهرس العناوين |       |                                                       |               |
|---------------|-------|-------------------------------------------------------|---------------|
| الصفحة        | الرمز | المبحث                                                | الفصل         |
| 2             | 1-1   | المقدمة                                               | الإطار العام  |
| 3             | 2-1   | الدراسات السابقة                                      |               |
| 6             | 3-1   | مشكلة الدراسة                                         |               |
| 6             | 4-1   | فرضيات الدراسة                                        |               |
| 7             | 5-1   | أهمية وأهداف الدراسة                                  |               |
| 7             | 1-5-1 | أهمية الدراسة                                         |               |
| 7             | 2-5-1 | أهداف الدراسة                                         |               |
| 7             | 6-1   | متغيرات الدراسة                                       |               |
| 8             | 7-1   | مجتمع وعينة وفترة الدراسة                             |               |
| 8             | 1-7-1 | مجتمع وعينة الدراسة                                   |               |
| 8             | 2-7-1 | فترة الدراسة                                          |               |
| 9             | 7-1   | منهج الدراسة                                          |               |
| 9             | 8-1   | مصادر جمع البيانات                                    |               |
| 11            | 1-2   | المبحث الأول: التنبؤ في سوق الأسهم                    | الإطار النظري |
| 11            | 1-1-2 | تمهيد المبحث الأول                                    |               |
| 11            | 2-1-2 | التحليل الفني                                         |               |
| 19            | 2-2   | المبحث الثاني: التنبؤ باستخدام نماذج الذكاء الاصطناعي |               |
| 19            | 1-2-2 | تمهيد المبحث الثاني                                   |               |

|           |            |                                                    |                        |
|-----------|------------|----------------------------------------------------|------------------------|
| 19        | 2-2-2      | نماذج الذكاء الاصطناعي وتعلم الآلة والتعلم العميق  |                        |
| 21        | 3-2-2      | الشبكات العصبية الاصطناعية                         |                        |
| <b>24</b> | <b>1-3</b> | <b>المبحث الأول: دراسة الحالة ومتغيرات الدراسة</b> | <b>الإطار التطبيقي</b> |
| 24        | 1-1-3      | دراسة الحالة                                       |                        |
| 26        | 2-1-3      | متغيرات الدراسة                                    |                        |
| 30        | 3-1-3      | فترة الدراسة                                       |                        |
| <b>33</b> | <b>2-3</b> | <b>المبحث الثاني: أسلوب الدراسة</b>                |                        |
| 33        | 1-2-3      | تحضير البيانات                                     |                        |
| 37        | 2-2-3      | إعداد النموذج                                      |                        |
| <b>41</b> | <b>3-3</b> | <b>المبحث الثالث: التنبؤ واختبار الفرضيات</b>      |                        |
| 42        | 1-4-3      | التجربة الأولى واختبار الفرضية الأولى              |                        |
| 44        | 1-4-3      | التجربة الثانية واختبار الفرضية الثانية            |                        |
| <b>46</b> | <b>4-3</b> | <b>المبحث الرابع: النتائج والتوصيات</b>            |                        |
| <b>47</b> | –          | <b>المصادر والمراجع</b>                            |                        |
| <b>51</b> | –          | <b>ملحق الدراسة</b>                                |                        |

| فهرس الجداول |                                                                                      |        |
|--------------|--------------------------------------------------------------------------------------|--------|
| رقم الجدول   | عنوان الجدول                                                                         | الصفحة |
| 1            | طرق قياس ودلالات متغيرات الدراسة                                                     | 28     |
| 2            | التوصيف الإحصائي لمتغيرات الدراسة                                                    | 34     |
| 3            | نتائج تقييم النموذج لاختيار الضبط الصحيح للمعلّات الفائقة                            | 39     |
| 4            | مقارنة متوسط وانحراف النتائج المتنبأ بها مع النتائج الواقعية لقيمة الإغلاق           | 43     |
| 5            | اختبار t لعينتين مستقلتين للنتائج المتنبأ بها مع النتائج الواقعية لقيمة الإغلاق      | 43     |
| 6            | مقارنة متوسط وانحراف النتائج المتنبأ بها مع النتائج الواقعية لقيمة مؤشر MACD         | 45     |
| 7            | اختبار t لعينتين مستقلتين للنتائج المتنبأ بها مع النتائج الواقعية لقيمة مؤشر<br>MACD | 45     |
| 8            | عينة مؤشر DWX                                                                        | 51     |

| فهرس الأشكال |                                                         |        |
|--------------|---------------------------------------------------------|--------|
| رقم الجدول   | عنوان الشكل                                             | الصفحة |
| 1            | التيار الرئيسي والثانوي والدوني لمؤشر DWX خلال عام 2023 | 13     |
| 2            | مثال على رسم الشمعة البياني لقيم مؤشرات التداول         | 15     |
| 3            | إشارات البيع والشراء التي يولدها مؤشر MACD              | 17     |
| 4            | إشارات البيع والشراء التي يولدها مؤشر RSI               | 18     |
| 5            | أساليب التعلم في نماذج تعلم الآلة                       | 20     |
| 6            | مجالات علم البيانات                                     | 20     |
| 7            | طبقات الشبكات العصبية الاصطناعية                        | 21     |
| 8            | حركة المؤشر خلال فترة الدراسة                           | 25     |
| 9            | متغيرات الدراسة                                         | 28     |
| 10           | هيكل فترة الدراسة                                       | 32     |
| 11           | مراحل عملية البحث التطبيقي                              | 33     |
| 12           | التوزيع الطبيعي لبيانات المتغير "قيمة الافتتاح"         | 35     |
| 13           | التوزيع الطبيعي لبيانات المتغير "قيمة الإغلاق"          | 35     |
| 14           | التوزيع الطبيعي لبيانات المتغير "مؤشر EMA الطويل"       | 35     |
| 15           | التوزيع الطبيعي لبيانات المتغير "مؤشر EMA القصير"       | 35     |
| 16           | التوزيع الطبيعي لبيانات المتغير "مؤشر MACD"             | 36     |
| 17           | شكل حزمة البيانات بعد معايرتها                          | 37     |
| 18           | بنية النموذج والطبقات المكونة له                        | 38     |

|    |                                                                                |    |
|----|--------------------------------------------------------------------------------|----|
| 41 | تجارب التنبؤ باستخدام النموذج                                                  | 19 |
| 42 | مقارنة نتائج التنبؤ مع النتائج الواقعية لقيم إغلاق مؤشر DWX خلال فترة الاختبار | 20 |
| 44 | مقارنة نتائج التنبؤ مع النتائج الواقعية لقيم مؤشر MACD خلال فترة الاختبار      | 21 |
| 52 | شكل جدول حزمة بيانات المدخلات بعد رفعها إلى البرنامج                           | 22 |
| 53 | شكل حزمة البيانات بعد معايرتها                                                 | 23 |
| 54 | تعريف متغيرات الدراسة                                                          | 24 |
| 55 | تقسيم أيام الفترة إلى أيام تدريب وأيام اختبار                                  | 25 |
| 56 | الأسطر البرمجية المستخدمة لبناء النموذج                                        | 26 |



الفصل التمهيدي:

# الإطار العام للبحث

## 1-1 المقدمة:

تعتبر عملية اتخاذ القرار الاستثماري في أصل ما معقدة لما تحتاجه من معالجةٍ طويلة ودقيقة لكميات كبيرة من البيانات التي تؤثر في قيمة الأصل المرغوب بالاستثمار فيه، خاصة عمليات الاستثمار في أسواق الأسهم، التي تشهد تقلباتٍ كثيرة خلال فتراتٍ زمنية قصيرة، لهذا يستعين المستثمرون بأدواتٍ تساعد في إنجاز هذه المعالجة بأفضل نتائج ممكنة. ومن أبرز هذه الأدوات، التحليل الفني Technical Analysis الذي يعتمد في عمله على دراسة السوق نفسه وعمليات التداول على السهم وأنماطها وقيم الأسعار التي حققها في الماضي للتنبؤ بالاتجاه الذي سوف يذهب إليه سعر السهم في المستقبل.

لكن بناء استراتيجيةٍ مثلى باستخدام التحليل الفني للتنبؤ بالاتجاهات التي ستسلكها أسعار الأسهم والقيم التي سوف تحققها، أو حتى غيره من التحليلات الأخرى، يحتاج معرفةً عميقةً في مؤشرات هذا التحليل لاستنباط التنبؤات من قيم تلك المؤشرات، عدا عن الوقت الطويل الذي تتطلبه هذه المعرفة لاكتسابها وتوظيفها؛ وهنا أتى دور التكنولوجيا، لتقدم حلاً لهذه المشكلة من خلال توظيف الذكاء الاصطناعي ونماذجها لتقوم هي بعمل التحليل الفني للسهم أو المؤشر أو السوق المراد الاستثمار فيه والتنبؤ -بالاعتماد على نتائج التحليل- للمستقبل دون تدخل بشري من خلال تطوير برمجيات تستخدم نماذج الذكاء الاصطناعي لإتمام عملية التنبؤ. وقد حققت هذه النماذج انتشاراً بين المستثمرين بسبب الفعالية التي حققتها وتفوق أدائها جوهرياً على الأداء البشري في عمليات التنبؤ في الأسواق المالية.

لهذا، قد تناولت العديد من الدراسات هذه النماذج لاختبار قدراتها ودقة نتائجها وتأثير ذلك على ربحية المستثمر، إضافة إلى محاولة تطوير برمجياتٍ أكثر قدرةً على إتمام المهمة بأفضل نتائج ممكنة. وتأتي هذه الدراسة كمحاولةٍ أخرى لاختبار قدرات الذكاء الاصطناعي في هذا المجال وتطبيقاً هو الأول من نوعه على سوق دمشق للأوراق المالية DSE لتتضم إلى الدراسات القليلة التي تناولت آفاق تطبيق هذه النماذج في التداول في الأسواق النامية ولتقدم في النهاية أداةً مساعدةً للمستثمرين في هذه السوق.

## 1-2 الدراسات السابقة:

### 1-2-1 الدراسات العربية:

(1) دراسة (الثلايا وآخرون، 2019) بعنوان:

"التنبؤ في سوق البحرين للأوراق المالية باستخدام التعلم العميق"

هدفت هذه الدراسة إلى التنبؤ بأسعار أسهم الشركات المدرجة في سوق البحرين للأوراق المالية باستخدام نموذج LSTM بالاعتماد على (أ) بيانات مؤشرات التداول (سعري الافتتاح والإغلاق، السعر الأعلى والسعر الأدنى، حجم التداول) و(ب) اثنان من مؤشرات التحليل الفني (المتوسط المتحرك البسيط SMA، المتوسط المتحرك الأسّي EMA) للفترة الممتدة من 2010-2018. ولتحقيق هدف الدراسة قام الباحثون بإعداد النموذج ثم تدريبه واختباره على بيانات مؤشر BAX (الذي يشمل جميع الأسهم المدرجة في السوق مجتمع الدراسة). وكانت نتيجة الدراسة هي إثبات قدرة النموذج على التنبؤ بأسعار الأسهم بأداءٍ عالٍ وغير فارق جوهرياً عن النتائج التي تحققت بالواقع.

(2) دراسة (الأبيض وآخرون، 2019) بعنوان:

"التنبؤ قصير المدى في سوق الأوراق المالية المغربية باستخدام الشبكات العصبية الاصطناعية"

"ANNs"

هدفت هذه الدراسة إلى تحديد النموذج الأفضل أداءً من نماذج الشبكات العصبية الاصطناعية Artificial Neural Networks في عمليات التنبؤ بأسعار الأسهم في المدى القصير جداً كما هدفت إلى تحديد أكثر أفق تنبؤ<sup>1</sup> يعطي نتائج دقيقة. ولتحقيق ذلك تم سحب عينة مكونة من 3 أسهم مدرجة في سوق المغرب للأسهم وتوظيف قيم مجموعة من المؤشرات الفنية (المتوسطان المتحركان البسيط والأسّي، الخط السيكلوجي Psychological Line، ومؤشر Stochastic) للفترة الممتدة من 2016-2017 لتدريب واختبار نموذجين (الأول نموذج MLP والثاني نموذج LSTM) للتنبؤ باتجاهات حركة أسعار أسهم العينة خلال المدد 10 دقائق و30 دقيقة و60 دقيقة التالية؛ ثم تمت

---

(1) طول المدة الزمنية التي يقع ضمنها التنبؤ في المستقبل.

مقارنة نتائجهما لتحديد النموذج الأفضل باستخدام دوال إحصائية. وتوصلت الدراسة إلى أنه عندما يكون أفق التنبؤ لمدة 10 دقائق تكون النتائج أكثر دقة بشكل جوهري من آفاق التنبؤ الأخرى، وأن كلا النموذجين كانا قادرين على التنبؤ بفعالية باتجاهات الأسعار إلا أن النموذج LSTM كان النموذج صاحب النتائج الأفضل والأكثر دقة وواقعية.

### 1-2-2 الدراسات الأجنبية:

(1) دراسة (Mehtab, et al., 2021) بعنوان:

#### “Stock Price Prediction Using Machine Learning and LSTM–Based Deep Learning Models”

هدفت هذه الدراسة إلى تحديد الفئة الأفضل من نماذج الذكاء الاصطناعي للتنبؤ بأسعار الأسهم. ولتحقيق ذلك تم تحديد 9 نماذج مختلفة من نماذج تعلم الآلة والتعلم العميق (نموذج الانحدار الخطي متعدد المتغيرات، نموذج MARS، نموذج شجرة الانحدار، نموذج Bagging، نموذج XGBoost، نموذج Random Forest، نموذج ANN، نموذج SVM، نموذج LSTM)، ثم توظيف (أ) مؤشرات التداول لمؤشر NIFTY 50 الخاص بسوق الأوراق المالية الهندية (سعري الإغلاق والافتتاح، السعريين الأدنى والأعلى خلال جلسة التداول، حجم التداول) بالإضافة إلى (ب) مدى حركة السعر (الفرق بين السعر الأدنى والسعر الأعلى خلال جلسة التداول الواحدة) للفترة الممتدة من 2014 حتى 2020 لتعمل كمدخلات تستخدم في عملية التنبؤ بسعر الافتتاح لليوم التالي. وتوصلت الدراسة إلى أن نماذج التعلم العميق كانت أكثر قدرة على التنبؤ بأسعار الأسهم.

(2) دراسة (Fazeli & Houghten, 2019) بعنوان:

#### “Deep Learning for the Prediction of Stock Market Trends”

هدفت هذه الدراسة إلى اختبار دقة الذكاء الاصطناعي في التنبؤ في أسواق الأوراق المالية. ولتحقيق هذا الهدف تم توظيف (أ) مؤشرات التداول و(ب) قيم مجموعة من المؤشرات الفنية (مؤشر الشدة النسبية RSI، مؤشر MACD، مؤشر Williams %R، مؤشر التقلب Volatility) لعينة مكونة من أسهم الشركات Apple و Google و Microsoft و Intel خلال الفترة الممتدة من 2014-2019،

واستخدام نموذج LSTM من خلال تدريبه على جزء من بيانات العينة ثم اختباره الجزء الآخر ومقارنة نتائج التنبؤ مع النتائج الحقيقية التي تحققت. وتوصلت الدراسة إلى أنه من غير الممكن التنبؤ بأسعار الأسهم باستخدام نماذج الذكاء الاصطناعي كقيم دقيقة إلا أنها قادرة على التنبؤ باتجاهات حركة الأسعار وبالتالي يمكن استخدامها لتوليد إشارات دخول/خروج من السوق أو بيع/شراء للسهم.

(3) دراسة (Shynkevich, et al., 2017) بعنوان:

### **"Forecasting Price Movements using Technical Indicators: Investigating the Impact of Varying Input Window Length"**

هدفت هذه الدراسة إلى اختبار تأثير طول الخطوات الزمنية وأفق التنبؤ على صحة نتائج التنبؤ بأسعار الأسهم باستخدام نماذج الذكاء الاصطناعي. ولتحقيق ذلك تم توظيف عدة نماذج (ANN، SVM)، (kNN) وذلك بهدف التأكد من ثبات النتائج حتى مع اختلاف نموذج الذكاء الاصطناعي المعتمد، ثم توظيف قيم بعض المؤشرات الفنية (المتوسطان المتحركان البسيط والأسّي، مؤشر ATR، مؤشر ADMI، مؤشر CCI، مؤشر ROC، مؤشر RSI، مؤشر Williams %R، مؤشر Stochastic) لمؤشر S&P500 للفترة الممتدة من 2002-2012. واكتشف في نهاية الدراسة وجود تأثير لطول الخطوات الزمنية وأفق التنبؤ على صحة نتائج التنبؤ، كما توصلت الدراسة إلى أن أفضل نتائج تنبؤ تتحقق عندما يكون طول نافذة المدخلات وأفق التنبؤ متساويان تقريباً.

### 1-3 مشكلة الدراسة:

إن جلّ ما يسعى المستثمرون في الأسواق المالية له، وبشكلٍ تجريدي، هو الإجابة عن سؤال واحد: "ماذا سيكون سعر الأصل في المستقبل؟"، فلما كانت الغاية من التداول هي تحقيق أرباحٍ بالدرجة الأولى، فإن الإجابة على هذا السؤال ستمكّن المتداول من معرفة ما إذا كان شراء الأصل سيجقق له ربحاً بارتفاع سعره أم خسارةً بانخفاضه؛ لذا يقوم هؤلاء المتداولون بمحاولة التنبؤ بسعر السهم من خلال قراءة مجموعة من مؤشرات التداول والمؤشرات الفنية، لكن رغم ذلك تبقى عملية استنباط توقع صحيح من قراءة هذه المؤشرات عمليةً صعبة بسبب كثرة المتغيرات التي تحكمها والاحتمالات الممكن حدوثها. إلا أنه، ومع تطور قدرات الحواسيب وتكنولوجيا الذكاء الاصطناعي، ظهر توجهٌ لدى البعض لاستخدام نماذج -تعتمد على الذكاء الاصطناعي- تقوم، عبر آليات تعلمٍ خاصة، بالتنبؤ بسعر السهم بناءً على قراءتها للمدخلات المستخدمة كبيانات مساعدة في التنبؤ، ليرسم المتداول بدوره قراره الاستثماري بالاعتماد على تنبؤات هذه النماذج. وللتأكد من مدى القدرة على التنبؤ في أسواق الأوراق المالية باستخدام هذه النماذج قام الباحث بإعداد هذه الدراسة طارحاً السؤالان التاليان:

(1) هل يمكن لنماذج الذكاء الاصطناعي التنبؤ بأسعار الأسهم؟

(2) هل يمكن لنماذج الذكاء الاصطناعي التنبؤ باتجاه حركة أسعار الأسهم؟

### 1-4 فرضيات الدراسة:

اعتمد في صياغة الفرضيات على أساس أنه إن كانت نماذج الذكاء الاصطناعي قادرةً على التنبؤ في أسواق الأوراق المالية فسوف لن يكون هناك فارقاً جوهرياً بين متوسط القيم التي تنبأت بها والقيم التي تحققت بالواقع. لذا، وفي ضوء محاولة الإجابة عن الأسئلة المطروحة، في مشكلة الدراسة قام الباحث بطرح الفرضيتين التاليتين ليتم اختبارهما في القسم التطبيقي من الدراسة:

(1) يوجد فارق جوهري بين أسعار الأسهم التي يتنبأ بها نموذج الذكاء الاصطناعي

للمستقبل والأسعار التي ستتحقق بالفعل.

(2) يوجد فارق جوهري بين اتجاه حركة أسعار الأسهم الذي تنبأ به نموذج الذكاء

الاصطناعي للمستقبل والاتجاه الذي ستسلكه بالفعل.

## 1-5 أهمية وأهداف الدراسة:

### 1-5-1 أهمية الدراسة:

تبرز أهمية الدراسة في جانبين:

الأهمية النظرية التي تتجلى من خلال إيضاح العديد من التعاريف والمفاهيم والمصطلحات المالية والاستثمارية والتكنولوجية، والتعريف بعمليات الاستثمار في الأسواق المالية والتحليلات المساعدة في عملية اتخاذ القرار الاستثماري كالتحليل الفني، إضافة إلى الإضاءة على قدرات الذكاء الاصطناعي ونماذجه وآلية عمله. والأهمية التطبيقية تتجلى من خلال مساعدة المتداول في السوق على اتخاذ القرار الاستثماري من خلال طرح نموذج يتنبأ باتجاهات أسعار الأسهم بفعالية بالاعتماد على الذكاء الاصطناعي.

### 1-5-2 أهداف الدراسة:

تتمثل أهداف الدراسة بـ:

- (1) التحقق من قدرة الذكاء الاصطناعي على التنبؤ بأسعار الأسهم.
- (2) التحقق من قدرة الذكاء الاصطناعي على التنبؤ باتجاه حركة أسعار الأسهم.

## 1-6 متغيرات الدراسة:

قام الباحث باختيار المتغيرات المناسبة في ضوء الأسئلة المكونة لمشكلتها، حيث للإجابة عن كل سؤال تمت الاستعانة بمزايا إدخال ومزايا هدف<sup>2</sup> معينة مناسبة للمشكلة وإجراء الاختبارات عليها وكانت هذه المزايا كالتالي:

---

(2) إن هذه الدراسة لا تتبع متغيراتها التصنيف التقليدي للمتغيرات (متغيرات تابعة وأخرى مستقلة) بل تنظر للمتغيرات كمزايا يستفيد منها النموذج في عملية التنبؤ وسوف يشرح في المبحث الأول من القسم التطبيقي معنى هذا التصنيف لمتغيرات الدراسة.

- المجموعة الأولى من المزايا: وضعت للإجابة عن السؤال الأول، وهي قسمين،

الأول هو مزايا الإدخال وهي المتغيرات التالية:

أ) قيمة الإغلاق

ب) قيمة الافتتاح

ج) مؤشر EMA القصير

د) مؤشر EMA الطويل

والثاني هو ميزة الهدف وهي:

قيمة الإغلاق (سعر السهم) في اليوم التالي

- المجموعة الثانية من المزايا: وضعت للإجابة عن السؤال الثاني، وهي أيضاً

قسمين، الأول هو ميزة الإدخال وهي المتغيرات التالية:

مؤشر  $MACD^3$

والثاني هو ميزة الهدف وهي:

قيمة مؤشر MACD في اليوم التالي

## 7-1 مجتمع وعينة وفترة الدراسة:

### 1-7-1 مجتمع وعينة الدراسة:

يتضمن مجتمع الدراسة بأسهم الشركات المدرجة في سوق دمشق للأوراق المالية، ولم يتم اختيار عينة من السوق بل اعتمد مؤشر السوق نفسه DWX المعبر عن كامل عن مجتمع الدراسة كبديل عن استخدام سعر سهم معين بذاته وذلك بهدف شمل عدد أكبر من الأسهم.

### 1-7-2 فترة الدراسة:

لتحقيق هدف الدراسة والإجابة على تساؤلاتها، حدد الباحث فترة الدراسة بين 2019-2022. وكان سبب اختيار هذه الأعوام هو شمل فترة قبل جائحة كوفيد-19 وفترة الجائحة وفترة التعافي من آثار

---

(3) تم اختيار مؤشر MACD كمقياس يعبر عن اتجاه حركة سعر السهم لقدرته على إعطاء نظرة عن الاتجاه الذي سلكه السهم خلال الفترة الماضية وانعكاس ذلك على الاتجاه الذي سيسلكه في المستقبل.



الجائحة وفترة ما بعد الجائحة، والغرض من هذا الشمل هو التحقق من مدى قدرة النموذج على تحقيق الغاية المرجوة منه وهي التنبؤ حتى في ظل اختلاف الظروف الخارجية المؤثرة من خلال تدريبه على بيانات فتراتٍ مختلفة من حيث ظروفها وتوجهات المتداولين فيها.

### **1-8 منهج الدراسة:**

اتبعت الدراسة المنهج الوصفي التحليلي، من خلال تحليل بيانات التداول التاريخية وقيم مؤشرات التداول والمؤشرات الفنية لمؤشر DWX ومن ثم بناء نموذج عمل لتحقيق هدف الدراسة.

### **1-9 مصادر جمع البيانات:**

بيانات التداول التاريخية المنشورة في موقع سوق دمشق للأوراق المالية [www.dse.gov.sy](http://www.dse.gov.sy).

الفصل الثاني:

# الإطار النظري

## 2-1 المبحث الأول: التنبؤ في سوق الأسهم:

### 2-1-1 تمهيد:

هناك سعرين من المهم جداً لكل مستثمر أن يعرفهما، وهما السعر الحالي للأصل الذي يريد أن يستثمر فيه أو أنه يملكه بالفعل والسعر المستقبلي له. وتأتي أهمية معرفتهما من أن الفرق بينهما هو ما سيحدد إن كان هذا الاستثمار رابحاً أم خاسراً. ولأن السعر الحالي معروف ومعلن، يكمن التحدي في إمكانية توقع السعر المستقبلي بشكل صحيح أو أقرب ما يمكن للصحة، ولمواجهة هذا التحدي يمارس المستثمرون عملية تنبؤ لسعر الأصل في المستقبل. ومن أبرز الأسواق التي يقوم روادها بممارسة هذه العملية هي الأسواق المالية؛ وتعرف عملية التنبؤ في الأسواق المالية بـ: "محاولة لتحديد قيمة سهم ما أو أداة مالية Financial Instrument متداولة في السوق في المستقبل" (Yates, 2022). ورغم تباين الآراء حول الأمر، إلا أنه يوجد بالفعل دلائل تدعم إمكانية التنبؤ في الأسواق المالية (Chong, et al., 2017).

أما بالنسبة لكيفية القيام بالتنبؤ، فهناك طرق متعددة للتنبؤ بأسعار الأسهم واتجاهاتها المستقبلية. حيث يمكن مثلاً معالجة المعلومات الواردة في الأخبار المنشورة حول السوق أو السهم أو الحالة الاقتصادية أو بعض المؤشرات الفنية وتحليلها للعثور على أنماط للتنبؤ بالأسعار المستقبلية وتوقع حول ما إذا كان السوق سيتجه نحو الارتفاع أو الانخفاض وربما تحديد القيم التي ستستقر عندها أسعار الأسهم أو مؤشر السوق (Fazeli & Houghten, 2019)، وهذا ما يسمى بالتحليل الفني.

### 2-1-2 التحليل الفني:

#### (أ) تعريف التحليل الفني:

يعرف التحليل الفني بأنه "أسلوب تداول يتم فيه تقييم الاستثمارات المتاحة وتحديد الفرص من خلال تحليل السلاسل الزمنية لقيم بعض المؤشرات الخاصة بالسهم أو الورقة المالية وتحديد الأنماط التي تتحرك ضمنها وبالتالي التمكن من التنبؤ بسعر السهم أو الاتجاه التالي لحركة السعر" (Hayes, 2022).

#### (ب) المنطق خلف التحليل الفني:

يعتمد التحليل الفني على فكرة أن أسعار الأسهم تتحرك ضمن أنماط معينة تكرر نفسها ويمكن ملاحظة وتحديد هذه الأنماط من قبل المستثمرون والاستفادة منها في توقع الحركة التالية للسعر (Stankovic, et al., 2015). وأن هذه الأنماط موجودة لأن أسعار الأسهم محكومة بشكل كبير بالعرض والطلب على السهم نفسه، حيث أن قوى العرض والطلب هي ما أدى لحدوث تغيرات في السعر وحجم التداول بالأساس (Hayes, 2022).

وكان من أبرز المساهمين في وضع الحجر الأساس لتطوير التحليل الفني بشكله الحديث، تشارلز داو، مع نظريته، نظرية داو<sup>4</sup> Dow Theory، في بدايات القرن الماضي. التي استندت على أربع مبادئ أساسية هي:

#### 1) السعر يلخص كل شيء:

يعتقد داو أن السعر الحالي يعكس جميع المعلومات حول السهم، أي أنه حدد عند هذه القيمة لأن قوى العرض والطلب تحركت بحسب المعلومات المتوفرة حوله لدى كل طرف من السوق وبالتالي يمكن القول إن قيمته تختزل جميع المعلومات المتاحة حول السهم فهي قد حددت بتراكم هذه المعلومات مع بعضها الذي دفع قوى العرض والطلب لتثبيت السعر عند هذه النقطة. ونظراً لذلك، فإن سعر السهم الحالي يمثل القيمة العادلة للسهم ويجب أن تشكل أساساً للتحليل، ومن هذا المنطلق، يستخدم التحليل الفني المعلومات التي يقدمها تحليل السلسلة الزمنية للسعر لتفسير ما يقوله السوق اليوم وفي الماضي بغرض تكوين رؤية للمستقبل (StockCharts.com, n.d.).

#### 2) تحركات الأسعار ليست عشوائية تماماً:

يرى داو أن السعر يتحرك بثلاث اتجاهات (تيارات) في آن معاً هي (ممدوح، 2023):

##### أ) تيار رئيسي Primary Trend:

يمثل هذا التيار الاتجاه طويل المدى الذي سلك مساره سعر السهم لمدة عام فأكثر، ويعكس التوجه العام لسعر السهم أو السوق عموماً خلال الفترة المحددة،

---

(4) لم يقم تشارلز داو بطرح نظريته كاملةً وبشكل مباشر، بل تم استنباطها من مجموعة كتاباته على مدى سنوات. وقد جمع هذه الكتابات ونقحها لتشكيل النظرية بشكلها النهائي زميله ويليم هاميلتون (خير بك، 2022).

فنقول -بحسب اتجاه الخط البياني للتيار الرئيسي، صاعد Uptrend أو هابط Downtrend- أن السوق في حالة ارتعاد Bearish أو في حالة اندفاع Bullish.

#### ب) تيار ثانوي Secondary Trend:

إذا أخذنا مثلاً عن سوق كان مؤشره يشهد اتجاهاً صاعداً لخط التيار الرئيسي لفترةٍ طويلة، مع مرور الوقت، سوف يبدأ المتداولون في السوق باكتتاب أرباحهم<sup>5</sup> الناتجة عن هذا الصعود المستمر، وهنا يحصل ما يسمى بـ "تصحيح السوق"، حيث ينخفض السعر (بنسبة 10% أو أكثر (Chen, 2022)) نتيجة ازدياد العرض في السوق وذلك لفترة مؤقتة ثم يعود السعر للارتفاع مرةً أخرى، اتجاه الانخفاض هذا ومن بعده الارتفاع هو التيار الثانوي متوسط المدى والذي يمتد عادة من بضعة أسابيع إلى عدة شهور.

#### ج) تيار دوني Minor Trend:

التيارات الدونية هي التقلبات في السعر أو قيمة مؤشر السوق بين يومٍ لآخر. وهي تحركاتٍ قصيرة المدى تنتج عن المضاربات الطبيعية في السوق أو التأثير بالأخبار المنشورة وهي غير مهمة أو مؤثرة لذا يتم تجاهلها في معظم الأوقات عند إجراء التحليل ويُركز على التيارين الرئيسي والثانوي.



(5) اكتتاب الأرباح هو قيام المستثمرين بتسليم الأوراق التي يحملونها (بيعها) وذلك لجني الأرباح التي حققتها نتيجة الزيادة في قيمتها بشكلٍ نقدي (ManagementStudyGuide.com, n.d.).

### (3) حجم التداول يؤكد اتجاه السعر:

بحسب قوانين العرض والطلب يجب أن تكون العلاقة بين حجم التداول وسعر السهم أو قيمة مؤشر السوق عكسية. حيث أن حدوث ارتفاع في السعر يعني أن الطلب أعلى من العرض وهذا يترجم في انخفاض حجم تداول السهم، بنفس الطريقة، انخفاض السعر يعني أن العرض أعلى من الطلب وهذا يعني ارتفاع حجم تداول السهم.

### (4) جميع مؤشرات السوق تؤكد بعضها:

حتى يتأسس اتجاه جديد لتيار السوق يجب أن تؤكد المؤشرات بعضها، فمثلاً، إذا اتجه التيار الرئيسي لمؤشر DWX نحو الأعلى يجب أن يتجه تيار مؤشر DLX الرئيسي أيضاً نحو الأعلى حتى نقول إن هناك اتجاهاً جديداً للتيار بدأ يتشكل.

### (ج) أدوات التحليل الفني:

#### ❖ مؤشرات التداول:

تقوم هذه المؤشرات بعرض بيانات السوق حول سعر السهم أو مؤشر السوق خلال فترة معينة (يوم واحد عادةً). وهي مكونة من المؤشرات التالية:

- سعر الإغلاق: السعر الذي أغلق عنده التداول على السهم في نهاية اليوم.
- سعر الافتتاح: السعر الذي افتتح عنده التداول على السهم في بداية اليوم.
- السعر الأعلى: أكبر سعر تم تداول السهم عليه خلال اليوم.
- السعر الأدنى: أصغر سعر تم تداول السهم عليه خلال اليوم.
- حجم التداول: كمية الأسهم التي تم تداولها خلال اليوم.

تُعرض هذه المؤشرات عادة في رسم الشمعة البياني Candlestick Chart. وهي مفيدة لأنها الأساس الذي يساعدنا في حساب قيم بعض المؤشرات الفنية، فمثلاً، سعري الافتتاح والإغلاق يساعدان في حساب الزخم حيث أن الفرق بينهما يمثل الزخم الذي تم تداول السهم فيه خلال اليوم، وبنفس الطريقة، يساعد قياس الفرق بين السعيرين الأعلى والأدنى على قياس التقلب في قيمة السهم خلال اليوم (Mitchell, 2021).

لذا، تعتبر هذه المؤشرات من الأدوات الهامة لدى المستثمر، خاصةً توفيرها لبيانات تاريخية تساعد في القيام بتحليل للسلاسل الزمنية للتنبؤ بالقيم المستقبلية الخاصة بالسهم أو مؤشر السوق.

الشكل رقم (2): مثال على رسم الشمعة البياني لقيم مؤشرات التداول



### ❖ المؤشرات الفنية:

المؤشرات الفنية هي "معادلات رياضية تحلل السعر وحجم التداول التاريخي للسهم لتحديد إشارات تداول Trading Signals تفيد المستثمر في معرفة الوقت الأنسب للدخول والخروج من السوق" (Lund, 2022).

وتصنف المؤشرات الفنية بحسب (Kirkpatrick II, 2022) إلى:

#### 1) مؤشرات التيار Trend Indicators:

يختص هذا النوع من المؤشرات برسم التوجه الحالي لتيار السعر، صعوداً Up أم هبوطاً Down. وتساعد هذه المؤشرات في تحديد التالي:

##### ▪ اتجاه التيار *Trend Direction*

يساعد المؤشر في تحديد اتجاه التيار من خلال قيمه، حيث إذا كانت قيمه تزداد يوماً تلو الآخر أي أن رسم البياني يميل نحو الأعلى فالتيار يتجه صعوداً، أما إذا كانت قيمه تتخفض يوماً تلو الآخر أي أن رسم البياني يميل نحو الأسفل فالتيار يتجه نحو الهبوط.

##### ▪ طول التيار *Trend Duration*

إن اختيار المتداول لعدد الأيام الداخلة في حساب المؤشر يساعد في تحديد طول التيار الذي يعرضه، فمؤشر المتوسط المتحرك لـ 200 يوم يعرض التيار طويل المدى لسعر السهم أما مؤشر المتوسط المتحرك لـ 50 يوماً يعرض التيار متوسط المدى لسعر السهم أما مؤشر المتوسط المتحرك لأقل من 50 يوماً فيعرض تياراً قصير المدى لسعر السهم.

يندرج ضمن هذه الفئة من المؤشرات:

- المتوسط المتحرك البسيط Simple Moving Average:

يقيس هذا المؤشر المتوسط الحسابي لسعر السهم خلال الفترة المحددة من قبل المتداول. وقد سمي بـ "المتحرك" لأنه في كل يومٍ جديدٍ في الفترة المحددة يضاف سعر جديد إلى الأسعار السابقة الداخلة في حسابه فتتحرك قيمته.

- المتوسط المتحرك الأسّي Exponential Moving Average:

كما مؤشر SMA، يعرض هذا المؤشر المتوسط الحسابي لسعر السهم خلال فترة محددة، لكن الاختلاف هو أن مؤشر EMA يقوم بإعطاء وزن أكبر في معادلته للأيام الأكثر حداثةً (الأيام القريبة من يوم حساب قيمته) بدلاً من إعطاء جميع الأيام أوزاناً متساوية -يساعد هذا الأمر المؤشر أن يكون أكثر قرباً في متابعة السعر من مؤشر SMA.

## (2) مؤشرات الزخم Momentum Indicators:

تقوم هذه المؤشرات بقياس شدة أو ضعف السعر من خلال قياسها لمعدل تقلبه. وتساعد هذه المؤشرات في تحديد زخم التيار Trend Momentum من خلال تحديدها لحالة التداول الحالية على السهم إن كانت بيع بشكلٍ مفرط Overbought أم شراء بشكلٍ مفرط Oversold.

يندرج ضمن هذه الفئة من المؤشرات:

- مؤشر MACD:



- يقيس مؤشر MACD الزخم من خلال قياس الفرق بين مؤشر EMA لـ 12 يوماً ومؤشر EMA لـ 26 يوماً. ويكون لمؤشر MACD قيمة موجبة عندما يكون مؤشر EMA قصير المدى أكبر من مؤشر EMA طويل المدى.

- يمكن التنبؤ باستخدام مؤشر MACD عند مقارنته مع مؤشر آخر هو خط الإشارة Signal Line (وهو متوسط المتحرك الأسّي لمؤشر MACD، ويكون عادةً متوسط آخر 9 أيام)، فعندما ينخفض مؤشر MACD عن خط الإشارة يمكن اعتبار ذلك إشارة بيع لأن السعر سوف ينخفض في المستقبل، وعندما يرتفع مؤشر MACD فوق خط الإشارة يمكن اعتبار ذلك إشارة شراء لأن السعر سوف يرتفع في المستقبل (Dolan, 2023).

الشكل رقم (3): إشارات البيع والشراء التي يولدها مؤشر MACD



#### • مؤشر الشدة النسبية Relative Strength Index:

- يقيس مؤشر RSI الزخم من خلال قياس السرعة التي يتغير بها السعر. لتحديد ما إذا كان السهم يشتري بشكل مفرط أو يباع بشكل مفرط. وتتأرجح قيمة المؤشر بين 0-100 فإذا كان أقل من 30 يعتبر السهم يباع بشكل مفرط وعندما يكون أعلى من 70 يعتبر السهم يشتري بشكل مفرط.

- يمكن التنبؤ باستخدام مؤشر RSI من خلال قيمته نفسها، حيث عندما يصبح المؤشر < 70 يمكن اعتبار ذلك إشارة بيع لأن السعر قد ينخفض قريباً لأن السهم قد شهد ارتفاع كبيراً في سعره مؤخراً، وعندما يصبح المؤشر > 30 يمكن اعتبار ذلك

إشارة شراء لأن السعر قد يرتفع قريباً لأن السهم قد شهد انخفاضاً كبيراً في سعره مؤخراً (Fidelity.com, n.d.).

الشكل رقم (4): إشارات البيع والشراء التي يولدها مؤشر RSI



### (3) مؤشرات التقلب: Volatility Indicators

تقيس هذه المؤشرات تقلب سعر السهم، وهي تساعد في قياس المخاطر. ومن أهم المؤشرات التي تدرج تحت هذه الفئة:

#### • مؤشر Bollinger Bands

يقيس هذا المؤشر التقلب ويساعد بالتنبؤ باستخدام ثلاث خطوط (الأول يمثل الذراع العليا للمؤشر وهي المتوسط المتحرك البسيط (9 أيام) لسعر السهم مجموعاً له الانحراف المعياري لمتوسط السعر خلال آخر 3 أيام وتمثل الحد الأعلى لمجال تقلب السعر، والثاني هو الذراع الدنيا للمؤشر وهي المتوسط المتحرك البسيط مطروحاً منه الانحراف المعياري لمتوسط السعر خلال آخر 3 أيام أيضاً، وتمثل الحد الأدنى لمجال تقلب السعر، والثالث هو خط مؤشر المتوسط المتحرك البسيط) حيث كلما اقترب SMA من الذراع العليا يمكن اعتبار ذلك إشارة إلى أن السعر سينخفض لأنه اقترب من الحد الأعلى لتقلبه، والعكس صحيح، فإذا اقترب SMA من الحد الأدنى يمكن اعتبار ذلك إشارة إلى أن السعر سيرتفع قريباً لأنه اقترب من حد تقلبه الأدنى.

### (4) مؤشرات الحجم: Volume Indicators

من أهم المؤشرات التي تدرج تحت هذه الفئة:

#### • مؤشر OBV

يقيس هذا المؤشر ضغط البيع والشراء على السعر من خلال إضافة حجم التداول في الأيام التي يرتفع فيها السعر وطرح حجم التداول في الأيام التي ينخفض فيها السعر.

## 2-2 المبحث الثاني: التنبؤ باستخدام نماذج الذكاء الاصطناعي:

### 2-2-1 تمهيد:

مع التطور التقني الكبير الذي حدث في مجال الحوسبة خلال العقود الأخيرة، باتت الحواسيب أكثر قدرة على معالجة المعلومات وإيجاد العلاقات بين المتغيرات بشكل كبير جداً، بل وباتت لديها قدرات محاكاة للعقل البشري تمكنها من معالجة المعلومات كما يعالجها الذكاء البشري. وبنفس الوقت، شهدت الأسواق المالية -مع تطور العلوم المالية وأساليب الاستثمار والعولمة التي جعلت الأسواق تتداخل فيما بعضها فباتت المنافسة مع كل العالم وليست محلية فقط- احتدام التنافس فيها بين المتداولين والشركات المدرجة لتحصيل أكبر مكاسب ممكنة؛ هذا الأمر دفع المتداولين في الأسواق المالية إلى محاولة توظيف التكنولوجيا لخدمة مصالحهم والاستفادة من القدرات المتطورة للحواسيب ونماذج الذكاء الاصطناعي في مساعدتهم على اتخاذ القرار الاستثمار من خلال التنبؤ بأسعار الأسهم واتجاهات الأسعار وغيرها من قيم المؤشرات المساعدة على اتخاذ قرار استثماري رابح في هذه الأسواق.


### 2-2-2 نماذج الذكاء الاصطناعي وتعلم الآلة والتعلم العميق:

نماذج الذكاء الاصطناعي هي أحد التطبيقات العملية لمجال علم البيانات Dats Science فهي "أدوات وخوارزميات تستخدم لتدريب الحواسيب على معالجة وتحليل البيانات"، وتعمل بعض هذه النماذج بتقنية تعلم الآلة Machine Learning حيث تقوم باستخدام الخوارزميات المبنية عليها بالتعلم من البيانات التي تغذى بها وتحاول إيجاد العلاقات بين متغيراتها لتتمكن من إيجاد معالم يمكن الاستفادة منها في توقع نتائج مستقبلية لوحدها دون تدخل بشري (TheDecisionLab.com, n.d.).

ومن المهم في نماذج تعلم الآلة التمييز بين التعلم الخاضع للإشراف Supervised Learning التعلم غير الخاضع للإشراف Unsupervised Learning؛ حيث أن التعلم الخاضع للإشراف هو الحالة التي تكون فيها البيانات التي غذي بها النموذج مصنفة يدوياً Labeled، أي أنها مقسمة إلى متغيرات


ومصنفة بطريقة تمكن الآلة من التمييز بين بيانات الإدخال والبيانات الهدف والتنبؤ بحسب ما تم توجيهها به بتصنيف البيانات. أما التعلم غير الخاضع للإشراف فهو الحالة التي يتم فيها تغذية النموذج ببيانات غير مصنفة وبالتالي لم يتم إخبار النموذج صراحة بما يجب فعله بهذه البيانات ويجب أن يتعلم لوحده أولاً كيفية التمييز بينها ثم إجراء التنبؤ بحسب تصنيفه للبيانات (Klingler, 2023).

الشكل رقم (5): أساليب التعلم في نماذج تعلم الآلة



وداخل نماذج تعلم الآلة هناك نوع خاص هو نماذج التعلم العميق، وهي النماذج الأكثر مناسبة للتنبؤ خصوصاً في الأسواق المالية بالاعتماد على التحليل الفني (Mehtab, et al., 2021)، حيث أن نماذج التعلم العميق يمكنها تعلم التعرف على الأنماط في البيانات تحديداً، في حين أن نماذج تعلم الآلة العادية أكثر عمومية ولا تحاول التعرف على الأنماط (Klingler, 2023).

الشكل رقم (6): مجالات علم البيانات



### 2-2-3 الشبكات العصبية الاصطناعية:

الشبكات العصبية الاصطناعية Artificial Neural Network، هي إحدى نماذج تعلم الآلة وتقع في قلب خوارزميات التعلم العميق. اسمها وبنيته مستوحاة من الدماغ البشري لأنها تحاكي الطريقة التي تتصل وتتبادل من خلالها الخلايا العصبية البيولوجية المعلومات مع بعضها البعض.


تتكون شبكات ANN من عقد Nodes (خلايا عصبية Neural Networks) مترابطة ومنظمة في طبقات Layers، وتتدفق المعلومات عبر هذه العقد ومن طبقة إلى طبقة، وتقوم الشبكة بتحليل البيانات للتدريب والتعلم منها والتمكن من التعرف على الأنماط ومن ثم التنبؤ (IBM.com, n.d.).

#### ❖ بنية الشبكات العصبية الاصطناعية:

بحسب (Singh, 2021) فإن شبكات ANN لبنيتها الخصائص التالية:

- تتكون بنية هذه الشبكات من ثلاث طبقات رئيسية هي طبقة إدخال وطبقات مخفية وطبقة إخراج.
- يمكن التفكير في الطبقات المخفية على أنها "طبقات تقطير"، حيث تقوم كل طبقة باستخراج بعض الأنماط من المدخلات التي غذي النموذج بها ثم ترسلها إلى الطبقة التالية لمزيد من التحليل. هذا الأمر يساعد على تسريع وتحسين كفاءة الشبكة من خلال التعرف -في كل مرحلة وبشكل تدريجي- فقط على أهم المعلومات من المدخلات والتخلص من المعلومات الزائدة عن الحاجة ولا تفيد النموذج في عملية التنبؤ.

الشكل رقم (7): طبقات الشبكات العصبية الاصطناعية



### ❖ مزايا الشبكات العصبية الاصطناعية:

بحسب (Singh, 2021) فإن لشبكات ANN المزايا التالية عن باقي نماذج تعلم الآلة تجعلها أكثر ملائمة للتنبؤ باستخدامها في الأسواق المالية:

(1) يمكن لهذه الشبكات أن تتعلم وتشكل نماذج للتفاعلات غير الخطية والمعقدة، وهو أمر بالغ الأهمية لأن العديد من العلاقات بين المدخلات والمخرجات في الحياة الواقعية غير خطية ومعقدة (مثال: العلاقات بين سعر السهم والمؤشرات الفنية أو الأساسية أو الاقتصادية).

(2) يمكن لهذه الشبكات، بعد التعلم من المدخلات التي غذيت بها والعلاقات فيما بينها، التعميم، حيث قد يستنتج النموذج علاقات غير معروفة ببيانات مجهولة مما يسمح له بالتعميم والتنبؤ ببيانات غير معروفة.

(3) لا تفرض شبكات ANN أي قيود على متغيرات الإدخال، على عكس العديد من نماذج التنبؤ الأخرى. علاوة على ذلك، أثبتت العديد من الدراسات أن الشبكات العصبية الاصطناعية يمكن أن تحاكي بشكل أفضل لبيانات ذات التقلبات العالية والتباين غير الثابت بسبب قدرتها على اكتشاف الارتباطات الكامنة في البيانات دون فرض أي ارتباطات محددة مسبقاً. وهذا مفيد بشكل خاص في التنبؤ بالسلاسل الزمنية المالية عند تقلب كبير في البيانات.

### ❖ نموذج LSTM:

نموذج LSTM هو أحد أنواع نماذج "الشبكات العصبية المتكررة Recurrent Neural Networks" التي تتبع مجموعة شبكات ANN ليكون النموذج الذي سوف تطبق الدراسة باستخدامه. ويقدم نموذج LSTM حلاً لمشكلة مهمة جداً تعاني منها شبكات ANN وهي مشكلة "التلاشي المتدرج Gradient Vanishing Problem" من خلال استخدام "خلايا الذاكرة" للتغلب على التلاشي المتدرج للمعلومات القديمة من ذاكرة النموذج (Mehtab, et al., 2021). لذا تستخدم معظم الدراسات الحديثة نموذج LSTM للتنبؤ في تحليلات السلاسل الزمنية في المجال المالي (Guo, 2022).

الفصل الثالث:

# الإطار التطبيقي

### 3-1 المبحث الأول: دراسة الحالة ومتغيرات الدراسة:

#### 3-1-1 دراسة الحالة:

تم اختيار مؤشر الأسهم المتقل بالقيمة السوقية DWX لتطبيق اختبارات هذه الدراسة عليه لأنه يدخل في حسابه جميع الأسهم المدرجة في السوق وبالتالي فإن التغير في قيمته يعبر عن التغير في قيمة الأسهم المدرجة في السوق عموماً. وفيما يلي نبذة عن مؤشر DWX تسرد تاريخه وتشرح طريقة حساب قيمته وتعرض الأسهم المدرجة فيه..

#### (أ) نبذة عن مؤشر DWX:

مؤشر DWX أو مؤشر سوق دمشق المتقل هو أحد مؤشرات سوق دمشق للأوراق المالية DSE، أطلق عام 2010، ويعتمد أسلوب التثقل بالقيمة السوقية للشركات الداخلة في احتساب معادلته، حيث تعطى كل شركة وزناً بقدر ما تشكل قيمتها السوقية من القيمة السوقية لعينة المؤشر الإجمالية، وتتكون عينة المؤشر من جميع الشركات المدرجة في السوق النظامي والموازي، وبالنسبة للشركات المدرجة حديثاً فلا تدخل بالمؤشر إلا بعد تحديد سعر أساس لها عبر الجلسة الاستكشافية (dse.gov.sy)، بالتالي، يمكن اعتباره مؤشراً لحالة السوق نفسها.

#### • طريقة حسابه:

تحتسب قيمة المؤشر باستخدام المعادلة التالية (dse.gov.sy):

$$DWX Value = \sum \left( \frac{AVP_s}{BP_s} \times W_i \right) \times F$$

حيث:

-  $DWX Value$ : قيمة المؤشر.

-  $AVP_s$ : متوسط سعر السهم.



-  $BP_s$ : سعر الأساس، وهو متوسط سعر السهم قبل إدخاله في المؤشر (أي متوسط سعره في الجلسة الافتتاحية له).

-  $W_i$ : وزن الشركة في المؤشر، ويساوي القيمة السوقية لشركة السهم مقسومة على القيمة السوقية الإجمالية للشركات المدرجة في السوق.

-  $F$ : المعامل، وتعديل قيمته عند حصول أي من إجراءات الشركات أو إدخال أو إخراج شركة إلى/من العينة.

#### • الشركات الداخلة في عينة المؤشر:


يعرض الجدول رقم (8) في ملحق الدراسة عينة الشركات الداخلة في حساب قيمة المؤشر بحسب تقرير السوق السنوي لعام 2022 (dse.gov.sy).

وتجدر الإشارة إلى أن عينة المؤشر في عام 2022 لم تتغير عن عامي 2021 و2020 بحسب تقارير السوق الخاصة بهم (dse.gov.sy) أي أن عينة المؤشر كانت ثابتة على امتداد فترة الدراسة.

#### ب) قيم المؤشر خلال فترة الدراسة:

يعرض الشكل التالي قيم المؤشر (قيم الإغلاق) خلال فترة الدراسة الممتدة من 2019-2022:

الشكل رقم (8): حركة المؤشر خلال فترة الدراسة



### 3-1-2 متغيرات الدراسة:

تسمى المتغيرات التي تتعامل نماذج الذكاء الاصطناعي مع قيمها "مزايا Features"، هذه المزايا تقسم إلى مزايا إدخال **Input Features** ومزايا هدف **Target Features**، حيث يقوم النموذج بقراءة مزايا الإدخال وتحليلها وقياس العلاقة بينها وبين بعضها وبين الميزة الهدف للتوصل إلى طريقة يتنبأ بها بقيم ميزة الهدف (Bhandari, et al., 2022).

يجب ملاحظة أن نوعي المزايا هما مدخلات للنموذج، وللفهم أكثر، يمكن النظر إليهما كطرفي معادلة، مزايا الإدخال هي الطرف  $X$  ومزايا الهدف هي الطرف  $Y$ ، وهناك علاقة بينهما تمكننا من التنبؤ بقيم  $Y$  بالاعتماد على قيم  $X$ . وبما أن هدف الدراسة هو التنبؤ بالاعتماد على أحد نماذج الذكاء الاصطناعي، بالتالي، ستقسم متغيرات الدراسة بنفس الطريقة.

وقد قام الباحث باختيار المتغيرات المناسبة لتطبيق الدراسة في ضوء الأسئلة المكونة لمشكلتها، حيث للإجابة عن كل سؤال تمت الاستعانة بمزايا إدخال ومزايا هدف معينة مناسبة للمشكلة وإجراء الاختبارات عليها وكانت هذه المزايا كالتالي:

- للإجابة عن السؤال الأول، "هل يمكن لنماذج الذكاء الاصطناعي التنبؤ بقيم الإغلاق؟"، قام الباحث بتوظيف مزايا الإدخال التالية:

|                       |                    |
|-----------------------|--------------------|
| أ) قيمة افتتاح المؤشر | ج) مؤشر EMA القصير |
| ب) قيمة إغلاق المؤشر  | د) مؤشر EMA الطويل |

أما ميزة الهدف فكانت:

قيمة الإغلاق في اليوم التالي

- للإجابة عن السؤال الثاني، "هل يمكن لنماذج الذكاء الاصطناعي التنبؤ باتجاهات قيم الإغلاق؟"، قام الباحث بتوظيف ميزة الإدخال التالية:


مؤشر MACD

أما ميزة الهدف فكانت:

قيمة مؤشر MACD في اليوم التالي

ويلخص الشكل التالي متغيرات الدراسة:

الشكل رقم (9): متغيرات الدراسة



ويوضح الجدول التالي طرق حساب ودلالة كل متغير من متغيرات الدراسة:

الجدول رقم (1): طرق قياس ودلالات متغيرات الدراسة

| المتغير                     | طريقة القياس                                                                 | الدلالة                                                                                                                                                                   | المصدر <sup>6</sup>     |
|-----------------------------|------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-------------------------|
| <u>مزايا الإدخال</u>        |                                                                              |                                                                                                                                                                           |                         |
| قيمة الافتتاح               | تعتمد قيمها بحسب البيانات المنشورة في موقع السوق                             | قيمة المؤشر عند افتتاح جلسة التداول                                                                                                                                       | (Mehtab, et al., 2021)  |
| قيمة الإغلاق                |                                                                              | قيمة المؤشر التي أغلقت عليها جلسة التداول                                                                                                                                 |                         |
| المتوسط المتحرك الأسّي *EMA | $EMA = Value_{Today} (Multiplayer **) + EMA_{Yesterday} [1 - (Multiplayer)]$ | متوسط قيمة المؤشر بين اليوم واليوم الماضي مع إعطاء وزن نسبي أعلى للقيمة اليوم لأنها أكثر أهمية نسبياً (من حيث تأثيرها في تحديد قيمة المؤشر التالية) من قيم الأيام السابقة | (الثلاثيا وآخرون، 2019) |

(6) يكتب في هذا العمود الدراسة السابقة التي استدل بها الباحث لاختيار كل متغير من متغيرات دراسته.

|                                                                                                                                                                                                                                                                                                                                                                                                                                                                       |                                                                                                                           |                                                   |                                     |
|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------|-------------------------------------|
| (Fazeli & Houghten, 2019)                                                                                                                                                                                                                                                                                                                                                                                                                                             | الفرق بين المتوسط المتحرك الأسّي الطويل المدى والقصير المدى، ويساعد في إعطاء إشارات البيع والشراء<br>Buy and Sell Signals | $MACD\ Line = EMA_{Long} - EMA_{Short}$           | تقارب/تباعد المتوسط المتحرك<br>MACD |
| <b>مزايا الهدف</b>                                                                                                                                                                                                                                                                                                                                                                                                                                                    |                                                                                                                           |                                                   |                                     |
| -                                                                                                                                                                                                                                                                                                                                                                                                                                                                     | قيمة إغلاق المؤشر في اليوم التالي                                                                                         | تعتمد قيمتها بحسب البيانات المنشورة في موقع السوق | قيمة الإغلاق في اليوم التالي        |
| -                                                                                                                                                                                                                                                                                                                                                                                                                                                                     | قيمة مؤشر MACD في اليوم التالي                                                                                            | تعتمد قيم مؤشر MACD المحسوبة في مزايا الإدخال     | قيمة مؤشر MACD في اليوم التالي      |
| <p><b>إيضاح:</b></p> <p>* استخدم الباحث في الدراسة مؤشرين EMA هما مؤشر EMA القصير (متوسط قيم الإغلاق خلال 12 يوماً الماضي) ومؤشر EMA الطويل (متوسط قيم الإغلاق خلال 26 يوماً الماضية).</p> <p>** المضاعف Multiplier هو ثابتٌ يستخدم لإعطاء وزنٍ لكل طرف من معادلة المتوسط المتحرك الأسّي، حيث <math>Multiplier = \frac{2}{1+Time\ Steps}</math>. والخطوات الزمنية Time Steps هي عدد الأيام التي سوف يعتمد النموذج على قيمها للتنبؤ باتجاه المؤشر في اليوم التالي.</p> |                                                                                                                           |                                                   |                                     |

#### ❖ العلاقة بين متغيرات الدراسة:

لا تعتبر العلاقة بين طرفي المتغيرات قائمةً على أساس متغيرٍ مستقلٍ وآخر تابعٍ له بل هي علاقة متبادلة بين الطرفين، يؤثران ببعضهما البعض (Mehtab, et al., 2021). ولإيضاح الفكرة نطرح المثال التالي: إن قيم مؤشرات التداول (قيمة الافتتاح وقيمة الإغلاق) والمؤشرات الفنية (قيمة مؤشر EMA ومؤشر MACD) اليوم سوف تساعدنا بالتنبؤ باتجاه المؤشر في اليوم التالي، وبنفس الطريقة، قيمة المؤشر اليوم سوف تؤثر في قيم مؤشرات التداول والمؤشرات الفنية غداً.

### 3-1-3 فترة الدراسة:

#### 1-3-1-3 معيار تحديد فترة الدراسة:

اعتمد الباحث في تحديده للفترة على هدفٍ هو تدريب النموذج على أكبر عدد وشكلٍ ممكن من الحالات على افتراض أن ذلك سيعزز قدرته على التنبؤ بنتائج أكثر دقة وصحة عند اختبارها، لذلك، وفي ضوء هذا الهدف، تم وضع معيارين لتحديد الفترة هما: (أ) أن تكون الفترة طويلة بما يكفي ليتدرب النموذج على عدد كافٍ من الحالات بشكلٍ يؤهله للتنبؤ؛ (ب) تنوع ظروف السوق خلال فترة الدراسة، حيث إن تحديد فترة تشمل ضمنها عدة فتراتٍ جزئية تتباين فيها ظروف السوق وعمليات التداول من حيث الاستقرار بين فتراتٍ مستقرة وفتراتٍ غير مستقرة سيدرب النموذج على مجموعة أوسع من الظروف التي يمكن للسوق أن يعيشها وبالتالي سيعزز قدرة النموذج على التنبؤ في ظل تباين ظروف الفترات التي يتنبأ لها.

#### 2-3-1-3 شكل فترة الدراسة:

##### (أ) حدود فترة الدراسة وطولها:

في ضوء المعيارين المُعتمَدين، تم تحديد فترة الدراسة لتمتد من تاريخ 1/كانون الثاني/2019 حتى 31/كانون الأول/2022، بطول 1461 يوماً منهم 918 يوماً فقط يشكلون أيام تداول<sup>7</sup>، أي أن صافي عدد الأيام (حجم الفترة) الذي سوف يدخل في عملية تدريب واختبار النموذج هو 918 يوماً.

##### (ب) هيكل فترة الدراسة:

تتضمن فترة الدراسة أربع فترات جزئية متفاوتة في درجة الاستقرار، هذه الفترات موزعة كالتالي:

##### • الفترة الأولى – حالة الاستقرار:

– تمثل هذه الفترة الجزئية حالة السوق قبل جائحة كوفيد-19، حيث كانت خلالها ظروف السوق مستقرة نسبياً ولا يوجد أزمات حقيقية خارجية تؤثر بشكلٍ كبير في حركة التداولات اليومية.

---

(7) أيام التداول: الأيام التي تعقد فيها جلسات تداول في السوق وبالتالي هي الأيام الوحيدة التي تدخل في الدراسة.

- امتدت هذه الفترة الجزئية من 1/كانون الثاني/2019 إلى 31/كانون الثاني/2019 وشملت 236 يوم تداول من 365 يوماً هو إجمالي عدد أيام الفترة. وسيتم استخدام بياناتها لتدريب النموذج على التنبؤ.

• الفترة الثانية - حالة عدم الاستقرار:

- كانت آثار جائحة كوفيد-19 خلال هذه الفترة الجزئية في أوجها؛ فكانت عملية التنبؤ بأسعار الأسهم باستخدام التحليل الفني عملية صعبة لصعوبة التنبؤ بما سيتجه له عموم المستثمرين في المستقبل، حيث صدمت السوق في بداية العام من بدأ الحكومة السورية اتخاذ إجراءات لمواجهة الجائحة كان جزءاً كبيراً منها مقيداً للفاعليات الاقتصادية مما جعل المستثمرين يعيشون حالة تخبط.

- امتدت هذه الفترة الجزئية من 1/كانون الثاني/2020 إلى 31/كانون الأول/2020 وشملت 211 يوم تداول من 366 يوماً هو إجمالي عدد أيام الفترة. وسيتم استخدام بياناتها لتدريب النموذج على التنبؤ.

• الفترة الثالثة - حالة شبه الاستقرار:

- بدأت آثار الجائحة خلال هذه الفترة الجزئية تتراجع مع بدأ الحكومة رفع الإجراءات الخاصة التي فرضتها، ودخلت الأسواق مرحلة التعافي وعودة الاستقرار التدريجي، وبالتالي بدأت في هذه المرحلة تعود عملية التنبؤ بأسعار الأسهم أكثر إمكانية وأقل صعوبة.

- امتدت هذه الفترة الجزئية من 1/كانون الثاني/2021 إلى 31/كانون الثاني/2021 وشملت 240 يوم تداول من 365 يوماً هو إجمالي عدد أيام الفترة. وسيتم استخدام بياناتها لتدريب النموذج على التنبؤ.


• الفترة الرابعة - فترة الاختبار:

- خلال هذه الفترة الجزئية يمكن اعتبار السوق قد تجاوز مرحلة الجائحة والتعافي من آثارها وعادت الظروف إلى وضعها المستقر في فترة قبل كوفيد-19.

- امتدت هذه الفترة الجزئية من 1/كانون الثاني/2022 إلى 31/كانون الثاني/2022 وشملت 231 يوم تداول من 365 يوماً هو إجمالي عدد أيام الفترة. وسيتم استخدام بياناتها لاختبار وتقييم قدرة النموذج على التنبؤ.

هكذا تكون فترة الدراسة قد حددت وقُسمت بما يحقق المعايير الموضوعية من قبل الباحث وبما يضمن تدريب النموذج على فترة طويلة بما فيه الكفاية مع تنوع صفات الفترة لتتكون لديه القدرة التنبؤ بنتائج أكثر دقة وصحة.

الشكل رقم (10): هيكل فترة الدراسة



### 3-2 المبحث الثاني: أسلوب الدراسة:

مرت عملية البحث التطبيقي للدراسة بثلاث مراحل هي: (1) تحضير البيانات التي سوف يتم إدخالها للنموذج ليتنبأ بالاعتماد عليها؛ (2) إعداد النموذج الذي سوف يتنبأ باستخدام الذكاء الاصطناعي؛ (3) التنبؤ واختبار الفرضيات عبر مقارنة نتائج التنبؤ التي وصل لها النموذج مع القيم الحقيقية خلال فترة الاختبار.

وسيتم في هذا المبحث عرض المرحلتين الأولى والثالثة بشكلٍ تفصيلي وتترك المرحلة الثالثة للمبحث الرابع.

الشكل رقم (11): مراحل عملية البحث التطبيقي



### 3-2-1 تحضير البيانات:

المرحلة الأولى في الدراسة هي تحضير البيانات التي سيغذى بها النموذج، وتشمل خطوتين، الأولى هي حساب البيانات نفسها وتتم بحساب قيم جميع المتغيرات لكل يوم من أيام فترة الدراسة، والثانية هي معايرة البيانات لتكون مناسبة للنموذج ليفهمها.

### 3-2-1-1 حساب قيم المتغيرات:

تتكون البيانات من قيم مؤشرات التداول والمؤشرات الفنية التي تم اختيارها كمتغيرات للدراسة (مزايا النموذج Model Features). وقد تم حسابها بالطريقة التالية:

- قيم الافتتاح والإغلاق: اعتمدت قيمها ذاتها المنشورة في موقع السوق الرسمي.

- المؤشرات الفنية: حسبت قيمها يدوياً من قبل الباحث بالاعتماد على قيم إغلاق المؤشر وبحسب معادلاتها الرياضية.

ونعرض فيما يلي بعض المعلومات والتفاصيل عن مواصفات البيانات التي غذي بها النموذج..



### (أ) حجم البيانات:

تتكون بيانات مزايا الإدخال Input Feature (سعر الافتتاح، سعر الإغلاق، مؤشر EMA القصير، مؤشر EMA الطويل، مؤشر MACD) من 4,590 قيمة موزعة على 918 يوماً أي 5 قيم مختلفة لليوم الواحد بمقدار قيمة واحدة لكل متغير في كل يومٍ من أيام الدراسة. هذه القيم سوف يقوم النموذج بقراءتها وتحليلها ليتمكن من التنبؤ بقيم ميزة الهدف Target Feature (سعر الإغلاق في اليوم التالي، قيمة مؤشر MACD في اليوم التالي) التي يبلغ عددها 1,836 قيمة أي قيمتين مختلفتين لكل يومٍ من أيام الدراسة بمقدار قيمة واحدة لكل متغير.

### (ب) التحليل الوصفي للبيانات:

يتضمن الجدول التالي معلوماتٍ وصفية لبيانات متغيرات الدراسة، تعرض هذه المعلومات المتوسط الحسابي وأكبر قيمة وأصغر قيمة والانحراف المعياري والالتواء والتقلطح.

الجدول رقم (2): التوصيف الإحصائي لمتغيرات الدراسة

| المتغير       | أكبر قيمة | أصغر قيمة | المتوسط الحسابي | الانحراف المعياري | الالتواء | التقلطح |
|---------------|-----------|-----------|-----------------|-------------------|----------|---------|
| قيمة الافتتاح | 29,543.31 | 5,419.28  | 11,458.1        | 6,512.40          | 1.017    | -0.342  |
| قيمة الإغلاق  | 30,244.68 | 5,430.56  | 11,478.77       | 6,533.28          | 1.019    | -0.329  |
| EMA القصير    | 28,778.92 | 5,505.28  | 11,343.45       | 6,396.94          | 1.016    | -0.373  |
| EMA الطويل    | 27,930.32 | 5,563.78  | 11,182.93       | 6,236.60          | 1.019    | -0.402  |
| MACD          | 1,230.62  | -125.63   | 160.52          | 268.76            | 2.047    | 3.700   |

يلاحظ من الجدول السابق التالي:

بالنسبة للمتغيرات: قيم الافتتاح والإغلاق ومؤشري EMA الطويل والقصير..


- أن قيم متغيري قيمة الافتتاح وقيمة الإغلاق كانت متقاربة بشكلٍ كبير، حيث أن أكبر وأصغر قيمة افتتاح سجلها المؤشر كانت 29,543.31 نقطة و 5,419.28 على التوالي، بينما كانت أكبر وأصغر قيمة إغلاق سجلها عند 30,244.68 نقطة و 5,430.56 نقطة، أي بفارق 701.37 نقطة بالنسبة لأكبر قيمة و 11.28 نقطة بالنسبة لأصغر قيمة فقط؛ ونفس الأمر بالنسبة لقيم مؤشري EMA الطويل والقصير، اللذان حسباً باستخدام قيم الإغلاق للمؤشر فقط، حيث سجلا 28,778.92 نقطة بالنسبة

للقصير و27,930.32 نقطة بالنسبة للطويل كأكبر قيمة و5,505.28 نقطة بالنسبة للقصير و5,563.78 نقطة بالنسبة للطويل كأصغر قيمة خلال فترة الدراسة.


- وجد التقارب أيضاً في قيم الانحراف المعياري بالنسبة للمتغيرات الأربعة الأولى، حيث تراوحت جميعها بين 6,236.6 و6,533.28 نقطة، أي أنها جميعها كان انحرافها بنسبة 55%~ عن قيمة متوسطها الحسابي وهذا طبيعي بسبب التوزع الواسع لقيم المتغيرات الأربعة.

- أيضاً، نجد أن المتغيرات الأربعة الأولى حققت جميعها توزيع بيانات ملتوٍ بشدة نحو اليمين (موجب) حيث تراوحت قيم التواء الخطوط البيانية لتوزع قيم المتغيرات بين 1.016 لمؤشر EMA القصير و1.019 لقيمة الإغلاق ومؤشر EMA الطويل. وبنفس الوقت كان تفلطح الخط البياني سالباً للمتغيرات الأربعة ومتراوحاً بين -0.392 لقيمة الإغلاق و-0.402 (أصغر من 3 بكثير) لمؤشر EMA الطويل أي أن الخط البياني المعبر عن التوزع الطبيعي لقيم المتغيرات الأربعة كانت مفلطحة بشدة.



الشكل رقم (13): التوزع الطبيعي لبيانات المتغير "قيمة الإغلاق"



الشكل رقم (12): التوزع الطبيعي لبيانات المتغير "قيمة الافتتاح"




الشكل رقم (14): التوزع الطبيعي لبيانات المتغير "مؤشر EMA الطويل" الشكل رقم (15): التوزع الطبيعي لبيانات المتغير "مؤشر EMA القصير"



بالنسبة للمتغير: مؤشر MACD..

- تراوحت قيم المؤشر خلال فترة الدراسة بين أصغر قيمة لها عند -125.63 (أصغر فارق بين مؤشري EMA القصير و EMA الطويل) وأكبر قيمة عند 1,250.62 (أكبر فارق بين مؤشري EMA القصير و EMA الطويل)، وكان المتوسط الحسابي لقيم المؤشر يساوي 160.52 بانحرافٍ معياري يساوي 268.76.

الشكل رقم (16): التوزيع الطبيعي لبيانات المتغير "مؤشر MACD"



- وكان التواء الخط البياني لتوزيع قيم المتغير عند 2.047 (موجب) أي أنه أيضاً ملتوٍ نحو اليمين بشدة. أما التفلطح فكان موجباً على عكس باقي المتغيرات وعند 3.7 (أكبر من 3 بقليل) أي أن الخط البياني المعبر عن التوزيع الطبيعي لقيم المتغير كان مدبباً باعتدال.

### (ج) هيكل البيانات:

بحسب الأسلوب الذي سوف يسير عليه البحث، هناك مرحلتين أساسيتين في عملية تأهيل النموذج بعد مرحلة البناء هما مرحلة التدريب ثم مرحلة الاختبار. هاتان المرحلتان تتطلبان قاعدتي بيانات مختلفتين، الأولى تكون خاصة بتدريب النموذج على التنبؤ والثانية خاصة باختباره فقط. هذا الأمر استوجب تقسيم أيام الدراسة إلى قسمين رئيسيين هما:

القسم (A) أيام التدريب: طوله يساوي 3/2 من إجمالي عدد الأيام.

القسم (B) أيام الاختبار: طوله يساوي 3/1 من إجمالي عدد الأيام.

حيث ستستخدم بيانات القسم (A) لتدريب النموذج على عملية التنبؤ أولاً ثم سوف يطلب منه أن يتنبأ بقيم الإغلاق لأيام القسم (B) بالاستفادة مما تعلمه من تدريبه على أيام القسم A.

### 3-2-1-2 معايرة البيانات:

بحسب (Mehtab, et al., 2021) فإن نماذج الذكاء الاصطناعي تقدم نتائج تنبؤ غير دقيقة أو صحيحة بالمثل عندما تتم تغذيتها ببيانات غير معايرة Normalized، حيث أن النموذج عند تحليله للبيانات المدخلة إليه يقوم بالنظر إليها بالترتيب ويربطها مع بعضها البعض كقيم ممتدة من أصغر قيمة إلى أكبر قيمة.

لذا قام الباحث بمعايرة بيانات الدراسة قبل تغذية النموذج بها، وقد تم هذا باستخدام "معايير الأكبر والأصغر Min Max Scaling" الذي يحول قيم كل متغير إلى قيم ممتدة من الصفر (أصغر قيمة) إلى الواحد (أكبر قيمة).

الشكل رقم (17): شكل حزمة البيانات بعد معايرتها

```
[ ] from sklearn.preprocessing import MinMaxScaler
sc = MinMaxScaler(feature_range=(0,1))
dfscaled = sc.fit_transform(df)

print(dfscaled)

#print(X)
#print(Y)
```

```
[[0.03149184 0.02951144 0.03038997 ... 0.28664841 0.09841023 0.02940228]
 [0.03100187 0.02985986 0.03105974 ... 0.40584617 0.09812113 0.0285019 ]
 [0.03111545 0.02914528 0.03077609 ... 0.35933243 0.09646927 0.02784945]
 ...
 [0.97082992 0.94607924 0.97046848 ... 0.78017423 0.64420678 0.92769021]
 [0.97515175 0.96204456 0.97985443 ... 0.82043451 0.65833763 0.96426479]
 [1.          1.          1.          ... 0.88031879 0.71832118 1.          ]]
```

### 3-2-2 إعداد النموذج:

في هذه المرحلة تم تجهيز نموذج الذكاء الاصطناعي الذي سوف يقوم بالتنبؤ. وقد تمت هذه المرحلة على خطوتين، اختيار النموذج المناسب للتنبؤ ثم بناء النموذج وضبطه.

### 3-2-3-1 اختيار النموذج المناسب للتنبؤ:


تم اختيار نموذج LSTM الذي هو أحد أنواع نماذج "الشبكات العصبية المتكررة Recurrent Neural Networks" ليكون النموذج الذي سوف تطبق الدراسة باستخدامه. وقد كان سبب اختيار هذا النموذج تحديداً هو أنه يحل المشاكل التي تعاني منها نماذج RNN الأخرى. حيث أن الشبكات

العصبية المتكررة، ورغم أنها أفضل من الشبكات التقليدية ANN في استيعاب المعلومات، إلا أنها غير فعالة عند تصبح هذه المعلومات طويلة الأجل Long-term Information، ذلك لأنها تعاني من "مشكلة التلاشي المتدرج Gradient Vanishing Problem" (Bhandari, et al., 2022). ويقدم نموذج LSTM حلاً لهذه المشكلة من خلال استخدام "خلايا الذاكرة" للتغلب على التلاشي المتدرج للمعلومات القديمة من ذاكرة النموذج (Mehtab, et al., 2021). لذا تستخدم معظم الدراسات الحديثة نموذج LSTM للتنبؤ في تحليلات السلاسل الزمنية في المجال المالي (Guo, 2022).

### 3-2-2-3 بناء النموذج وضبطه:

بعد اختيار النموذج المناسب لعملية التنبؤ، وتحديد المتغيرات اللازمة مع حساب قيمها، تم بناء نموذج التنبؤ باستخدام لغة Python ومكتبات Keras وTensorflow عبر منصة Google Collab<sup>8</sup>.

الشكل رقم (8): بنية النموذج والطبقات المكونة له



(8) التفاصيل البرمجية لعملية بناء النموذج تم إرفاقها في ملحق الدراسة.

لكن قبل أن يصبح النموذج جاهزاً للتنبؤ، يجب أولاً ضبط معلماته الفائقة<sup>9</sup> Hyperparameters Tuning، ولضمان ضبط النموذج على أفضل قيم من المعلمات الفائقة تم تحديد عدة خيارات ممكنة لكل مُعلم فائق، فتم اختيار ثلاث احتمالات لعدد عصبونات الشبكة (100، 150، 200) وثلاث احتمالات لمعدل التعلم (0.1، 0.01، 0.001)، أما دالة الأمثلة فقد تم تثبيتها على دالة Adam. وتمت عملية اختيار الاحتمال الأفضل من خلال تشغيل النموذج مضبوطاً على مجموعاتٍ تمثل جميع احتمالات هذه القيم ثم تقييمه باستخدام دالة جذر متوسط مربع الخطأ Root Mean Squared Error (RMSE) واختيار مجموعة الاحتمالات التي تحقق أدنى قيمة لها. وقد شُغل النموذج ثلاث مرات على كل مجموعة ضبط ومن ثم اعتماد متوسط قيمة RMSE لكل تشغيل، أي بمجموع 27 اختباراً. وكانت النتائج كالتالي:

الجدول رقم (3): نتائج تقييم النموذج لاختيار الضبط الصحيح للمعلمات الفائقة

| متوسط قيمة RMSE | قيم المعلمات الفائقة |               |
|-----------------|----------------------|---------------|
|                 | معدل التعلم          | عدد العصبونات |
| 0.53            | 0.1                  | 100           |
| 0.21            | 0.01                 |               |
| 0.12            | 0.001                |               |
| 0.55            | 0.1                  | 150           |
| 0.26            | 0.01                 |               |
| <b>0.10</b>     | 0.001                |               |
| 0.28            | 0.1                  | 200           |
| 0.29            | 0.01                 |               |
| 0.15            | 0.001                |               |

(9) ضبط المعلمات الفائقة هي عملية ضبط خصائص النموذج لضمان الحصول على أفضل نتيجة ممكنة، وتم من خلال ضبط عدد العصبونات Neurons في الشبكة واختيار دالة الأمثلة Optimizer وتحديد معدل التعلم Learning Rate.

نجد من الجدول أن ضبط النموذج عند 150 عصبوناً في الشبكة ومعدل تعلم 0.1 يحقق أصغر درجة RMSE ممكنة، لذا هي قيم ضبط المَعْلَمَات الفائقة التي سيتم اعتمادها عند التنبؤ باستخدام النموذج.

### 3-3 المبحث الثالث: التنبؤ واختبار الفرضيات:

#### تذكرة بفرضيات الدراسة:

قام الباحث بوضع الفرضيات التالية:

(1) يوجد فارق جوهري بين قيم إغلاق مؤشر DWX التي يتنبأ بها نموذج الذكاء الاصطناعي والقيم التي يحققها المؤشر بالواقع.

(2) يوجد فارق جوهري بين قيم إغلاق مؤشر DWX التي يتنبأ بها نموذج الذكاء الاصطناعي والقيم التي يحققها المؤشر بالواقع.

بعد إعداد النموذج وضبط معالمته الفائقة أصبح جاهزاً لتغذيته بالمدخلات ليقوم بالتنبؤ، ثم سوف يتم مقارنة نتائج التنبؤ مع النتائج الحقيقية باستخدام الاختبارات الإحصائية لاختبار الفرضيات. لذا قام الباحث بإجراء تجربتين، الأولى كانت لاختبار الفرضية الأولى وتم فيها توظيف متغيرات الإدخال: قيمة الافتتاح وقيمة الإغلاق ومؤشري EMA القصير والطويل للتنبؤ بقيم متغير الهدف: قيمة إغلاق المؤشر في اليوم التالي، والثانية كانت لاختبار الفرضية الثانية وتم فيها توظيف متغير الإدخال: مؤشر MACD للتنبؤ بقيم متغير الهدف: قيمة مؤشر MACD في اليوم التالي، ثم قارن نتائج تنبؤ كل تجربة مع النتائج الحقيقية التي تحققت في الواقع. التجربتين تمتا على بيانات فترة اختبار النموذج التي حددها الباحث في بداية الدراسة والتي غطت 231 يوماً هي جميع أيام التداول في العام 2022.

الشكل رقم (19): تجارب التنبؤ باستخدام النموذج

| التجربة الأولى                                                    | التجربة الثانية                                                         |
|-------------------------------------------------------------------|-------------------------------------------------------------------------|
| اختبار قدرة النموذج على التنبؤ بقيمة إغلاق المؤشر في اليوم التالي | اختبار قدرة النموذج على التنبؤ باتجاه قيمة إغلاق المؤشر في اليوم التالي |




### 3-4-1 التجربة الأولى واختبار الفرضية الأولى:

#### (أ) نتائج التجربة الأولى:

حققت التجربة الأولى، الهادفة إلى التنبؤ بقيم إغلاق مؤشر DWX لتحليل إمكانية التنبؤ بقيمة المؤشر، نتائج تنبؤ تبدو قريبة جداً من النتائج الواقعية، حيث عند عرض الخط البياني لقيم الإغلاق للمؤشر التي تنبأ بها النموذج مع القيم التي تحققت بالواقع نجد التالي:

الشكل رقم (20): مقارنة نتائج التنبؤ مع النتائج الواقعية لقيم إغلاق مؤشر DWX خلال فترة الاختبار



حيث نلاحظ من الرسم أن الخط الممثل للقيم المتنبأ بها (الخط الأحمر) يسير على التوازي بشكل عام مع الخط الممثل للقيم التي تحقق بالواقع (الخط الأزرق)، لكن، ورغم ذلك، نلاحظ أنه عند الارتفاعات أو الانخفاضات في القيمة أن نتيجة التنبؤ تكون أكثر حدية في توقع حد الارتفاع أو الانخفاض فتستقر عند نتيجة أعلى أو أقل من النتيجة الواقعية.

#### (ب) اختبار الفرضية الأولى:

قام الباحث بإدخال بيانات التجربة الأولى إلى برنامج SPSS بهدف تحليلها إحصائياً وإجراء اختبار  $t$  لعينتين مستقلتين لاختبار وجود فارق جوهري بين العينتين (المتنبأ بها والواقعية) والتحقق من الفرضية الأولى فكانت النتائج التالية:

الجدول رقم (4): مقارنة متوسط وانحراف النتائج المتنبأ بها مع النتائج الواقعية لقيمة الإغلاق

| Group Statistics |       |     |            |                |                 |
|------------------|-------|-----|------------|----------------|-----------------|
|                  | Group | N   | Mean       | Std. Deviation | Std. Error Mean |
| Close Value      | Real  | 231 | 21904.0787 | 2835.53522     | 186.56452       |
|                  | Pred  | 231 | 21890.5394 | 2816.01249     | 185.28002       |

الجدول رقم (5): اختبار t لعينتين مستقلتين للنتائج المتنبأ بها مع النتائج الواقعية لقيمة الإغلاق

| Independent Samples Test |                             |                                         |      |                              |         |                 |                 |                       |                                           |           |
|--------------------------|-----------------------------|-----------------------------------------|------|------------------------------|---------|-----------------|-----------------|-----------------------|-------------------------------------------|-----------|
|                          |                             | Levene's Test for Equality of Variances |      | t-test for Equality of Means |         |                 |                 |                       |                                           |           |
|                          |                             |                                         |      |                              |         |                 |                 |                       | 95% Confidence Interval of the Difference |           |
|                          |                             | F                                       | Sig. | t                            | df      | Sig. (2-tailed) | Mean Difference | Std. Error Difference | Lower                                     | Upper     |
| Close Value              | Equal variances assumed     | .006                                    | .939 | .051                         | 460     | .959            | 13.53931        | 262.93536             | -503.16404                                | 530.24265 |
|                          | Equal variances not assumed |                                         |      | .051                         | 459.978 | .959            | 13.53931        | 262.93536             | -503.16410                                | 530.24272 |

- يلاحظ من الجدول رقم (4) أن متوسطا قيم الإغلاق، الواقعية والمتنبأ بها، كانا قريبان جداً من بعضهما مع تحقيق القيم الواقعية متوسطاً أكبر بقليل من متوسط قيم الإغلاق المتنبأ بها، هذا يعني أن النموذج كان يتنبأ بطريقة أكثر تحفظاً لكنها قريبة جداً من الواقع.

- كما يُلاحظ من الجدول رقم (5) أن قيم المجموعتين متجانسة بشكل كبير لأن معدل الدلالة المتعلق بـ F يساوي 0.939 ( $0.05 > 0.939$ ) وبالتالي نأخذ السطر الأول.

#### نص الفرضية الأولى:

يوجد فارق جوهري بين قيم إغلاق مؤشر *DWX* التي يتنبأ بها نموذج النكاه الاصطناعي والقيم التي يحققها المؤشر في الواقع.


- لاختبار وجود فارق جوهري بين متوسطي العينتين نقارن مستوى الدلالة  $\text{Sig.} = 0.959$  المتعلق بـ  $t$  مع مستوى الدلالة المفترض من قبل الباحث والذي يساوي 0.05 فنجد أن  $\text{Sig.}$  المتعلق بـ  $t$  أكبر ومنه نرفض الفرضية البديلة ونقبل الفرضية العدمية، أي أنه لا يوجد فارق جوهري بين قيم إغلاق المؤشر التي يتنبأ بها نموذج النكاه الاصطناعي والقيم التي يحققها المؤشر في الواقع.

### 3-4-2 التجربة الثانية واختبار الفرضية الثانية:

#### أ) نتائج التجربة الثانية:

حققت التجربة الثانية، الهادفة إلى التنبؤ بقيم مؤشر MACD لتحليل إمكانية التنبؤ باتجاهات حركة مؤشر DWX، نتائج تنبؤ تبدو قريبة جداً من النتائج الواقعية، حيث عند عرض الخط البياني لقيم مؤشر MACD التي تنبأ بها النموذج مع القيم التي تحققت بالواقع نجد التالي:

الشكل رقم (21) مقارنة نتائج التنبؤ مع النتائج الواقعية لقيم مؤشر MACD خلال فترة الاختبار



حيث نلاحظ من الرسم أن الخط الممثل للقيم المتنبأ بها (الخط الأحمر) يسير على التوازي بشكل عام مع الخط الممثل للقيم التي تحققت بالواقع (الخط الأزرق)، لكن، ورغم ذلك، نلاحظ أنه هنا أيضاً عند الارتفاعات أو الانخفاضات في القيمة تكون نتيجة التنبؤ تكون أكثر حدية في توقع حد الارتفاع أو الانخفاض فتستقر عند نتيجة أعلى أو أقل من النتيجة الواقعية.

#### ب) اختبار الفرضية الثانية:

قام الباحث بإدخال بيانات التجربة الثانية إلى برنامج SPSS بهدف تحليلها إحصائياً وإجراء اختبار  $t$  لعينتين مستقلتين لاختبار وجود فارق جوهري بين العينتين والتحقق من الفرضية الثانية فكانت النتائج التالية:

الجدول رقم (6): مقارنة متوسط وانحراف النتائج المتنبأ بها مع النتائج الواقعية لقيمة مؤشر MACD

| Group Statistics |       |     |          |                |                 |
|------------------|-------|-----|----------|----------------|-----------------|
|                  | Group | N   | Mean     | Std. Deviation | Std. Error Mean |
| MACD             | Real  | 231 | 371.0245 | 339.96659      | 22.36816        |
|                  | Pred  | 231 | 370.3777 | 341.67651      | 22.48066        |

الجدول رقم (7): اختبار t لعينتين مستقلتين للنتائج المتنبأ بها مع النتائج الواقعية لقيمة مؤشر MACD

| Independent Samples Test |                             |                                         |      |                              |         |                 |                 |                       |                                           |          |
|--------------------------|-----------------------------|-----------------------------------------|------|------------------------------|---------|-----------------|-----------------|-----------------------|-------------------------------------------|----------|
|                          |                             | Levene's Test for Equality of Variances |      | t-test for Equality of Means |         |                 |                 |                       |                                           |          |
|                          |                             | F                                       | Sig. | t                            | df      | Sig. (2-tailed) | Mean Difference | Std. Error Difference | 95% Confidence Interval of the Difference |          |
|                          |                             |                                         |      |                              |         |                 |                 |                       | Lower                                     | Upper    |
|                          |                             |                                         |      |                              |         |                 |                 |                       |                                           |          |
| Close Value              | Equal variances assumed     | .000                                    | .992 | .020                         | 460     | .984            | .64684          | 31.71301              | -61.67348                                 | 62.96716 |
|                          | Equal variances not assumed |                                         |      | .020                         | 459.988 | .984            | .64684          | 31.71301              | -61.67349                                 | 62.96717 |

- يلاحظ من الجدول رقم ( ) أن متوسطا قيم MACD، الواقعية والمتنبأ بها، كانا قريبان جداً من بعضهما مع تحقيق القيم الواقعية متوسطاً أكبر بقليل من متوسط قيم الإغلاق المتنبأ بها، وهذا يعني أن النموذج كان يتنبأ بطريقة أكثر تحفظاً لكنها قريبة جداً من الواقع.

- كما يُلاحظ من الجدول رقم ( ) أن قيم المجموعتين متجانسة بشكل كبير لأن معدل الدلالة المتعلق بـ F يساوي 0.992 ( $0.05 > 0.992$ ) وبالتالي نأخذ السطر الأول.

#### نص الفرضية الثانية:

يوجد فارق جوهري بين قيم مؤشر MACD التي يتنبأ بها نموذج الذكاء الاصطناعي والقيم التي حققها المؤشر في الواقع.

- لاختبار وجود فارق جوهري بين متوسطي العينتين نقارن مستوى الدلالة  $\text{Sig.} = 0.984$  المتعلق بـ  $t$  مع مستوى الدلالة المفترض من قبل الباحث والذي يساوي 0.05 فنجد أن  $\text{Sig.}$  المتعلق بـ  $t$  أكبر ومنه نرفض الفرضية البديلة ونقبل الفرضية العدمية، أي أنه لا يوجد فارق جوهري بين قيم مؤشر MACD التي يتنبأ بها نموذج الذكاء الاصطناعي والقيم التي حققها المؤشر في الواقع.

### 3-5 النتائج والتوصيات:

#### 3-5-1 نتائج الدراسة:

(1) حقق التنبؤ باستخدام نموذج LSTM نتائج تنبؤ قريبة جداً من الواقع حيث كانت المتوسطات الحسابية للقيم التي تنبأ بها النموذج (قيم إغلاق مؤشر DWX وقيم مؤشر MACD لفترة الاختبار) قريبة جداً من المتوسطات الحسابية للقيم التي تحققت بالواقع.

(2) لا يوجد فارق جوهري بين قيم إغلاق المؤشر التي يتنبأ بها نموذج الذكاء الاصطناعي والقيم التي يحققها المؤشر في الواقع.

(3) لا يوجد فارق جوهري بين قيم مؤشر MACD التي يتنبأ بها نموذج الذكاء الاصطناعي والقيم التي يحققها المؤشر في الواقع.

#### 3-5-2 التوصيات:

بناءً على نتائج الدراسة فام الباحث بطرح التوصيات التالية:

(1) يُنصح المتداولون في الأسواق المالية باستخدام نماذج الذكاء الاصطناعي كأداة مساعدة لهم في التنبؤ في هذه الأسواق، لكن لا ينصح بالاعتماد عليها بشكل كامل فلا زالت النتائج غير دقيقة بما فيه الكفاية.

(2) يمكن تطوير الدراسة أكثر بإعادتها مع دراسة ربحية استخدام هذه النماذج ومقارنتها مع الربحية في حال القيام بالتحليل الفني بالذكاء البشري ودون الاعتماد عليه.

(3) إن إضافة المزيد من المتغيرات كمزايا إدخال للنموذج قد يزيد من دقة نتائجه وصحتها.

(4) يمكن توسعة نطاق البحث في هذا المجال واستخدام نماذج الذكاء الاصطناعي في التنبؤ بمؤشرات مالية أخرى كأسعار العملات والذهب والسلع وحتى المؤشرات الاقتصادية كمعدلات التضخم والفائدة.

## المصادر والمراجع

### المصادر والمراجع العربية:

- (1) الثلايا، خ.، الألفي، ا. و محمد، ص. ا.، 2019. *التنبؤ في سوق البحرين للأوراق المالية باستخدام التعلم العميق*. IEEE, Manama, Bahrain.
- (2) خير بك، أ.، 2022. أهمية التحليل الفني للعميل ودوره في اتخاذ القرار الاستثماري. *مجلة جامعة حماة*، 144-131 pp.
- (3) سوق دمشق للأوراق المالية، 2022. *التقرير السنوي لعام 2022*، مكان غير معروف: سوق دمشق للأوراق المالية.
- (4) سوق دمشق للأوراق المالية، بلا تاريخ دليل آلية عمل المؤشر المثقل بالقيمة السوقية *DWX*.
- (5) لأبيض، ب.، بزازو، ع. ا. و بن أبو، ل.، 2018. *التنبؤ قصير المدى في سوق الأوراق المالية المغربية باستخدام الشبكات العصبية الصناعية ANNs*. Association, Rabat, Morocco. for Computing Machinery, pp. 1-6.
- (6) ممدوح، آ. ش.، 2023. التحليل الفني كأداة لاتخاذ القرار الاستثماري بالأسهم: دراسة تطبيقية في سوق العراق للأوراق المالية. *مجلة اقتصاديات الأعمال*، 2-225 pp.

- 1) Bhandari, H. et al., 2022. Predicting stock market index using LSTM. *Machine Learning with Applications*.
- 2) Chen, J., 2022. *Correction*. Available at: <https://www.investopedia.com/>
- 3) Chong, E., Han, C. & Park, F., 2017. Deep Learning Networks for Stock Market Analysis and Prediction: Methodology, Data Representations, and Case Studies. *Durham Research Online*, pp. 187–205.
- 4) Dolan, B., 2023. *MACD Indicator Explained, with Formula, Examples, and Limitations*. Available at: <https://www.investopedia.com/>
- 5) Fazeli, A. & Houghten, S., 2019. *Deep Learning for the Prediction of Stock Market Trends*. Los Angeles, California, USA, IEEE, pp. 5513–5521.
- 6) Fidelity.com, n.d. *Relative Strength Index (RSI)*. Available at: <https://www.fidelity.com/>
- 7) Guo, Y., 2022. *Stock Price Prediction Using Machine Learning*. Stockholm, Södertörn University.
- 8) Hayes, A., 2022. *Technical Analysis: What It Is and How to Use It in Investing*. Available at: <https://www.investopedia.com/>
- 9) IBM.com, n.d. *What are neural networks?*. Available at: <https://www.ibm.com/>
- 10) Kirkpatrick II, C. D., 2022. *Understanding Technical Indicators*. Available at: <https://www.fidelity.com/>

- 11) Klingler, N., 2023. *The Ultimate Guide to Understanding and Using AI Models*. Available at: <https://viso.ai/>
- 12) Lund, B., 2022. *Technical indicators: The tools of the trade*. Available at: <https://www.britannica.com/money>
- 13) ManagementStudyGuide.com, n.d. *Concept of Profit Booking and How It Affects Stock Markets*. Available at: <https://www.managementstudyguide.com/>
- 14) Mehtab, S., Sen, J. & Dutta, A., 2021. *Stock Price Prediction Using Machine Learning and LSTM-Based Deep Learning Models*. Virtual Conference, IEEE.
- 15) Mitchell, C., 2021. *Understanding an OHLC Chart and How to Interpret It*. Available at: <https://www.investopedia.com/>
- 16) Shynkevich, Y. et al., 2017. Forecasting Price Movements using Technical Indicators: Investigating the Impact of Varying Input Window Length. *Neurocomputing*, Volume 264, pp. 71–88.
- 17) Singh, G., 2021. *Introduction to Artificial Neural Networks*. Available at: <https://www.analyticsvidhya.com/>
- 18) Stankovic, J., Markovic, I. & Stojanovic, M., 2015. Investment Strategy Optimization Using Technical Analysis and Predictive Modeling in Emerging Markets. *Procedia: Economics and Finance*, pp. 51–62.
- 19) StockCharts.com, n.d. *Technical Analysis*. Available at: <https://school.stockcharts.com/>



20) TheDecisionLab.com, n.d. *Artificial Intelligence Models*. Available at:  
<https://thedecisionlab.com/>

21) Yates, T., 2022. *4 Ways to Predict Market Performance*. Available at:  
<https://www.investopedia.com/>

## ملحق الدراسة:

### 1- عينة مؤشر DWX خلال فترة الدراسة (بحسب تقرير السوق لعام 2022):

الجدول رقم (8): عينة مؤشر DWX

| الشركة | الرمز | تاريخ الإدراج |
|--------|-------|---------------|
| 1      | BBSF  | 2009          |
| 2      | AHT   | 2009          |
| 3      | UG    | 2009          |
| 4      | ARBS  | 2009          |
| 5      | BSO   | 2009          |
| 6      | BASY  | 2009          |
| 7      | IBTF  | 2009          |
| 8      | NAMA  | 2009          |
| 9      | SIIB  | 2009          |
| 10     | AVOC  | 2009          |
| 11     | UIC   | 2009          |
| 12     | BBS   | 2009          |
| 13     | QNBS  | 2010          |
| 14     | BOJS  | 2010          |
| 15     | AROP  | 2010          |
| 16     | NIC   | 2010          |
| 17     | SGB   | 2010          |
| 18     | ATI   | 2010          |
| 19     | SHRQ  | 2010          |
| 20     | FSBS  | 2011          |
| 21     | SAIC  | 2011          |
| 22     | SKIC  | 2012          |
| 23     | CHB   | 2014          |
| 24     | BBSY  | 2014          |

|      |       |                       |    |
|------|-------|-----------------------|----|
| 2018 | SYTEL | سيريتل موبايل تيليكوم | 25 |
| 2019 | MTN   | MTN سورية             | 26 |
| 2019 | ABC   | إسمنت البادية         | 27 |

## 2- إعداد النموذج:

لإعداد النموذج قام الباحث بتطوير برنامج عبر منصة Google Collab وباستخدام لغة البرمجة بايثون Python، هذا البرنامج سيمكن مستخدمه من التعامل مع النموذج ليحصل على النتائج المطلوبة، ويعمل البرنامج وفقاً للخطوات الرئيسية التالية:

### الخطوة الأولى: رفع حزمة بيانات المدخلات

في هذه الخطوة تم رفع Upload حزمة البيانات التي سوف يُغذى بها النموذج إلى منصة البرمجة باستخدام أداة خاصة. وتوضح الصورة التالية هذه المرحلة:

الشكل رقم (22) شكل جدول حزمة بيانات المدخلات بعد رفعها إلى البرنامج

The screenshot shows a Google Colab interface. At the top, there is a code cell with the following Python code:

```
from google.colab import files
#files.upload()

df = pd.read_csv('Price Prediction')
df
```

A callout box points to the code, stating: "استدعاء أداة رفع الملفات إلى منصة البرمجة Google Collab". Below the code, a table preview is shown with the following columns: Date, Open, Close, Short EMA, Long EMA, and Target. The first five rows of data are visible, with indices 0 through 4.

|   | Date       | Open    | Close   | Short EMA   | Long EMA    | Target  |
|---|------------|---------|---------|-------------|-------------|---------|
| 0 | 2018-12-16 | 6253.69 | 6230.00 | 6221.784690 | 6221.784690 | 6224.05 |
| 1 | 2018-12-17 | 6230.30 | 6224.05 | 6222.133199 | 6221.952491 | 6200.25 |
| 2 | 2018-12-18 | 6222.08 | 6200.25 | 6218.766553 | 6220.344899 | 6188.49 |
| 3 | 2018-12-19 | 6181.12 | 6188.49 | 6214.108622 | 6217.985277 | 6221.57 |
| 4 | 2018-12-20 | 6222.06 | 6221.57 | 6215.256526 | 6218.250812 | 6190.65 |

يظهر في الصورة السابقة شكل الجدول الذي تتوضع فيه البيانات المدخلة إلى البرنامج بعد رفعها إلى المنصة التي استخدمها الباحث لتطويره. لفهم الجدول يمكن أن ننظر إلى هيكله مقسماً بالشكل التالي:

- أفقيًا، يقسم الجدول إلى طرفين، الأول (المربع الأحمر في الصورة)، يشمل الأعمدة المُمثِّلة للمتغيرات التي سوف تستخدم في عملية التنبؤ، والثاني (المربع الأزرق)، هو العمود الممثل للمتغير المراد التنبؤ بقيمه.

- عموديًا، يقسم الجدول إلى أسطر، كل واحدٍ منها يحتوي قيم المتغيرات في يومٍ معين من أيام فترة الدراسة (المربع الأخضر).

بعد إنجاز الخطوة الأولى ننتقل للخطوة الثانية..

### الخطوة الثانية: معايرة البيانات Data Normalization:

في هذه الخطوة تم تحويل قيم البيانات المرفوعة إلى البرنامج إلى قيم بين الصفر والواحد، حيث تأخذ القيمة الأدنى في كل عمود الرقم 0 والقيمة الأعلى الرقم 1 وباقي القيم في العمود توزع على مقياس بين الرقمين.

تأتي الحاجة إلى هذه الخطوة من أن نموذج الذكاء الاصطناعي لا يستطيع أن يتعامل مع البيانات بالشكل الطبيعي بل ينظر لها كنسب مئوية تبدأ من الصفر وتنتهي بـ100%، لذا إن لم تتم هذه الخطوة فإن النموذج لن يتمكن من تحقيق نتائج تنبؤ صحيحة.


وتوضّح الصورة التالية حزمة البيانات بعد معايرتها:

الشكل رقم (23) شكل حزمة البيانات بعد معايرتها:

```
[ ] from sklearn.preprocessing import MinMaxScaler
    sc = MinMaxScaler(feature_range=(0,1))
    dfscaled = sc.fit_transform(df)

    print(dfscaled)

    #print(X)
    #print(Y)
```



```
[[[0.03149184 0.02951144 0.03038997 ... 0.28664841 0.09841023 0.02940228]
  [0.03100187 0.02985986 0.03105974 ... 0.40584617 0.09812113 0.0285019 ]
  [0.03111545 0.02914528 0.03077609 ... 0.35933243 0.09646927 0.02784945]
  ...
  [0.97082992 0.94607924 0.97046848 ... 0.78017423 0.64420678 0.92769021]
  [0.97515175 0.96204456 0.97985443 ... 0.82043451 0.65833763 0.96426479]
  [1.          1.          1.          ... 0.88031879 0.71832118 1.          ]]]
```

يلاحظ من الصورة السابقة أن جدول المدخلات تحول إلى مصفوفة تحوي قيم البيانات نفسها لكن بعد معايرتها فتغير شكلها إلى قيم بين 0 و 1 كما يظهر في الصورة. كما يلاحظ أن خصائص هيكل الجدول بقي محافظاً عليها بعد عملية المعايرة فبقي مكوناً أفقياً من نفس الطرفين، المربع الأحمر الممثل للمتغيرات التي سوف تستخدم في عملية التنبؤ والمربع الأزرق الممثل للمتغير المراد التنبؤ بقيمه؛ وعمودياً بقيت الأسطر تمثل قيم المتغيرات في كل يوم من أيام فترة الدراسة.

بعد إنجاز الخطوة الثانية ننتقل إلى الخطوة الثالثة..

#### الخطوة الثالثة: تعريف المتغيرات:

في هذه الخطوة تم تعريف النموذج على متغيرات الدراسة، المدخلات بطرفيها، والمخرجات؛ إضافة إلى تحديد الخطوات الزمنية Time Steps. وتأتي الحاجة إلى هذه الخطوة من أن النموذج بحاجة لأن يتم تعريف المتغيرات له حتى يتمكن من التعامل معها بشكل صحيح يمكنه من تحقيق نتائج تنبؤ صحيحة.

وتوضّح الصورة التالية الأسطر البرمجية التي استُخدمت لإنجاز عملية التعريف:

الشكل رقم (24): تعريف متغيرات الدراسة

```
[ ] X = []

backdays = 12
print(dfscaled.shape[0])
for j in range(8):
    X.append([])
    for i in range(backdays, df.shape[0]):
        X[j].append(dfscaled[i-backdays:i, j])

X=np.moveaxis(X, [0], [2])

X, yi =np.array(X), np.array(dfscaled[backdays:, -1])
Y=np.reshape(yi,(len(yi),1))

print(X.shape)
print(Y.shape)

918
(906, 12, 8)
(906, 1)
```

يحتوي المربع الأزرق سطر تعريف عدد الخطوات الزمنية، والمربع الأحمر يحتوي أسطر تعريف الطرف الأول من المتغيرات، أما المربع الأخضر فيحتوي أسطر تعريف الطرف الثاني من المتغيرات. بعد إنجاز الخطوة الثالثة ننتقل إلى الخطوة الرابعة..

#### الخطوة الرابعة: تعريف أيام التدريب وأيام الاختبار:

في هذه الخطوة تم تعريف النموذج بالأيام المخصصة بياناتها لتدريبه والأيام المخصصة بياناتها لاختباره عبر تقسيم الأسطر (الممثلة لأيام الدراسة كما شرحنا مسبقاً) إلى 675 سطرًا/يومًا تغطي أيام السنوات 2019 و 2020 و 2021 هي أيام التدريب، و 231 يومًا تغطي أيام سنة 2022 هي أيام الاختبار.

وتوضّح الصورة التالية الأسطر البرمجية التي استُخدمت لإنجاز عملية التقسيم:

الشكل رقم (25): تقسيم أيام الفترة إلى أيام تدريب وأيام اختبار

```
[ ] splitlimitX = int(len(X)*0.7457)

X_train, X_test = X[:splitlimitX], X[splitlimitX:]
Y_train, Y_test, = Y[:splitlimitX], Y[splitlimitX:]

print(X_train.shape)
print(Y_train.shape)
print(X_test.shape)
print(Y_test.shape)

(675, 12, 8)
(675, 1)
(231, 12, 8)
(231, 1)
```

بعد إنجاز الخطوة الثانية ننتقل إلى الخطوة الثالثة..

#### الخطوة الخامسة: بناء النموذج وتجهيزه للتنبؤ:

في هذه المرحلة تمت كتابة الأسطر البرمجية اللازمة لبناء النموذج مع تجهيزه للتنبؤ بقيم صحيحة من خلال تحديد عدد الطبقات وعُقدّها وأنواعها، ثم تفعيل "دوال أمثلة Optimizers" تقوم بمساعدة النموذج على أمثلة نتائج تنبؤه خلال عملية التدريب.

وتوضّح الصورة التالية الأسطر البرمجية التي استخدمت لبناء النموذج:

الشكل رقم (26): الأسطر البرمجية المستخدمة لبناء النموذج

```
from tensorflow.keras.models import Sequential
from tensorflow.keras.optimizers import Adam
from tensorflow.keras import layers

from keras import backend as K

Model = Sequential([layers.Input((backdays, 1)),
                    layers.LSTM(150),
                    layers.Dense(75, activation='relu'),
                    layers.Dense(75, activation='relu'),
                    layers.Dense(1)])

def rmse(Y_train, Y_pred):
    return K.sqrt(K.mean(K.square(Y_train - Y_pred)))

Model.compile(loss = 'mse',
              optimizer=Adam(learning_rate=0.01),
              metrics=[rmse])

Model.fit(x=X_train, y=Y_train, batch_size=15, epochs=30, shuffle=True, validation_split = 0.1)
```

يحتوي المربع الأزرق على الأسطر التي بواسطتها استدعاء المكتبات البرمجية التي تحتوي على نموذج الذكاء الاصطناعي LSTM (النموذج الذي اختاره الباحث لتطبيق الدراسة من خلاله) وأدواته، أما المربع الأحمر فيحتوي على الأسطر التي تم فيها بناء النموذج نفسه ورسم بنيته وتحديد خصائصه.