

نظام دعم قرار خبير عصبوني للقيام بالتنبؤ السعري في الأسواق المالية

Neuro-Expert Decision Support System for Stock Market Price Prediction

إعداد الطالب

جورج أبو نصار

بإشراف الدكتور

كادان الجمعة

العام الدراسي 2021-2022

جميع الآراء الواردة في هذا المشروع تعبر عن وجهة نظر معده ولا يتحمل المعهد أي مسؤولية عن مدى دقة أو مصداقية الآراء المطروحة فيه

شكر وتقدير

أتوجه بجزيل الشكر والعرفان للدكتور كادان الجمعة لإشرافه على هذا العمل البحثي، فهو لم يبخل عليّ بالجهد والوقت والمساعدة خلال دراستي في الاختصاص كما قدم الكثير من الدعم خلال أشهر العمل على هذا البحث.

أتوجه بالشكر لجميع أساتذة المعهد العالي لإدارة الأعمال لا سيما أساتذة اختصاص إدارة العمليات لتفانيهم وتقديهم بيئة داعمة لهذا الاختصاص ورعايتهم للطلاب دوماً خلال مرحلة دراستي.

أتوجه بشكر خاص للصديق الياس ميخائيل الذي كان بمثابة أخ لي والداعم الأول منذ الطفولة ولوقوفه بجانبى في أحلك أوقات مررت بها، فكان سنداً حقيقياً بكل ما تحمله الكلمة من معنى .

أتوجه بشكر كبير للصديقة مايا ديب لإيمانها الصادق بي ولدعمها الكبير في جميع المواقف فأتمنى أن أكون قادراً يوماً ما على الوقوف معها كما قامت هي بالوقوف بجانبى في حياتي.

أتوجه بشكر كبير للصديقة أليس حازر لتشجيعها الكبير لي ولفكرة البحث وتقديمها الوقت والدعم فهي خير موجه ومثال لإنسان يحب التعلم والتطور.

أشكر أصدقائي الذين قضيت معهم أجمل أيام حياتي والذين تركوا بصمة وأثر في حياتي كما أضافوا الكثير من السعادة والضحك والدعم ، خلا، إدوارد، تالا، لونا، دارين، الياس، عبادة، جان، قصي، وسام، وكل الأصدقاء اللذين لم أذكرهم إلا أنهم في القلب.

إهداء

إلى أبي وأمي اللذان قدما لي كل ما أملك، سندي الأول وعزتي في حياتي
ودافعي لأن أكون أفضل نسخة من نفسي.

إلى نور عيوني ومصدر طاقتي وبهجتي اليومي إخوتي.

إلى أكبر أمثلة للعطاء والحب في حياتي جدي وخالتي.

إلى جدي رحم الله روحها التي زرعت في نفسي أجمل القيم والصفات.

ملخص الدراسة

لطالما أثارت مشكلة التنبؤ السعري في الأسواق المالية اهتمام الباحثين، وهذا لما تحمله من أهمية من جهة، ولما تحمله من خصوصية من جهة أخرى، وذلك بسبب عدم خطية التغيرات السعرية، وعدد العوامل الكبير المؤثر بالتغيرات السعرية، أضف إلى ذلك الطبيعة الاحتمالية التي تجعل مشكلة التنبؤ السعري مشكلة معقدة.

هذا ما دفع الباحثين إلى محاولة اكتشاف الأنماط المخفية المتكررة في هذه الأسواق وذلك عبر أدوات ونماذج مختلفة تم تطويرها بشكل خاص لملائمة طبيعة هذه المشكلة. من أشهر هذه النماذج هي النماذج الرياضية التي تعتمد على تعلم الآلة والذكاء الصناعي، ولذلك لما تحمله من قدرة على التعامل مع تعقيد هذه المشكلة والاستفادة من حجم المعطيات الكبير المتعلق بها.

بالاعتماد على هذه النقاط بدأت فكرة هذا البحث لمحاولة إيجاد طريقة مبتكرة لحل هذه المشكلة بدمج مكونات مختلفة في مجال الذكاء الصناعي ونظم دعم القرار. يهدف هذا البحث لتصميم وتنفيذ نظام يحل مشكلة التنبؤ السعري وبنفس الوقت لا يتنازل عن تقديم قدرة تفسيرية للمستخدم عن وضع السوق كما يسمح بالمقارنة بين عدة بدائل عند الحاجة. لحل هذه المشكلة نقترح نظام دعم قرار هجين يدمج بين شبكة عصبونية اصطناعية ونظام خبير يعتمد على قواعد المعرفة للقيام بالتنبؤ السعري، وتقديم تقارير للمستخدم تشمل رسوم بيانية تفسيرية، ونصائح بحسب وضع السوق.

يقدم النموذج المقترح نتائج عالية الدقة بالاستفادة من الشبكة العصبونية عند تدريبها بمعطيات كبيرة، ويقدم أيضاً قدرة تفسيرية بالاستفادة من النظام الخبير، وأضفنا للنموذج مصفوفة قرار موزنة، للتعامل مع عدة بدائل محتملة عند تقارب التنبؤ. يتميز نموذج NES المقترح بقدرته على توليد معطيات مشتقة إضافية من المعطيات الأولية التي يجلبها النظام من مصادرها. كما يتصف نموذج NES المقترح بالمرونة من جهة، فهو قادر على التعامل مع بدائل مختلفة وحجوم معطيات مختلفة، ومن جهة أخرى، فهو يتميز بالمتانة حيث أنه لا ينحاز إلى مكونات النموذج الأقل دقة خلال عملها.

الكلمات المفتاحية: نظم دعم القرار، الشبكات العصبونية الاصطناعية، النظم الخبيرة، تمييز الأنماط، الشموع اليابانية، المؤشرات التقنية.

Abstract

The problem of price forecasting in the financial markets has always been a big interest of researchers because of its importance, and its special features.

The main challenge comes from the non-linear price changes, the large number of factors affecting price changes, in addition to the probabilistic nature that makes the price prediction problem complex.

This motivated researchers to try to discover the hidden recurring patterns in these markets through different tools and models that were specially developed to suit the nature of this problem. Mathematical models that rely on Machine Learning and Artificial Intelligence are the most competent at this point because of their ability to deal with the complexity of this problem, and utilizing the large volume of data related to it.

Based on these points, the idea of this research emerged, to try and find an innovative way to solve this problem by integrating different components in the field of Artificial Intelligence and Decision Support Systems. This research aims to design and implement a system that solves the problem of price prediction, but at the same time does not compromise on providing an explanatory power to the user, about the market situation. In addition, it allows comparison between several alternatives when needed.

To solve this problem, we propose a hybrid decision support system that combines an Artificial Neural Network, with an Expert Knowledge-Based System, to generate user reports that include explanatory graphs, price forecasting, and market-based advice.

The proposed model provides high-accuracy results by utilizing the neural networks when training it with large data, and also provides an explanatory ability by utilizing the Expert System. The proposed NES model is distinguished by its ability to generate additional derived data from the raw data that the system fetches from its sources. The proposed NES model is characterized by flexibility, as it is able to deal with different alternatives and different data volumes, but also by robustness as it is not biased to the least accurate components of the model in practice.

Keywords: Decision Support Systems, Artificial Neural Networks, Expert Systems, Pattern Recognition, Japanese Candlesticks, Technical Indicators.

فهرس المحتويات

II	ملخص الدراسة:
V	Abstract
VI	فهرس المحتويات
XI	فهرس الأشكال
XIV	فهرس الجداول
XV	فهرس الرماز
XVI	فهرس المصطلحات والاختصارات
1	الفصل الأول التمهييد
1.1	الإطار العام للبحث
2.1	مقدمة
3.1	الأسواق المالية وتحدياتها
1.3.1	Japanese Candlesticks الشموع اليابانية
2.3.1	تحديات ومشكلات أنماط الشموع اليابانية
4.1	النمذجة التنبؤية في الأسواق المالية وتحدياتها
5.1	النظم الخبيرة (ES) Expert Systems
1.5.1	هندسة ومكونات النظم الخبيرة
6.1	الشبكات العصبونية الاصطناعية (ANN) Artificial Neural Networks
1.6.1	آلية عمل الشبكات العصبونية
1.1.6.1	المستشعر Perceptron
2.1.6.1	دوال التنشيط Activation Functions
3.1.6.1	الطبقات المخفية Hidden Layers
4.1.6.1	التعلم عبر الانتشار العكسي Learning Through Backpropagation
2.6.1	الشبكات العصبونية في حل مشاكل القطاع المالي
7.1	نظم دعم القرار في القطاع المالي
3.1	الخلفية والمشكلة
7.1	إشكالية البحث

20	1.7.1 كيفية انتقاء المتغيرات المناسبة
21	2.7.1 كيفية جلب المعطيات المناسبة ومعالجتها
21	4.7.1 طريقة بناء النظام الخبير والشبكة العصبونية الاصطناعية
22	5.7.1 طريقة التعامل مع البدائل المختلفة عند تقارب التنبؤ
23	8.1 هدف البحث
23	9.1 أهمية هذا البحث
23	10.1 موجز عن الحل المقترح
24	11.1 مساهمات البحث
25	12.1 مخطط البحث
26	الفصل الثاني الدراسة المرجعية
27	1.2 مقدمة
27	2.2 إطار المقارنة "إطار الأبعاد الأربع"
27	1.2.2 النموذج المترفع المستخدم Meta-Model
28	3.2 بناء إطار المقارنة
29	1.3.2 بعد الموضوع
29	1.1.3.2 مجال الرؤية
30	2.1.3.2 سوق النموذج
30	3.1.3.2 تحليل الاستثمار
32	2.3.2 بعد الاستخدام
32	1.2.3.2 الغاية النهائية
32	2.2.3.2 الأهداف المرحلية (الوظائف)
33	3.2.3.2 القيمة المضافة للمقاربة
33	3.3.2 بعد النموذج
33	1.3.3.2 معطيات النموذج
33	1.1.3.3.2 آلية الحصول على المعطيات
34	2.1.3.3.2 نوع المعطيات المستخدمة
34	2.3.3.2 دخل النموذج

35	3.3.3.2 نوع مقارنة النموذج
36	4.3.3.2 تقنيات النموذج
37	5.3.3.2 المؤشرات التقنية المستخدمة
38	6.3.3.2 قابلية التعلم للنموذج
39	7.3.3.2 القدرة التفسيرية للنموذج
40	4.3.2 بعد التنفيذ والتحقق
40	1.4.3.2 الأدوات المستخدمة
41	2.4.3.2 لغات البرمجة المستخدمة
42	4.4.3.2 أدوات اختبار الصحة
44	5.4.3.2 مقاييس اختبار الأداء
44	6.4.3.2 خرج التنفيذ
46	5.3.2 ملخص إطار المقارنة
48	6.3.2 المقاربات ذات الصلة بموضوع البحث
48	1.6.3.2 مقارنة (Casanova I. J, 2012)
50	2.6.3.2 مقارنة (Martinson, 2012)
51	3.6.3.2 مقارنة (C. Zopounidis, 1997)
55	4.6.3.2 مقارنة (K.H. Lee, 1999)
57	5.6.3.2 مقارنة (Murkute, 2015)
59	6.6.3.2 مقارنة (DP-LSTM, Li, 2019)
61	7.6.3.2 مقارنة (Indika, 2021)
62	7.3.2 تقييم ومقارنة المقاربات السابقة بناءً على الإطار المقترح
66	4.2 خاتمة
68	الفصل الثالث نموذج البحث
69	1.3 مقدمة
69	2.3 تذكر بمشكلة البحث
69	3.3 مفاهيم وخلفية النموذج المقترح
70	4.3 الهيكلية عالية المستوى

72	5.3. الهيكلية التفصيلية للنموذج.....
75	6.3. مكونات النموذج المقترح وسبب اختيارها.....
75	1.6.3. مكونات النظام الخبير وسبب اختيارها.....
76	2.6.3. مكونات الشبكة العصبونية وسبب اختيارها.....
77	3.6.3. مكونات المصفوفة الموزونة وسبب اختيارها.....
78	7.3. خصائص الحل المقترح.....
79	8.3. خطوات تنفيذ النموذج.....
82	9.3. خاتمة.....
83	الفصل الرابع المحاكاة وبناء النموذج الأولي.....
84	1.4. مقدمة.....
84	2.4. بيئة العمل والتطوير.....
84	3.4. بناء النموذج الأولي.....
85	1.3.4. جلب المعطيات الخام.....
88	2.3.4. توليد معطيات مشتملة.....
88	1.2.3.4. تقاطع المتوسطات المتحركة Double Moving Average.....
90	2.2.3.4. مؤشر القوة النسبية RSI.....
91	3.2.3.4. المتوسط المتحرك المتسارع EMA.....
91	4.2.3.4. مؤشر الزخم ADX.....
92	3.3.4. دمج أطر المعطيات.....
93	4.4. بناء النظام الخبير.....
95	1.4.4. بناء صفوف للمعرفة.....
97	2.4.4. الأنماط المستخدمة في نموذجنا.....
98	3.4.4. بناء قاعدة المعرفة.....
98	1.3.4.4. أنماط الهبوط وأنماط الهبوط القوية Falling & Strong Falling Patterns.....
101	2.3.4.4. أنماط الصعود وأنماط الصعود القوية Rising & Strong Rising Patterns.....
104	3.3.4.4. أنماط عدم التأكد أو المحايدة Neutral Patterns.....
105	4.3.4.4. أنماط استمرار الاتجاه القوية والضعيفة Strong & Weak Trend Continuation Patterns.....

107.....	Strong & Weak Trend Reversal Patterns	5.3.4.4 أنماط انعكاس الاتجاه القوية والضعيفة
112.....	4.4.4 هيكليّة شجرة قرار النموذج	
114.....	5.4 بناء الشبكة العصبونيّة	
114.....	Data Preparation	1.5.4 تحضير المعطيات
117.....	Time Embedding Layer	2.5.4 طبقة التضمين الزمني
120.....	Attention Transformer Layer	3.5.4 طبقة محول الانتباه
123.....	5.4 دمج تنبؤ النموذجين	
123.....	AHP	6.4 بناء مصفوفة القرار الموزّنة وتقدير الأوزان بحسب طريقة
127.....	UI	7.4 بناء واجهة استخدام لنظام النموذج المقترح
127.....	8.4 خاتمة	
129.....	الفصل الخامس التنفيذ والتحقق	
130.....	1.5 مقدمة	
130.....	2.5 اختبار أداء الشبكة العصبونيّة	
132.....	3.5 اختبار أداء النّظام الخبير	
135.....	4.5 اختبار اتساق المصفوفة الموزّنة	
136.....	5.5 قيود وتحديات البحث	
68.....	الفصل السادس النتائج والتوصيات	
139.....	1.6 مقدمة	
139.....	2.6 خلاصة البحث	
140.....	3.6 الآفاق المستقبلية	
147.....	الملاحق	
147.....	الملحق الأول (النّظام الخبير)	
149.....	الملحق الثاني (الشبكة العصبونيّة)	
149.....	الملحق الثالث (حالة عملية)	

فهرس الأشكال

3.....	الشكل (1) التمثيل البياني للشموع اليابانية (NISON, 2001)
5.....	الشكل (2) أكثر الأنماط شيوعا بحسب (MORRIS, 2006)
8.....	الشكل (3) الآلية المبسطة لعمل النظام الخبير
9.....	الشكل (4) آلية عمل المستشعر البسيط
10.....	الشكل (5) الفرق بين العصبون الاصطناعي والطبيعي
10.....	الشكل (6) معادلة وشكل تابع الخطوة
11.....	الشكل (7) معادلة وشكل التابع السيني
11.....	الشكل (8) التمثيل البياني لتابع التفعيل RELU
12.....	الشكل (9) الهيكلية العامة للشبكة العصبونية التقليدية
13.....	الشكل (10) آلية عمل خوارزمية GD بسرعات تعلم مختلفة
14.....	الشكل (11) مخطط مكونات خلايا LSTM
15.....	الشكل (12) هيكلية عمل نموذج TRANSFORMER ATTENTION
15.....	الشكل (13) الفرق بين الانتباه متعدد الرؤوس والانتباه النقطي الوحيد
17.....	الشكل (14) التسلسل المنطقي لخوارزميات MCDM
18.....	الشكل (15) مثال على مراحل التسلسل الهرمي التحليلي
24.....	الشكل (16) نمذجة أولية لفكرة مقارنة الحل
28.....	الشكل (17) النموذج المترفع لإطار المقارنة المستخدم (ALJOMAA, 2011)
29.....	الشكل (18) بنية إطار المقارنة بشكل عام
32.....	الشكل (19) الفرق بين التحليل التقني والأساسي
48.....	الشكل (20) بنية إطار المقارنة المناسب لموضوع البحث
52.....	الشكل (21) يوضح آلية عمل نظام KBDSS
53.....	الشكل (22) بنية نظام LASS لدعم قرار القروض التجارية
53.....	الشكل (23) بنية نظام FINEVA الخبير لدعم القرار
56.....	الشكل (24) هيكل الحل المقترح لدراسة
56.....	الشكل (25) شكل الشبكة العصبونية المستخدم
58.....	الشكل (26) هيكلية النظام المستخدم
60.....	الشكل (27) يعبر عن سحابة الكلمات المستخدمة
61.....	الشكل (28) يعبر عن النموذج المترفع المستخدم

71	الشكل (29) الهيكلية عالية المستوى لنموذج NES المقترح
74	الشكل (30) الهيكلية التفصيلية للنموذج المستخدم
85	الشكل (31) طريقة عرض مؤشر الخوف والجشع
87	الشكل (32) تمثيل التغيرات السعرية بالشموع اليابانية بطريقة تفاعلية باستخدام MLPFINANCE
89	الشكل (33) تمثيل نقاط البيع والشراء بيانياً باستخدام مكتبة MATPLOTLIB
91	الشكل (34) تمثيل مؤشر القوة النسبية بيانياً باستخدام مكتبة MATPLOTLIB
96	الشكل (35) الشكل العام لشجرة صفوف الأنماط
96	الشكل (36) ربط صفوف مرعة الأنماط بالنصائح للمستخدم
99	الشكل (37) النمط BLACK
99	الشكل (38) النمط BIG BLACK
99	الشكل (39) النمط BEARISH SHAVEN BOTTOM
100	الشكل (40) النمط BEARISH SHAVEN HEAD
100	الشكل (41) النمط TWEEZER TOPS
100	الشكل (42) النمط THREE BLACK CROWS
101	الشكل (43) شرط تحول النمط الهابط إلى نمط هابط قوي
101	الشكل (44) النمط WHITE
102	الشكل (45) نمط BIG WHITE
102	الشكل (46) نمط WHITE SHAVEN BOTTOM
102	الشكل (47) نمط WHITE SHAVEN HEAD
103	الشكل (48) نمط WHITE SHAVEN HEAD
103	الشكل (49) نمط THREE WHITE SOLDIERS
104	الشكل (50) شرط تحول النمط الصاعد إلى نمط صاعد قوي
104	الشكل (51) أنماط DOJI
105	الشكل (52) نمط SPINNING TOP
105	الشكل (53) نمط FALLING & RISING WINDOW
106	الشكل (54) نمط BULLISH & BEARISH SEPARATING LINE
107	الشكل (55) نمط BEAR & BULL FLAG
107	الشكل (56) شروط تحويل نمط الاستمرار لنمط استمرار قوي
108	الشكل (57) نمط BULL & BEAR HARAMI
109	الشكل (58) نمط HAMMER & HANGING MAN

109.....	الشكل (59) نمط DARK CLOUD
110.....	الشكل (60) نمط BEARISH & BULLISH DOJI STAR
110.....	الشكل (61) نمط BEARISH & BULLISH ENGULFING
111.....	الشكل (62) نمط MORNING & EVENING STAR
112.....	الشكل (63) شروط تحويل أنماط الانعكاس لأنماط انعكاس قوية
113.....	الشكل (64) مخطط شجرة المعرفة للنظام الخبير المقترح
114.....	الشكل (65) سعر إغلاق وحجم تداول عملة بيتكوين الرقمية باستخدام مكتبة MATPLOTLIB
117.....	الشكل (66) سعر الإغلاق المقسوم بعد تطبيقه باستخدام مكتبة MATPLOTLIB
118.....	الشكل (67) تمثيل الصفة غير الدورية للزمن بيانياً
118.....	الشكل (68) تمثيل الصفة الدورية للزمن بيانياً
120.....	الشكل (70) تمثيل بياني لمصفوفات الانتباه أحادية الرأس
121.....	الشكل (71) تمثيل استخراج أوزان مصفوفة انتباه أحادية الرأس
121.....	الشكل (72) دمج 3 مصفوفات أوزان انتباه أحادية الرأس
122.....	الشكل (73) الهيكلية المفصلة لطبقة التضمين ENCODER
124.....	الشكل (74) تمثيل طريقة AHP بحالتنا
128.....	الشكل (75) واجهة المستخدم المقترحة لنظام نموذجنا
131.....	الشكل (76) تغير قيمة تابع التكلفة بالنسبة لعدد الحقب
131.....	الشكل (77) مقارنة السعر المتوقع بالسعر الحقيقي
132.....	الشكل (78) مقارنة MAPE في التدريب والاختبار
134.....	الشكل (79) خوارزمية اختبار أداء النظام الخبير المقترحة
150.....	الشكل (80) عرض تسلسل عمل الشبكة العصبونية كشجرة باستخدام مكتبة TENSORFLOW
151.....	الشكل (81) نمط SPINNING TOP في هذه الحالة العملية

فهرس الجداول

28.....	الجدول (1) طريقة عرض الأوجه (ALJOURMAA, 2011)
32.....	الجدول (2) أوجه بعد الموضوع.....
33.....	الجدول (3) أوجه بعد الاستخدام.....
39.....	الجدول (4) أوجه بعد النموذج.....
46.....	الجدول (5) أوجه بعد التنفيذ والتحقق.....
46.....	الجدول (6) ملخص إطار المقارنة.....
49.....	الجدول (7) مقارنة (CASANOVA, 2012) وفق إطار المقارنة.....
51.....	الجدول (8) مقارنة (MARTINSON, 2017) وفق إطار المقارنة.....
54.....	الجدول (9) مقارنة (C. ZOPOUNIDIS, 1997) وفق إطار المقارنة.....
56.....	الجدول (10) مقارنة (K.H. LEE, 1999) وفق إطار المقارنة.....
58.....	الجدول (11) مقارنة (MURKUTE, 2015) وفق إطار المقارنة.....
60.....	الجدول (12) مقارنة (LI, 2019) بحسب إطار المقارنة.....
61.....	الجدول (13) مقارنة (INDIKA, 2021) بحسب إطار المقارنة.....
63.....	الجدول (14) إسقاط المقاربات الستة المدروسة على إطار الأبعاد الأربع الذي تم بناؤه.....
67.....	الجدول (15) مقاربتنا المقترحة وفق إطار المقارنة المقترح.....
70.....	الجدول (16) دلالات الهيكلية المستخدمة في النظام.....
84.....	الجدول (71) أهم المكاتب المستخدمة لبناء النموذج ونسخها.....
86.....	الجدول (18) مثال على إطار معطيات خام باستخدام مكتبة PANDAS.....
87.....	الجدول (19) إطار معطيات مؤشر الخوف والجشع باستخدام مكتبة PANDAS.....
90.....	الجدول (20) المتوسطات المتحركة وإشارات البيع والشراء باستخدام PANDAS.....
92.....	الجدول (21) إطار معطيات مؤشر الزخم باستخدام PANDAS.....
93.....	الجدول (22) إطار المعطيات بعد تجميعه باستخدام PANDAS.....
93.....	الجدول (23) رموز مكونات الشموع اليابانية.....
94.....	الجدول (24) أنماط الشموع اليابانية بصيغة شبه رياضية بحسب (MORRIS, 2006).....
115.....	الجدول (24) جدول يظهر تغير المعطيات بالنسبة المئوية باستخدام PANDAS.....
116.....	الجدول (26) دخل الشبكة العصبونية النهائي باستخدام PANDAS.....
125.....	الجدول (27) الشكل العام لمصفوفة معايير AHP.....
125.....	الجدول (28) مقياس أهمية المعايير بالنسبة لبعضها.....
126.....	الجدول (29) قيم أهمية المعايير بالنسبة لبعضها.....
126.....	الجدول (30) الخطوة الثانية لاستخراج الأوزان.....
127.....	الجدول (31) الخطوة الثالثة لاستخراج الأوزان.....

الجدول (32) جدول يمثل حساب مؤشر الترابط والاتساق CI	135
الجدول (33) مؤشر العشوائية بحسب حجم المصفوفة	136
الجدول (34) يمثل دلالة مجالات قيم CI	136
الجدول (35) تسلسل عمل الشبكة العصبونية	149

فهرس الرمّاز

الرمّاز (1) طريقة جلب معطيات خام للأسهم والعملات	86
الرمّاز (2) كشط مؤشر الخوف والجشع باستخدام API	87
الرمّاز (3) تابع لحساب المتوسطات المتحركة	88
الرمّاز (4) تابع لإيجاد نقاط مرجحة للبيع والشراء	89
الرمّاز (5) استخراج وتمثيل مؤشر القوّة النسبية بيانياً	90
الرمّاز (6) بناء صف معرفة الشمعة	95
الرمّاز (7) بناء صف معرفة المعلومات الإضافية	95
الرمّاز (8) بناء صفوف معرفة أنواع الأنماط	97
الرمّاز (9) أسماء جميع الأنماط المستخدمة في النظام وتصنيفها	98
الرمّاز (10) نمط BLACK	98
الرمّاز (11) نمط BIG BLACK	99
الرمّاز (12) حساب التغير بالنسبة المئوية لإطار المعطيات	115
الرمّاز (14) بناء طبقة التضمين الزمني	119
الرمّاز (15) نمط 3WHITE SOLDIERS	147
الرمّاز (16) نمط 3BLACK CROWS	147
الرمّاز (17) نمطا RISING WINDOW و BEARISH SHAVEN BOTTOM	147
الرمّاز (18) أنماط BEARISH/BULLISH SHAVEN HEAD, TWEEZER BOTTOMS	148
الرمّاز (19) نمطا DOJI, BULLISH DOJI STAR	148

فهرس المصطلحات والاختصارات

الاختصار	المصطلح باللغة الانكليزية	المصطلح باللغة العربية
–	Japanese Candlesticks	الشموع اليابانية
–	Pattern Recognition	تمييز الأنماط
–	Bullish	صاعد
–	Bearish	هابط
EMH	Efficient Market Hypothesis	فرضية السوق الفعال
RW	Random Walk Theory	نظرية المسير العشوائي
–	Predictive Modeling	النمذجة التنبؤية
TA	Technical Analysis	التحليل التقني
FA	Fundamental Analysis	التحليل الأساسي
SVM	Support Vector Machines	آلات دعم المتجه
–	Auto Regression	الانحدار التلقائي
ARMA	Auto Regressive Moving Average	المتوسط المتحرك المنحدر تلقائياً
ARIMA	Auto Regressive Integrated Moving Average	المتوسط المتحرك المدمج المنحدر تلقائياً
ES	Expert Systems	النظم الخبيرة
KB	Knowledge Base	قاعدة المعرفة
KBS	Knowledge Based Systems	النظم القائمة على المعرفة
WM	Working Memory	الذاكرة العاملة
–	Inference Engine	محرك الاستدلال
UI	User Interface	واجهة الاستخدام
NLP	Natural Language Processing	معالجة اللغات الطبيعية
–	Forward Chaining	الاستدلال الأمامي
–	Backwards Chaining	الاستدلال الخلفي
–	Conflict Resolution	حل نزاعات المعرفة
–	Normalization	التطبيع
DSS	Decision Support Systems	نظم دعم القرار
MCDM	Multi Criteria Decision Making	اتخاذ قرار متعدد المعايير
MCDSS	Multi Criteria Decision Support System	نظام دعم قرار متعدد المعايير
AHP	Analytical Hierarchy Process	طريقة التسلسل الهرمي التحليلي
PEST	Political Economic Social Technological Analysis	تحليل الظروف السياسية الاقتصادية الاجتماعية التكنولوجية
ARCH	Autoregressive Conditionally Heteroscedastic	الانحدار التلقائي غير المتجانس

خوارزميات Ensemble	Ensemble Algorithms	–
متوسط الأخطاء المطلقة بالنسبة المئوية	Mean Absolute Percentage Error	MAPE
إطار الأبعاد الأربع	Four Views Framework	–
المعطيات الخام	Raw Data	–
المعطيات المشتقة	Derived Data	–
المعطيات المهيكلة	Structured Data	–
المعطيات شبه المهيكلة	Semi-Structured Data	–
المعطيات غير المهيكلة	Unstructured Data	–
أسعار السوق (افتتاح، أعلى، أدنى، إغلاق)	Market Price (Open, High, Low, Close)	OHLC
المؤشرات التقنية	Technical Indicators	TI
مؤشرات المشاعر	Sentiment Indicators	SI
النظام الهجين	Hybrid System	–
تصنيف Naïve Bayes	Naïve Bayes Classification	–
خوارزميات المجموعات الغائمة	Fuzzy Sets Algorithms	–
الخوارزميات الجينية	Genetic Algorithms	GAs
المنهجيات الهجينة	Hybrid Approaches	–
متوسط مؤشر الاتجاه	Average Directional Movement Index	ADX
مؤشر انحراف التقارب المتوسط المتحرك	Moving Average Convergence Divergence	MACD
مؤشر القوة النسبية	Relative Strength Index	RSI
نسبة السعر إلى الأرباح	Price To Earnings Ratio	P/E
الربحية بالنسبة للسهم	Earnings Per Share	–
المتوسط المتحرك البسيط	Simple Moving Average	SMA
المتوسط المتحرك الأسّي	Exponential Moving Average	EMA
مؤشر الخوف والجشع	Fear & Greed Index	F&G
العائد على الاستثمار	Return on Investment	ROI
متوسط دقة التنبؤ	Mean Prediction Accuracy	MPA
متوسط مربع الأخطاء	Mean Standard Error	MSE
نسبة الإصابة	Hit Ratio	–
المحاكاة	Simulation	–
التصنيف	Classification	–
التصنيف الثنائي	Binary Classification	–
هيكلية النموذج	Model Architecture	–
نظام خبير عصبوني	Neuro Expert System	NES
صفات السوق	Market Qualities	–

زخم السوق	Market Momentum	–
شراء بشكل مجحف	Over Bought	–
بيع بشكل مجحف	Over Sold	–
مصفوفة عدم تأكد	Confusion Matrix	–
مقود بالمعطيات	Data Driven	–
لغة برمجة غرضية التوجه	Object Oriented Programming Language	OOPL
التقلب	Volatility	–
وحدات معالجة الرسومات	Graphical Processing Unit	GPU
واجهة برمجة التطبيق	Application Programming Interface	API
عداد	Ticker	–
صقل المعطيات	Data Smoothing	–
التقاطع الذهبي	Golden Cross	–
التقاطع المميت	Death Cross	–
ليس رقم	Not A Number	NAN
مؤشر الاتجاه الإيجابي	Directional Movement Positive	DMP
مؤشر الاتجاه السلبي	Directional Movement Negative	DMN
نمط غير دوري	Non-Periodic Pattern	–
نمط دوري	Periodic Pattern	–
الغابات العشوائية	Random Forest	–
التصويت	Voting	–
المتوسطات المقتلة	Weighted Averaging	–
التكديس	Stacking	–
مؤشر الاتساق	Consistency Index	CI
مؤشر العشوائية	Random Index	RI
روبوت تداول	Trading Bot	–
الذكاء الاصطناعي	Artificial Intelligence	AI
الشبكات العصبونية الاصطناعية	Artificial Neural Networks	ANN
الشبكات العصبونية المتكررة	Recurrent Neural Network	RNN
الشبكة العصبونية التشريحية	Convolutional Neural Networks	CNN
الشبكات العصبونية الاحتمالية	Probabilistic Neural Network	PNN
الشبكات العصبونية أمامية التغذية	Feed Forward Neural Networks	FFNN
المستشعر	Perceptron	–
الوزن	Weight	–
الانحياز	Bias	–

توابع التنشيط	Activation Function	–
تابع تنشيط الخطوة	Heaviside Activation Function	–
تابع التنشيط السيني	Sigmoid Activation Function	–
تابع تنشيط SoftMax	SoftMax Activation Function	–
تابع تنشيط الوحدة الخطية المصححة	Rectified Linear Unit Activation Function	ReLU
الانتشار العكسي	Back Propagation	BP
تابع التكلفة	Loss Function	–
تابع تكلفة Sparse Categorical Crossentropy	Sparse Categorical Crossentropy Loss Function	–
خوارزمية أمثلة ADAM	ADAM Optimization Algorithm	–
قاعدة السلسلة	Chaining Rule	–
نزول التدرج	Gradient Descent	GD
الطبقات المخفية	Hidden Layers	–
التعلم الآلي	Machine Learning	ML
حزم	Batches	–
حقب	Epochs	–
سلسلة	Sequence	–
الانتباه متعدد الرؤوس	Multi-Headed Attention	–
الانتباه وحيد الرأس	Single- Headed Attention	–
الذاكرة طويلة، قصيرة المدى	Long - Short Term Memory	LSTM
نموذج انتباه المحولات	Attention Transformer Model	–
نموذج التضمين، فك التضمين	Encoder Decoder Model	–
أزواج القيمة والمفتاح	Key- Value Pairs	K-V
سحابة الكلمات	Word Cloud	–
أدنى قيمة محلية	Local Minima	–
الإفراط في التناسب	Over Fitting	–
من زمن لمتجه	Time to Vector	Time2Vec
التسرب	Drop Out	–
ضبط دقيق	Fine Tuning	–
بوابة نسيان	Forget Gate	–
معطيات تحقق	Validation Data	–
معطيات اختبار	Testing Data	–
معطيات تدريب	Training Data	–
كشط المعطيات	Data Scrapping	–

الفصل الأول

التمهيد

1.1 الإطار العام للبحث

يندرج هذا البحث ضمن إطار إدارة نظم المعلومات، وتحديدًا نظم دعم القرار، وذلك عن طريق إنشاء نظام خبير وشبكة عصبونية اصطناعية للقيام بالتنبؤ بسعر الفترة القادمة، بالاستفادة من المعطيات المتاحة في أسواق الأوراق المالية وأسواق العملة الالكترونية.

يهدف هذا النظام لتقديم بيئة تساعد صناع القرار بالقيام بقرارات مناسبة في ظل التغيرات اليومية المستمرة وذلك من خلال الاستفادة من معارف خبير في مجال مشكلة التنبؤ السعري في الأسواق المالية، والتعرف على الأنماط التي قد تكون مبهمة لمتخذ القرار في السلاسل الزمنية السعريّة للأسواق المالية، وتقديم تقارير تدعم هذا التنبؤ ليستفيد منها المستخدم الأخير للنظام.

2.1 مقدمة

لطالما كانت مشكلة التنبؤ بالأحداث المستقبلية مشكلة تثير فضول البشرية لما تحمله من فائدة في حال حلها، وأحد أهم أجزاء هذه المشكلة في العالم الحديث القدرة على التنبؤ بالأسعار المستقبلية، لما يحمل حل هذه المشكلة من فائدة للعديد من أصحاب المصلحة في شتى القطاعات الصناعية والمالية، كما أن النماذج التي طوّرت لحل هذه المشكلة شاهدة تسارعاً كبيراً في القرن الأخير، بدءاً بنماذج الانحدار البسيط والمتعدد إلى نماذج أكثر تعقيداً كالمتوسطات المتحركة وظهرت المؤشرات المالية كأدوات مساعدة لحل هذه المشكلة وظهرت نماذج تمثيل بياني جديدة كالشموع اليابانية، كأداة تعبيرية ممتازة للتغيرات السعريّة وهي المستخدمة في هذه الدراسة كما ظهرت بعدها أدوات أكثر تعقيداً لحل هذه المشكلة كونها شديدة التعقيد، وذلك لشبه استحالة حصر متغيراتها من شركات ومستثمرين (كسوق مفتوح وحر) ومتغيرات سياسية اقتصادية بيئية كـ بعض أهم المتغيرات التي تؤثر على السوق. فيمكن القول إن هذه المشكلة احتمالية بامتياز، وهذا ما دفع الباحثين لتطوير أدوات أكثر تعقيداً، كالأنظمة الخبيرة والشبكات العصبونية وإدخال مفاهيم رياضية احتمالية، كالمنطق الغائم لمواجهة الطبيعة الاحتمالية للمشكلة وهذا ما سنهدف إلى مواجهته في بحثنا.

3.1 الأسواق المالية وتحدياتها

بدأت نواة لفكرة البورصة في بلجيكا في عام 1531 في مدينة أنتويرب، حيث بدأت باجتماع عدد من السماسرة والمقرضين للتعامل مع قضايا الديون التجارية والحكومية والفردية. إلا أن هذه الظاهرة لا يمكن اعتبارها أول سوق مالي حقيقي، ففي القرن السادس عشر لم تكن هناك أسهم حقيقية، بالرغم من وجود عدد من نوى شركات تمويل الأعمال التي تنتج دخلاً كما تفعل الأسهم، إلا أنه لم يكن هناك حصة رسمية تم تداولها. (Smith, 2004) أما أول سوق بورصة رسمي مسجل هي بورصة أمستردام، فهي أقدم سوق للأوراق المالية بحسب المعايير الحديثة في العالم. تأسست بورصة أمستردام للأوراق المالية في عام 1602 من قبل شركة الهند الشرقية الهولندية Verenigde Oostindische Compagnie (VOC)، للتعامل في الأسهم والسندات المطبوعة. تم تغيير اسمها لاحقاً إلى بورصة أمستردام، وكانت أول من بدأ رسمياً تداول الأوراق المالية. (Braudel .F, 1982)

يمكن القول إن أهم وظيفة لسوق الأوراق المالية هي رعاية المشاريع الريادية وتسهيل التمويل للشركات الجديدة والمبتكرة. فسوق الأوراق المالية يعمل بشكل فعال، بآلية أنه يخصص رأس المال بكفاءة ويوفر الأموال الكافية للشركات المنتجة، والتي بدورها تشجع المنافسة والابتكار، وفي النهاية يكافئ نماذج الأعمال الكفؤة ويخرج بشكل تلقائي النماذج التي لا تعمل. بشكل مختصر فإن فكرة الأسواق المالية تأتي من مفهوم تسهيل الوصول لوسائل الإنتاج للشركات القادرة على ذلك، وهذا ما يحرك العجلة الاقتصادية. مع ذلك، فإن الأدبيات لم تستطع إيجاد مقدار مساهمة الأسواق المالية بشكل دقيق للنمو الاقتصادي (Zingales, 2003). أما السهم (المعروف أيضاً باسم حقوق الملكية) هو ورقة مالية تمثل ملكية جزء صغير من الشركة. يمنح هذا مالك السهم نسبة من أصول الشركة وأرباحها مساوية لمقدار الأسهم التي يمتلكونها. (Hayes, A, 2022) يعتمد عائد الاستثمار، أو ما يحصل عليه المستثمر من أرباح، على نجاح أو فشل تلك الشركة. إذا كانت الشركة تعمل بشكل جيد وتحقق أرباحاً من المنتجات أو الخدمات التي تبيعها، فإن المستثمر يستفيد نتيجة لذلك.

هناك طريقتان رئيسيتان لكسب المال من الأسهم الطريقة الأولى أرباح الأسهم، فعندما تكون الشركات المدرجة في السوق مربحة، يمكنهم اختيار توزيع بعض هذه الأرباح على المساهمين عن طريق دفع أرباح. إما يأخذ المستثمر أرباح الأسهم نقدًا أو يعيد استثمارها لشراء المزيد من الأسهم في الشركة. يشار إلى الأسهم التي تدفع أرباحاً أعلى من المتوسط أحياناً باسم "أسهم الدخل". الطريقة الثانية عبر أسهم مكاسب رأس المال، حيث يتم شراء الأسهم وبيعها باستمرار طوال كل يوم تداول، وتتغير أسعارها باستمرار. عندما يرتفع سعر السهم أعلى مما دفع المستثمر لشراؤه، يمكنه بيع أسهمه بربح. تُعرف هذه الأرباح باسم مكاسب رأس المال. في المقابل، إذا قام ببيع الأسهم بسعر أقل مما دفعه لشراؤه، فهي خسارة رأس المال. (Hayes, A, 2022)


تعتمد كل من أرباح الأسهم ومكاسب رأس المال على التدفقات النقدية للشركة، فمن جهة توزيعات الأرباح نتيجة لأرباح الشركة ومن جهة أخرى مكاسب رأس المال بناءً على طلب المستثمر على الأسهم. يعكس الطلب عادة احتمالات الأداء المستقبلي للشركة. الطلب القوي نتيجة رغبة العديد من المستثمرين في شراء سهم معين يؤدي إلى زيادة سعر سهم السهم. من ناحية أخرى، إذا كانت الشركة غير مربحة أو إذا كان المستثمرون يبيعون أسهمها بدلاً من شرائها، يؤدي هذا لانخفاض سعر السهم. (Hayes, A, 2022)

1.3.1 الشموع اليابانية Japanese Candlesticks

تعد مخططات الشموع اليابانية شكلاً من أشكال التحليل الفني، وهي أداة متعددة الاستخدامات يمكن دمجها مع أي أداة فنية أخرى، وستساعد في تحسين أي تحليل فني للسوق من خلال تمثل حجم حركات الأسعار بشكل مرئي بألوان مختلفة لاتخاذ القرارات بناءً على الأنماط التي تحدث بانتظام والتي تساعد في التنبؤ بالاتجاه قصير المدى للسعر. (Nison, 2001)

تستخدم الشموع اليابانية بكثرة في هذا المجال لقدرتها التعبيرية العالية عما يحدث في السوق من ناحية العرض والطلب وهي مؤلفة من أربع مكونات، سعر الافتتاح والسعر الأعلى والسعر الأدنى وسعر الإغلاق، يسمى مربع مخطط الشموع بالجسم الحقيقي ويقاس الفرق بين أسعار الفتح والإغلاق. إذا كان سعر الإغلاق أعلى من سعر

الافتتاح، فإن الجسم يكون أبيض (أو أخضر). بمعنى آخر، الجسم الأبيض يعني ارتفاع الأسعار خلال اليوم. أما إذا كان سعر الإغلاق أقل من سعر الافتتاح، فإن الجسم يكون أسود (أو أحمر) اصطلاحاً. بمعنى آخر، الجسم الأسود يعني انخفاض الأسعار خلال اليوم. إذا كانت أسعار الإغلاق والفتح متطابقة، فسيكون الجسم الحقيقي مجرد خط أفقي يسمى دوجي. الخطوط الرأسية أعلى وأسفل جسم الشمعة هي الظلال. يسمى أعلاه الظل العلوي، في حين أن الظل السفلي يسمى الظل السفلي. وهي تمثل الأسعار المرتفعة والمنخفضة على التوالي ضمن إطار زمني محدد، ويمكن تمثيلها بألوان أخرى، الأكثر شيوعاً هو اللون الأخضر للشموع الصاعدة والأحمر للشموع الهابطة ويمكن تمثيلها بيانياً بالشكل التالي: (Tharavanij et al, 2017)




الشكل (1) التمثيل البياني للشموع اليابانية (Nison, 2001)

أما تمييز الأنماط Pattern Recognition فهي القدرة على التعرف على مجموعة كاملة معقدة تتكون أو مضمنة في العديد من العناصر المنفصلة الأبسط، وقد يكون تمييز الأنماط بصرياً أو التعرف على الأنماط الزمنية للأصوات أو تمييز أنماط رياضية عن طريق خوارزميات ويمكن التعرف على الأنماط من خلال المعرفة المكتسبة مسبقاً، أو بناءً على المعلومات المستخرجة إحصائياً كمعرفة جديدة. (Toussaint, 2014)


يمكن تصنيف أنماط الشموع إلى أنماط ليوم واحد ويومين وثلاثة أيام، عادة يمثل اليوم الواحد شمعة يومية. إذا كان النمط يشير إلى استمرار الاتجاه الحالي، فهو نمط استمراري. في المقابل، إذا كان يشير إلى تغيير في الاتجاه، فهو نمط انعكاس. يقترح (Nison, 1991) بأن أنماط الانعكاس أكثر أهمية لأنها ستساعد المتداولين على الشراء عند القاع والبيع عند الذروة. يوجد أكثر من 60 نمط شائع للشموع اليابانية إلا أننا سنذكر طريقة تمثيل بعض أهمها كصيغة شبه رياضية وتفسير طريقة قراءة النمط باللغة المحكية، الآن سنستعرض مخططاً موسعاً يحتوي

بالترتيب أهم الأنماط المستخدمة بالمجال بحسب (Morris, 2006)، وذلك بالترتيب بحسب قوة النمط وبحسب الفترات الزمنية للنمط (نمط مكون من فترة واحدة، نمط مكون من فترتين، نمط مكون من ثلاث فترات)


Bullish patterns (ordered according to signal strength)




Bearish patterns (ordered according to signal strength)




Bullish patterns



Bearish patterns





الشكل (2) أكثر الأنماط شيوعاً بحسب (Morris, 2006)

2.3.1 تحديات ومشكلات أنماط الشموع اليابانية

من المثير للدهشة أنه على الرغم من تاريخها الطويل وشعبيتها، لا يوجد حتى الآن اتفاق حول ما إذا كان هذه الأداة مربحة أم لا. أما بالنسبة لفعالية هذه الأنماط فتبين لبعض الباحثين أن أنماط الشموع غير موثوقة بنهاية الأمر وقدرتها التنبؤية محدودة ولا يمكن الاعتماد عليها لأنها لا تعتمد على معلومات كافية وأن متغير السعر يؤثر فيه عدد كبير من المتغيرات التي لا يمكن حصرها، مثل (Marshall, 2006) و (Horton, 2009) التي طبقت أبحاثهم على سوق الأوراق الأمريكية واليابانية وغيرهم من باحثين الذين عارضوا فكرة استخدام هذه الأنماط كأداة تنبؤية جيدة. مع ذلك وجد باحثون آخرون أن الاعتماد على هذه الأنماط مربح على المدى القصير، مثل أبحاث (Goo et al, 2007) و (Lu et al, 2012) التي طبقت على سوق الأوراق المالية الصينية والتاوانية.

إضافةً لذلك، تنص فرضية السوق الفعال EMH على أن أسعار الأوراق المالية تعكس بالفعل جميع المعلومات المتاحة وذات الصلة (Fama, 1970). نتيجة لذلك، لا يمكن أن يؤدي التحليل التقني بما في ذلك أنماط الشموع التي تستخدم معطيات التداول التاريخية فقط إلى عوائد إيجابية غير طبيعية. مع ذلك فإنه يوجد باحثون ينقضون فرضية السوق الفعال بفرضيات معاكسة أي أن الأسواق غير فعالة بشكل كامل. أما وفقاً لنظرية RW Random Walk Theory فإن سعر السهم يجري "مسيراً عشوائياً"، مما يعني أن جميع الأسعار المستقبلية لا تتبع أي اتجاهات أو أنماط، وهي انحراف تلقائي عن الأسعار السابقة، ولا يمكن للمستثمر توقع السوق (Fama, 1995). يمكن القول إنه حتى لو كانت أنماط الشموع اليابانية فعالة إلا أنها مقيدة بالعديد من العوامل لذلك يجب إضافتها كعامل إضافي لأدوات أخرى أو كإشارة دخول أو خروج من السوق بعد النظر إلى عوامل عديدة أخرى.

4.1 النمذجة التنبؤية في الأسواق المالية وتحدياتها

تشكل النمذجة التنبؤية في الأسواق المالية فحوى أغلب الأبحاث العلمية في هذا المجال وذلك لما تحمله من أهمية لأصحاب المصلحة من مستثمرين، ويمكن تعريف النمذجة التنبؤية Predictive Modeling، بأنها عملية تقديم نموذج إحصائي أو خوارزمية تنقيب معطيات، لغرض تقديم تنبؤ كخرج Y لهذا النموذج لوقت $t+k$ ، $k>0$ حيث أن k هي مدة زمنية أكبر من الصفر، وباختصار، أي نموذج قادر على القيام بتنبؤ مستقبلي بدرجة ثقة معينة بغض النظر عن المقاربة المستخدمة والأدوات لبناء النموذج يعتبر نموذج تنبؤي. يجدر بالذكر أن كل النماذج التنبؤية التي تم بنائها كأدوات للتنبؤ في الأسواق المالية بنهاية الأمر تصب ضمن التحليل التقني TA أو التحليل الأساسي FA. (Geisser, 2019)

تذكر (Chopra et al, 2021) بمراجعتها المنهجية أن أكثر من 88 بالمئة من الأبحاث التي تمت مراجعتها قد درست المقارنة من أجل التحقق من دقة نماذجها المعيارية، مما يبين أن أغلب الأبحاث لمشكلة التنبؤ السعري تهتم كأولوية قاطعة بكسر عتبة دقة التنبؤ للنماذج السابقة. أغلب المنهجيات المستخدمة كانت عبارة عن شبكات عصبونية أو عصبونية هجينة، بما في ذلك الخرائط المعرفية الضبابية، وآلات الدعم Support Vector Machines (SVM) والشبكات العصبونية أمامية التغذية Feed Forward Neural Networks (FFNN) والشبكات العصبونية المتكررة Recurrent Neural Networks (RNN)، والشبكات العصبونية الاحتمالية Neural Networks (PNN)، وغيرها فيما يتعلق بالتقنيات التقليدية، مثل نماذج الانحدار بجميع تفرعاتها وعائلة GARCH، Probabilistic، وغيرها فيما يتعلق بالتقنيات التقليدية، مثل نماذج الانحدار بجميع تفرعاتها وعائلة GARCH، بالأنحصر والانحدار التلقائي (AR)، والمتوسط المتحرك المنحدر تلقائياً Auto Regressive (ARMA)، والمتوسط المتحرك المدمج المنحدر تلقائياً Integrated Moving Average (ARIMA)، ونماذج النظم الخبيرة، ونماذج المسير العشوائي RW، والنماذج الخطية وغير الخطية. يتم إجراء المقارنة بالتبادل مع أي من الأساليب التقليدية وغير التقليدية علاوة على ذلك، في الأبحاث التي شملتها المراجعة المنهجية، تُظهر نماذج الذكاء الاصطناعي أداءً أفضل عند مقارنتها بالنماذج التقليدية. أما بالنسبة لتطبيق هذه النماذج، فعادةً تطبق في مجال الأسواق المالية للقيام بالتحليل التقني TA لسهولة أتمتة النظام وتوفير المعطيات المناسبة، فهي قادرة على استخدام جميع النماذج السابقة فيها. أما بالنسبة للتحليل الأساسي FA فمجال تطبيقات النماذج تصبح أضيق، إلا أنه تستخدم نماذج الانحدار الخطي، وطرق تحويل المتغيرات النوعية لكمية، كما تعتبر نظم خبيرة ونظم دعم قرار ذات استخدام شائع، بسبب سهولة النسبية لمحاكاة قرارات خبير عند مقارنة عدة بدائل، كما يمكن إدخال مفهوم المنطق الغائم إلى هذه النماذج لسهولة الدمج بينها، وكونها مناسبة لمحاكاة ظروف عدم التأكد المترافقة مع قرارات الاستثمار. (Rouf et al, 2021)

5.1 النظم الخبيرة (Expert Systems (ES

يمكن تعريف النظام الخبير على أنه برنامج يستخدم تقنيات الذكاء الاصطناعي (Artificial Intelligence (AI، لمحاكاة حكم وسلوك الإنسان أو المنظمة التي لديها معرفة وخبرة في مجال معين. عادةً ما يشتمل النظام الخبير على قاعدة معرفية تحتوي على الخبرة المتراكمة ومحرك الاستدلال أو مجموعة من القواعد لتطبيق قاعدة المعرفة

على كل حالة معينة موصوفة للبرنامج، كما يمكن تعزيز قدرات النظام بإضافات إلى قاعدة المعرفة أو إلى مجموعة القواعد. قد تتضمن الأنظمة الحالية قدرات تعلم الآلة التي تسمح لها بتحسين أدائها بناءً على الخبرة، تمامًا كما يفعل البشر. (Feigenbaum, 1992) غالبًا ما يتم الخلط بين النظم الخبيرة والنظم القائمة على المعرفة إلا أن النظام القائم على المعرفة Knowledge Based System نظام برمجي يستخدم قاعدة معرفية لدعم عمليات التفكير لحل مشكلة في فضاء تطبيق معين. الأنظمة الخبيرة هي أمثلة على ذلك، لكن الأنظمة القائمة على المعرفة يمكن أن تتخذ أشكالًا أخرى كثيرة ويمكن العثور عليها في العديد من مجالات الذكاء الاصطناعي. (Feigenbaum, 1992)

1.5.1 هندسة ومكونات النظم الخبيرة


طور مهندسو المعرفة العديد من التقنيات التي يمكن استخدامها لابتكار بنى أنظمة خبير مناسبة. هذه الأساليب مختلفة تشترك بعدة مكونات وهي التي تجعل النظام الخبير ما هو عليه نذكرها بشكل مختصر بالشكل التالي:

- قاعدة المعرفة (KB) Knowledge Base: مستودع للاستدلال أو القواعد الخاصة التي توجه استخدام المعرفة والحقائق. يحتوي على المعرفة اللازمة للفهم والصياغة وحل المشكلات. (Lebowitz. M, 1989)
- الذاكرة العاملة (WM) Working Memory: تحتوي الذاكرة العاملة فقط على الحقائق التي تصف الحالة الحالية لمشكلة. يمكن مقارنتها مع ذاكرة الوصول العشوائي للكمبيوتر الشخصي، أو الذاكرة قصيرة المدى للعقل البشري. (Lebowitz. M, 1989)
- أما محرك الاستدلال Inference Engine فهو يحاكي عملية التفكير، وتوجد القواعد في قاعدة المعرفة التي تتوافق مع محتويات الذاكرة العاملة ويطبقها على المشكلة. (Newell et al, 1972)
- واجهة الاستخدام (UI) User Interface: توفر تسهيلات للتفاعل مع النظام، حيث قد يطلب ES من المستخدم بعض أسئلة للمستخدم، من خلال معالجة اللغة الطبيعية (NLP) Natural Language Processing، أو القوائم والرسومات. يعمل كوسيط لنقل المعطيات والمعرفة. (Newell et al, 1972)

تستخدم النظم الخبيرة نوعين من الخوارزميات نسميها خوارزميات استدلال. الأولى، هي التسلسل الأمامي Forward Chaining (أو الاستدلال الأمامي)، وهي إحدى الطريقتين الرئيسيتين للاستدلال عند استخدام محرك الاستدلال ويمكن وصفه منطقيًا بأنه تطبيق متكرر للوضعيات. التسلسل إلى الأمام هو إستراتيجية تنفيذ شائعة للأنظمة الخبيرة وأنظمة قواعد الأعمال والإنتاج. يبدأ التسلسل الأمامي بالمعطيات المتاحة ويستخدم قواعد الاستدلال لاستخراج المزيد من المعطيات (من المستخدم النهائي مثلاً) حتى يتم الوصول إلى الهدف. يبحث محرك الاستدلال الذي يستخدم التسلسل الأمامي في قواعد الاستدلال حتى يعثر على واحدة حيث يُعرف أن السابقة (If) صحيحة. عندما يتم العثور على مثل هذه القاعدة، يمكن للمحرك أن يستنتج، أو يستدل، ما يترتب على ذلك (عبارة then)، مما يؤدي إلى إضافة معلومات جديدة إلى معطياته. ستقوم محركات الاستدلال بالتكرار خلال هذه العملية حتى يتم الوصول إلى الهدف. (Feigenbaum, 1992)

أما الثانية، فهي التسلسل العكسي (أو الاستدلال العكسي) Backwards Chaining هي طريقة استدلال توصف بأنها تعمل للخلف من الهدف وتولد الأهداف أهدافاً فرعية لنصل إلى معارف جديدة من المعارف السابقة وتكرر

هذه العملية ويصبح بإمكاننا تطبيق قواعد أكثر في محرك الاستدلال حتى نصل إلى الهدف الأساسي. يتم استخدامها في محركات الاستدلال، وتطبيقات الذكاء الاصطناعي الأخرى وعادة ما تستخدم هذه الطريقة الاستراتيجية البحث في العمق (Russell & Norvig, 2009). لكن إذا أمكن للنظام تطبيق عدة قواعد تقع في مشكلة نزاع معرفة، ونحل هذه المشكلة بعدة طرق نسميها حلول نزاعات المعرفة Conflict Resolution فلا بد أن يحدث تعارض التصنيف عند مطابقة أكثر من قاعدة مع الحقائق المؤكدة. تُستخدم استراتيجيات حل النزاعات في أنظمة الإنتاج في الذكاء الاصطناعي، كما هو الحال في الأنظمة الخبيرة القائمة على القواعد، للمساعدة في اختيار القاعدة التي سيتم تنفيذها. تنشأ الحاجة إلى مثل هذه الاستراتيجية عندما يتم استيفاء شروط قاعدتين أو أكثر من خلال قواعد الحقائق المعروفة حالياً. (Forgy, 1976). يوضح الشكل التالي الآلية المبسطة لعمل النظام الخبير.



الشكل (3) الآلية المبسطة لعمل النظام الخبير

6.1 الشبكات العصبونية الاصطناعية (Artificial Neural Networks (ANN)


غالبًا ما تُستخدم الشبكات العصبونية للتحليل الإحصائي ونمذجة المعطيات، حيث يُنظر إلى دورها على أنه بديل للانحدار ولعدد كبير من تقنيات التحليل وتعلم الآلة (Cheng, 1994). بالتالي، يتم استخدامها عادة في المشاكل التي قد تصاغ من حيث التصنيف أو التنبؤ. بعض الأمثلة تتضمن التعرف على الصور والكلام، والتعرف على الأحرف النصية، ومجالات الخبرة البشرية مثل التشخيص الطبي والمسح الجيولوجي، والتنبؤ بمؤشرات السوق المالية. هذا النوع من المشاكل يقع أيضاً ضمن مجال الذكاء الاصطناعي الكلاسيكي يرى الباحثون أن الشبكات العصبونية تقدم أسلوباً جديداً للحوسبة الموزعة المتوازية، وبالتالي توفر بديل لتقنيات الخوارزمية التقليدية. (Lawrence, 1994)

1.6.1 آلية عمل الشبكات العصبونية

تحاكي الشبكات العصبونية بشكل فضفاض الطريقة التي تحل بها أدمغتنا المشكلة عن طريق أخذ المدخلات ومعالجتها وتوليد المخرجات. مثل الإنسان، تتعلم الشبكات كيفية التعرف على الأنماط، لكنها تفعل ذلك من خلال التدريب على مجموعات المعطيات المصنفة. قبل أن نصل إلى الشبكة ككل، نلقي نظرة على أبسط الخلايا العصبونية الاصطناعية (المستشعر)، وكيف يعالج المدخلات وينتج المخرجات.

1.1.6.1 Perceptron المستشعر

تم تطويره في الخمسينيات من القرن الماضي من قبل الباحث (Rosenblatt, 1958)، بينما نستخدم اليوم نماذج مطورة من الخلايا العصبونية الاصطناعية، إلا أنها تتبع المبادئ العامة التي وضعها للمستشعر. يأخذ المستشعر عدة مدخلات ثنائية، $(0,1)$ $x_1, x_2, x_3 \dots$ ، وينتج ناتجًا ثنائيًا واحدًا على الشكل التالي:



الشكل (4) آلية عمل المستشعر البسيط

يطبق المستشعر دالة خطية على المدخلات وإذا كان الناتج أكبر من عتبة ما، فإن الخرج يكون 1 أما إذا كان أقل من العتبة، فيكون الخرج 0. (Rosenblatt, 1958) ويمكن تمثيل ذلك رياضياً بالشكل التالي:

$$\text{If } \sum_i w_i x_i < \text{threshold} \text{ then output} = 0$$

$$\text{If } \sum_i w_i x_i \geq \text{threshold} \text{ then output} = 1$$

في الصيغة أعلاه تمثل x_i الدخل ذو المؤشر i وتمثل w_i الوزن ذو المؤشر i وهي نفسها أمثال المجاهيل في المعادلات الخطية التقليدية ويمكن تعديل الصيغة الرياضية أعلاه لتصبح بالشكل الحالي للعصبون. فننقل العتبة إلى الجانب الآخر من عدم المساواة، ونستبدلها بما يُعرف باسم انحياز العصبون. الآن يمكننا إعادة كتابة المعادلة بالشكل التالي (Rosenblatt, 1958):

$$\text{If } \sum_i w_i x_i - \text{bias} < \text{then output} = 0$$


$$\text{If } \sum_i w_i x_i - \text{bias} \geq \text{then output} = 1$$

في البداية نقوم بشكل عشوائي بتعيين أرقام للأوزان لأننا لا نعرف الأرقام الصحيحة مسبقاً، وبما أن الشبكة العصبونية تتدرب، فإنها تُجري تغييرات تدريجية على تلك الأوزان لإنتاج مخرجات أكثر دقة. بالمثل، لا نعرف قيمة العتبة الصحيحة، ومبدأ الشبكة العصبونية أنها تجري تغييرات على العتبة (الانحياز) والوزن لإنتاج مخرجات أكثر دقة. الآن مع الانحياز، نحتاج فقط إلى إجراء تغييرات على الجانب الأيسر من المعادلة، بينما يمكن أن يظل الجانب الأيمن ثابتاً. (Goodfellow et al, 2017)

2.1.6.1 دوال التنشيط Activation Functions

ببساطة، دالة التنشيط هي دالة تضاف إلى الشبكة العصبونية لمساعدة الشبكة على تعلم الأنماط المعقدة في المعطيات. عند المقارنة بنموذج قائم على الخلايا العصبونية الموجود في أدمغتنا، فإن وظيفة التنشيط هي في النهاية تحديد ما يجب إطلاقه على الخلية العصبونية التالية. هذا هو بالضبط ما تفعله وظيفة التنشيط في ANN


أيضاً. يأخذ إشارة الخرج من الخلية السابقة ويحولها إلى شكل يمكن أخذه كمدخل للخلية التالية. (Goodfellow et al, 2017)، ويمكن تلخيص المقارنة في الشكل أدناه.



A cartoon drawing of a biological neuron (left) and its mathematical model (right).

الشكل (5) الفرق بين العصبون الاصطناعي والطبيعي


الصيغة الرياضية المستخدمة في المستشعر في الفقرة السابقة هي مجرد واحدة من العديد من توابع التنشيط (والأبسط) المستخدمة في التعلم العميق، ويسمى تابع الخطوة Heaviside.



$$f(h) = \begin{cases} 0 & \text{if } h < 0 \\ 1 & \text{if } h \geq 0 \end{cases}$$


الشكل (6) معادلة وشكل تابع الخطوة

من أشهر توابع التنشيط التابع السيني sigmoid، لأنه حتى عند التعامل مع المطلقات (نعم أو لا)، من المفيد جعل الناتج يعطي قيمة بسيطة. إنها تشبه إلى حد ما الإجابة بـ "ربما" عند طرح سؤال بنعم أو لا ليس لدينا أي فكرة عنه، بدلاً من التخمين. هذه ميزة أساسية لدالة Sigmoid التي تتفوق فيها على Heaviside، فمثل تابع الخطوة Heaviside، فإن التابع السيني له قيمه بين (0 و 1). ولكن هذه المرة، ليس هناك خطوة فقد تم تنعيمه لإنشاء خط متصل. بالتالي، يمكن اعتبار المخرجات احتمالية للنجاح، فمثلاً الناتج 0.5 يعني أن الشبكة ليس لديها فكرة عما إذا كانت نعم أم لا، بينما الناتج 0.8 يعني أن الشبكة شبه متأكدة أنها نعم. يعد امتلاك هذه الميزة أمراً مهماً لإمكانات تعلم الشبكة فمن الأسهل تعليم الشبكة التحرك بشكل تدريجي نحو الإجابة الصحيح، بدلاً من مجرد القفز مباشرة من 0 إلى 1. (Jain, 2019)



الشكل (7) معادلة وشكل التابع السيني

إلا أن هذا التابع أيضاً له مشاكله الخاصة كما يصعب تعليم الشبكات العصبونية التي تستخدم هذا التابع كتابع تنشيط، وأكثر توابع التنشيط استخداماً هي SoftMax وهو شكل أكثر عمومية من السيني. يتم استخدامه في مشاكل التصنيف متعدد الفئات. على غرار السيني، فإنه ينتج قيمة في النطاق من 0 إلى 1، لذلك يتم استخدامه كطبقة نهائية في نماذج التصنيف. كما أن ReLU (Rectified Linear Unit) أو الوحدة الخطية المصححة من أكثر التوابع انتشاراً لخطيتها وسهولة تعليم الشبكة في حال استخدامها بالعديد من أنواع الشبكات خصوصاً الشبكة العصبونية التشريرية وتمثل معادلتها بالشكل $f(x) = \max(0, x)$ (Jain, 2019) ونرفق تمثيلاً بيانياً لهذا التابع.



الشكل (8) التمثيل البياني لتابع التفعيل ReLU


كما توجد العديد من التوابع الأخرى وتفرعات للتوابع المذكورة مثل tanh، و Leaky ReLU و ReLU6، إلا أننا لن نتطرق لها في هذا البحث.

3.1.6.1 الطبقات المخفية Hidden Layers

يتم نمذجة الشبكات العصبونية كمجموعات من الخلايا العصبونية متصلة في رسم بياني غير دوري. بمعنى آخر، يمكن أن تصبح مخرجات بعض الخلايا العصبونية مدخلات إلى خلايا عصبونية أخرى. لا يُسمح باللفات بالشبكات العصبونية الطبيعية، لأن هذا يعني وجود حلقة لا نهائية في الممر الأمامي للشبكة. غالباً ما يتم تنظيم نماذج الشبكة العصبونية في طبقات متميزة من الخلايا العصبونية. بالنسبة للشبكات العصبونية العادية، فإن النوع الأكثر شيوعاً من الطبقات هو الطبقة المتصلة تماماً حيث تكون الخلايا العصبونية بين طبقتين متجاورتين متصلة بشكل

زوجي تمامًا، لكن الخلايا العصبونية داخل طبقة واحدة لا تشترك في أي اتصالات. في جميع الرسوم البيانية للشبكة العصبونية، تكون الطبقة الموجودة في أقصى اليسار هي طبقة الدخل (أي المعطيات التي تغذيها)، والطبقة الموجودة في أقصى اليمين هي طبقة الإخراج (توقع / إجابة الشبكة). يُعرف أي عدد من الطبقات بين هاتين الطبقتين باسم الطبقات المخفية. كلما زاد عدد الطبقات، زادت دقة عملية صنع القرار. (Lawrence, 1994)

نرفق بالشكل التالي الهيكلية العامة لشبكة عصبونية تقليدية تحوي طبقتين مخفيتين.




الشكل (9) الهيكلية العامة للشبكة العصبونية التقليدية

4.1.6.1 التعلم عبر الانتشار العكسي Learning Through Backpropagation

ربما تكون خوارزمية الانتشار العكسي Backpropagation هي حجر الأساس في تعليم الشبكة العصبونية. تم تقديم هذه الخوارزمية لأول مرة في الستينيات لاجتياز الأشجار بطريقة سريعة وفي هياكل المعطيات وبعد 30 عامًا تم تطبيقها للتعلم من قبل تقريبًا (Rumelhart et al, 1989) فأصبح بإمكاننا تخمين قيمة باستخدام الشبكة العصبونية، وحساب التفاضل والتكامل لحساب الخطأ عبر المشتقات الجزئية. ثم نقوم بإصلاح هذا الخطأ للحصول على تخمين أفضل وإعادة النشر مرة أخرى للعثور على خطأ أكثر دقة. تُظهر طريقة التخمين هذه تكرار الانتشار العكسي. يستغرق تدريب نموذج الذكاء الاصطناعي وقتًا طويلاً والكثير من العمليات الحسابية لأن عدد مرات استخدام هذه الخوارزمية التي تعتمد على التفاضل والمشتقات الجزئية كبير. الهدف النهائي من الانتشار العكسي هو إيجاد التغيير في الخطأ فيما يتعلق بالأوزان في الشبكة. إذا كنا نتطلع إلى تغيير إحدى القيمتين بالنسبة إلى أخرى، فهذا مشتق. بالنسبة لخريطتنا الحسابية، تمثل كل عقدة دالة وتقوم كل حافة بإجراء عملية على العقدة المرفقة (الضرب بالوزن). نبدأ من عقدة الخطأ ونعود إلى عقدة واحدة في كل مرة مع أخذ المشتق الجزئي للعقدة الحالية فيما يتعلق بالعقدة في الطبقة السابقة. كل مصطلح مرتبط بالمصطلح السابق للحصول على التأثير الكلي، وهذا ما يعرف بقاعدة السلسلة Chain Rule. (Scarff B, 2021)

تُعرف الخوارزمية الكاملة لهذا باسم نزول التدرج Gradient Descent (GD)، وهي خوارزمية تحسين تكرارية من الدرجة الأولى تستخدم للعثور على حد أدنى / أقصى محلي لتابع ما. تُستخدم هذه الطريقة بشكل شائع في التعلم الآلي ML لتقليل تابع التكلفة، حيث يستنتج الخطأ (عادةً بحساب التفاضل والتكامل) ويُصحح باستخدام Backpropagation للوصول إلى القيمة الدنيا المحلية، ومن العوامل التي تؤثر بسرعة التعلم هي كمية المعطيات

التي تدخل النظام كحزم Batches وحقب epochs، كما يمكن إضافة خوارزميات أمثلة أخرى لتحسين الدقة وعملية التعلم. (Kwiatkowski. R, 2021) يعبر الشكل التالي عن آلية عمل الخوارزمية بسرعات تعلم مختلفة للوصول لقيمة دنيا محلية.



الشكل (10) آلية عمل خوارزمية GD بسرعات تعلم مختلفة


2.6.1 الشبكات العصبونية في حل مشاكل القطاع المالي

تُستخدم الشبكات العصبونية على نطاق واسع، مع تطبيقات للعمليات المالية وتخطيط المؤسسات والتجارة وتحليلات الأعمال. اكتسبت الشبكات العصبونية أيضاً اعتماداً واسع النطاق في تطبيقات الأعمال مثل حلول أبحاث التنبؤ والتسويق، واكتشاف الاحتيال، وتقييم المخاطر. (Chen, 2022) تقوم الشبكة العصبونية بتقييم معطيات الأسعار وتكشف عن فرص اتخاذ القرارات التجارية بناءً على تحليل المعطيات. يمكن للشبكات أن تميز الترابط غير الخطي الدقيق والأنماط الأخرى التي لا تستطيع طرق التحليل الفني الأخرى القيام بها. وفقاً لبحث (Pang et al, 2018) تختلف دقة الشبكات العصبونية في عمل تنبؤات أسعار الأسهم. تتنبأ بعض النماذج بأسعار الأسهم الصحيحة بنسبة 50 إلى 60 في المائة من الوقت، بينما يتسم البعض الآخر بالدقة في 70 في المائة من جميع الحالات. افترض البعض أن تحسين الكفاءة بنسبة 10 في المائة هو كل ما يمكن للمستثمر أن يطلبه من الشبكة العصبونية حتى تكون فعالة.

نذكر بعض أهم أنواع الشبكات العصبونية في حل مشكلة التنبؤ للأسواق المالية:

- الشبكة العصبونية التشريرية Convolutional Neural Network (CNN) هي شبكة مهيأة لتحليل وتحديد المعطيات المرئية مثل الصور الرقمية أو الصور الفوتوغرافية. تستخدم هذه الشبكة كدخل لها صور سلاسل زمنية للشموع اليابانية للتنبؤ بنوع وحجم الشمعة القادمة وهو الاستخدام الشائع لهذا النوع من الشبكات في سياق البحث. من أبرز الأبحاث التي أدخلت هذا المفهوم في التنبؤ المالي. (Chen et al, 2020)
- الشبكة العصبونية المتكررة Recurrent Neural Network (RNN) هي شبكة تم تكييفها لتحليل معطيات السلاسل الزمنية أو سجل الأحداث أو الترتيب الزمني، لذلك يعتبر هذا النوع من الشبكات الأكثر استخداماً على الإطلاق بالنسبة للأسواق المالية، لأن هذه الشبكة قادرة على النقاط أنماط متكررة بغض النظر عن الخطية أي لها ذاكرة خاصة بها. تفرق هذه الشبكة عن الشبكات عن الشبكات التقليدية، الفرق أنه في الشبكة العصبونية التقليدية، تكون كل المدخلات والمخرجات مستقلة عن بعضها البعض. لكن بالنسبة للعديد من


المهام، فهي ليست فكرة سيئة. إذا كان الهدف توقُّع الكلمة أو الجملة التالية، فنحن بحاجة إلى معرفة الكلمات التي تسبقها. يشار إلى RNNs في كثير من الأحيان لأنها تؤدي نفس المهام لكل عنصر، ويعتمد الخرج على الكلمات السابقة. (Patil et al, 2022) تمتلك RNNs ذاكرة تخزن المعلومات حول ما تم حسابه حتى الآن. هناك مشكلة واحدة في RNN وهي "التبعيات طويلة الأجل"، وأيضاً تتطلب RNN مزيداً من الذاكرة، لحل هذه المشكلة تقترح خلايا ذاكرة طويلة، قصيرة المدى LSTM، تحتوي LSTM على حالة خلية تحتوي على ذاكرة إضافية، والتي تُستخدم لتخزين المعلومات السابقة ذات الصلة للتنبؤ. بعض المعلومات موجودة في خلية، حالة الهيكل المعدل، والمعروفة باسم البوابة. هناك خطوات لأداء مثل هذه المهمة. في الخطوة الأولى تقرر الخلية إذا كان سيتم التخلص من أي من المعلومات المتاحة أم لا من خلال بوابة نسيان Forget Gate. بعد ذلك، تأتي بوابة لتحديد المعلومات الجديدة التي سيتم تخزينها. تخزين المعلومات الجديدة وإضافة وحذف المعلومات وفقاً للبوابة السابقة. في الخطوة الأخيرة، يتم تطبيق وظيفة التنشيط على معطيات الإخراج. (Patil et al, 2022) نكتفي بذكر فكرة خلايا LSTM ونعرض بالشكل التالي مكوناتها وطريقة عملها.



الشكل (11) مخطط مكونات خلايا LSTM

- نموذج انتباه المحولات Transformer Attention Model: أحدثت بنية المحولات ثورة في استخدام الانتباه من خلال الاستغناء عن الشبكات التكرارية RNN والتشريدية CNN، عن طريق نموذج Transformer الذي اقترحه (Vaswani et al, 2017) بدلاً من ذلك، يعتمد فقط على استخدام الانتباه الذاتي، أي يقوم النموذج بالانتباه على الأنماط المعنوية في أي تسلسل زمني أو ترتيب من خلال تطوير نموذج التضمين وفك التضمين encoder-decoder، حيث يتم حساب تمثيل تسلسل في حالة سلسلة زمنية أو جملة إذا كنا نقوم بمعالجة اللغات الطبيعية NLP عن طريق ربط كلمات مختلفة في نفس التسلسل. يمكن وصف وظيفة الانتباه بأنها تعيين استعلام ومجموعة من أزواج المفاتيح والقيمة (Key-Value) لمخرج، حيث يكون الاستعلام والمفاتيح والقيم والمخرجات كلها متجهات. يتم احتساب الناتج كمجموع مرجح من القيم، حيث يتم حساب الوزن المخصص


لكل قيمة بواسطة دالة توافق للاستعلام بالمفتاح المقابل. تم استخدام هذا النموذج للتنبؤ وتمييز الأنماط للسلاسل الزمنية في الأسواق المالية، كطريقة جديدة للتنبؤ. والشكل التالي يبين باختصار هيكلية عمل النموذج.




الشكل (12) هيكلية عمل نموذج Transformer Attention

نرفق أيضاً الفرق بين الانتباه متعدد الرؤوس والانتباه وحيد الرأس (النقطي الوحيد) بالشكل التالي.

Scaled Dot-Product Attention



Multi-Head Attention



الشكل (13) الفرق بين الانتباه متعدد الرؤوس والانتباه النقطي الوحيد

7.1 نظم دعم القرار في القطاع المالي

أولاً نعرف القرار بأنه اختيار بديل أفضل من عدة بدائل أخرى، والعملية التي تم اعتمادها من أجل الوصول إلى القرار النهائي تعرف باسم صنع القرار. يعد القرار ضرورياً في جميع الوظائف الإدارية مثل التخطيط والتنظيم والتوظيف والتوجيه ويتم تنفيذ جميع الوظائف الإدارية من خلال وسيلة القرار. (Koontz, 1955)

أما نظرية القرار فهي نظرية اقتصادية تستخدم لتقييم الخيارات المتاحة واتخاذ القرار الأفضل وتوفر هيكلاً رسمياً لاتخاذ خيارات عقلانية في حالة عدم اليقين، وتستخدم أدوات ونماذج رياضية كدالة المنفعة، وتتقاطع مع نظرية الاحتمالات ونظرية الألعاب بشكل كبير وأخيراً لها ارتباط بسلوك المستهلك حيث تتأثر في سلوك متخذ القرار ودرجة حبه للمخاطرة كما يمكن تطبيقها في أي مجال طالما يوجد لدينا قرار. (Peterson, 2017)


أما نظم دعم القرار (DSS) Decision Support Systems فيمكن القول عنها أنها نظم تفاعلية قائمة على الحواسيب، تساعد صانعي القرار على استخدام المعطيات والنماذج لحل المشكلات المنظمة أو غير المنظمة أو شبه المنظمة (Sprague et al, 1996). توفر DSS تحليلاً متنوعاً دون بذل الكثير من جهود البرمجة وعادة ما يتم توجيهه نحو المستخدمين / المديرين غير التقنيين. تشمل الاستخدامات الرئيسية للمديرين لنظام DSS البحث عن المعطيات ذات الصلة واسترجاعها وتحليلها، للسماح لهم بتلخيص النقاط الرئيسية التي تساعد في اتخاذ قرارات أكثر استنارة وتحققاً. غالباً ما يبحث المستخدمون عن الارتباطات بين المعطيات دون إعادة كتابة تطبيق البرنامج، وتسمح معظم نظم دعم القرار بإمكانيات الرسوم البيانية، والتي لا تسمح فقط بتحليل الاتجاهات وإعداد التقارير لكبار المديرين التنفيذيين، ولكنها تساعد المديرين أيضاً في رسم خرائط التحليل المشترك والسيناريوهات البديلة للإجابة عن أسئلة من نمط (ماذا لو؟). بالتالي، تدعم DSS كلاً من القرارات التكتيكية والاستراتيجية ويتم توظيفها للاستفادة من خبرة المدير في مجال معين. (Louw et al, 2002)

تشكل أنظمة دعم القرار متعددة المعايير (MCDSS) Multi Criteria Decision Support Systems فئة مهمة من أنظمة دعم القرار في القطاع المالي والاستثمار وإدارة المحافظ. يوفر MCDSS الإطار المنهجي المطلوب لاستيعاب الطبيعة متعددة المعايير لمشكلة إدارة المحافظ واختيار الأسهم، بالإضافة إلى ذلك، فإنه يؤدي إلى تطوير واقعي النماذج آخذة بعين الاعتبار المعيارين الأساسيين للاستثمار (الأرباح المتوقعة والمخاطر)، كما تأخذ في الاعتبار أخرى معايير لا تقل أهمية مشتقة من التحليل الأساسي والتقني، وأخذ بعين الاعتبار رأي المستثمر وأهدافه وتفضيلاته وسياساته. (Louw et al, 2002) كما توجد أنظمة دعم قرار مالية تجارية شهيرة مثل نظام

FINEVA وCABAL وCREDEX. (Zopoundis, 1997)

منذ الستينيات كان اتخاذ القرار متعدد المعايير (MCDM) Multi criteria Decision making مجالاً بحثياً نشطاً، وأنتج العديد من النظريات والمقالات والكتب التطبيقية، خصوصاً في القطاع المالي، وتم تصميم طرق MCDM لتعيين بديل مفضل، وتصنيف البدائل في عدد صغير من الفئات وترتيب البدائل، MCDM هو مصطلح عام لجميع الأساليب الموجودة لمساعدة الأشخاص على اتخاذ القرارات وفقاً لتفضيلاتهم في الحالات التي يوجد فيها أكثر من معيار متضارب ويمكن القول إنها طريقة للتعامل مع المشاكل المعقدة عن طريق كسر المشاكل إلى قطع


أصغر. بعد موازنة بعض الاعتبارات وإصدار الأحكام بشأن أصغر المكونات، يتم إعادة تجميع القطع لتقديم صورة شاملة إلى متخذ القرار. تتعامل معظم طرق MCDM مع بدائل منفصلة، والتي تم وصفها بواسطة مجموعة من المعايير. يمكن تحديد قيم المعايير كمعلومات أساسية أو ترتيبية. نرفق الآن التسلسل المنطقي لآلية عمل خوارزميات MCDM (Velasquez, 2013).



الشكل (14) التسلسل المنطقي لخوارزميات MCDM

أما بالنسبة لأنواع التثقيف في نماذج دعم القرار المالي، فإنه يوجد عدد كبير من التفرعات بحسب النموذج المدروس فمثلاً نموذج CGX المالي يستخدم طريقة التسلسل الهرمي التحليلي (Analytical Hierarchical Process (AHP)، وهي طريقة وضعها Thomas Saaty توفر هيكلًا لتنظيم وتحليل القرارات المعقدة، تم وصف الأسس الرياضية ل AHP في عام 1980 وتستخدم لترتيب البدائل عندما يتم النظر في جميع معايير القرارات في وقت واحد ويعتمد

على ثلاث مبادئ أساسية المقارنة الزوجية، التحليل، التوليف. يجب بناء التسلسل الهرمي لتأسيس العلاقة بين الهدف والمعايير الفرعية والبدائل على الشكل التالي وهو مثال على طريقة التسلسل الهرمي التحليلي AHP.



الشكل (15) مثال على مراحل التسلسل الهرمي التحليلي

يقوم مستخدمو AHP أولاً بتحليل مشكلة القرار الخاصة بهم إلى تسلسل هرمي للمشكلات الفرعية التي يسهل فهمها، ويمكن تحليل كل منها بشكل مستقل. يمكن أن تتعلق عناصر التسلسل الهرمي بأي جانب من جوانب مشكلة القرار (لملمس أو غير ملموس)، تم قياسه بعناية أو تقديره بشكل تقريبي، أي شيء ينطبق على القرار المطروح. بمجرد بناء التسلسل الهرمي، يقوم صانعو القرار بتقييم عناصره المختلفة بشكل منهجي من خلال مقارنتها مع بعضها البعض في كل مرة، فيما يتعلق بتأثيرها على عنصر أعلى منهم في التسلسل الهرمي. عند إجراء المقارنات، يمكن لصانعي القرار استخدام معطيات ملموسة حول العناصر، لكنهم عادة ما يستخدمون أحكامهم حول معنى النسبي للعناصر وأهميتها.

تحول AHP هذه التقييمات إلى قيم عددية يمكن معالجتها ومقارنتها عبر النطاق الكامل للمشكلة. يتم اشتقاق الوزن، أو الأولوية العددية لكل عنصر من عناصر التسلسل الهرمي، مما يسمح بمقارنة العناصر المتنوعة وغير القابلة للقياس مع بعضها البعض بطريقة منطقية ومتسقة. تميز هذه القدرة برنامج AHP عن تقنيات صنع القرار الأخرى. في الخطوة الأخيرة من العملية، يتم حساب الأولويات العددية لكل من بدائل القرار. تمثل هذه الأرقام القدرة النسبية للبدائل على تحقيق هدف القرار، لذا فهي تسمح بالنظر المباشر في مسارات العمل المختلفة. (Saaty, 2008) وتوجد نماذج أخرى تعتمد على طرق أخرى مثل UTASTAR وغيرها إلا أننا لن نتوسع في جميع هذه الطرق. (Zopoundis, 1997). كما أنه يمكن الاستفادة من المعايير التي يطرحها تحليل PEST في صنع قرار متعدد المعايير فيمكن اخذ أبعاد هذا التحليل كمعايير قرار، وهو تحليل يأخذ بعين الاعتبار أربعة مصادر للتغيير، مصادر سياسية، واقتصادية، واجتماعية، وتكنولوجية (PEST: Political, Economic, Social, Technological).

تحليل PEST هو تحليل قوي ومستخدم على نطاق واسع أداة لفهم المخاطر الاستراتيجية. يحدد تغييرات وتأثيرات الاقتصاد الكلي والخارجي البيئة على الوضع التنافسي للشركة.

تتكون البيئة الخارجية من متغيرات خارجة عن سيطرة الشركة، ولكنها تتطلب التحليل لإعادة تنظيم استراتيجية الشركة لتقييم بيئات العمل. تعمل الشركات كجزء لنظام بيئي أكبر، فهم عرضة لمجموعة متنوعة من العوامل الخارجية، والتي يمكن أن يكون تأثير كبير على الوضع التنافسي للشركة. يسعى الاستراتيجيون إلى فهم العوامل وتقييم كيفية نماذج الأعمال يجب أن تتطور للتكيف مع بيئتهم. التخفيف من آثار العوامل الخارجية من خلال الإستراتيجية والفرص الوقائية يتم استغلالها في أعقاب المنافسة الجديدة، لصنع قرارات بضوء هذا التحليل. (Bonnici et al, 2015)

3.1. الخلفية والمشكلة

بعد وضع السياق العام للبحث، والتعرف بشكل مختصر على أهم مصطلحات البحث، لا بد من تلخيص التحديات التي تواجه هذا البحث كونه يحاول حل مشكلة التنبؤ المستقبلي لأسعار سوق مالي والتي كانت عوائق للأبحاث السابقة، وتوجهات الحل الأساسية السابقة لهذه المسألة ومناقشة التحديات التي لم تستطع المحاولات السابقة تقديم حلول مجدية لها.

إن أحد أهم التحديات في مشكلة التنبؤ في السلاسل الزمنية هي عدم خطية المعطيات، ولذلك فشلت نماذج الانحدار البسيطة بالتعامل مع المشكلة، إلا أنها قد تشكل مؤشراً للاتجاه العام بأفضل الأحوال، وهنا تطورت نماذج الانحدار الخطي لحل هذه المشكلة، فظهرت نماذج الانحدار المتعدد والآني، كنماذج محسنة عن نموذج الانحدار الخطي البسيط، وطبقت في الأسواق المالية وعرفت بنماذج ARCH. إلا أنه توجد تحديات أخرى تقف في وجه المشكلة مثل وجود متغيرات عديدة تؤثر في سعر السهم مهما كان نوعه وهنا بدأ الباحثون بوضع نظريات تفسر التغيرات مجهولة السبب مثل نظرية السوق الفعال EMH التي تنص على أن سعر كل سهم يمتص كل المعرفة الموجودة في السوق في أي وقت. نظراً لأن المشاركين في السوق يستخدمون جميع المعلومات المعروفة على النحو الأمثل، فإن تقلبات السعر لا يمكن التنبؤ بها، حيث تحدث المعلومات الجديدة بشكل عشوائي (Fama, 1970) وفي هذه الحالة من الممكن التنبؤ بشكل دقيق جداً إذا كانت تتوفر لدينا جميع المعلومات والمعرفة الداخلة للسوق في كل لحظة إلا أن هذا مستحيل تطبيقياً، فهنا نجمع المعلومات والمعارف المتوفرة لدينا ونقوم ببناء النموذج على هذا الأساس.

أما وفقاً لنظرية المسير العشوائي RW فإن سعر السهم يجري "مسيراً عشوائياً"، مما يعني أن جميع الأسعار المستقبلية لا تتبع أي اتجاهات أو أنماط، وهي انحراف تلقائي عن الأسعار السابقة، ولا يمكن للمستثمر توقع السوق. (Fama, 1995)

مع كل ذلك تطورت النماذج لتشمل نقل المعرفة من خبير وبناء نموذج لنظام يعتمد على معرفة الخبير وتشكيلها على شكل قواعد إلا أن مشكلة هذا الحل، بالرغم من أنه قد يوفر قوة تعبيرية ويحاكي المنطق البشري، إلا أنه لا يتفوق على خبير فعلي في المجال وإنما يحاكيه. وهنا ظهر اهتمام كبير بالشبكات العصبونية الاصطناعية كونها

قادرة على التعلم الذاتي والتفوق على الخبراء في قطاع ما إلا أن مشكلة هذه النماذج كونها تحتاج كمية هائلة من المعطيات للتدريب بحكم أن تدريب الشبكة بطيء، كما أنها لا تعطي قدرة تفسيرية أو تعبيرية لسبب إظهار خرج ما من النظام وهي مشكلة كبيرة عندما يريد صانع القرار معرفة سبب صحة التنبؤ. يمكن تلخيص عقبات مشاكل النماذج المستخدمة في الأدبيات بالشكل التالي:

- اختيار المنهجية المناسبة للتعامل مع خصوصية مشكلة التنبؤ السعري.
- اختيار المتغيرات المناسبة التي تعطي أكبر قدر من المعلومات التي يمكن أن يستفيد منها النظام.
- طريق معالجة المعطيات الداخلة في النموذج فلا تستقبل كل النماذج جميع أنواع المعطيات (بعضها معطيات نصية تحتاج معالجة خاصة وبعضها الآخر تحتاج لتطبيع).
- قيام النموذج بتنبؤ صحيح.
- صحة التنبؤ حتى في حال عدم وجود معطيات كافية.
- سرعة القيام بالتنبؤ وهي مشكلة موجودة لدى النماذج التي تتعامل مع كميات كبيرة من المعطيات أو في النماذج التي تقوم بالتعلم لأول مرة لسعر سهم ما.
- القدرة التفسيرية للنموذج، أي قدرته على القيام بإظهار دلائل لمتخذ القرار عن سبب صحة التنبؤ ومخرجات للنظام.

7.1 إشكالية البحث

تتكون إشكالية البحث من مجموعة من الأسئلة والمقترحات التي سنفصلها في الفقرات التالية.

1.7.1 كيفية انتقاء المتغيرات المناسبة

تظهر مجموعة من الأسئلة التي يجب مواجهتها عند انتقاء المتغيرات التي ستكون دخل للنظام ويمكن تلخيصها بالشكل التالي:

- ما هي المتغيرات التي يجب أن تدخل النظام ولماذا؟
 - ما هي كيفية انتقاء متغيرات بحيث يكون عددها كاف وتعطي أكبر قدر من المعلومات ليستفيد منها النظام؟
- مقترحنا:** المتغيرات التي تدخل في نظامنا المقترح هي متغيرات سعرية من جهة، مثل العناصر التي تشكل الشموع اليابانية (سعر الإغلاق، سعر الافتتاح، السعر الأعلى، السعر الأدنى). لم نقترح إدخال سعر وحيد مثل سعر الإغلاق فقط وذلك كي نستفيد من القدرة التعبيرية الإضافية لمجموعة الأسعار المقترحة كما أنها تقوم بتضخيم المعطيات لاستفيد منها الشبكة العصبونية. كما نقترح إدخال متغيرات أخرى تعبر عن المؤشرات المالية، وهي معطيات مشتقة من المعطيات الأساسية، من خلال معادلات رياضية لإعطاء قدرة تعبيرية إضافية للشبكة، واستخراج تفسيرات وضع السوق الحالي للمستخدم. من المهم انتقاء متغيرات لا تعبر عن نفس المعنى لذلك لم نستخدم في نموذجنا مؤشرات مختلفة تعبر عن نفس المعنى.

2.7.1 كيفية جلب المعطيات المناسبة ومعالجتها

جلب معطيات مناسبة والتأكد من صلاحيتها ومناسبة حجمها لتكون فعالة في النظام، كما أن معالجة المعطيات الأولية هي إحدى المشاكل الفرعية التي نواجهها لحل المشكلة الأساسية ويمكن صياغة هذه التساؤلات بالشكل التالي:

- ما هي طريقة اختيار مصادر المعطيات بحيث يكون مصدرها موثوق وغير متحيز؟
- كيف سنتعامل مع مجموعات معطيات ذات حجوم مختلفة بحيث يكون تذبذب فعالية النظام أقل ما يمكن مهما كانت حجوم المعطيات الداخلة له؟
- ما هي طريقة دمج مجموعات معطيات مجلوبة من مصادر عدة، ضمن مجموعة معطيات موحدة؟
- كيف نعالج المعطيات الأولية لاستخراج معطيات ثانوية نستفيد منها؟
- ما هي طرق تضخيم المعطيات التي يمكن الاستفادة منها بخصوصية مسألتنا؟
- كيف ننقي معطيات ثانوية مناسبة مستخرجة من المعطيات الأولية تعطي قدرة تعبيرية لتمييز الأنماط في خصوصية مسألتنا؟

مقترحنا: نبدأ بطريقة اختيار مصادر المعلومات، نقترح جلب المعطيات من خلال واجهة برمجة التطبيقات API المواقع الرسمية للأسواق الأوراق المالية، بغض النظر إن كانت أسهم شركات أم عملات رقمية، وبذلك نكون تجاوزنا مشكلة موثوقية المعطيات وعدم تحيزها. بالنسبة للتعامل مع حجوم معطيات مختلفة، فإن أصغر سلسلة معطيات يمكن أن يقبلها النظام الخبير هي 3 نقاط معطيات (Data Points) كاملة، أما بالنسبة للشبكة العصبونية فإن أصغر سلسلة يمكن أن يقبلها هي 128 نقطة معطيات (سطر في إطار المعطيات)، وذلك لكي تستطيع الشبكة الربط بين هذه النقاط لإعطاء تنبؤ أكثر دقة أي لالنقاط التبعيات طويلة الأمد، من المفضل أن يدخل إلى النظام الهجين معطيات أكبر، (128 سطر أو أكثر) إلا أنه قادر على إعطاء خرج بثلاث أسطر معطيات فقط ويكون هذا الخرج فقط من النظام الخبير وليس من الشبكة العصبونية. طريقة دمج المعطيات الثانوية والأولية هي بدمج أطر المعطيات مع إلغاء الأسطر التي تحتوي على قيم فارغة، ونستخرج المعطيات الثانوية من خلال معادلات المؤشرات المالية الرياضية بطريقة مؤتمتة، وذلك لتضخيم المعطيات الأولية. أما بالنسبة لانتقاء هذه المعطيات، اخترنا في النموذج معطيات تعبر عن مشاعر السوق مؤشر الخوف والجشع (Fear & Greed index) ومعطيات تعبر عن الزخم إن كان قوياً أم ضعيفاً ADX كما استخدمنا المتوسطات المتحركة قصيرة الأجل وطويلة الأجل لدراسة نقاط تقاطعها، ومؤشر القوة النسبية ليبين إن كان السهم يباع أو يشتري بشكل مجحف.

4.7.1 طريقة بناء النظام الخبير والشبكة العصبونية الاصطناعية

تحتوي هذه الجزئية على عدة تساؤلات يجب الإجابة عنها ونصيغها بالشكل التالي:

- ما هي آلية نقل المعرفة من خبير مختص في مجال المشكلة وكيفية صياغة هذه المعرفة بشكل قواعد يعمل وفقها محرك الاستدلال؟

- ما هي خوارزمية الاستدلال المناسبة لمحرك الاستدلال؟

- كيف ننقي الشكل المناسب للشبكة العصبونية الاصطناعية؟
- ما هي آلية تدريب هذه الشبكة العصبونية الاصطناعية وتقييمها؟
- ما هي آلية دمج النظام الخبير مع الشبكة العصبونية؟

مقترحنا: نقترح نقل معرفة الخبراء في مجال المشكلة بحسب معادلات رياضية (أي معرفة غير ضبابية) من مراجع تمت مراجعتها من قبل خبراء آخرين وتحويل هذه المعرفة إلى رماز برمجي، وشرح باللغة الطبيعية يقدم للمستخدم، ونقوم بصياغة هذه القواعد على شكل قواعد ماذا لو، إذاً (if-then). بالنسبة لخوارزمية الاستدلال المناسبة فنعتمد خوارزمية الاستدلال الأمامي Forward Chaining، وذلك لأننا ننطلق من المعطيات التي لدينا نحو المعرفة، وليس العكس. توجد عدة أشكال للشبكة العصبونية التي يمكن أن تلائم مشكلة بحثاً، إلا أننا نستخدم طبقة تضمين زمني وطبقة محولات الانتباه في نموذجنا المقترح، وهو من النماذج الجديدة نسبياً التي أظهرت كفاءتها عند التعامل مع السلاسل (الزمنية أو اللغات الطبيعية)، نستخدم عند تدريب هذه الشبكة تابع التكلفة التالي " Loss Function: Sparse Categorical Crossentropy" وذلك لأننا أمام مسألة تصنيف ثنائي، أي هل من المتوقع أن يرتفع السعر أم ينخفض في الفترة الزمنية القادمة، أما بالنسبة لخوارزمية الأمثلة فقد استخدمنا خوارزمية ADAM، بالنسبة للتقييم نقوم بعرض رسوم بيانية تعبر عن دقة النموذج للتأكد من صحة النموذج، أما للتأكد من الأمثلية نستخدم مقياس الدقة Accuracy، ومقياس متوسط الأخطاء المطلقة بالنسبة المئوية، MAPE (Mean Absolute Percentage Error). وبالنسبة لنموذج ensemble، وهي طريقة المتوسطات المثقلة لدمج تنبؤ نموذجين أو أكثر.

5.7.1 طريقة التعامل مع البدائل المختلفة عند تقارب التنبؤ

بعد أن توصلنا إلى تنبؤ لسعر سهم ما، إلا أنه يوجد عدة بدائل متقاربة بالتنبؤ ونريد إيجاد طريقة لنرجح إحدى هذه البدائل مما يطرح التساؤل التالي:

- ما هي طريقة المقارنة بين عدة بدائل عند تقارب التنبؤ وما هي المعايير المناسبة لذلك؟

مقترحنا: نقترح طريقة سهلة وديناميكية للمقارنة بين عدة بدائل وهي طريقة المصفوفة الموزنة متعددة المعايير، أما بالنسبة للمعايير فإنها تختلف بحسب الحالة والمعطيات المتوفرة التي سيدخلها المستخدم، إلا أننا نقترح معايير أولية مناسبة للعديد من الحالات، وهي معايير PEST، أي البيئة الحالية السياسية، والاقتصادية، والاجتماعية، والتكنولوجية، لأن هذه العوامل يمكن تقديرها من مستخدم عقلائي ولا يمكن إدخالها في النظام الخبير والشبكة العصبونية على شكل دخل مستمر. أما بالنسبة للأوزان فيتم وضعها من قبل المستخدم بحسب إطار AHP، ويجدر بالذكر أننا نقترح ان تكون أيضاً ديناميكية، أي يمكن تغييرها من مستخدم النظام لأن أهمية المعيار قد تختلف بين سعر عملة رقمية أو سهم شركة نفط، أو سعر ذهب. فلكل حالة خصوصية معينة.

أخيراً يمكن صياغة إشكالية البحث كالتالي:

"كيفية بناء نظام دعم قرار تنبؤي لسعر عملة أو سهم أو أكثر، يتعامل مع مجموعات معطيات باختلاف أحجامها وباختيار متغيرات ومعطيات مناسبة، بالإضافة لآلية معالجتها والقيام بتنبؤ مناسب، وتقديم تقرير وتفسير بسيط لمساعدة متخذ القرار."

8.1 هدف البحث


يهدف البحث لبناء نموذج أولي لنظام تنبؤ لسعر أسهم وعمليات رقمية. وهو نظام هجين يدمج ما بين نظام خبير قادر على توليد رسوم بيانية وإعطاء تقارير تفسيرية لوضع السوق الحالي لمتخذ القرار، وبين شبكة عصبونية اصطناعية قادرة على التعامل والاستفادة من مجموعات المعطيات الكبيرة للقيام بتنبؤات دقيقة، والدمج بين خرج النموذجين للقيام بتنبؤ مناسب. حيث تتم الاستفادة من نقاط قوة كل مكون من مكونات النظام المترفع، وتلافي نقاط ضعف هذه المكونات أيضاً.

9.1 أهمية هذا البحث

تكمن أهمية هذا البحث بكونه مقارنة جديدة تدمج عدة نماذج موجودة مسبقاً بآلية فريدة، للقيام بالتنبؤ السعري، وتقديم تقارير وقدرة تفسيرية لمستخدم هذا النظام. نضيف للأهمية التصميمية لهذا النموذج، دراسة مرجعية تقارن وفق إطار الأبعاد الأربع، أبحاث تعالج نفس مشكلة بحثنا، مع مناقشة نقاط قوة وضعف هذه النماذج للاستفادة منها عند بناء نموذجنا المقترح. كما نقوم ببناء نموذج أولي للمقارنة المقترحة عن طريق تطبيق حالة عملية (سعر عملة بيتكوين الرقمية)، بدءاً من جلب معطيات أولية وتضخيمها عن طريق استخراج معطيات مشتقة وهي مؤشرات مالية مختلفة، وتوليد تقارير ورسوم بيانية حقيقية، إضافة لمعالجتها للوصول إلى مرحلة المقارنة بين البدائل وبناء مصفوفة القرار الموزنة.

10.1 موجز عن الحل المقترح

يوفر الحل المقترح حل لمشكلة التنبؤ السعري، أولاً من خلال نظام دعم قرار هجين يعتمد على شبكة عصبونية ANN ونظام خبير ES، وحل مشكلة ثانوية وهي المقارنة بين البدائل عند تقارب التنبؤ، إضافةً للقدرة التفسيرية للنموذج المقترح والتقارير المرافقة له، يهدف نموذجنا المقترح إلى تقادي نقاط ضعف كل مكون إفرادي من مكونات النموذج، وتقديم نظام دعم قرار فعال لمستخدميه.



الشكل (16) نمذجة أولية لفكرة مقارنة الحل

يبين الشكل (16) أعلاه الفكرة الأولية لمقاربة البحث، حيث يدخل متخذ القرار معطيات للنموذج كدخول، على شكل معطيات مالية عن السهم أو العملة المدروسة، لتدخل بشكل متوازي على الشبكة العصبونية والنظام الخبير، مهمة النظام الخبير هي مطابقة القواعد المعرفية الموضوعية من خبراء في هذا المجال، لإعطاء المستخدم النصيحة المالية، للاستثمار في العملة أو السهم المدروس أو بيعه، إضافة لتقديم تقارير للمستخدم، أما الشبكة العصبونية تقوم بالتنبؤ السعري، وندمج مخرجات النموذجين ليتم عرضها للمستخدم من خلال واجهة يقوم بصنع القرار بضوء مخرجات النظام، ويقدم النموذج خيار إضافي في حال عدم التأكد عند وجود عدة بدائل، من خلال مصفوفة قرار موزنة لتقوم بالترجيح بين البدائل المتاحة لصانع القرار.

11.1 مساهمات البحث

ويشمل البحث المساهمات التالية:

- تصميم وتنفيذ نظام هجين يقوم بالتنبؤ السعري بالاعتماد على شبكة عصبونية ونظام خبير قائم على المعرفة.
- تحقيق خواص تميز النموذج المقترح عن مقاربات نماذج أخرى، كوجود قدرة تفسيرية، والقدرة على التعامل مع حجوم معطيات مختلفة، وتوليد تقارير، ودمج بين مكونات النموذج بطريقة تحقق الاعتماد على النموذج الأكثر دقة، وإمكانية التعامل مع وجود عدة بدائل في حال تقارب التنبؤ.

- التحقق من صحة وأداء النموذج من خلال معايير الدقة بالنسبة للشبكة العصبونية، واقتراح خوارزمية تحقق من صحة النظام الخبير تعطي أوزان نسبية للأنماط تسمح بحل مشكلة نزاعات المعرفة كما تسمح باستخراج دقة النموذج مما يسمح لنا لاحقاً بدمج التنبؤ الخارج عن مكونات النموذج.

12.1 مخطط البحث

نظم هذا البحث فصول عدة وهي:

الفصل الأول: التمهيد ويقدم مدخلاً لموضوع البحث وأهميته.

الفصل الثاني: الدراسة المرجعية، ويحتوي على دراسة للأعمال السابقة نبين فيها أهم المقاربات والطرائق المنشورة في مجال مشكلة التنبؤ السعري في الأسواق المالية، ومقارنة بين هذه الطرائق، كما نقوم بتقييم مقاربتنا المعروضة باعتماد مجموعة من المعايير.

الفصل الثالث: النموذج المقترح، ونقدم في هذا الفصل هيكلية النموذج ومدخلاته وأسباب استخدامها وخصائصه ومخرجات هذا النموذج.

الفصل الرابع: بناء النموذج الأولي ونناقش في هذا الفصل بيئة العمل والتطوير، المنصات والأدوات التي تم استخدامها، خوارزميات النموذج وخطوات بناءه، إضافة لواجهات تفاعلية للمستخدم النهائي.

الفصل الخامس: التحقق والنتائج، يحتوي هذا الفصل على الاختبارات والتحقق من النموذج، ونتائج هذه الاختبارات.

الفصل السادس: الخاتمة والآفاق المستقبلية.

الفصل الثاني

الدراسة المرجعية

1.2 مقدمة

يهتم هذا البحث ببناء نموذج تنبؤ سعري للسلاسل الزمنية في الأسواق المالية. نقدم في هذا الفصل مجموعة من المقاربات التي تهتم بتطوير حلول لمشكلة البحث المدروسة، والتي تم استichاء فكرة النموذج الجديد منها وتقسّم إلى محورين، مقاربات استخدمت النظم الخبيرة وتفرعاتها ومقاربات أخرى استخدمت الشبكات العصبونية وتفرعاتها من أجل تقديم دراسة مرجعية ومقارنة منهجية للتوجهات المعتمدة في فيها، وذلك بالاعتماد على إطار الأبعاد الأربع، من أجل التوصل إلى التوجهات الأفضل لاتباعها وتلك الواجب تفاديها، ووضع أساس منهجي لبناء النموذج النهائي للبحث.

نهدف من خلال عرض المقاربات إلى تأطيرها ومقارنتها ببعضها البعض عبر استخدام طريقة للمقارنة مستوحاة من إطار الأبعاد الأربع Four views Framework (Rolland, 1998).

يوفر هذا الإطار توصيفا هيكلياً لأربعة أبعاد للمقاربة المدروسة بحيث يسهل علينا مقارنة المقاربات مع بعضها، وتوضيح خصائص كل مقاربة، حيث يتوافق كل بعد مع جانب أساسي من جوانب المقاربة المدروسة. نستعرض في الفقرات التالية إطار المقارنة المقترح بشكل تفصيلي من حيث تعريف الأبعاد الأربع، ومركباتها ثم نقوم بعدها بتطبيق إطار المقارنة المستخرج على المقاربات المدروسة، بما فيها مقاربتنا المقترحة.

2.2 إطار المقارنة "إطار الأبعاد الأربع"

يضع إطار المقارنة "إطار الأبعاد الأربع" بين يدينا أداة علمية وفكرية ومفاهيمية لتحليل المقاربات المدروسة، وتسلط الضوء على النقاط الأساسية التي تتمتع بها كل مقاربة، فقد أثبت هذا الإطار فعاليته في تحسين فهمنا للعديد من الاختصاصات والنماذج كونه يوضح الفروقات بينها والقيم المضافة في كل نموذج.

يقدم إطار المقارنة توصيفا هيكلياً لأربعة أبعاد للمقاربة المدروسة بحيث يسهل مقارنة المقاربات مع بعضها وتوضيح ميزات كل مقاربة، وتحليلها. يفيد هذا الإطار بالتالي:

تحديد المشاكل المتعلقة بالمقاربات، ومقارنة هذه المقاربات مع بعضها، لذا سنقوم باستخدام إطار المقارنة للمساعدة في فهم، ومقارنة المقاربات من حيث التقنيات، والأدوات والأساليب المستخدمة فيها، في سياق تطوير إطار عمل يهدف إلى تطوير نموذج جديد يستفيد من نقاط قوة النماذج السابقة لهذه المقاربات ويتفادى نقاط ضعفها كما يمكننا من خلال هذه المقارنة المرجعية التعرف على دخل هذه النماذج المختلفة لانتقاء دخل مناسب أيضاً.

1.2.2 النموذج المترفع المستخدم Meta-Model

يمكن مواءمة الإطار الأولي للأبعاد الأربع من خلال تعريف التي تشكل الأوجه التي تشكل البعد المرتبط بها بهدف عرض النهج المراد توصيفه، ويتميز كل بعد باسم ويقاس باستخدام مجموعة من الأوجه، كل منها له قيم محددة في المجال.

هناك ثلاثة أنواع من المجالات، النوع البسيط، النوع المعدود، والمجموعة:

النوع البسيط Simple: يتوافق النوع البسيط مع الأنواع المحددة مسبقاً، مثل الأعداد الصحيحة، والمنطقية والسلسلة.


النوع المعدود Enum: أي أن الوجه سيكون له قيمة واحدة من قيم القائمة المحددة {قيمة X، قيمة Y، قيمة Z}.

نوع المجموعة Set: عندما يمكن أن يأخذ أحد الوجوه قيمة أو أكثر من قائمة محددة مسبقاً (Aljoumaa, 2011).
يقدم الجدول مثالا على طريقة عرض الأوجه، والمجالات، وقيم العينة.

الجدول (1) طريقة عرض الأوجه (Aljoumaa, 2011)

الوجه	مجال القيم	قيم الوجه
الوجه 1	قيمة وحيدة	1
الوجه 2	قيمة واحدة من قيم القائمة {قيمة X، قيمة Y، قيمة Z}	القيمة Y
الوجه 3	مجموعة القيم (قيمة 1، قيمة 2، قيمة 3)	القيمة 1، القيمة 3

يمثل الشكل (17) النموذج المترفع لإطار المقارنة المستخدم



الشكل (17) النموذج المترفع لإطار المقارنة المستخدم (Aljoumaa, 2011)

3.2 بناء إطار المقارنة


يتكون إطار المقارنة من أربع أبعاد يسمح كل بعد بتحليل جانب معين من جوانب المقارنة عن طريق طرح أربعة تساؤلات جوهرية وهي: "ماذا؟" "ولماذا؟" "وكيف؟" "وبأي طريقة؟" (Rolland, 1998). تتيح هذه الأبعاد مناقشة هادفة لميزات كل مقارنة كما يتكون كل بعد من مجموعة من الأوجه Facets يحدد كل وجه من الأوجه نقطة مقارنة وحيدة بين المقاربات.

إن هذه الأبعاد هي:

- بعد "الموضوع" أو "المحتوى"، يجيب عن السؤال: ما المعرفة المتضمنة في المقاربة؟ ويهتم بنوع المعرفة المعبر عنها في المقاربة.
- بعد "الاستخدام"، يجيب عن السؤال: لماذا نستخدم المقاربة؟ ويشير إلى النماذج المستخدمة في المقاربة.
- بعد "النموذج"، يجيب عن السؤال: كيف تم تصور نموذج المقاربة؟ ويشير إلى النماذج المستخدمة في المقاربة.

- بعد "التنفيذ والتحقيق"، يجب عن السؤال: ما خصائص المقاربة المتعلقة بالتنفيذ والتحقيق؟ ويعرض الوسائل التقنية المستخدمة لتحقيق المقاربة.

يبين الشكل (18) بنية إطار المقارنة بشكل عام، حيث تظهر فيه الأبعاد الأربع وهي:



الشكل (18) بنية إطار المقارنة بشكل عام

سوف نفصل في الفقرات الآتية أوجه كل بعد ونعرف القيم الذي يأخذها كل وجه من الوجوه.

1.3.2 بعد الموضوع

يركز هذا البعد على الغرض الأساسي من وراء بناء نماذج تنبؤ سعري في سوق مالي، أي سبب الاتجاه نحو هذه المقاربة على الشكل التالي:

1.1.3.2 مجال الرؤية

يحدد درجة التفصيل في مشكلة، وأهداف ومساهمات البحث. بالإضافة إلى هيكلية وتنفيذ الحل المقترح. ويأخذ قيمتين:

صندوق أسود: يكون مستوى التفصيل محدود، ويكتفي بنظرة سطحية عامة عن الموضوع، وهيكلية الحل، ومنهجية تنفيذه.

صندوق أبيض: يتمتع البحث بوضوح وتفصيل لموضوع البحث، وهيكلية الحل، ومنهجية تنفيذه.

أخيراً ، يعرف وجه مجال الرؤية في طريقة عرض المقاربات على أنه قيمة واحدة من قيم القائمة أدناه:

مجال الرؤية: قيمة واحدة من قيم القائمة {صندوق أسود، صندوق أبيض}

2.1.3.2 سوق النموذج

نذكر شرحاً بسيطاً للأسواق المالية التي طبقت عليها الدراسات السابقة المرجعية:

IBEX35: هو مؤشر مثل للقيمة السوقية المدرجة للتداول الحر للأسهم الأكثر سيولة المدرجة في بورصة مدريد. تتم إعادة تقييم وموازنة المؤشر مرتين كل عام لضمان بقاء سيولة أكثر 35 سهم في البورصة في المؤشر. (Tragget, 2020)

NSE: تعد البورصة الوطنية الهندية المحدودة NSE أكبر سوق مالي في الهند تأسست في عام 1992، وتطورت إلى سوق الكتروني متطور، احتل المرتبة الرابعة في العالم من حيث حجم تداول الأسهم. (Chen, 2021)

S&P 500: هو مؤشر أسهم يتتبع أسعار أسهم 500 من أكبر الشركات العامة في الولايات المتحدة، ويعرف رسمياً باسم مؤشر أسعار الأسهم المركب Standard & Poor's 500، وهو أحد الأدوات الرئيسية المستخدمة لمتابعة أداء الأسهم الأمريكية. (Curry, 2021)

NASDAQ: هو أول سوق الكتروني للأوراق المالية يتم إدراج أكثر من 5000 شركة فيه، ويتألف من سوقين منفصلين، وهما سوق NASDAQ الوطني، الذي يتداول في الأوراق المالية لشركات كبيرة ونشطة، وسوق NASDAQ لرأس المال الصغير الذي يتداول في شركات النمو الناشئة. (NASDAQ, 2020)

FTSE: وتعد اختصاراً لـ Financial Times Stock Exchange وهي مؤسسة مالية بريطانية متخصصة في تقديم عروض المؤشرات للأسواق المالية العالمية. تمتلك مجموعة بورصة لندن مجموعة FTSE Russel Group وغيرها من العلامات التجارية المالية. (Young, J., 2022)

KOSPI: تعبر عن مؤشرات أسهم السوق الكورية المركبة، وهي سلسلة من المؤشرات التي تتبع البورصة الكورية الشاملة ومكوناتها. كل من مؤشرات KOSPI متوسطة ومتقلبة ومرجحة برأس المال. (Kenton, 2021)

يمكن تمثيل وجه سوق النموذج ببعض أهم الأسواق المالية بالشكل التالي:

سوق النموذج: قيمة واحدة من قيم القائمة {IBEX35, NSE, S&P500, NASDAQ, FTSE, KOSPI...}

3.1.3.2 تحليل الاستثمار

تصب كل محاولات الباحثين للتنبؤ بمستقبل شركة أو سهم للاستثمار بها، بغض النظر عن الأدوات التي استخدمت لتطبيقه ضمن التحليل إما التقني للمدى التكتيكي القريب أو التحليل الأساسي للمدى البعيد.

التحليل التقني Technical Analysis: هو منهجية تداول تستخدم لتقييم الاستثمارات وتحديد فرص التداول من خلال تحليل الاتجاهات الإحصائية التي تم جمعها من نشاط التداول، مثل حركة السعر وحجم التداول، ويرى البعض أن التحليل الفني هو مجرد دراسة لقوى العرض والطلب كما تنعكس في تحركات أسعار السوق للأوراق المالية. (Griffioen, 2003)

يحاول التحليل الفني التنبؤ بحركة السعر لأي منتج قابل للتداول أو يخضع عمومًا لقوى العرض والطلب، بما في ذلك الأسهم والسندات والعقود الآجلة وأزواج العملات. في الواقع، يرى البعض التحليل التقني على أنه مجرد دراسة لقوى العرض والطلب حيث تنعكس في تحركات أسعار السوق للأوراق المالية. هناك المئات من الأنماط والإشارات

التي طورها الباحثون لدعم تداول التحليل التقني. طور المحللون التقنيون أيضاً أنواعاً عديدة من أنظمة التداول لمساعدتهم على التنبؤ بحركات الأسعار والتداول عليها. (Hayes, A, 2022)


تركز بعض المؤشرات بشكل أساسي على تحديد اتجاه السوق الحالي، بما في ذلك مناطق الدعم والمقاومة، بينما يركز البعض الآخر على تحديد قوة الاتجاه واحتمالية استمراره. تشمل المؤشرات الفنية أنماط الرسوم البيانية شائعة الاستخدام، أشهرها أنماط الشموع اليابانية وخطوط الاتجاه والمتوسطات المتحركة ومؤشرات الزخم. كما يستخدم التحليل التقني للتنبؤ السعري على المستوى التكتيكي قصير الأجل. (Hayes, A, 2022)

يهدف التحليل التقني لاكتشاف الأنماط أملاً أن تكون هذه الأنماط إشارة لارتفاع سعري أو انخفاض أو انقلاب اتجاه. يمكن تعريف النمط على أنه ترتيب أو تسلسل موجود بانتظام في أغراض أو أحداث قابلة للمقارنة وقد يكون شكل أو تسلسل معين يمكن تمييزه في إجراءات أو مواقف معينة. (Toussaint, 2014)

التحليل الأساسي Fundamental Analysis: هو طريقة لقياس القيمة الجوهرية للسهم من خلال فحص العوامل الاقتصادية والمالية ذات الصلة. يدرس المحللون أي شيء يمكن أن يؤثر على قيمة السهم، من عوامل الاقتصاد الكلي مثل حالة الظروف الصناعة إلى عوامل الاقتصاد الجزئي مثل فعالية إدارة الشركة. الهدف النهائي هو الوصول إلى رقم يمكن للمستثمر مقارنته بالسعر الحالي للأوراق المالية لمعرفة ما إذا كانت الورقة المالية مسعرة بأقل من قيمتها الحقيقية أو مبالغ فيها. كما تحاول جميع تحليلات الأسهم تحديد ما إذا كان يتم تقييم الورقة المالية بشكل صحيح داخل السوق الأوسع. عادة ما يتم إجراء التحليل الأساسي من منظور كلي إلى منظور جزئي من أجل تحديد الأوراق المالية التي لا يتم تسعيرها بشكل صحيح من قبل السوق. (Segal .T, 2022)

بحسب (Segal .T, 2022) يدرس المحللون عادةً بالترتيب، الحالة العامة للاقتصاد ثم قوة الصناعة المحددة قبل التركيز على أداء الشركة الفردية للوصول إلى قيمة سوقية عادلة للسهم. بالنسبة للأسهم، يستخدم التحليل الأساسي الإيرادات والأرباح والنمو المستقبلي والعائد على حقوق الملكية وهوامش الربح ومعطيات أخرى لتحديد القيمة الأساسية للشركة وإمكانية النمو المستقبلي. كل هذه المعطيات متوفرة في المعطيات المالية للشركة، ويقسم التحليل الأساسي إلى تحليل الكمي والنوعي.

تكمن مشكلة تعريف كلمة أساسيات في أنها يمكن أن تغطي أي شيء يتعلق بالرفاهية الاقتصادية للشركة. من الواضح أنها تتضمن أرقاماً مثل الإيرادات والأرباح، ولكنها يمكن أن تشمل أيضاً أي شيء من حصة الشركة في السوق إلى جودة إدارتها. في هذا السياق، تعتبر الأساسيات الكمية هي المتغيرات التي يمكن التعبير عنها بأرقام. هذا هو السبب في أن أكبر مصدر للمعطيات الكمية هو المعطيات المالية. من خلالها يتم قياس الإيرادات والأرباح والأصول وغير ذلك بدقة كبيرة. أما الأساسيات النوعية فهي أقل قابلية للقياس. قد تشمل جودة المديرين التنفيذيين الرئيسيين للشركة، والاعتراف بالعلامة التجارية، وبراءات الاختراع، والتكنولوجيا الخاصة بها.



الشكل (19) الفرق بين التحليل التقني والأساسي

نمثل وجه تحليل الاستثمار بالشكل التالي:

تحليل الاستثمار: قيمة واحدة من قيم القائمة {تحليل تقني، تحليل أساسي}

أخيراً يمكن تلخيص بعد الموضوع على الشكل التالي:

الجدول (2) أوجه بعد الموضوع

الوجه	مجال القيم الممكنة
مجال الرؤية	قيمة واحدة من قيم القائمة {صندوق أسود، صندوق أبيض}
سوق النموذج	قيمة واحدة من قيم القائمة {IBEX35, NSE, S&P500, NASDAQ, FTSE, KOSPI}
تحليل الاستثمار	قيمة واحدة من قيم القائمة {تحليل تقني، تحليل أساسي}

2.3.2 بعد الاستخدام

يركز على سياق استخدام مقاربات بناء نظم التنبؤ للسلاسل الزمنية ويجيب عن تساؤل: "لماذا تستخدم المقاربة المدروسة؟" ويهتم بالغاية النهائية للمقاربة، والأهداف المرحلية (الوظائف)، ويمكن التعبير عن البعد بالأوجه التالية:

1.2.3.2 الغاية النهائية

تختلف الأهداف والغايات النهائية لبناء للنماذج بحسب كل حالة حتى لو كانت هذه النماذج تحت مظلة التنبؤ السعري للسلاسل الزمنية، وتتركز حول قيمة واحدة أو عدة قيم بالشكل التالي:

الغاية النهائية: مجموعة القيم (اختيار أحد الأسهم لإضافته لمحفظة، التنبؤ بسعر الإغلاق لليوم التالي، التنبؤ بتصنيف اليوم التالي (أعلى، أدنى)، التنبؤ بالتوقيت المناسب للقيام باستثمار جديد، ...)

2.2.3.2 الأهداف المرحلية (الوظائف)

تمثل مجموعة وظائف جرى تنفيذها في المقاربة في سبيل الوصول للغاية النهائية، ويمكن أن يتم في سياق تطبيق المقاربة تنفيذ أحد أو كل الأهداف، ويأخذ وجه الأهداف المرحلية قيمة أو أكثر من المجموعة كالاتي:

الأهداف المرحلية: مجموعة القيم (اختيار المتغيرات، تحويل قيمها لغائمة، بناء قاعدة معرفة/قواعد، محاكاة، التدريب، الاختبار، بناء النماذج، دمج النماذج، اختيار النموذج الأنسب، ...)

3.2.3.2 القيمة المضافة للمقاربة

تم تصنيف القيم المضافة للأبحاث المرجعية لهذه الدراسة إلى: دمج عدة نماذج سابقة، مقارنة عدة نماذج، بناء نموذج جديد، تجربة محاكاة، إدخال متغيرات جديدة لنموذج سابق، بناء قواعد استدلال جديدة بالاعتماد على خبير، وتأخذ واحدة أو أكثر من القيم المذكورة:

القيمة المضافة للمقاربة: مجموعة القيم (دمج عدة نماذج سابقة، مقارنة عدة نماذج، بناء نموذج جديد، تجربة محاكاة، إدخال متغيرات جديدة لنموذج سابق، بناء قواعد استدلال جديدة بالاعتماد على خبير، ...)

أخيراً يمكننا تلخيص بعد الاستخدام بالجدول التالي:

الجدول (3) أوجه بعد الاستخدام

الوجه	مجال القيم الممكنة
الغاية النهائية	مجموعة القيم (اختيار أحد الأسهم لإضافته لمحفظة، التنبؤ بسعر الإغلاق لليوم التالي، التنبؤ بتصنيف اليوم التالي (أعلى، أدنى)، التنبؤ بالتوقيت المناسب للقيام باستثمار جديد، ...)
الأهداف المرحلية	مجموعة القيم (اختيار المتغيرات، تحويل قيمها لغائمة، بناء قاعدة معرفة/قواعد، محاكاة، التدريب، الاختبار، بناء النماذج، دمج النماذج، اختيار النموذج الأنسب، ...)
القيمة المضافة للمقاربة	مجموعة القيم (دمج عدة نماذج سابقة، مقارنة عدة نماذج، بناء نموذج جديد، تجربة محاكاة، إدخال متغيرات جديدة لنموذج سابق، بناء قواعد استدلال جديدة بالاعتماد على خبير، ...)

3.3.2 بعد النموذج

يجيب عن السؤال التالي: كيف يتم تصور نموذج المقاربة؟ ويشير إلى النماذج المستخدمة في المقاربة. يتعلق هذا البعد بالمفاهيم والتصاميم والأدوات المستخدمة. ويمثل بالأوجه التالية:

1.3.3.2 معطيات النموذج

ندرس هنا المعطيات التي يمكن أن تستخدمها النماذج المدروسة في دراستنا المرجعية ونقسم إلى:

1.1.3.3.2 آلية الحصول على المعطيات

يمكن تقسيم آلية الحصول على المعطيات إلى خام، أي أنه يمكن الحصول عليها من مصادر رسمية مباشرة ولا يتم التعديل عليها أو استخراج معطيات جديدة من هذه المعطيات الأساسية ومعطيات مشتقة نحصل عليها بعد التعديل والتحويل، وبحسب الأدبيات فإن:

المعطيات الخام Raw Data: يستخدم هذا المصطلح للإشارة إلى المعطيات التي تم جمعها قبل أن يتم تحويل هذه المعطيات أو تحليلها بأي شكل من الأشكال، يمكن أن ينطبق المصطلح على المعطيات بمجرد جمعها أو بعد تنظيفها، ولكن ليس بأي شكل من الأشكال المزيد من التحويل أو التحليل. (Lavarkas, 2008)

المعطيات المشتقة Derived Data: المعطيات المشتقة هي معطيات مشتقة من معطيات أخرى باستخدام نوع تحويل رياضي أو منطقي أو أي نوع آخر من التحويل، وقد تكون أيضاً تجميع معطيات من عدة مصادر ضمن إطار واحد. (Kitchin .R, 2017) وتتركز حول قيمة واحدة أو عدة قيم بالشكل التالي:

آلية الحصول على المعطيات: مجموعة القيم (معطيات خام، معطيات مشتقة)

2.1.3.3.2 نوع المعطيات المستخدمة

يتعلق هذا الوجه بتصنيف المعطيات، وتنسيقها أو صيغتها وذلك بما يتعلق بمعطيات الدخل والخرج. في الدراسات المرجعية لمشكلة البحث تم استخدام 3 من المعطيات (المعطيات المهيكلة، المعطيات شبه المهيكلة).

المعطيات المهيكلة Structured Data: تتضمن المعطيات المهيكلة النصوص والأرقام بأصنافها، وتتم معالجة هذه المعطيات بسهولة، يتم تخزين المعطيات المهيكلة في شكل صفوف وأعمدة، يمكن إدارتها بسهولة باستخدام لغة الاستعلام المهيكلة SQL. (Praveen, 2017)

المعطيات شبه المهيكلة Semi-Structured Data: تتضمن المعطيات شبه المهيكلة، رسائل البريد الإلكتروني، لغة الترميز القابلة للامتداد XML، وتنسيق ترميز الكائنات JSON. المعطيات شبه المهيكلة غير مناسبة لقاعدة المعطيات العلائقية، حيث يتم استخدام نماذج المعطيات التي تستند للرسم البياني لتخزينها، مثل نماذج NOSQL (Praveen, 2017). تأخذ قيمة واحدة أو عدة قيم لأن النماذج التي تستخدم المعطيات شبه المهيكلة تربطها بمعطيات مهيكلة.

المعطيات غير المهيكلة Unstructured Data: تتضمن المعطيات غير المهيكلة مثل مقاطع الفيديو، والصور، والتسجيلات الصوتية، ومن أجل تخزينها، يتم استخدام قواعد المعطيات NoSQL. (Praveen, 2017)

ويتركز نوع المعطيات المستخدمة حول قيمة واحدة أو عدة قيم بالشكل التالي:

نوع المعطيات المستخدمة: مجموعة القيم (معطيات مهيكلة، معطيات شبه مهيكلة، المعطيات غير المهيكلة)

2.3.3.2 دخل النموذج

يتعلق هذا الوجه بنوع الدخل في المقاربات التي تدرس التنبؤ السعري للأسواق المالية، يمكن تقسيم دخل النماذج المدروسة إلى:

سعر السوق Market Price: هو السعر الحالي الذي يمكن عنده شراء أو بيع أصل أو خدمة. يتم تحديد سعر السوق للأصل أو الخدمة من خلال قوى العرض والطلب. السعر الذي تتساوى فيه الكمية المعروضة مع الكمية المطلوبة هو سعر السوق. (Friedman, 1984) في حال الأسواق المالية قد يكون السعر هو سعر الإغلاق لفترات

مختلفة (ساعية، يومية، أسبوعية، شهرية) أو مجموعة الأسعار المترافقة لتشكيل الشموع اليابانية (سعر أدنى، سعر أعلى، سعر افتتاح، سعر إغلاق). (Fama, 1965)

المؤشرات التقنية Technical Indicators: المؤشر التقني هو نمط رياضي مشتق من المعطيات التاريخية التي يستخدمها المتداولون الفنيون أو المستثمرون للتنبؤ باتجاهات الأسعار المستقبلية واتخاذ قرارات التداول. يستخدم معادلة رياضية لاشتقاق سلسلة من نقاط المعطيات من السعر السابق والحجم ومعطيات الفائدة المفتوحة. عادة ما يتم عرض المؤشر الفني بيانياً ومقارنته مع مخطط الأسعار المقابل للتحليل. تلتقط آليات المؤشر الفني السلوك وأحياناً مشاعر المستثمرين لتقديم دليل على الاتجاهات المستقبلية لنشاط السعر. (Huang, 2019)

مؤشرات المشاعر Sentiment Indicators: مؤشرات المعنويات المستخرجة من أخبار الأسواق المالية للمتداولين هي أمثلة على هذه المؤشرات. يتم توفير طرق النمذجة واختبارات الفرضيات الإحصائية على معطيات حقيقية، فالهدف العام هو تقديم مبادئ توجيهية للممارسين الماليين للأمور المناسبة بناء وتفسير معلوماتهم الرقمية المعتمدة على الوقت تمثل التصور العام لاتجاه الشركات وأسعار الأسهم والأسواق المالية بشكل عام (Arrattia, 2021). ويكون دخل النموذج بالنسبة لمقاربات هذه المشكلة عادة أخبار مالية أو مؤشرات مشاعر جاهزة مثل Fear & Greed index.

أخيراً نمثل وجه دخل النموذج بقيمة واحدة مجموعة أو أكثر من القيم التالية:

دخل النموذج: مجموعة القيم (سعر السوق (ساعي، يومي، اسبوعي، أدنى، افتتاح، ...)، المؤشرات التقنية، مؤشرات المشاعر، ...)

3.3.3.2 نوع مقارنة النموذج

نريد أن نعرف هنا إذا كانت المقاربة تستخدم نظاماً هجيناً يدمج بين نموذجين أم نظاماً بسيطاً يستخدم نموذجاً واحداً لحل هذه المشكلة وهنا نعرض تعريفاً بسيطاً للمفهومين في مجال تعلم الآلة Machine Learning:

النظام الهجين Hybrid System: النظام الهجين في ML هو نظام ذكي مؤطر من خلال الجمع بين تقنيتين ذكيتين على الأقل للحصول على أداء أعلى ونتائج أمثلة، مثل المنطق الغائم، والشبكات العصبونية، والخوارزميات الجينية، والتعلم المعزز. في بعض الأحيان، تحتوي الطرق الهجينة على نموذج واحد للتنبؤ ونموذج آخر لتحسين وحدة التنبؤ للوصول إلى مخرجات دقيقة، ولذلك تم الادعاء بأن الطرق الهجينة التي تحتوي على طرق مفردة مختلفة لها مرونة وقدرة عالية مقارنة بالطرق الفردية. (Ardabili, 2019)

النظام البسيط Simple System: هو النظام الذي يعتمد على نموذج واحد للقيام بوظيفة ما، إلا أنه يجدر بالقول إن أداء نظام بسيط مبني بشكل صحيح، قد يفوق أداء نظام هجين مبني بطريقة خاطئة أو غير أمثلة. (Ardabili, 2019)

يأخذ هذا الوجه قيمة واحدة من إحدى هاتين القيمتين بالشكل التالي:

نوع مقارنة النموذج: قيمة واحدة من قيم القائمة {نظام هجين، نظام بسيط}

4.3.3.2 تقنيات النموذج

صنف Nusrat Rouf تقنيات النماذج في مراجعته المنهجية (Rouf et al, 2021)، والتي تشمل تقنيات تعلم الآلة للتنبؤ السعري في الأسواق المالية، وأخذت الورقة البحثية بعين الاعتبار أبحاث هذا المجال لمدة عقد من الزمن محللة المنهجيات والتقنيات والتطور الذي حصل في هذا المجال إضافة إلى الاتجاهات المستقبلية. وبحسب هذه الدراسة فإن أهم التقنيات في هذا المجال:

الشبكات العصبونية الاصطناعية (Artificial Neural Network (ANN): هي خوارزمية تعلم آلي تعتمد كمبدأ على محاكاة نموذج خلية عصبونية بشرية، يصفها (Haykin, 1998) على أنها رسم بياني موجه من وحدات معالجة بسيطة يمكنها اكتساب المعرفة من البيئة، من خلال عملية التعلم وتخزين المعرفة، وهي عبارة عن عقد مترابطة موضوعة بشكل طبقات، كل طبقة تحتوي على عقد وفي كل عقدة تابع رياضي يسمى تابع تنشيط، يحكم ما إذا كانت العقدة (العصبون) نشطاً أم لا وتحتوي بشكل عام على طبقة دخل، طبقة مخفية على الأقل، وطبقة خرج، وتتغير أوزان بشكل ديناميكي في الوصلات بين العقد بحسب خوارزميات التعلم، بحسب عملية تسمى الانتشار العكسي Backpropagation. (Guresen, 2011)

النظام الخبير (Expert System (ES): هو برنامج يستخدم تقنيات الذكاء الاصطناعي AI لمحاكاة حكم وسلوك الإنسان أو المنظمة التي لديها معرفة وخبرة في مجال معين. عادةً ما يشتمل النظام الخبير على قاعدة معرفية تحتوي على الخبرة المتراكمة ومحرك الاستدلال أو مجموعة من القواعد لتطبيق قاعدة المعرفة على كل حالة معينة موصوفة للبرنامج. يمكن تعزيز قدرات النظام بإضافات إلى قاعدة المعرفة أو إلى مجموعة القواعد. قد تتضمن الأنظمة الحالية قدرات تعلم الآلة التي تسمح لها بتحسين أدائها بناءً على الخبرة، تمامًا كما يفعل البشر. (Feigenbaum, 1992)

آلة المتجه الداعم الخطي (Support Vector Machine (SVM): هي مصنفات خطية خاصة تعتمد على مبدأ تعظيم قيمة تابع منفعة، وبنفس الوقت تقليل قيمة تابع خطر هيكلي، مما يحسن من تعقيد المصنف بهدف تحقيق تعميم لتصنيف مشكلة ما، تعتبر قوة هذا النموذج بكونه يتعامل مع أبعاد متعددة (مستوى فائق) Hyperplane، الذي يفصل المعطيات على نحو أمثل إلى فئتين. (Adankon, 2009)

الانحدار الخطي Linear Regression: هو إجراء إحصائي لحساب قيمة المتغير التابع من المتغير المستقل، يقيس الانحدار الخطي الارتباط بين متغيرين. فهي تقنية نمذجة حيث يتم توقع متغير تابع بناءً على واحد أو أكثر من المتغيرات المستقلة، كما يجدر بالذكر أنه الأكثر استخداماً بين جميع الأساليب الإحصائية. (Kumari, 2018)

نايف بايز Naïve Bayes: هي طريقة تصنيف، تصنف المعطيات بناءً على نظرية بايز للاحتمال، من ميزات هذه الطريقة أنها سريعة للغاية ويمكن أن تتسع لمجموعات معطيات كبيرة ويتم استخدام هذه الطريقة على نطاق واسع للتنبؤ السعري في الأسواق المالية، في هذه الحالة يكون لدينا تصنيفين للتنبؤ (تنبؤ بارتفاع، تنبؤ بانخفاض) (Xianya, 2019). كما استخدم عدد من الباحثين خوارزمية Naïve Bayes لتحليل مشاعر معطيات نصية من مصادر متعددة. (Murshed, 2021)

الخوارزميات الجينية (Genetic Algorithms (GA): هي منهجية إرشادية لحل المشكلات التي تحاكي عملية التطور الطبيعي وتطبق مفهوم الانتقاء الطبيعي لاختيار أفضل حل ممكن. في مشاكل التنبؤ السعري يتم استخدام هذه الخوارزميات لتحسين دقة النماذج التنبؤية (Lin, 2004). كما تم تطوير نظم دعم قرار ذكية تستخدم الخوارزميات الجينية لإنشاء قواعد التداول واستراتيجيات البيع والشراء المثلى. (Kim, 2017)

خوارزميات المجموعات الغائمة Fuzzy Sets Algorithms: المجموعة الغائمة هي فئة من الأغراض متصلة بدرجات من الانتماء، وكل غرض له درجة من الانتماء تتراوح بين الصفر والواحد. تمتد مفاهيم التضمين، والاتحاد، والتقاطع، والتكامل، والتحدب، وما إلى ذلك (Zadeh, 1965). أما ضمن سياق الأبحاث التي لها علاقة بالتنبؤ السعري للأسواق المالية فتعتبر مقارنة نظم الاستدلال العصبونية الغائمة (Artificial Neural Fuzzy Inference System (ANFIS هي الخوارزمية الضبابية الأكثر شيوعاً وعادة ما يتم دمج منهجية المنطق الغائم مع مقاربات أخرى لمعالجة ظروف عدم التأكد في الأنظمة. (Nair, 2010)

المنهجيات الهجينة Hybrid Approaches: هي مزيج من التقنيات المختلفة المستخدمة في تحسين أداء نماذج التنبؤ. يوجد عدد محدود نسبياً من الدراسات التي تستخدم خوارزميات هجينة في هذا المجال إلا أنها أثبتت فعاليتها، على سبيل المثال يمكن الجمع ما بين تنبؤات خطية ونماذج غير خطية أو دمج شبكات عصبونية مع نماذج أخرى، ومن ميزات هذه المنهجية أنه يوجد عدد غير محدود من المجموعات التي يمكن تجريب جمعها بطرائق مختلفة وينسب متفاوتة. (Rouf et al, 2021)

يأخذ هذا الوجه قيمة واحدة أو مجموعة قيم بالشكل التالي:

تقنيات النموذج: مجموعة القيم (الشبكات العصبونية الاصطناعية، النظام الخبير، آلة المتجه الداعم الخطي، الانحدار الخطي، ...)

5.3.3.2 المؤشرات التقنية المستخدمة

عند استخدام النماذج المالية المذكورة سابقاً فيوجد عدد من المعايير المالية التي يمكن الاستفادة نذكر شرحاً بسيطاً لأهمها:

متوسط مؤشر الاتجاه Average Directional Movement Index (ADX): هو مؤشر اتجاه يستخدم لقياس قوة الاتجاه وزخمه. عندما يكون مؤشر ADX أعلى من 40، يعتبر أن الاتجاه يتمتع بقدر كبير من قوة الاتجاه، إما لأعلى أو لأسفل اعتماداً على الاتجاه الذي يتحرك فيه السعر. عندما يكون المؤشر أقل من 20 فإن الاتجاه يعتبر ضعيفاً أو غير معنوي. (Wilder, 1978)

مؤشر انحراف التقارب المتوسط المتحرك Moving Average Convergence Divergence (MACD): يساعد هذا المؤشر على رؤية اتجاه وزخم التغيرات السعرية، كما يوفر عدد من الإشارات التجارية، عندما يكون المؤشر أكبر من الصفر، يكون السعر في مرحلة صعود، وإذا كان أقل من الصفر فهذا يعني أنه دخل في مرحلة هبوط. كما يوجد خط آخر هو خط الإشارة للشراء وخط الإشارة للبيع إذا تجاوز MACD هذه الخطوط قد تكون هذه إشارة أخرى للقيام ببيع أو شراء. (Appel, 1985)

مؤشر القوة النسبية (RSI): هو مؤشر يتحرك بين 0 و 100 يقيس مكاسب الأسعار الأخيرة مقارنة بخسائر الأسعار الأخيرة. وبالتالي فإن مستويات مؤشر القوة النسبية تساعد في قياس الزخم وقوة الاتجاه. (Wilder, 1978)

نسبة السعر إلى الأرباح (Price to Earnings (P/E ratio): هي النسبة لتقييم الشركة التي تقيس سعر سهمها الحالي بالنسبة إلى ربحية السهم (Earnings Per Share (EPS). تُعرف أيضاً نسبة السعر إلى الأرباح أحياناً باسم مضاعف السعر أو مضاعف الأرباح. يستخدم المستثمرون والمحللون نسب السعر إلى العائد، لتحديد القيمة النسبية لأسهم الشركة. يمكن استخدامه أيضاً لمقارنة شركة ما بسجلها التاريخي أو لمقارنة الأسواق الإجمالية ببعضها البعض أو بمرور الوقت. (Shiller, 2001)

المتوسط المتحرك البسيط (Simple Moving Average (SMA): هو متوسط متحرك حسابي يتم حسابه عن طريق إضافة الأسعار الحديثة، ثم قسمة هذا الرقم على عدد الفترات الزمنية كمتوسط حسابي. على سبيل المثال، يمكن إضافة سعر إغلاق ورقة مالية لعدد من الفترات الزمنية ثم قسمة هذا الإجمالي على نفس العدد من الفترات. تستجيب المتوسطات قصيرة الأجل بسرعة للتغيرات في سعر الورقة المالية الأساسية بينما تكون استجابة المتوسطات طويلة الأجل أبطأ. (Hepple, 2001)

المتوسط المتحرك الأسّي (Exponential Moving Average (EMA): المتوسط المتحرك الأسّي EMA هو نوع من المتوسط المتحرك MA يضع وزناً وأهمية أكبر على أحدث نقاط المعطيات. يُشار أيضاً إلى المتوسط المتحرك الأسّي باسم المتوسط المتحرك الأسّي المرجح. يتفاعل المتوسط المتحرك المرجح بشكل أسّي مع تغيرات الأسعار الأخيرة بشكل أكثر أهمية من المتوسط المتحرك البسيط SMA الذي يطبق وزناً متساوياً على جميع الأسعار لفترة. (Hepple, 2001)

مؤشر الخوف والجشع (Fear & Greed index): تم تطويره بواسطة منصة CNNMoney لقياس اثنين من المشاعر الأساسية التي تؤثر على مقدار استعداد المستثمرين لدفع ثمن الأسهم. يقاس مؤشر الخوف والجشع على أساس يومي وأسبوعي وشهري وسنوي. من الناحية النظرية، يمكن استخدام المؤشر لقياس ما إذا كان سوق الأسهم مسعراً بشكل عادل. ويستند هذا إلى المنطق القائل بأن الخوف المفرط يميل إلى خفض أسعار الأسهم، ويميل الجشع المفرط إلى إحداث تأثير معاكس.^[1]

ويأخذ وجه المؤشرات التقنية المستخدمة قيمة واحدة أو أكثر من مجموعة القيم:

المؤشرات التقنية المستخدمة: مجموعة القيم (ADX, P/E, SMA, EMA, RSI, MACD, F&G...)

6.3.3.2 قابلية التعلم للنموذج

بحسب (Kalai, 2003) فإننا قادرون على القول إن النموذج قابلاً للتعلم إذا كان مصمم النموذج قادراً على إنشاء قاعدة تعلم لمعرفة تفضيل الوكيل، عندما تتوافق تفضيلات الوكيل مع النموذج الذي تم بناءه، بوجود معطيات كافية،

^[1] CNNMoney Fear & Greed Index: <https://edition.cnn.com/markets/fear-and-greed>

وبشكل موحد على العمليات التي تولد مشاكل الاختيار، بنسبة خطأ ضئيلة، يمكن القول إن النموذج قابل للتعلم عند قيامه بتحسين أداءه بعملية التدريب، وهو مفهوم مرتبط بتعلم الآلة ML، والشبكات العصبونية الاصطناعية ANN. أما النماذج الغير قابلة للتعلم وهي الحالة العامة فهي أي نماذج لا تحقق الشروط المذكورة أعلاه. في دراستنا المرجعية يمكن التمييز بين مقاربات استخدمت نماذج قابلة للتعلم كالشبكات العصبونية الاصطناعية والمقاربات الهجينة، وبين مقاربات أخرى استخدمت طرق غير قابلة للتعلم. على هذا الأساس يمكن القيام بالتصنيف بالشكل التالي:

قابلية تعلم النموذج: قيمة واحدة من قيم القائمة {قابل للتعلم، غير قابل للتعلم}

7.3.3.2 القدرة التفسيرية للنموذج

يمكن تصنيف المقاربات التي تقوم بالتنبؤات السعرية في الأسواق المالية إلى نماذج قادرة على إعطاء قدرة تفسيرية للتنبؤ، ونماذج غير قادرة على القيام بذلك، وعلى هذا الأساس قمنا بالتصنيف التالي:

النموذج القادر على التفسير: هو النموذج القادر على جعل المستخدم أو القارئ على الفهم من خلال وصفه أو إعطاء أسبابه، والقوة التفسيرية هي قدرة الفرضية أو النظرية على شرح الموضوع الذي يتعلق به بشكل فعال. يمكن القول إن النموذج الغير قادر على التفسير هو الذي لا يحقق المعيار السابق. (Marchionni, 2022)

بالتالي يأخذ وجه القدرة على التفسير إحدى القيمتين على الشكل التالي:

القدرة التفسيرية للنموذج: قيمة واحدة من قيم القائمة {قادر على التفسير، غير قادر على التفسير}

يمكن تلخيص هذا البعد على بالجدول التالي:

الجدول (4) أوجه بعد النموذج

الوجه	مجال القيم الممكنة
معطيات النموذج	مجموعة القيم (معطيات خام، معطيات مشتقة)
	مجموعة القيم (معطيات مهيكلة، معطيات شبه مهيكلة، المعطيات غير المهيكلة)
دخل النموذج	مجموعة القيم (سعر السوق (ساعي، يومي، اسبوعي، أدنى، افتتاح، ...)، المؤشرات التقنية، مؤشرات المشاعر، ...)
نوع مقارنة النموذج	قيمة واحدة من قيم القائمة {نظام هجين، نظام بسيط}
تقنيات النموذج	مجموعة القيم (الشبكات العصبونية الاصطناعية، النظام الخبير، آلة المتجه الداعم الخطي، الانحدار الخطي...)
المؤشرات التقنية المستخدمة	مجموعة القيم (ADX, P/E, SMA, EMA, RSI, MACD, F&G...)
قابلية تعلم النموذج	قيمة واحدة من قيم القائمة {قابل للتعلم، غير قابل للتعلم}
القدرة التفسيرية للنموذج	قيمة واحدة من قيم القائمة {قادر على التفسير، غير قادر على التفسير}

4.3.2 بعد التنفيذ والتحقق

يعالج بعد التنفيذ والتحقق الأدوات المستخدمة، لغات البرمجة المستخدمة، الخوارزميات المستخدمة، أدوات اختبار الصحة، أدوات اختبار الأداء (الأمثلية)، خرج النموذج وتمثل هذه الجوانب بالأوجه التالية:

1.4.3.2 الأدوات المستخدمة

نعرض في هذه الفقرة أهم الأدوات المستخدمة في مجال التنبؤ السعري في الأسواق المالية ومجال تعلم الآلة ML: أداة (Valence Aware Dictionary and Sentiment Reasoner (VADER): هي عبارة عن معجم وأداة تحليل مشاعر قائمة على قواعد المعرفة، والتي تتلاءم بشكل خاص مع المشاعر التي يتم التعبير عنها في وسائل التواصل الاجتماعي. وهي أداة مفتوحة المصدر بموجب ترخيص معهد MIT. (Hutto, 2014)

منصة (Natural Language Toolkit (NLTK: هي منصة رائدة لبناء برامج Python للعمل مع معطيات اللغة البشرية. يوفر واجهات سهلة الاستخدام لأكثر من 50 مجموعة وموارد معجمية مثل WordNet، جنباً إلى جنب مع مجموعة من مكتبات معالجة النصوص للتصنيف والترميز والاشتقاق والعلامات والتحليل والتفكير الدلالي. (Perkins, 2017)

أداة DELPHI: هي امتداد للغة البرمجة باسكال، توفر ميزات البرمجة غرضية التوجه مثل الفئات، والطرق، كما تدعم العديد من المنصات وأنظمة التشغيل. (Lischner, 2000)

منصة ProRealTime: هو برنامج رسم بياني ومنصة تداول للبورصة وهو برنامج تحليل تقني تم تصميمه وتطويره في فرنسا بواسطة IT-Finance. يتكون من منصة تداول إلكترونية بالإضافة لبرنامج تحليل فني يستخدم لتحليل الأسواق المالية. [2]

مكتبة NumPy: هي المكتبة الأساسية للحوسبة العلمية بلغة برمجة Python التي توفر كائن مصفوفة متعددة الأبعاد، وكائنات مشتقة متنوعة (مثل المصفوفات والمصفوفات المقنعة)، ومجموعة متنوعة من الإجراءات للعمليات السريعة على المصفوفات، بما في ذلك التلاعب الرياضي والمنطقي بالشكل والفرز والاختيار والإدخال / الإخراج وتحويلات فورييه المنفصلة والجبر الخطي الأساسي والعمليات الإحصائية الأساسية والمحاكاة العشوائية وغير ذلك الكثير. (Harris, 2020)

مكتبة Matplotlib: هي مكتبة شاملة لإنشاء الرسوم البيانية الثابتة والمتحركة والتفاعلية بلغة برمجة Python وتوفر منصة غرضية التوجه لتضمين الرسوميات للتطبيقات باستخدام تعاون مع أدوات ومكتبات أخرى. (Hunter, 2007)

مكتبة Keras: هي واجهة برمجة تطبيقات بلغة Python مفتوحة المصدر صممت لتوفر واجهة للشبكات العصبونية الاصطناعية والتعلم العميق، وتركز على أن تكون سهلة الاستخدام وقابلة للتوسع، وتقليل عدد الإجراءات المطلوبة من المستخدم لحالات الاستخدام والشائعة، تعمل Keras كواجهة لمكتبة TensorFlow. (Chollet, 2015)

[2] ProRealTime Platform: <https://www.prorealtime.com/en/>

مكتبة TensorFlow: عبارة عن منصة مفتوحة المصدر شاملة للتعليم الآلي. يحتوي على نظام بيئي شامل ومرن للأدوات والمكتبات وموارد المجتمع التي تتيح للباحثين دفع أحدث ما توصلت إليه التكنولوجيا في تعلم الآلة والمطورين لبناء ونشر التطبيقات التي تعمل بنظام التعلم الآلي بسهولة. تم تطوير TensorFlow بواسطة فريق Google Brain للاستخدام الداخلي لشركة Google في البحث والإنتاج. (Dean, 2016)

مكتبة Scikit-Learn: هي مكتبة مجانية مفتوحة المصدر للتعلم الآلي بلغة Python يتميز بخوارزميات تصنيف وانحدار وتجميع مختلفة بما في ذلك آلات ناقلات الدعم والغابات العشوائية وغيرها من الخوارزميات الجاهزة، وهو مصمم للتعامل مع مكاتب Python الرقمية والعلمية مثل NumPy وSciPy. (Gramfort, 2011)

أخيراً يأخذ هذا الوجه قيمة واحدة أو أكثر من قيم المجموعة بالشكل التالي:

الأدوات المستخدمة: مجموعة القيم (VADER, NLTK, ProRealTime, NumPy Matplotlib, Keras ...)

2.4.3.2 لغات البرمجة المستخدمة

نعرض في هذه الفقرة بعض أهم لغات البرمجة المستخدمة لتنفيذ نماذج الحل وهي بحسب الأكثر شيوعاً بالشكل التالي:

لغة Python: هي لغة برمجة مفسرة، وعالية المستوى، للأغراض العامة وهي تدعم نماذج برمجية متعددة، بما في ذلك البرمجة المهيكلية (خاصة الإجرائية)، غرضية التوجه، والوظيفية، وتتمتع بمكاتب قياسية شاملة خاصة بها. (Rossum, 1995)

لغة C++: هي لغة كمبيوتر غرضية التوجه أنشأها عالم الكمبيوتر Bjorne Stroustrup كجزء من تطور عائلة C للغات. تم تطويره كتحسين عبر الأنظمة الأساسية للغة C. لتزويد المطورين بدرجة أعلى من التحكم في الذاكرة وموارد النظام. (Strustrup, 2000)

لغة Java: تم تطوير لغة برمجة Java بواسطة Sun Microsystems في أوائل التسعينيات. على الرغم من أنها تستخدم بشكل أساسي للتطبيقات المستندة إلى الإنترنت، فإن Java هي لغة بسيطة وفعالة وذات أغراض عامة. تم تصميم Java في الأصل لتطبيقات الشبكة المضمنة التي تعمل على أنظمة أساسية متعددة. إنها لغة محمولة غرضية التوجه، مفسرة. (Austerlitz, 2003)

لغة Pascal: باسكال هي لغة برمجة إلزامية وإجرائية، صممها نيكلاوس ويرث كلغة صغيرة وفعالة تهدف إلى تشجيع ممارسات البرمجة الجيدة باستخدام البرمجة المهيكلية وهيكلية المعطيات. تم تسميته على شرف عالم الرياضيات والفيلسوف والفيزيائي الفرنسي بليز باسكال. (Wirth, 2012)

يأخذ نمثل وجه لغة البرمجة المستخدمة بالشكل التالي:

لغة البرمجة المستخدمة: قيمة واحدة من قيم القائمة {Python, C++, Java, Pascal,...}

3.4.3.2 الخوارزميات المستخدمة

نستعرض بعض أهم الخوارزميات المستخدمة في المقاربات التي تحل مشاكل مشابهة في هذه الفقرة:

خوارزمية أصل التدرج Gradient Descent: هو خوارزمية تحسين تكرارية من الدرجة الأولى تستخدم للعثور على حد أدنى / أقصى محلي لتابع ما. تُستخدم هذه الطريقة بشكل شائع في التعلم الآلي (ML) والتعلم العميق (DL) لتقليل تابع التكلفة أو الخسارة (على سبيل المثال في الانحدار الخطي). (Hazan, 2022)

خوارزمية أمثلة ADAM optimization algorithm: تعد خوارزمية تحسين آدم امتداداً لنسب التدرج العشوائي الذي شهد مؤخرًا اعتماداً أوسع لتطبيقات التعلم العميق في رؤية الكمبيوتر ومعالجة اللغة الطبيعية، آدم هي خوارزمية أمثلة يمكن استخدامها بدلاً من إجراء نزول التدرج العشوائي Gradient Descent الكلاسيكية لتحديث أوزان الشبكة التكرارية بناءً على معطيات التدريب. (Diederick, 2014)

خوارزمية الانتشار العكسي Back Propagation: تعتبر هذه الخوارزمية حجر الأساس في الشبكات العصبونية تم تقديم هذه الخوارزمية لأول مرة في الستينات وبعد ذلك بنحو 30 عاما استخدمها (Williams, 1989) تُستخدم الخوارزمية لتدريب شبكة عصبونية بشكل فعال من خلال طريقة تسمى قاعدة السلسلة. بعد كل تمريرة للأمام عبر الشبكة تقوم back propagation بتمريرة للخلف مع أثناء ضبط معلمات النموذج (الأوزان والثوابت) وبهذه الطريقة يمكن القول إن الشبكة تتعلم. (Williams, 1989)

خوارزمية الاستدلال الأمامي Forward Chaining: هي إحدى خوارزميتين رئيسيتين للاستدلال عند استخدام محرك الاستدلال ويمكن وصفه منطقياً بأنه تطبيق متكرر للوضعيات. التسلسل إلى الأمام هو إستراتيجية تنفيذ شائعة للأنظمة الخبيرة وأنظمة قواعد الأعمال والإنتاج. يبدأ التسلسل الأمامي بالمعطيات المتاحة ويستخدم قواعد الاستدلال لاستخراج المزيد من المعطيات (من المستخدم النهائي، على سبيل المثال) حتى يتم الوصول إلى الهدف. يبحث محرك الاستدلال الذي يستخدم التسلسل الأمامي في قواعد الاستدلال حتى يعثر على واحدة حيث يُعرف أن السابقة (عبارة If) صحيحة. عندما يتم العثور على مثل هذه القاعدة، يمكن للمحرك أن يستنتج ما يترتب على ذلك (عبارة ثم)، مما يؤدي إلى إضافة معلومات جديدة إلى معطياته. ستقوم محركات الاستدلال بالتكرار خلال هذه العملية حتى يتم الوصول إلى الهدف. (Feigenbaum, 1992)

خوارزمية الاستدلال العكسي Backwards Chaining: هي خوارزمية استدلال توصف بأنها تعمل للخلف من الهدف وتولد الأهداف أهدافاً فرعية لنصل إلى معارف جديدة من المعارف السابقة وتكرر هذه العملية ويصبح بإمكاننا تطبيق قواعد أكثر في محرك الاستدلال حتى نصل إلى الهدف الأساسي. يتم استخدامها في محركات الاستدلال، وتطبيقات الذكاء الاصطناعي الأخرى وعادة ما تستخدم هذه الطريقة الاستراتيجية البحث في العمق (Russell & Norvig, 2009)

أخيراً فإن وجه الخوارزميات التي يمكن استخدامها تأخذ قيمة واحدة أو مجموعة قيم المجموعة بالشكل التالي:

الخوارزميات المستخدمة: مجموعة القيم (Gradient Descent, ADAM, Back propagation, Forward Chaining ...)

4.4.3.2 أدوات اختبار الصحة

نستعرض في هذه الفقرة بعض أدوات اختبار الصحة لنعرف إذا ما كان النموذج فعال بالدرجة الأولى لنؤكد من أمثله بأدوات أخرى كخطوة تالية ويمكن بعدها مقارنة النماذج ببعضها من خلال هذه الأدوات والمعايير:

الرسوم البيانية: هي طريقة سهلة وبسيطة لمعرفة اقتراب التنبؤ بشكل عام للسعر الحقيقي إلا أنه لا يمكن اعتبارها أداة اختبار أداء إلا إذا كنا نقارن عدة نماذج في نفس الرسم البياني وهي وسيلة أيضاً قوية لأنها تعطي فكرة عامة عن صحة النموذج بزمان ضئيل جداً. لتمثيل هذه المعرفة تم استخدام برامج إحصائية جاهزة مثل برنامج EViews أو مكاتب برمجية مثل Matplotlib (Hunter, 2007).

الجدول: هي عادة جداول تمثل القيم المتوقعة بأعمدة والقيم الفعلية بأعمدة ويمكن اعتبارها أداة اختبار صحة لأنها تعطينا لمحة إلا أنه من غير الممكن اعتبار الجداول أداة اختبار أمثلة أداء بل هذه الجداول تتم معالجتها وتطبيق معادلات رياضية إحصائية على معطياتها للتوصل إلى مؤشرات الأداء وتستخدم برامج جاهزة لتوليد الجداول أو مكاتب برمجية مثل pandas (McKinney, 2010).

المحاكاة Simulation: هي نموذج رياضي يصف أو يخلق حسابياً عملية نظام يمثل صورة قريبة قدر الإمكان للواقع وهي أفضل تمثيل معرفي لدينا للواقع المعقد، أي أعمق تصور لدينا لماهية الواقع. (Vallverdu, 2014) في النماذج المالية شهدت الفترة الأخيرة ميلاً لنماذج المحاكاة مثل نموذج مونت كارلو للمحاكاة المالية. تُستخدم محاكاة مونت كارلو لنمذجة احتمالية النتائج المختلفة في عملية لا يمكن التنبؤ بها بسهولة بسبب تدخل المتغيرات العشوائية. إنها تقنية تستخدم لفهم تأثير المخاطر وعدم اليقين في نماذج التنبؤ والتنبؤ. يمكن استخدام محاكاة مونت كارلو لمعالجة مجموعة من المشاكل في كل مجال تقريباً مثل التمويل والهندسة وسلسلة التوريد والعلوم. يشار إليها أيضاً باسم محاكاة الاحتمالات المتعددة. (McLeish, 2005) كما شهد المجال أدوات محاكاة مجانية ومتاحة للجميع وصديقة للمستخدم كبرامج محاكاة مثل Investopedia simulator: تم تصميم برنامج محاكاة Investopedia لمساعدة أي شخص على تعلم آليات شراء وبيع الأوراق المالية في بيئة خالية من المخاطر. تحاكي أداة التعلم هذه الأنشطة التي يواجهها المستثمرون عند تقديم الطلبات من خلال وسيط. يوفر المحاكى تنبؤاً في الوقت الفعلي للتغيرات في قيمة الاستثمارات المحاكاة من خلال إظهار أداء المستخدمين لاستثماراتهم. (Scott G, 2022) تعتبر المحاكاة إحدى طرائق التأكد من صحة النموذج فإذا كانت نتيجة المحاكاة بعد فترة من الزمن إيجابية فالنموذج فعال وإذا كانت النتيجة سلبية فيكون النموذج مرفوضاً ويمكن تقسيم المحاكاة في الأسواق المالية إلى نوعي محاكاة كالتالي:

الأرباح Profit: هي الربح الذي تحققه الشركة في فترة محددة، وعادة ما يتم تعريفها على أنها ربع سنة أو سنة. بعد نهاية كل ربع سنة، ينتظر المحللون الإفراج عن أرباح الشركات التي يتبعونها. تتم دراسة الأرباح لأنها تمثل رابطاً مباشراً لأداء الشركة (Tuovila, 2022). أما عند محاكاة قرارات شراء وبيع لمدة زمنية ما فعندما تكون نتيجة المحاكاة هو ربح أي فوق الصفر فيمكن القول عن النموذج أنه فعال إلا أننا لا يمكن الحكم على أدائه أو أمثليته إلا إذا قمنا بمقارنة النتائج بطرق أخرى. (O'Donoghue, 2017)

العائد على الاستثمار Return On Investment (ROI): هو مقياس اقتصادي يستخدم للإشارة إلى مقدار الفوائد الاقتصادية المستمدة من البرنامج فيما يتعلق بتكاليفه. (Brouselle, 2016) عند محاكاة قرارات الشراء والبيع يمكن

حساب معدل العائد على رأس المال المستثمر، والنتيجة تكون نسبة مئوية يمكننا من خلالها تقدير نجاح النموذج أو فشله فإذا كان معدل العائد على رأس المال سالب أو نسبة ضئيلة جداً يمكن القول إن النموذج غير مقبول. نمثل هذا الوجه بقيمة واحدة أو أكثر من قيم المجموعة بالشكل التالي:

أدوات اختبار الصحة: مجموعة القيم (الرسوم البيانية، الجداول، المحاكاة (الربح، العائد على الاستثمار...))

5.4.3.2 مقاييس اختبار الأداء

نستعرض في هذه الفقرة أهم مقاييس اختبار الأداء التي تستخدمها الأبحاث لحل مشاكل التنبؤ:

متوسط دقة التنبؤ (Mean Prediction Accuracy (MPA): يعبر عن القيمة المطلقة المتوسط الحسابي للتنبؤ لسعر السهم l في الفترة الزمنية t مطروحاً من السعر الحقيقي على متوسط القيم الحقيقية.

$$MPA_t = 1 - \frac{1}{L} \sum_{l=1}^L \frac{|X_{t,l} - X_{mean_{t,l}}|}{X_{t,l}} \quad (Li, 2019)$$

متوسط مربع الأخطاء (Mean Standard Error (MSE): وهي من أشهر أدوات الإحصاء يدل متوسط الخطأ التربيعي MSE على مدى اقتراب خط الانحدار من مجموعة من النقاط. يقوم بذلك عن طريق أخذ المسافات من النقاط إلى خط الانحدار (هذه المسافات هي الأخطاء) وتربيعها. التربيع ضروري لإزالة أي علامات سلبية. كما أنه يعطي وزناً أكبر للاختلافات الأكبر. يطلق عليه متوسط الخطأ التربيعي لأنه يعثر على متوسط مجموعة من الأخطاء. كلما انخفض MSE، كان التنبؤ أفضل، وتعطى معادلته بالشكل التالي. (Vandepu, 2019)

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \tilde{y}_i)^2$$

متوسط الأخطاء المطلقة بالنسبة المئوية (Mean Absolute Percentage Error (MAPE): هو مقياس لمدى دقة نظام التنبؤ. يقيس هذه الدقة كنسبة مئوية، ويمكن حسابه على أنه متوسط نسبة الخطأ المطلق لكل فترة زمنية مطروحاً منه القيم الفعلية مقسومة على القيم الفعلية. وتعطى معادلته بالشكل: (Vandepu, 2019)

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

نسبة الإصابة (Hit Ratio): هي نسبة تعبر عن عدد مرات الإصابة في تنبؤ ما على جميع عدد مرات التنبؤ ونعبر عنها بالشكل $\text{Hit Ratio\%} = (\text{Hit frequency} / (\text{Hit frequency} + \text{Fail frequency})) * 100$ (K.H. Lee, 1999) نمثل القيم التي يمكن أن يأخذها هذا الوجه بالشكل التالي:

أدوات اختبار الأداء: مجموعة القيم (MPA, MSE, MAPE, Hit Ratio, ...)

6.4.3.2 خرج التنفيذ

يمثل شكل المعرفة التي نتجت عن تنفيذ المقربة المقترحة وتأخذ عدة أوجه وهي:

اختيار أحد الأسهم لمحفظه: استثمار المحفظة هو ملكية الأسهم أو السندات أو الأصول المالية الأخرى مع توقع أنها ستكسب عائداً أو تنمو في القيمة بمرور الوقت، أو كليهما. يمكن تقسيم استثمارات الحافظة إلى فئتين رئيسيتين:

يتضمن الاستثمار الاستراتيجي شراء الأصول المالية لإمكانات نموها على المدى الطويل أو عائد دخلها، أو كليهما، بقصد الاحتفاظ بهذه الأصول لفترة طويلة. أما النهج التكتيكي يتطلب نشاط بيع وشراء نشط على أمل تحقيق مكاسب على المدى القصير (Chen, 2021). أغلب الدراسات التي تعتمد على تمييز الأنماط والمقاربات التي تعتمد على التحليل التقني للسوق المالي يعتمد على النهج التكتيكي في الاستثمار.

التنبؤ بسعر الإغلاق لليوم التالي: سعر الإغلاق هو السعر الخام أو القيمة النقدية لآخر سعر تم تداوله في ورقة مالية قبل إغلاق السوق رسميًا للتداول العادي. غالبًا ما تكون النقطة المرجعية التي يستخدمها المستثمرون لمقارنة أداء السهم منذ اليوم السابق وكثيرًا ما تستخدم أسعار الإغلاق لإنشاء رسوم بيانية خطية تصور تغيرات الأسعار التاريخية بمرور الوقت. التنبؤ بهذا السعر يشكل قسم كبير من أبحاث الأسواق المالية لأهميتها العملية (Hillion, 2004).

التصنيف Classification: تعني كلمة تصنيف وضع الأشياء في فئات، وتجميعها معًا بطريقة مفيدة. في التعلم الآلي، يرتبط مصطلح التصنيف بشكل شائع بنوع معين من التعلم حيث يتم إعطاء أمثلة لفئة أو أكثر، مصنفة باسم الفصل، إلى خوارزمية التعلم. تنتج الخوارزمية مصنفاً يقوم بتعيين خصائص هذه الأمثلة، والتي يتم التعبير عنها عادةً كأزواج قيمة السمة، إلى تسميات الفئات. يتم تصنيف مثال جديد بفئته غير معروفة عندما يتم منحه تسمية فئة بواسطة المصنف، بناءً على خصائصه (Ellin, 2004). أما في مجال الأسواق المالية فالاستخدام الشائع للتصنيف، هو التصنيف الثنائي Binary Classification، وغالبًا يكون على شكل تنبؤ لارتفاع أو انخفاض. (Rouf et al, 2021).

هيكليّة النموذج Model Architecture: هي تحديد جزئي للنظام، تبين الخصائص المختلفة للنظام. إنها نسخة مصغرة ومبنية بجميع التفاصيل الأساسية للنظام. تتضمن هيكليّة النموذج، تحديد خصائص النظام والتعبير عنها كنماذج بحيث يمكن فهم النظام (Kazman et Al, 2014).

التنبؤ بالتوقيت المناسب للقيام باستثمار جديد: تجيب تنبؤات الوقت عادةً على أسئلة مثل كم من الوقت سيستغرق ذلك؟ وما مقدار الوقت الذي تحتاجه، لا يتعين على نماذج الوقت الفعلي فقط التعامل مع فهم الوقت الذي يتوقعون فيه الأحداث، ولكن يتعين عليهم أيضاً التأكد من عدم فقدانها خواص الصحة في حال اضطرابات غير مسبوقة. غالبًا ما يكون توقيت السوق مكونًا رئيسيًا لاستراتيجيات الاستثمار المدارة بفعالية، وهو دائمًا استراتيجية أساسية للمتداولين. قد تتضمن الأساليب التنبؤية لتوجيه قرارات السوق معطيات أساسية أو فنية أو كمية أو اقتصادية (Halkjelsvik, 2018).

نمثل وجهه خرج التنفيذ بالشكل التالي:

خرج التنفيذ: مجموعة القيم (اختيار أحد الأسهم لمحفظه، التنبؤ بسعر الإغلاق لليوم التالي، تصنيف، التنبؤ بالتوقيت المناسب للقيام باستثمار جديد، ...)

ويمكن تلخيص هذا البعد على الشكل:

الجدول (5) أوجه بعد التنفيذ والتحقق

الوجه	مجال القيم الممكنة
الأدوات المستخدمة	مجموعة القيم (VADER, NLTK, ProRealTime, NumPy Matplotlib, Keras, ...)
لغة البرمجة المستخدمة قيمة	واحدة من قيم القائمة {Python, C++, Java, Pascal, ...}
الخوارزميات المستخدمة	مجموعة القيم (Gradient Descent, ADAM, Back propagation, Forward Chaining, ...)
أدوات اختبار الصحة	مجموعة القيم (الرسوم البيانية، الجداول، المحاكاة (الربح، العائد على الاستثمار، ...، ...)
أدوات اختبار الأداء	مجموعة القيم (MPA, MSE, MAPE, Hit Ratio, ...)
خرج التنفيذ	مجموعة القيم (اختيار أحد الأسهم لمحفظه، التنبؤ بسعر الإغلاق لليوم التالي، تصنيف، التنبؤ بالتوقيت المناسب للقيام باستثمار جديد، ...)


5.3.2 ملخص إطار المقارنة

بعد تفصيل إطار المقارنة في الفقرات السابقة من جميع وجوهه بالإضافة للمحلة سريعة عن القيم التي قد تأخذها هذه الأوجه قمنا بتلخيص ما توصلنا إليه في الجدول (6)، والذي يعرض فيه الأبعاد الأربعة بالإضافة إلى أوجه كل بعد والقيم الممكنة لهذه الأوجه.

الجدول (6) ملخص إطار المقارنة

البعد	الوجه	القيمة	القيم الممكنة
الموضوع	مجال الرؤية	قيمة واحدة	{صندوق أسود، صندوق أبيض}
	سوق النموذج	متعدد القيم	{IBEX35, NSE, S&P500, NASDAQ, FTSE, KOSPI, ...}
	تحليل الاستثمار	قيمة واحدة	{تحليل تقني، تحليل أساسي}
بعد الاستخدام	الغاية النهائية	متعدد القيم	(اختيار أحد الأسهم لإضافته لمحفظه، التنبؤ بسعر الإغلاق لليوم التالي، التنبؤ بتصنيف اليوم التالي (أعلى، أدنى)، التنبؤ بالتوقيت المناسب للقيام باستثمار جديد)
	الأهداف المرحلية	متعدد القيم	(اختيار المتغيرات، تحويل قيمها لغائمة، بناء قاعدة معرفة/قواعد، محاكاة، التدريب، الاختبار، بناء النماذج، دمج النماذج، اختيار النموذج الأنسب، ...)

	القيمة المضافة للمقاربة		متعدد القيم	(دمج عدة نماذج سابقة، مقارنة عدة نماذج، بناء نموذج جديد، تجربة محاكاة، إدخال متغيرات جديدة لنموذج سابق، بناء قواعد استدلال جديدة بالاعتماد على خبير، ...)
	معطيات النموذج	آلية الحصول على المعطيات	متعدد القيم	(معطيات خام، معطيات مشتقة)
بعد النموذج		نوع معطيات النموذج	متعدد القيم	(معطيات مهيكلية، معطيات شبه مهيكلية، المعطيات غير المهيكلية)
	دخل النموذج		متعدد القيم	(سعر السوق (ساعي، يومي، اسبوعي، أدنى، افتتاح، ...)، المؤشرات التقنيّة، مؤشرات المشاعر، ...)
	نوع مقارنة النموذج		قيمة واحدة	{نظام هجين، نظام بسيط}
	تقنيات النموذج		متعدد القيم	(الشبكات العصبونية الاصطناعية، النظام الخبير، آلة المتجه الداعم الخطي، الانحدار الخطي...)
	المؤشرات التقنيّة المستخدمة		متعدد القيم	(ADX, P/E, SMA, EMA, RSI, MACD,) (F&G...
	قابلية تعلم النموذج		قيمة واحدة	{قابل للتعلم، غير قابل للتعلم}
	القدرة التفسيرية للنموذج		قيمة واحدة	{قادر على التفسير، غير قادر على التفسير}
	الأدوات المستخدمة		متعدد القيم	(VADER, NLTK, ProRealTime, NumPy) (Matplotlib, Keras ...
	لغة البرمجة المستخدمة		قيمة واحدة	{Python, C++, Java, Pascal...}
	التنفيذ والتحقق	الخوارزميات المستخدمة		متعدد القيم
أدوات اختبار الصحة		متعدد القيم	(الرسوم البيانية، الجداول، المحاكاة (الربح، العائد على الاستثمار..)) ...)	
أدوات اختبار الأداء		متعدد القيم	(MPA, MSE, MAPE, Hit Ratio...)	
خرج التنفيذ		متعدد القيم	(اختيار أحد الأسهم لمحفظة، التنبؤ بسعر الإغلاق لليوم التالي، تصنيف، التنبؤ بالتوقيت المناسب للقيام باستثمار جديد،...)	



الشكل (20) بنية إطار المقارنة المناسب لموضوع البحث

6.3.2 المقاربات ذات الصلة بموضوع البحث

يوجد العديد من المقاربات في دراسات سابقة تهتم بموضوع حل مشكلة التنبؤ السعري في السلاسل الزمنية والأسواق المالية، كونها مشكلة تثير اهتمام العديد من المستثمرين ومحللين المعطيات والرياضيين والاقتصاديين، وقد جرى في هذا البحث تنفيذ دراسة مرجعية مؤلفة من ستة أوراق بحثية تأخذ مقاربات مشابهة لمقاربتنا، وهذا لإسقاط إطار المقارنة عليها ومقارنتها مع مقاربتنا المقترحة.

1.6.3.2 مقارنة (Casanova I. J, 2012)

حيث اقترح Casanova I. J نظام دعم قرار هجين لمساعدة المستثمر على انتقاء استثمار جديد لإضافته على المحفظة اعتماداً على محرك استدلال معتمد على المنطق الغائم. لا تهتم هذه المقاربة بالتفصيلات، حيث تم الاكتفاء بنظرة سطحية عامة عن آلية الحل. تم اعتماد المنطق الغائم في هذه المقاربة في ثلاث أماكن وهي (set theory,)

(fuzzy fuzzy if – then rules, fuzzy reasoning). بتوابع انتماء تحتوي 3 درجات من الانتماء (صغير، متوسط، كبير). يحاكي هذا النظام منطق وتصرفات خبير في هذا المجال من خلال استكشاف اختيارات الاستثمار المتاحة وتقييمها باستخدام مقاربات المنطق الغائم على المؤشرات التقنية وأخذ القرار باستخدام محرك استدلال يعتمد على القواعد. يميز النظام عند البدء نوعين من الأصول التي يمكن شرائها بحسب الغاية إلى أصول تكتيكية، وهي أصول من المتوقع أن ترتفع في المدى القريب وبالتالي فرصة ربحية عالية ويتم بيع هذه الأصول بسرعة عندما يتحقق شرط الربح، وأصول استراتيجية من المتوقع زيادة سعرها في المدى البعيد. تكون معطيات النموذج في هذه الحالة معطيات مهيكلية، ومن حيث آلية الحصول عليها فهي خام للسعر ومشتقة للمؤشرات التقنية المالية. تم وضع قواعد المعرفة في هذا النظام بالاعتماد على السعر الأدنى اليومي ومؤشرات تقنية مالية وهي ARP, RSI, MA, DMA. كما تم وضع حد أعلى لتحمل الخسارة قبل البيع وهو 4% فعندما يصل السعر الجديد لسعر أقل من السعر الحالي ب 4% يقوم النظام بالبيع التلقائي.

تم تقييم هذا النظام على 3 فترات زمنية (سنة، ثلاث سنوات، خمسة سنوات) من خلال تجربة محاكاة قرارات الاستثمار ومقارنة الربحية الافتراضية بربحية أفضل شركات الاستشارة والاستثمار في اسبانيا في سوق IBEX. وتم التوصل إلى أن هذا النظام ناجح لاختيار استثمارات جديدة لأنه يحاكي منطق الخبراء كما أنه كان أكثر نجاحاً خلال مدة الخمسة سنوات من شركات الاستثمار والاستشارة بنسبة تفوق 15% وهي نسبة ممتازة كما أن الطريقة المقترحة لاختيار الاستثمارات مبتكرة وغير مسبقة في المجال ولذلك تحتل التطوير المستقبلي على الأجزاء المختلفة في النظام. (Casanova, 2012)

الجدول (7) مقارنة (Casanova, 2012) وفق إطار المقارنة

البعد	الوجه	القيم الممكنة
بعد الموضوع	مجال الرؤية	صندوق أسود
	سوق النموذج	IBEX35
	تحليل الاستثمار	تحليل تقني
بعد الاستخدام	الغاية النهائية	القيام باختيار أحد الأسهم لإضافته لمحفظة
	الأهداف المرحلية	اختيار المتغيرات، تحويل قيمها لغائمة، بناء قاعدة معرفة/قواعد، محاكاة، دمج النماذج
	القيمة المضافة للمقارنة	دمج عدة نماذج سابقة، تجربة محاكاة، بناء قواعد استدلال جديدة بالاعتماد على خبير
	آلية الحصول على المعطيات	معطيات خام، معطيات مشتقة
	نوع معطيات النموذج	معطيات مهيكلية

بعد النموذج	دخول النموذج	السعر، مؤشرات تقنية
	نوع مقارنة النموذج	نظام هجين
	تقنيات النموذج	النظام الخبير، المنطق الغائم
	المؤشرات التقنية المستخدمة	ARP, RSI, MA, DMA
	قابلية تعلم النموذج	غير قابل للتعلم
	القدرة التفسيرية للنموذج	قادر على التفسير
بعد التنفيذ والتحقق	الأدوات المستخدمة	NRC fuzzy toolkit
	لغة البرمجة المستخدمة	-
	الخوارزميات المستخدمة	Forward Chaining, fuzzification
	أدوات اختبار الصحة	Simulation, APR (annual percentage rate)
	أدوات اختبار الأداء	Variance
	خرج التنفيذ	تصنيف الأصول إلى تكتيكية واستراتيجية، خيار لشراء أو بيع سهم من عدة بدائل

2.6.3.2 مقارنة (Martinson, 2012)

قام Martinson بإجراء تحليل مقارنة وتقييم الأثر لقيم مختلفة لمؤشر القوة النسبية RSI ووقف الخسارة على خوارزمية تداول تعتمد على أنماط الشموع اليابانية، لا تهتم هذه المقارنة بالتفاصيل، حيث تم الاكتفاء بنظرة سطحية عامة عن آلية الحل.

يهدف البحث بشكل أساسي للتنبؤ السعري للفترة القادمة بنظام بسيط يتألف من تنبؤات مختلفة لمعايير خوارزمية تتنبأ باستخدام Candlestick patterns, RSI, Stop loss limit والتوصل للتنبؤ الأفضل. يمكن القول أن معطيات النموذج هي معطيات مهيكلية، كما أنها خام وذلك لأن البرنامج المستخدم يؤمن هذه المعطيات دون تطبيق معادلات إضافية لاشتقاق معطيات إضافية مثل RSI. فهي مبنية أساساً في البرنامج ويختار المستخدم إظهارها أو عدم إظهارها. تم بناء النموذج باستخدام أداة Pro Realtime software لجلب المعطيات وتمثيلها بيانياً على شكل شموع يابانية، كما تمت كتابة الخوارزميات باستخدام ProBuilder Language، وتم اختباره على كل من سوق OMXS30 السويدي وسوق المملكة المتحدة FTSE100 وتم تعديل الخوارزمية لقيم حدية مختلفة للمؤشرات للتوصل لأفضل قيم وهذا من خلال تقييم 6 خوارزميات مختلفة وتم اختيار أكثر 10 أنماط شموع يابانية شائعة في السوق. يمكن اعتبار القيمة المضافة للبحث هي بناء عدة خوارزميات مشتقة من خوارزمية أصلية، ومقارنة بين عدة نماذج، وأظهرت نتائج البحث أن التكوينات المختلفة لمؤشر القوة النسبية ووقف الخسارة له أثر كبير على خوارزمية التداول القائمة على أنماط الشموع. يمكن تقسيم خوارزميات التداول في ثلاثة أزواج بحسب التشابه وتم تقييم صحة النموذج وأدائه باستخدام عدد كبير من المؤشرات.

النموذج على الرغم من فعاليته إلا أن إضافة متغيرات جديدة عليه هو ممارسة ينصح بها للأبحاث القادمة كما أن الإطار الزمني المدروس بسبب قيود البرنامج المستخدم في البحث قد يؤثر على النتائج. (Martinson, 2017)

الجدول (8) مقارنة (Martinson, 2017) وفق إطار المقارنة


البعد	الوجه	القيم الممكنة
بعد الموضوع	مجال الرؤية	صندوق أسود
	سوق النموذج	OMEXS30
	تحليل الاستثمار	تحليل تقني
بعد الاستخدام	الغاية النهائية	التنبؤ بتصنيف اليوم التالي (أعلى، أدنى)، القيام بقرار شراء أو بيع أوتوماتيكي
	الأهداف المرحلية	بناء خوارزميات، محاكاة، اختبار الخوارزميات، اختيار النموذج (الخوارزمية) الأنسب
	القيمة المضافة للمقارنة	مقارنة بين عدة نماذج، تجربة محاكاة
بعد النموذج	معطيات النموذج	آلية الحصول على المعطيات
		نوع معطيات النموذج
	معطيات خام	
	معطيات مهيكلة	
	السعر الأعلى، السعر الأدنى، سعر الافتتاح، سعر الإغلاق، مؤشرات تقنية	
	دخل النموذج	
	نوع مقارنة النموذج	
	نظام بسيط	
	Algorithmic trading	
	Candlestick patterns, RSI, Stop loss limit	
بعد التنفيذ والتحقق	تقنيات النموذج	
	المؤشرات التقنيّة المستخدمة	
	قابلية تعلم النموذج	
	القدرة التفسيرية للنموذج	
	غير قابل للتعلم	
	قادر على التفسير	
	الأدوات المستخدمة	
	Pro Realtime software	
	لغة البرمجة المستخدمة	
	ProBuilder	
بعد التنفيذ والتحقق	الخوارزميات المستخدمة	
	–	
	أدوات اختبار الصحة	
	Simulation, winning trades, losing trades	
	أدوات اختبار الأداء	
بعد التنفيذ والتحقق	أدوات اختبار الأداء	
	Gain%, winning trades %, Gain / loss ratio, Avg gain / trade	
بعد التنفيذ والتحقق	أدوات اختبار الأداء	
	قرار بالبيع أو الشراء	
بعد التنفيذ والتحقق	أدوات اختبار الأداء	
	خرج التنفيذ	

3.6.3.2 مقارنة (C. Zopounidis, 1997)

يقدم C. Zopounidis تحليلاً موسعاً لتطبيق أنظمة دعم القرار القائمة على المعرفة KBDSS في الإدارة المالية. كما نشأت KBDSS من مزج نظم دعم القرار DSS مع النظم الخبيرة ES، وذلك بالاستفادة من نظم دعم القرار متعددة المعايير، والنماذج التي تستخدم النماذج الإحصائية لمتغيرات متعددة في آن واحد. يهتم هذا البحث بالتفصيلات


وبشرح دقيق لبعض أهم المشاكل والتقنيات التي تواجه الباحثين الذين يريدون حل مشاكل مشابهة، حيث يتمتع بوضوح وتفصيل لموضوع البحث، ولهيكليته حله، ولمنهجية تنفيذه.

إن الغايات النهائية للمقاربة هو تصميم نظام دعم قرار بالاستفادة من نظم مشهورة سابقة بهدف مساعدة القارئ الذي يريد تصميم نظاماً جديداً للاستفادة من مقاربات أخرى والدمج بينها وتهدف هذه الأنظمة لمساعدة متخذ القرار بالقيام باختيار سهم أو أصل جديد للاستثمار به إضافة لمحفظته المستثمر وتصميم هذا النظام بالأخذ بعين الاعتبار معطيات جديدة خاصة خيارات الدين Credit أملاً بتحسين فعالية النظام. في البداية تم تحديد المشاكل الحالية والقيود المفروضة على هذين النهجين ومناقشة الإطار المنهجي القائم على استخدام KBDSS وتطبيقاته في الإدارة المالية. لم يتم ذكر أية أدوات أو لغات برمجة مستخدمة إلا أنه من ذكر أهم التقنيات المستخدمة بأنظمة دعم القرار. نعرض أدناه التمثيل البياني لبعض أهم أنظمة دعم القرار في القطاع المالي التي تناولتها هذه الدراسة:




الشكل (21) يوضح آلية عمل نظام KBDSS

كما يوجد في البحث بعض البنى العلاقية لبعض الأنظمة العالمية لمساعدة متخذي القرار لشراء أصول بالاعتماد على عدة مصادر تمويل وعدة نسب مالية عالمية. مثل نظام LASS لتحليل القروض التجارية، وهو نموذج أولي له بنية فريدة كنظام دعم قرار، يعتمد على تحويل المعرفة إلى قواعد معرفة ومن ثم لمحرك استدلال كما في الشكل التالي.



الشكل (22) بنية نظام LASS لدعم قرار القروض التجارية

أخيراً نستعرض هيكلية نظام FINEVA الذي يربط بين منهجية اختيار متعدد المعايير UTASTAR مع قاعدة المعطيات، والنظام الخبير، والتنبؤات، وتحليل النسب المالية وما شابه.



الشكل (23) بنية نظام FINEVA الخبير لدعم القرار

وقد توصل الباحث أن الاحتمالات ووجهات النظر الجديدة التي تقدمها KBDSS تحسن من عملية صنع القرار ومن نوعية القرار خاصة في مجال الإدارة المالية، ويمكن تلخيص النتائج في ثلاث جوانب أساسية. أولها فهم

العملية ونتائج النظام لأن دمج قاعدة المعرفة في DSS يمكن أن تساعد صانعي القرار على فهم نتائج النماذج الرياضية فالمعرفة توفر قاعدة التفسيرات اللازمة فيما يتعلق بعملية التفكير في النظام، فإن المنهجية المستخدمة من قبل النظام ممكن أن تكون واضحة للمستخدم كما يمكن أن تفسر أو تبرر القرار المستخدم. من النتائج التي تم تحقيقها، وتجنبنا لسوء الفهم وسوء التفسير، يتم تحويل النتائج الكمية إلى نوعية كما أن التفسيرات التي يسهل فهمها وغالبا ما تكون ذات أهمية أكبر لصناع القرار. موضوعية واكتمال النتائج التي تعتمد على الخبير إضافة لنتائج النماذج الرياضية هي القيمة المضافة المحصلة من دمج النظم الخبيرة المعتمدة على نقل معرفة خبير مع نماذج نظم دعم القرار.

يعرض في هذا البحث تمثيل هيكلي للعلاقة بين قواعد المعطيات، ومحرك الاستدلال، والمعطيات التي تكون دخل للنظام. (C. Zopounidis, 1997)

الجدول (9) مقارنة (C. Zopounidis, 1997) وفق إطار المقارنة

البعد	الوجه	القيم الممكنة
بعد الموضوع	مجال الرؤية	صندوق أبيض
	سوق النموذج	-
	تحليل الاستثمار	تحليل أساسي
بعد الاستخدام	الغاية النهائية	تصميم ومقارنة عدة نماذج
	الأهداف المرحلية	تحليل عدة هياكل نظم
	القيمة المضافة للمقارنة	دمج عدة نماذج سابقة، مقارنة عدة نماذج
بعد النموذج	معطيات النموذج	معطيات خام، معطيات مشتقة
		معطيات مهيكلة
	دخول النموذج	
	نوع مقارنة النموذج	
	تقنيات النموذج	
	المؤشرات التقنية المستخدمة	
	قابلية تعلم النموذج	
	القدرة التفسيرية للنموذج	
	الأدوات المستخدمة	
	لغة البرمجة المستخدمة	
	الخوارزميات المستخدمة	


بعد التنفيذ والتحقق	أدوات اختبار الصحة	-
	أدوات اختبار الأداء	ROI, ROE
	خرج التنفيذ	قرارات من نوع Classification (Give Credit/ Don't Give Credit)، قرارات من نوع MCDM، هيكلية النموذج

4.6.3.2 مقارنة (K.H. Lee, 1999)

قام K.H. Lee بتطوير نظام خبير لتحليل مخطط الشموع اليابانية للتنبؤ بأفضل وقت للدخول، ويحتوي النظام الخبير على أنماط وقواعد يمكن الاعتماد عليها للتنبؤ بالأنماط وتحركات سعر السهم المستقبلي، يهتم هذا البحث بالتفصيلات وبشرح دقيق لبعض أهم المشاكل والتقنيات التي تواجه الباحثين الذين يريدون حل مشاكل مشابهة، حيث يتمتع بوضوح وتفصيل لموضوع البحث، ولهيكليته حله، ولمنهجية تنفيذه. الهدف الأساسي للبحث هو القيام بتنبؤ الوقت المناسب للقيام باستثمار جديد من خلال التنبؤ السعري لأنماط الشموع اليابانية، حيث تصنيف الأنماط المحددة إلى خمس مجموعات بحسب معانيها (هابط، صاعد، محايد، استمرار اتجاه، انعكاس اتجاه)، أما الأهداف المرحلية كانت من خلال تصميم النموذج وبناء قاعدة معرفة وتحويلها إلى قواعد بلغة برمجة باسكال، وتم استخدام أداة DELPHI، ومن ثم تمييز ما هي الأنماط الأقوى وما هي خصائصها.

معطيات هذا النموذج هي معطيات خام مهيكلية تتألف من سعر الافتتاح، سعر الإغلاق، السعر الأعلى، السعر الأدنى، وذلك لتمثيلها أيضاً بيانياً على شكل شموع يابانية. يمكن القول إن هذا النموذج من النماذج البسيطة كما أنه لم يستخدم مؤشرات مالية أو معطيات بما يشبه ذلك، ومع هذا فإنه يمكن القول إنه توجد قدرة تفسيرية للنموذج (حيث يمكن القول إن السعر متوقع بالصعود لوجود النمط التالي...). تم التحقق من صحة وأمثلة النتائج من خلال من خلال التجارب على مجموعة معطيات الاستثمار في الأسهم الحقيقية خلال 5 سنوات (1992-1997). نتائج هذه الدراسة نصت على أن معدل نجاح النظام (معدل الإصابة) بشكل متوسط 72%. إلا أن النموذج يعاني من بعض القيود، مثل عدم وجود تعلم تلقائي كما أن القواعد والمعرفة قد تتغير مع مرور الزمن وتغير السوق، وهنا يمكن تعديل النموذج وإعادة تقييمه بعد كل فترة زمنية. كما أن حل نزاعات المعرفة في هذه الدراسة تم حلها من خلال طريقة الأولوية التي أثبتت فعاليتها بحسب هذه الدراسة إلا أنه من المفاجئ أن القواعد التي تصف أنماط معقدة أو بسيطة كانت نسبة نجاحها أقل من القواعد متوسطة التعقيد. نرى هيكلية تصميم الحل المقترح لدى بناء

النظام الخبير في الشكل التالي. (K.H. Lee, 1999)



الشكل (24) هيكل الحل المقترح لدراسة


الجدول (10) مقارنة (K.H. Lee, 1999) وفق إطار المقارنة

البعد	الوجه	القيم الممكنة
بعد الموضوع	مجال الرؤية	صندوق أبيض
	سوق النموذج	KOSPI
	تحليل الاستثمار	تحليل تقني
بعد الاستخدام	الغاية النهائية	تنبؤ الوقت المناسب للقيام باستثمار جديد
	الأهداف المرحلية	تصميم النموذج، بناء قاعدة معرفة، تحويلها إلى قواعد بلغة البرمجة، اختبار النموذج
	القيمة المضافة للمقارنة	بناء نموذج جديد، بناء قواعد استدلال جديدة بالاعتماد على خبير
بعد النموذج	آلية الحصول على المعطيات	معطيات خام
	نوع معطيات النموذج	معطيات مهيكلية


السعر الأعلى، السعر الأدنى، سعر الافتتاح، سعر الإغلاق	دخل النموذج	
نظام بسيط	نوع مقارنة النموذج	
ES	تقنيات النموذج	
لا يوجد	المؤشرات التقنية المستخدمة	
غير قابل للتعلم	قابلية تعلم النموذج	
قادر على التفسير	القدرة التفسيرية للنموذج	
DELPHI	الأدوات المستخدمة	بعد التنفيذ والتحقق
PASCAL	لغة البرمجة المستخدمة	
Forward chaining	الخوارزميات المستخدمة	
Hit frequency	أدوات اختبار الصحة	
Hit Ratio %	أدوات اختبار الأداء	
قرار بالبيع أو الشراء أو التريث	خرج التنفيذ	

5.6.3.2 مقارنة (Murkute, 2015)

يقدم Murkute نموذجاً يستخدم الشبكات العصبونية الاصطناعية للتنبؤ بسعر اليوم القادم، بالاعتماد على سعر يومين سابقين كدخل إضافة للعديد من المؤشرات المالية الأخرى كدخل من يومين سابقين، لا تهتم هذه المقاربة بالتفاصيل، حيث تم الاكتفاء بنظرة سطحية عامة عن آلية الحل. يمكن تقسيم هذا النموذج إلى عدة مراحل أولها إيجاد المعطيات التاريخية لسعر سهم ما وتحويلها لصيغة csv، وهي المعطيات الخام في هذا البحث كانت مصادر المعطيات الخام yahoo finance, money control، ثم معرفة المتغيرات التي تدخل النموذج كمعطيات مشتقة التي هي في حالتنا (PE ratio, SMA) ثم إدخالها بتابع تطبيع، والخطوة التالية هنا إدخال هذه المعطيات المطبوعة في طبقة شبكة عصبونية اصطناعية مخفية، بعدها فك التطبيع وإظهار الخرج على شكل السعر المتوقع لليوم التالي. وقد أظهرت الدراسة عدة نتائج أهمها نجاح هذا النموذج ووصوله لمقدار خطأ لا يتجاوز الـ 6% إلا أن كمية المعطيات الداخلة في النموذج هي ما يميز نجاح التنبؤ أم لا فيمكن القول إنه في حال عدم وجود معطيات كافية فإن دقة النموذج تنخفض بشكل كبير، كما أنه يمكن للأبحاث القادمة تطوير النموذج من خلال إدخال عوامل الأنباء الاقتصادية كدخل إضافة لزيادة صحة التنبؤ. نعرض الشكل التالي الذي يوضح منهجية وخطوات العمل والشكل الذي يمثل الشبكة العصبونية المستخدمة. (Murkute, 2015).



الشكل (26) هيكلية النظام المستخدم



الشكل (25) شكل الشبكة العصبونية المستخدم

الجدول (11) مقارنة (Murkute, 2015) وفق إطار المقارنة

البعد	الوجه		القيم الممكنة
بعد الموضوع	مجال الرؤية		صندوق أسود
	سوق النموذج		NSE
	تحليل الاستثمار		تحليل تقني
بعد الاستخدام	الغاية النهائية		التنبؤ بسعر إغلاق اليوم التالي
	الأهداف المرحلية		تطبيع المعطيات، تصميم النموذج، تدريب النموذج، اختبار النموذج
	القيمة المضافة للمقاربة		إدخال متغيرات جديدة لنموذج سابق
بعد النموذج	معطيات النموذج	آلية الحصول على المعطيات	معطيات خام، معطيات مشنقة
		نوع معطيات النموذج	معطيات مهيكلية
	دخل النموذج		سعر الافتتاح، مؤشرات تقنية
	نوع مقارنة النموذج		نظام بسيط
	تقنيات النموذج		Normalization / Denormalization ANN (Multi perceptron model)
	المؤشرات التقنيّة المستخدمة		On balance volume, PE ratio, SMA, index ratio, PROC

قابلية تعلم النموذج	قابل للتعلم
القدرة التفسيرية للنموذج	غير قادر على التفسير
الأدوات المستخدمة	-
لغة البرمجة المستخدمة	Python
الخوارزميات المستخدمة	Back propagation, Gradient Descent
أدوات اختبار الصحة	Graph, Table
أدوات اختبار الأداء	Error Rate
خرج التنفيذ	السعر المتوقع لليوم التالي

6.6.3.2 مقارنة (DP-LSTM, Li, 2019)

إن DP-LSTM نموذج جديد يعتمد على شبكة عصبونية عميقة لتوقع أسعار الأسهم، والذي يتضمن المقالات الإخبارية كمعلومات مخفية ويدمج مصادر الأخبار المختلفة من خلال آلية تسمى الخصوصية التفاضلية. لا تهتم هذه المقاربة بالتفاصيل، حيث تم الاكتفاء بنظرة سطحية عامة عن آلية الحل. الغاية النهائية من البحث هي التنبؤ السعري للفترة التالية، ويمكن اعتبار بناء النموذج بمكوناته المختلفة والتدريب والتحقق أهدافاً مرحلية. يقوم النظام بتحليل السعر من خلال نموذج المتوسط الانحدار الذاتي المتحرك ARMA مع الأخذ بعين الاعتبار المعلومات المالية المستخرجة من المقالات الإخبارية كدخل إضافي لهذا النموذج، وهذا ما يميز النموذج فالمعطيات الداخلة تقسم إلى معطيات مهيكلة وهي السلسلة الزمنية للسعر، ومعطيات غير مهيكلة وهي شكل مقالات إخبارية لها علاقة بالسوق المدروس. بعد ذلك، تم تصميم شبكة عصبونية عميقة قائمة على LSTM الذي يتكون من ثلاث مكونات: LSTM، نموذج VADER والخصوصية التفاضلية الآلية DP. وتم تطبيق النموذج على معطيات S&P500 وهو مؤشر يدرس أكثر 500 شركة متقلة بحجم التداول وعدة عوامل أخرى في السوق المفتوح للولايات المتحدة. يمكن القول أن النظام بسيط بالرغم من كونه يدمج عدة مكونات مختلفة ضمن الشبكة العصبونية إلا أنها فقط مكونات ضمن الشبكة. وأظهرت النتائج أن نموذج DP-LSTM المقترح يمكن تخفيض أخطاء التنبؤ بشكل كبير. كما توصل الباحث إلى أنه إذا اعتمدنا على المعلومات المستخرجة من الأخبار للتنبؤ بشكل كامل، قد نزيد التحيز بسبب بعض التقارير غير الموضوعية، لذلك تعزز DP-LSTM متانة نموذج التنبؤ. (Li, 2019)

نعرض بشكل مبسط طريقة معالجة اللغة الطبيعية للأنباء الاقتصادية، وهي معالجة NLTK المستخدمة، حيث تم تحويل كل عنوان أخبار إلى رمز فردي. ثم طبق تحليل Sentiment Intensity لمعرفة مدى قوة تعبير الكلمات بأوزان وأرقام وحساب درجة القطبية، وهذا ما يولد سحابة كلمات موجبة (على اليسار) وسحابة كلمات سلبية (على اليمين). لكل من الأخبار الإيجابية والسلبية، نحسب وزن كل الكلمات والترتيب لهم لإنشاء سحابة الكلمات wordcloud، من الناحية البصرية كلما كانت الكلمة أكبر، ظهرت بشكل متكرر أكثر في المصدر.




الجدول (12) مقارنة (Li, 2019) بحسب إطار المقارنة

60

7.6.3.2 مقارنة (Indika, 2021)

قامت Indika بمقارنة عدة طرق لدمج النماذج للتنبؤ المالي بما في ذلك المتوسط، المتوسط المرجح، التراص، والغابة العشوائية. وتم استخدام الانحدار للتنبؤ بسعر إغلاق اليوم التالي لسهم كما تم استخدام نموذج LSTM ونموذج SVM كنماذج فردية أخرى للتنبؤ. لا تهتم هذه المقارنة بالتفاصيل، حيث تم الاكتفاء بنظرة سطحية عامة عن آلية الحل. يمكن اعتبار الهدف النهائي للمقارنة التوصل لأفضل طريقة دمج بين 4 نماذج، والأهداف الفرعية هي تطبيق كل نموذج على حدة وتطبيق طرق دمج مختلفة ومقارنة النتائج. أما بالنسبة لمعطيات هذا النموذج فهي معطيات مهيكلة خام، يمكن القول إن نوع النظام هجين، وهو نظام قابل للتعليم كما تم تحليل معطيات 10 سنوات من تاريخ أنشط 20 شركة في بورصة NASDAQ. توصلت هذه الدراسة لعدة نتائج أهمها أن نموذج SVM لا يمكنه التعرف على الأنماط الرئيسية في معطيات السلاسل الزمنية في التصنيف إلا أن نموذج LSTM أدى لنتائج مرضية في التنبؤ كما أن خوارزميات ensemble مناسبة لدمج النماذج التنبؤية فهي قادرة على أخذ القيمة المضافة من إيجابيات النموذج المناسب وتقادي سلبات النماذج الأقل دقة خصوصاً عند استخدام خوارزمية ensemble المناسبة، كما أن فضاء العمل في هذا المجال مناسب للأبحاث المستقبلية، حيث أن دمج النماذج والمقارنة بينها مشكلة غير حتمية وتحتمل التطوير دوماً بتطوير النماذج المستخدمة (Indika, 2021).



الشكل (28) يعبر عن النموذج المترفع المستخدم

الجدول (13) مقارنة (Indika, 2021) بحسب إطار المقارنة

البعد	الوجه	القيم الممكنة
بعد الموضوع	مجال الرؤية	صندوق أسود
	سوق النموذج	NASDAQ
	تحليل الاستثمار	تحليل تقني
بعد الاستخدام	الغاية النهائية	التنبؤ بسعر إغلاق اليوم التالي، تصنيف
	الأهداف المرحلية	بناء مكونات النموذج المترفع كل على حدى، تجربة طرق دمج مختلفة، تقييم كل التنويعات، بناء النموذج المترفع النهائي
	القيمة المضافة للمقارنة	دمج بين عدة نماذج، مقارنة عدة تنويعات في النظام نفسه

معطيات النموذج	آلية الحصول على المعطيات	معطيات خام
	نوع معطيات النموذج	معطيات مهيكلة
بعد النموذج	نوع مقارنة النموذج	نظام هجين
	دخل النموذج	السعر
	تقنيات النموذج	SVM, linear regression, LSTM
	المؤشرات التقنيّة المستخدمة	لا يوجد
	قابلية تعلم النموذج	قابل للتعلم
	القدرة التفسيرية للنموذج	غير قادر على التفسير
بعد التنفيذ والتحقق	الأدوات المستخدمة	NumPy, TensorFlow, Keras, sci-kit learn
	لغة البرمجة المستخدمة	Python
	الخوارزميات المستخدمة	Back propagation, Gradient Descent, ensemble (stacking, boosting, random forest)
	أدوات اختبار الصحة	–
	أدوات اختبار الأداء	Accuracy, Precision, Recall, F1 metric
	خرج التنفيذ	السعر المتوقع لليوم التالي

7.3.2 تقييم ومقارنة المقاربات السابقة بناءً على الإطار المقترح

بعد دراسة المقاربات السابقة، قمنا بوضع الجدول التالي الذي يمثل تقييمنا لجميع المقاربات المدروسة وفق إطار المقارنة المقترح، ويوضح مقاربتنا الجديدة التي هي محور هذه الدراسة، بناءً على الإطار المقترح، وتعريف المفاهيم ضمنه، نعرض تحليلاً لجميع المقاربات المدروسة وفق الإطار الذي قمنا ببنائه.

البعد	الوجه	Casanova,) (2012	(Martinson, 2017)	(C. Zopounidis, 1997)	(K.H. Lee, 1999)	(Murkute, 2015)	(Li, 2019)	(Indika,2021)	مقاربتنا (NES, 2022)
بعد الموضوع	مجال الرؤية	صندوق أسود	صندوق أسود	صندوق أبيض	صندوق أبيض	صندوق أسود	صندوق أسود	صندوق أسود	صندوق أبيض
	سوق النموذج	IBEX35	OMEXS30	-	KOSPI	NSE	S&P 500	NASDAQ	BTC
	تحليل الاستثمار	تحليل تقني	تحليل تقني	تحليل أساسي	تحليل تقني	تحليل تقني	تحليل تقني	تحليل تقني	تحليل تقني
بعد الاستخدام	الغاية النهائية	القيام باختيار أحد الأسهم لإضافته لمحفظة	التنبؤ بتصنيف اليوم التالي (أعلى، أدنى)، القيام بقرار شراء أو بيع أوتوماتيكي	تصميم ومقارنة عدة نماذج	تنبؤ الوقت المناسب للقيام باستثمار جديد	إغلاق اليوم التالي	التنبؤ بسعر إغلاق اليوم التالي	التنبؤ بسعر إغلاق اليوم التالي، تصنيف	التنبؤ بسعر إغلاق اليوم التالي
	الأهداف المرحلية	اختيار المتغيرات، تحويل قيمها لغائمة، بناء قاعدة معرفة/قواعد، محاكاة، دمج النماذج	بناء خوارزميات، محاكاة، اختبار الخوارزميات، اختيار النموذج (الخوارزمية) الأنسب	تحليل عدة هياكل نظم	تصميم النموذج، بناء قاعدة معرفة، تحويلها إلى قواعد بلغة البرمجة، اختبار النموذج	تطبيق المعطيات، تصميم النموذج، تدريب النموذج، اختبار النموذج	تطبيق المعطيات، تصميم النموذج، تدريب النموذج، اختبار النموذج	بناء مكونات النموذج المترقع كل على حدة، تجربة طرق دمج مختلفة، تقييم كل التنويعات، بناء النموذج المترقع النهائي	اختيار معطيات مناسبة، بناء قاعدة معطيات، تطبيق المعطيات، تصميم النموذج، بناء قواعد معرفة النموذج تدريب النموذج، اختبار النموذج
	القيمة المضافة للمقاربة	دمج عدة نماذج سابقة، تجربة محاكاة، بناء قواعد استدلال جديدة بالاعتماد على خبير	مقارنة بين عدة نماذج، تجربة محاكاة	دمج عدة نماذج سابقة، مقارنة عدة نماذج	بناء نموذج جديد، بناء قواعد استدلال جديدة بالاعتماد على خبير	إدخال متغيرات جديدة لنموذج سابق	إضافة مكونات جديدة على نموذج سابق، مقارنة عدة تنويعات في النظام نفسه	دمج بين عدة نماذج، مقارنة عدة تنويعات في النظام نفسه	تصميم نموذج جديد، دمج بين نموذجين، إدخال متغيرات جديدة لنموذج سابق، بناء قواعد استدلال جديدة بالاعتماد على خبير
	معطيات النموذج	معطيات خام، معطيات مشتقة	معطيات خام، معطيات مشتقة	معطيات خام	معطيات خام، معطيات مشتقة	معطيات خام، معطيات مشتقة	معطيات خام	معطيات خام، معطيات مشتقة	معطيات خام، معطيات مشتقة
بعد النموذج	معطيات	معطيات	معطيات	معطيات	معطيات	معطيات	معطيات	معطيات	معطيات
	معطيات	معطيات	معطيات	معطيات	معطيات	معطيات	معطيات	معطيات	معطيات
بعد النموذج	دخل النموذج	السعر، مؤشرات تقنية	السعر الأعلى، السعر الأدنى، سعر الافتتاح، سعر الإغلاق، مؤشرات تقنية	السعر، مؤشرات تقنية	سعر الافتتاح، مؤشرات تقنية، سعر الافتتاح، سعر الإغلاق	سعر الافتتاح، مؤشرات تقنية	سعر الإغلاق، مؤشرات المشاعر	السعر	سعر الافتتاح، سعر الإغلاق، السعر الأدنى، مؤشرات تقنية، مؤشرات المشاعر

نوع مقارنة النموذج	نظام هجين	نظام بسيط	نظام بسيط	نظام بسيط	نظام بسيط	نظام بسيط	نظام هجين	نظام هجين
تقنيات النموذج	ES, Fuzzy logic	Algorithmic trading	ES, KBDSS, AHP, UTASTAR,	ES	Normalization / Denormalization ANN (Multi perceptron model)	Normalization / Denormalization RNN, LSTM, DP, ARMA, NLP	SVM, linear regression, LSTM	ES, Normalization, ANN, Time2Vec, Transformer
المؤشرات التقنيّة المستخدمة	ARP, RSI, MA, DMA	Candlestick patterns, RSI, Stop loss limit	Gross income, current ratio, quick ratio, dept equity	لا يوجد	On balance volume, PE ratio, SMA, index ratio, PROC	لا يوجد	لا يوجد	30SMA, 100SMA, EMA, ADX, RSI, Fear & Greed
قابلية تعلم النموذج	غير قابل للتعلم	غير قابل للتعلم	غير قابل للتعلم	غير قابل للتعلم	قابل للتعلم	قابل للتعلم	قابل للتعلم	قابل للتعلم
القدرة التفسيرية للنموذج	قادر على التفسير	قادر على التفسير	قادر على التفسير	قادر على التفسير	غير قادر على التفسير	غير قادر على التفسير	غير قادر على التفسير	قادر على التفسير
الأدوات المستخدمة	NRC fuzzy toolkit	Pro Realtime software	-	DELPHI	-	NLTK, VADER, yfinance	NumPy, TensorFlow, Keras, sci-kit learn	Yfinance, pandas, Matplotlib, NumPy, TensorFlow, Keras, Experta...
لغة البرمجة المستخدمة	-	ProBuilder	-	PASCAL	Python	Python	Python	Python
الخوارزميات المستخدمة	Fuzzification, FC	-	-	FC	BP, GD	BP, GD	BP, GD, ensemble	BP, GD, FC, ADAM
أدوات اختبار الصحة	Simulation, APR (annual percentage rate)	Simulation, winning trades, losing trades	-	Hit frequency	Graph, Table	Graph	-	Graph
أدوات اختبار الأداء	Variance	Gain%, winning trades %, Gain / loss ratio, Avg gain / trade	ROI, ROE	Hit Ratio %	Error Rate	MSE, accuracy, MPA, Mean Error percent	Accuracy, Precision, Recall, F1 metric	Accuracy, MAPE, MAE
خرج النموذج	تصنيف الأصول إلى تكتيكية واستراتيجية، خيار لشراء أو بيع سهم من عدة بدائل	قرار بالبيع أو الشراء	قرارات من نوع Classification قرارات من نوع MCDM هيكلية النموذج	قرار بالبيع أو الشراء أو التريث	السعر المتوقع لليوم التالي	السعر المتوقع لليوم التالي	السعر المتوقع لليوم التالي	هيكلية النموذج، السعر المتوقع لليوم التالي وتصنيفه، تقرير مالي وتفسير له

بعد التنفيذ والتحقق

بداية يمكن تصنيف المقاربات المدروسة إلى نماذج قابلة للتعليم كما في Li و Indika و Murkute، وإلى نماذج غير قابلة للتعليم، وهي مقاربات Casanova, Martinson, K.H. Lee, C. Zopounidis، لكل منها نقاط قوة ونقاط ضعف. يمكن القول أن النماذج القادرة على التعلم هي نماذج تعاني من مشكلة الصندوق الأسود بمعنى أن أصحاب المصلحة يمكنهم الاستفادة من خرج النظام وهو التنبؤ إلا أنه لا يمكن معرفة ماذا يجري ضمن النظام، إلا أنه من نقاط القوة أن خرج التنبؤ ذو دقة عالية، والعكس صحيح بالنسبة للنماذج الغير قادرة على التعلم فيتم تعويض ما خسره متخذ القرار بدقة التنبؤ في هذه النماذج بالقدرة التفسيرية التي يمكن اعتبارها مهمة لمتخذي القرار في خصوصية مشكلة البحث.

تتشابه مقاربتا K.H Lee و Casanova بكونهما مقاربتان تستخدمان النظم الخبيرة لحل مشكلة التنبؤ السعري ومن إيجابيات هذه النماذج كونها قادرة على إعطاء تفسير إن لزم الأمر، إلا أن من سلبيات هذه النماذج أن دقتها تكون في نفس مجال خطأ خبير في هذا المجال، كما أن أحد المشاكل الأخرى التي تواجه هذا النوع من النماذج هي تشكيل قواعد معرفة جيدة وهذا بحسب خبير المجال الذي يريد نقل المعرفة لمهندس النظام، كما أن درجة فهم مهندس النظام للمعرفة، كي يتمكن من ترميزها، أيضاً متفاوت بحسب الحالة، كما يمكن أن تكون المعرفة من قبل خبير ما مختلفة عن معرفة خبير آخر، أي توجد حدود ضبابية في المعرفة وهذا هو سبب توجه مصممي الأنظمة للأنظمة الهجينة والضبابية، فهي تعالج مشكلة عدم التأكد بتوابع درجات الانتماء وهذا ما اعتمدته Casanova في بحثه لذا نجد أن النموذج ناجح بحسب المحاكاة التي تؤكد ذلك. إلا أننا غير قادرين على الحكم بين النموذجين لأن مقياس الأداء مختلف كما أن نموذج K.H Lee يعتمد كخرج إذا كان الوقت مناسب للاستثمار أم لا، أما النظام الخبير الغائم يعالج أيضاً فكرة وجود أكثر من بديل وتصنيف الأصول إلى تكتيكية واستراتيجية.

يمكن القول أيضاً أن مقاربة C. Zopounidis تعالج فكرة النظم الخبيرة إلا أنها تأخذ بعد تصميمي وتحليلي لبعض نظم دعم القرار المعتمدة على المعرفة KBDSS، وتتميز بمعالجة تعدد البدائل بطريقتي AHP و UTASTAR، كما تتميز بتصاميم معقدة لمشاكل اختيار استثمارات طويلة الأجل ومنح القروض. أما مقاربة Martinson، فبالرغم من أنها تستخدم نموذج غير قابل للتعليم إلا أنه قائم على خوارزميات التداول المختلفة لمعرفة أي أفضل تنويع لمعايير مؤشرات مالية نستخدمها في النماذج الأخرى، وتشابه مع مقاربة Casanova بكونها تعتمد على المحاكاة. أما بالنسبة لمعطيات كل هذه النماذج فهي معطيات مهيكلة ما عدا الدراسات التي تعتمد على تحليل اللغات الطبيعية NLP، في حالتنا دراسة Li، والنماذج التي تعتمد على السعر وتنويعاته مثل K.H Lee. فتكون المعطيات خام، فهي مستخرجة من الأسواق المالية بشكل مباشر، لكن كل المقاربات التي تعتمد على المؤشرات المالية المختلفة في دراستنا المرجعية معطياتها مشتقة من المعطيات الأولية الخام، وهذا ما يعطي النماذج معلومات أكبر من المعطيات الأساسية، فالمعطيات المشتقة لها قدرة تعبيرية مفيدة عند إضافتها كمعايير للنماذج، كما يمكن أن تلعب دور بتضخيم المعطيات في النماذج القادرة على التعلم مثل مقاربة Li و Murkute و Indika وهي النماذج التي تعتمد على أنواع متعددة من الشبكات العصبونية، فهي تستخدم بالغالبة لغة برمجة Python وذلك لسهولة استخدامها وتوفر مكاتب مختصة بتعلم الآلة، إذا أردنا أن نقارن مقاربة Li و Murkute نلاحظ أن النموذجين يستخدمان شبكة

عصبونية إلا أن نوعها يختلف حيث أن مقارنة Murkute يستخدم شبكة Multi-Layer Perceptron Model وهي طريقة فعالة وذات أداء جيد إلا أنه من ميزات نموذج Li أنه يستخدم خلايا LSTM التي تعطي وزن للأنماط السابقة ذات الأهمية وتنسى الأنماط غير المعنوية، لذا فهي من أفضل النماذج لتنبؤ السلاسل الزمنية. كما تم تدعيم هذا النموذج بأدوات تعلم الآلة لتحليل اللغات الطبيعية بغاية تحليل مشاعر السوق من خلال إدخال مقالات مالية كدخل إضافي على النموذج، إلا أنه لا يمكن الحكم على أفضلية نموذج على الآخر لاستخدامهما أدوات قياس أداء مختلفة. بجهة أخرى فإن مقارنة Indika تعتمد أيضاً على خلايا LSTM لكن كجزئية من عدة تقنيات، يتم دمجها بمجموعة خوارزميات ensemble، وتعتبر طريقة مميزة لحل مشكلة التنبؤ السعري. أخيراً يمكن القول إن الحلول المقترحة في المقاربات السابقة هي فعالة باختلاف المنهجيات المستخدمة، إلا أنه يمكن القول أن التنازل عن بعض الإيجابيات مقابل إيجابيات أخرى في المقاربات المدروسة هو أمر شائع عند حل مشكلة بحثنا.

4.2 خاتمة

تم في هذا البحث بناء الإطار العام للمقارنة وعرض مكوناته بشكل تفصيلي، وعرض مجموعة من المقاربات السابقة التي حل مشكلة التنبؤ السعري في الأسواق المالية للمستثمرين، ثم جرى إسقاط المقارنات السابقة بالإضافة إلى مقاربتنا على إطار المقارنة، وقمنا أخيراً بتقديم تحليل لهذه المقاربات من حيث تشابهها مع مقاربتنا المقترحة، كما أشرنا إلى مميزات وتحديات كل مقارنة.

بعد مناقشة الأعمال السابقة، وبناءً على دراسة التوجهات فيها، قمنا بتحديد موقع عملنا، وأبعاده وخصائصه، كما قمنا بالاستفادة من إيجابيات المقارنات المذكورة ومحاولة نقادي نقاط الضعف فيها، لوضع أساس منهجي لمقاربتنا الجديدة التي سنقوم فيها ببناء نموذج قادر على القيام بالتنبؤ السعري والقيام بتفسير لصاحب القرار مع تقديم تقارير موافقة لتدعيم قراره، وبناءً على ما سبق، قمنا بتحديد توجه مقاربتنا التي تختلف في توجهها عن الأبحاث السابقة في نفس المجال بما يلي:

- تدعم مقاربتنا موضوع قيام النموذج بإعطاء تفسير لصاحب القرار وتقديم تقارير لدعم هذا القرار.
- تهدف المقاربة إلى بناء نموذج قادر على التنبؤ السعري بدقة عالية بالاستفادة من الشبكات العصبونية.
- تستخدم المقاربة معطيات مهيكلة خام ومشتقة لزيادة متانة النموذج وتضخيم المعطيات التي تساعد في التدريب.
- تستفيد من معطيات مختلفة عن النماذج السابق، وذلك أملاً بزيادة المعلومات التي يستفيد منها النموذج والصادرة عنه لصاحب القرار.
- تستخدم المقاربة نظام هجين يستفيد من عناصر مختلفة من مكوناته الأساسية ويتقاضي نقاط ضعف هذه المكونات الإفرادية.
- تتضمن إثباتات لصحة النظام وتثبت أن أدائه يقع ضمن المجال المقبول من خلال اختبار النموذج من حيث الصحة والأداء وذلك باستخدام مكاتب Matplotlib لاختبار الصحة بالرسوم البيانية الموافقة كما تستخدم مكتبة TensorFlow و Keras لاختبار الأداء من خلال مقاييس أداء عدة مثل الدقة Accuracy، ومتوسط القيمة المطلقة للخطأ كنسبة مئوية، MAPE.

- تغطي المستخدم مجال لاختيار بديل من عدة بدائل عند تقارب التنبؤ، من خلال مصفوفة قرار متعدد المعايير موزنة بطريقة AHP، كما تتميز هذه المصفوفة بديناميكيته، من ناحية اختيار الأوزان والمعايير والبدائل. يمكن تلخيص مقاربتنا في الجدول (15)، والذي يبين تموضع المقاربة المدروسة في إطار المقارنة المقترح.

الجدول (15) مقاربتنا المقترحة وفق إطار المقارنة المقترح

البعد	الوجه	القيم الممكنة
بعد الموضوع	مجال الرؤية	صندوق أبيض
	سوق النموذج	BTC
	تحليل السوق	تحليل تقني
بعد الاستخدام	الغاية النهائية	التنبؤ بسعر إغلاق اليوم التالي
	الأهداف المرحلية	اختيار معطيات مناسبة، بناء قاعدة معطيات، تطبيع المعطيات، تصميم النموذج، بناء قواعد معرفة النموذج تدريب النموذج، اختبار النموذج
	القيمة المضافة للمقاربة	تصميم نموذج جديد، دمج بين نموذجين، إدخال متغيرات جديدة لنموذج سابق، بناء قواعد استدلال جديدة بالاعتماد على خبير
بعد النموذج	معطيات النموذج	آلية الحصول على المعطيات
		نوع معطيات النموذج
	معطيات خام، معطيات مشنقة	
	معطيات مهيكلة	
	سعر الافتتاح، سعر الإغلاق، السعر الأعلى، السعر الأدنى، مؤشرات تقنية، مؤشرات المشاعر	
	دخل النموذج	
	نوع مقارنة النموذج	
	نظام هجين	
	تقنيات النموذج	
	ES, Normalization, ANN, Time2Vec, Transformer, Decision matrix	
بعد التنفيذ والتحقق	المؤشرات التقنية المستخدمة	
	30SMA, 100SMA, EMA, ADX, RSI, Fear & Greed	
	قابلية تعلم النموذج	
	قابل للتعلم	
	القدرة التفسيرية للنموذج	
	قادر على التفسير	
	الأدوات المستخدمة	
	Yfinance, pandas, Matplotlib, NumPy, TensorFlow, Keras, Experta,	
	لغة البرمجة المستخدمة	
	Python	
بعد التنفيذ والتحقق	الخوارزميات المستخدمة	
	Back propagation, Gradient Descent, Forward Chaining, AHP	
	أدوات اختبار الصحة	
	Graph	
	أدوات اختبار الأداء	
بعد التنفيذ والتحقق	أدوات اختبار الأداء	
	Accuracy, MAPE, MAE	
بعد التنفيذ والتحقق	خرج التنفيذ	
	نموذج أولي، توقع السعر وتصنيفه لليوم التالي، تقرير مالي وتفسير له، نصيحة للمستخدم، اختيار بديل	

الفصل الثالث

نموذج البحث

1.3. مقدمة

يقدم هذا الفصل لمحة عن نموذج (NES) Neuro Expert System الخاص بالبحث القائم على نظام هجين يدمج بين النظام الخبير ES والشبكة العصبونية الاصطناعية ANN للاستفادة من إيجابيات كل نظام على حدة وتغادي سلبيات كل منهما. نعرض أيضاً في هذا القسم هيكلية النموذج عالية المستوى والمفصلة، كما نناقش مكوناته وسبب استخداماً وخصائص هذا النموذج وخطوات تنفيذه.

2.3. تذكرة بمشكلة البحث

تكمن مشكلة البحث بالتنبؤ السعري للأسواق المالية بأن العديد من النماذج غير صالحة للاستخدام، بسبب القيود المترافقة مع طبيعة المسألة، مثل عدم الخطية والعشوائية والتقلب المستمر بالأسعار، كما أن النماذج الصالحة للاستخدام لها قيود أخرى، مثل عدم وجود قدرة تفسيرية، إضافة لوجود مجال كبير لتحسين النماذج، وتجربة نماذج جديدة بهدف تحسين دقة التنبؤ. كما تعتبر هذه المشكلة صعبة الحل لسببين أساسيين، الأول الطبيعة الاحتمالية لهذه المشكلة، والثاني عدم القدرة على حصر المتغيرات التي تؤثر في السوق مما يجعلها مشكلة تستحق الدراسة.

3.3. مفاهيم وخلفية النموذج المقترح

نقترح نظام NES لحل مشكلة البحث، يعتمد هذا النموذج على نظام هجين يدمج ما بين نظام خبير قادر على تمييز أنماط الأسواق المالية، وبين شبكة عصبونية قادرة على التعرف على الأنماط العميقة الموجودة في السوق، التي لا يمكن التعرف عليها باستخدام أدوات تقليدية أو تمييزها عن طريق خبراء في هذا القطاع.

يقوم النظام الخبير بتقديم تنبؤ للمستخدم عن طريق تمييز حالة السوق، إضافة لتفسير بسيط عن سبب قيام النظام الخبير بإعطاء هذه النتيجة، وأخيراً تقريراً لحظياً عن حالة السوق، إضافة لرسومات بيانية تترافق مع نصيحة للمستخدم إما بالتحفظ أو بالشراء أو بالبيع (القوي أو الضعيف). يعتمد النظام الخبير على نقل المعرفة من خبراء في مجال المشكلة، ونمذجة أنماط التحليل التقني من شموع يابانية ومؤشرات تقنية على شكل قواعد معرفة، ليتم استخدامها لاحقاً في النظام الخبير إضافة لبرمجية بسيطة تقوم باستخراج معطيات ثانوية من المعطيات الأولية كما تقوم بتحويلها لرسومات بيانية كي يستفيد منها مستخدم النظام. يتمثل دور الشبكة العصبونية بإيجاد تنبؤ دقيق لسعر إغلاق اليوم التالي كي يستفيد منها النظام أيضاً، وتم بناء هذه الشبكة باستخدام أحد أكثر الممارسات الشائعة عند التعامل مع سلسلة زمنية أو عند التعامل مع معالجة اللغات الطبيعية NLP، عن طريق تضمين الزمن بطبيعته الخطية والحيوية للنقاط عدة أنواع من الأنماط بغض النظر عن طبيعتها. إضافة لآلية الانتباه Attention التي أصبحت طريقة ذات استخدام واسع في الفترة الأخيرة كبديل عن طرق أخرى شهيرة في هذا المجال، وذلك لجعل الشبكة قادرة على الانتباه على الأنماط الهامة وترك الأنماط غير الهامة.


يتناسب هذا النظام المقترح مع عوامل المشكلة التي نريد حلها، فهو قادر على القيام بالتنبؤ حتى في ظل عدم وجود معطيات كافية، ويتميز بمتانتة فطريقة الدمج بين مكوناته تسمح بأن يعمل كل مكون على حدة، كما يوفر تقارير تفسيرية للمستخدم، ودقة كافية لاعتماده كنموذج مساعد لاتخاذ القرار.

4.3. الهيكلية عالية المستوى

يقوم نموذج NES بجلب معطيات أولية من مصادرها ويقوم بمعالجتها وتجميعها للحصول على معطيات ثانوية مشتقة، لتضخيم المعطيات الأولية، إضافة للقدرة التعبيرية الإضافية التي تكتسبها المعطيات عند القيام بهذه العملية. ثم يقوم النظام بإدخال هذه المعطيات إلى شقي النظام بآن واحد. ليتم معالجتها على التوازي فتقوم الشبكة العصبونية بتطبيع المعطيات Normalization أولاً، وحساب التغيرات الحاصلة بكل متغير على حدى عبر الزمن، كي تستفيد الشبكة منها كدخل مناسب لها على شكل حزم مصفوفات Matrix Batches، بعدها يتم معالجتها بحسب هيكلية الشبكة العصبونية المستخدمة Attention + Time embedding لتعطي كخرج التنبؤ بسعر إغلاق اليوم التالي، في هذه الأثناء تدخل المعطيات الأولية والثانوية المشتقة قبل عملية التطبيع Normalization، للنظام الخبير الذي يعد التمثيلات البيانية الموافقة، ومن ثم القيام بتطبيق القواعد الموافقة لمعرفة النظام، وأخيراً يقوم النظام بتجميع الخرج من عناصر النظام المختلفة وإظهارها للمستخدم النهائي على شكل، تنبؤ، ونصيحة، ورسوم بيانية، وتفسير للمستخدم عن طريق واجهة تفاعلية. يتميز النموذج الذي تم بناؤه بقابليته للتوسع والتعديل وإضافة معارف جديدة أو استخدام مفاهيم أخرى على الشبكة العصبونية والنظام الخبير مثل المنطق الغائم. نرفق الشكل (29) الذي يمثل هيكلية النظام عالية المستوى، الذي يعالج المعطيات المدخلة، وهي معطيات تغير السعر اليومي بتنسيقها الخام، ويظهر المخرجات المتوقعة لمستخدمي النظام.

الجدول (16) دلالات الهيكلية المستخدمة في النظام

الدلالة	الشكل	الدلالة	الشكل
إظهار للمستخدم		بداية أو نهاية	
قاعدة معطيات		دخل أو خرج	
مجموعة من العمليات في النظام		شبكة عصبونية اصطناعية	
عملية يدوية		عملية في النظام	
مصفوفة		قرار	
		دخل يدوي	



الشكل (29) الهيكلية عالية المستوى لنموذج NES المقترح

5.3. الهيكلية التفصيلية للنموذج

يمكن أن نقسم النموذج المقترح إلى 6 مراحل، وسنشرح في هذه الفقرة كل مرحلة بشكل أكثر تفصيلاً لتكوين فكرة عامة عن آلية عمل النموذج وهيكلته من الناحية التصميمية.

في المرحلة الأولى يقوم المستخدم بتحديد أحد العملات (أو عدة عملات) بإدخال رمز السهم أو العملة Ticker وهو رمز من ثلاث أو أربعة أحرف كما يحدد المستخدم المدة الزمنية (بداية - نهاية) فيجلب النظام المعطيات المطلوبة وهي عبارة عن سعر الافتتاح، الإغلاق، السعر الأعلى، السعر الأدنى، حجم التداول، مؤشر الخوف والجشع. ثم يقوم بالعمليات الرياضية المناسبة لها وهي في نموذجنا المؤشرات التالية، (EMA, ShortSMA, LongSMA, RSI, ADX)، كل من هذه المؤشرات تعبر عن صفات مختلفة من السوق Market Qualities نتناولها عند الحديث عن خصائص النموذج وأسباب اختيار مكوناته.

في المرحلة الثانية، يقوم النموذج بتجميعها ضمن إطار معطيات واحد حتى لا تتواجد المعطيات في عدة أماكن. إلا أنه يجدر بالذكر أن المعطيات الداخلة للشبكة العصبونية تحتاج لمعالجة إضافية تتمثل بالتطبيع Normalization، كما أنه لأول مرة عند استخدام الشبكة لتدريبها يجب تقسيم المعطيات وهو ما يسمى ب Data Splitting إلى معطيات للتدريب Training Data، ومعطيات للتأكد Validation Data، ومعطيات للاختبار Testing Data، ونسبة هذه المعطيات للمعطيات الأساسية أمر يرجع لمستخدم النموذج إلا أننا اعتمدنا أحد النسب الشائعة وهي 70%، 10%، 20%، تبعاً. كما يقوم النظام بتقسيمها على شكل سلاسل أصغر Sequences، وهكذا تكون معطيات النموذج جاهزة كي تكون دخلاً له للمعالجة اللاحقة.


هنا تبدأ المرحلة الثالثة، وهي عبارة عن محرك النظام، وآلية عمله بعد استلام الدخل المطلوب كمعطيات جاهزة للمعالجة. في هذه المرحلة تعمل الشبكة والنظم الخبير في آن واحد، فيبدأ النظام الخبير بعملية رسم المخططات البيانية اللازمة للمستخدم، كما يقوم بعملية مطابقة القواعد مع القواعد الموجودة لديه أساساً في قاعدة المعرفة. تنفذ تعليمات القواعد التي أطلقت والتي حققت الطرف الأيسر من القاعدة بحسب خوارزمية Forward Chaining، وتبعاً للقواعد التي أطلقت، والرسومات البيانية الناتجة، يقوم النظام بإعداد تقرير يشرح النتائج التي توصل لها النظام الخبير لعرضها لمستخدم النظام في المرحلة الأخيرة. أما الشبكة العصبونية تقوم بإدخال المعطيات التي تم تجهيزها على شكل مصفوفات، فتدخل هذه المصفوفات عبر طبقة الإدخال Input Layer، ثم تدخل إلى الطبقات المخفية وهي بالترتيب طبقة تضمين زمني Time2Vec، طبقة انتباه أحادي الرأس Single head attention، طبقة انتباه متعدد الرؤوس Multi headed attention، طبقة محول Transformer، وأخيراً طبقة الخرج Output Layer. ويكون خرج هذه الطبقة هو تنبؤ سعر إغلاق اليوم التالي.

المرحلة الرابعة، تجمع ما بين نتيجة النظام الخبير ونتيجة الشبكة العصبونية من خلال خوارزمية ensemble وهي خوارزمية لها عدة أشكال للدمج بين خرج عدة نماذج، نختار في نموذجنا أحد الأشكال المناسبة لحالتنا، وذلك لترجيح قوة تنبؤ النموذج الأقوى على حساب التنبؤ الأضعف، حيث أن النموذج لا يضحى بالدقة، مهما كان نوع المعطيات الداخلة له.

المرحلة الخامسة، عرض النتائج للمستخدم، وهذا عن طريق واجهة تفاعلية، تمكن المستخدم من تقييم التنبؤ، ورؤية التمثيلات البيانية والتقارير، لاتخاذ القرار النهائي على ضوء المعلومات التي يقدمها النظام.

المرحلة السادسة: وهي مرحلة اختيارية إذا كان مستخدم النظام يريد المقارنة بين عدة بدائل، يمكنه الاعتماد على خرج الشبكة والنظام الخبير لاقتراح البديل المناسب، إلا أن النظام يحتفظ بالنتيجة الأعلى للقيمة التنبؤية التي أخرجها النموذج، ويعطي تنقيلاً أدنى للمعايير الأخرى وذلك للاستفادة بشكل أمثل من تعقيد الأدوات المستخدمة سابقاً، وعدم انحياز النموذج لرأي المستخدم، بل يقدم طريقة ترجيح إذا كان تنبؤ بدلين أو أكثر من الأسهم والعمليات متقارب جداً بحيث لا يمكننا اتخاذ قرار.

نعرض الشكل (30) الذي يمثل شكل هيكلية النموذج ومراحل عمله.



الشكل (30) الهيكلية التفصيلية للنموذج المستخدم

6.3. مكونات النموذج المقترح وسبب اختيارها

نعرض في هذه الفقرة المكونات التي نقترحها لكل جزئية من النموذج، وسبب اختيار كل مكون بمناقشة بسيطة تشرح عدم استخدام بعض البدائل المشهورة الأخرى.

1.6.3 مكونات النظام الخبير وسبب اختيارها

قاعدة المعطيات Data Base: تمثل قاعدة معطيات النموذج، الدخل الذي سوف يقرأه محرك الاستدلال لاحقاً لمطابقته مع قواعد المعرفة. يوجد سبب لاستعمال كل متغير في نموذجنا، سنناقش هنا سبب اختيار كل متغير، أولاً نبدأ بالمجموعة الأولى من المتغيرات وهي المجموعة الأساسية التي يمكن من خلالها تمثيل المعطيات على شكل شموع يابانية، أي سعر الافتتاح، سعر الإغلاق، السعر الأدنى، السعر الأعلى، حيث يمكن من خلال هذه المكونات الأربعة الحصول على قدرة تعبيرية جيدة عن حركة السوق، أي قوة البائعين (العرض) وقوة الشارين (الطلب)، ويمكن تمييز أنماط الشموع اليابانية بأنواعها من خلال هذه المتغيرات، وعلى أساسها بدأت فكرة البحث. المجموعة الثانية من المتغيرات تتضمن متغيرات التحليل التقني، نبدأ بسبب اختيار ShortSMA و LongSMA وهما على الترتيب المتوسط المتحرك قصير الأجل والمتوسط المتحرك طويل الأجل، والفكرة من اختيار هذين المتغيرين، وتمثيلهما بيانياً أنه عند تقاطع المتوسطين فهذا يدل على تغير في الاتجاه، وبالتالي يولد إشارة تدل مستخدم النظام على أنه يجب الشراء أو البيع عند هذه النقطة. أما مؤشر القوة النسبية RSI فهو متغير يعبر عن كون السهم أو العملة يتم شرائها بشكل مجحف أو بيعها بشكل مجحف، Overbought or Oversold، وهذا يدل على أن هناك تغير في الاتجاه عند الوصول للقيم الحدية، وتوسع بهذه القيم وبدالاتها لاحقاً. ننقل إلى مؤشر ADX وهو يعبر عن قوة زخم السوق Market Momentum، فقيمة هذا المؤشر إضافة لمؤشرين DMP و DMN التابعين له، يدلان على إذا كان السوق يتحلى بزخم قوي أو ضعيف، وإذا كان إيجابياً أو سلبياً. أخيراً مؤشر الخوف والجشع، الذي يعبر عن مشاعر السوق، أي إذا كان السوق في حالة خوف وبالتالي إقبال شديد على العرض، أو في حالة جشع وبالتالي إقبال شديد على الشراء. هكذا نكون قد شرحنا قاعدة معطيات نموذجنا وسبب اختيار عناصره.

قاعدة المعرفة Knowledge Base: أحد عناصر النظام الخبير ES الذي لا يمكن الاستغناء عنه هي قاعدة المعرفة، وهي كما يوحي الاسم، قاعدة تحتوي على معرفة خبير في مجال المشكلة ويتم تمثيلها على شكل قواعد من نمط If-Then ليقرأها محرك الاستدلال في المرحلة اللاحقة. تعتبر قاعدة المعرفة هي هيكل النظام الخبير، فجودة النظام تعتمد على جودة قواعده، وهذا يتعلق بمعرفة الخبير، وبجودة نقل معرفته للنظام. يتألف نظام NES المقترح من قاعدة معارف مقترحة تحتوي على فئتين من أنواع القواعد، الفئة الأولى هي القواعد التي تحتوي أنماط الشموع اليابانية فقط وهي قواعد بسيطة ومركبة بحسب عدد أيام النمط فهي تزداد تعقيداً بازدياد عدد الأيام. استخدمنا في النظام المقترح أكثر من 30 قاعدة أنماط الشموع ويمكن زيادتها لاحقاً لتطوير النموذج. الفئة الثانية من القواعد هي القواعد التي تتعلق بالمؤشرات التقنية وهي تدمج في مرحلة لاحقة مع قواعد الفئة الأولى لإعطاء نصيحة مناسبة للمستخدم.

محرك الاستدلال Inference engine: يعمل محرك الاستدلال على مطابقة القواعد التي وضعناها مسبقاً، ويستخدم محرك الاستدلال الخاص بهذا النموذج، خوارزمية التسلسل الأمامي Forward Chaining ويرجع ذلك إلى طبيعة المسألة فهي مقوده بالمعطيات Data Driven، لنصل للنتائج الموافقة في الطرف الأيسر من القاعدة، أما لو كنا نبدأ من فرضية مسبقة ونريد الوصول لها فكنا استخدمنا خوارزمية التسلسل الخلفي Backwards Chaining، ويعتبر محرك الاستدلال من المكونات الرئيسية للنظام الخبير، ولا يمكن الاستغناء عنه فهو الذي يطابق المعطيات بالمعرفة لإظهار نتيجة.

واجهة المستخدم User Interface (UI): يتم التفاعل بين النظام والمستخدم عن طريق واجهة المستخدم، وذلك لتسهيل تبادل المعلومات، والمعطيات. وجود واجهة مستخدم جيدة في نظامنا، يمكن متخذ القرار المقارنة بين عدة بدائل، واختيار أسهم وعمليات لتطبيق التنبؤ عليها، فقط بإدخال رمزها والمدة الزمنية للمعطيات التي يريد المستخدم إدخالها. تجعل واجهة الاستخدام النموذج الرياضي قابل للاستخدام بالنسبة لمتخذ القرار حتى بعدم وجود خبرة بالآلية عمله، كما أنه أكثر قابلية للاستخدام حتى للخبراء. وهذا ما يجعل واجهة الاستخدام ذات أهمية كبيرة.

2.6.3. مكونات الشبكة العصبونية وسبب اختيارها

طبقة الدخل Input Layer: هي طبقة إلزامية من مكونات الشبكة العصبونية، تتم معالجة المعطيات قبل إدخالها لهذه الطبقة، ولا يوجد خواص مميزة لهذه الطبقة إلا أنها تدفع بمصفوفات المعطيات للطبقة التي تليها، لمعالجة إضافية.

طبقة تضمين زمني Time Embedding: عند التعامل مع سلاسل زمنية أو جملة في اللغات الطبيعية، فإن موقع الكلمة بالنسبة للجملة أو موقع السعر بالنسبة للسلسلة في حالتنا، له أهمية كبيرة، وبما أن نموذجنا المقترح يدخل السلاسل بالتوازي، أي تتم معالجة أجزاء مختلفة من السلسلة بشكل آني، فيصعب على النموذج التعلم أو استخراج معنى من موقع كل سعر، لذلك يقترح طبقة تضمين زمني لعلاج هذه المشكلة، بدون هذه الطبقة قد يعتبر النموذج أن زخم السعر في 2008 له نفس تأثير التغيرات التي تحدث الآن على سعر السهم غداً وهذا أمر مرفوض، فكرة هذه الطبقة هي تضمين الزمن على شكل متجهات Vectors، ومنه سمي نموذج Time2Vec.

طبقة محول الانتباه Transformer Attention Layer: المحولات هي بنية شبكة عصبونية تستخدم آلية الاهتمام الذاتي، مما يسمح للنموذج بالتركيز على الأجزاء ذات الصلة من السلسلة الزمنية لتحسين صفات التنبؤ. تتكون آلية الانتباه الذاتي من طبقة انتباه أحادية الرأس، (في حالتنا ثلاث طبقات)، وظيفتها تركيز الاهتمام على نقطة وحيدة بالنسبة لباقي النقاط، وطبقة متعددة رؤوس الانتباه حيث يتم دمج المصفوفات الثلاث، كي يستطيع النموذج التركيز على مدة زمنية أطول. آلية الانتباه الذاتي قادرة على ربط جميع خطوات السلاسل الزمنية مع بعضها البعض في وقت واحد، مما يؤدي إلى خلق تبعية طويلة المدى. أخيراً، تتم موازنة كل هذه العمليات داخل بنية المحولات، مما يسمح بتسريع عملية التعلم. لن ننتعمق في هذه الفقرة بتفاصيل تقنية أكثر عن هذه الطبقة، إلا أننا يمكن أن نناقش سبب عدم استخدام مقاربات شهيرة أخرى في الشبكات العصبونية المتكررة RNN، مثل LSTM

أو GRU، وهذا لأنه بالرغم من فعاليتها إلا أنه يصعب عليها النقاط أنماط ذات مدى زمني واسع إلا إذا زدنا عدد الخلايا بشكل كبير وهذا ما يجعلها أبطأ بالتدريب، لذلك تعد هذه الطرق محدودة نسبياً.

طبقة الخرج Output Layer: هي أيضاً من الطبقات الإجبارية للشبكة العصبونية، لهذه الطبقة عدة وظائف، فغير أنها تقوم بإظهار النتيجة النهائية كما يوحي الاسم، بل من خلالها يتم حساب مدى اقتراب أو ابتعاد الشبكة عن النتيجة الصحيحة في مرحلة التدريب عبر توابع التكلفة المختلفة Loss Function، لتقوم خوارزمية الأمثلة بتعديل الأوزان والتحيزات الخاصة بالشبكة لتحسين أدائها.

3.6.3. مكونات المصفوفة الموزونة وسبب اختيارها

اخترنا في نموذجنا المقترح طريقة المصفوفة الموزونة لحل MCDM وذلك لأنها سريعة التطبيق، وديناميكية بشدة مقارنة بطرق أخرى مثل ELECTRE3 التي تحتاج إلى مؤشرات إضافية قد لا يستطيع المستخدم تعيينها بدقة، كما أن عدد البدائل والمعايير لا يزيد من تعقيد هذه الطريقة بشكل أسّي مثل طرق أخرى، لذا نستطيع تغيير البدائل والمعايير والأوزان بوقت قياسي بتغيير متطلبات السوق والمستخدم.

المعايير Criteria: المعايير في نموذجنا المقترح هي ديناميكية جداً، فمن وجهة نظر تصميمية لسنا مضطرين أن نضع المستخدم في صندوق طالما أن المعايير في الواقع هي دوماً متغيرة إلا أننا نقترح بعض المعايير التي تناسب الأسواق المالية، مثل زخم سعر السهم والظروف السياسية والظروف الاقتصادية والظروف التكنولوجية إن كان السهم المدرس هو سعر عملة رقمية، وقصدنا اقتراح هذه المعايير لأنه صعب نمذجتها بقيم كمية أو استخراجها كدفع معطيات مستمر كما أنها تعتمد بشكل كبير على المعلومات التي يملكها المستخدم، وإلا كنا أدخلنا هذه العوامل بشكل أكبر ضمن النظام الخبير أو الشبكة العصبونية المستخدمة. فيمكن طلب تقييم الوضع الاقتصادي أو سيولة الشركة أو سمعتها من المستخدم، ولذلك إيجابية أن يشارك المستخدم في عملية صنع القرار، ونحد سلبية هذه المقاربة (وهي تدخل العامل البشري الذي قد يتصرف بغير عقلانية) بجعل وزن المعايير التي يدخلها المستخدم أقل بكثير من وزن معيار التنبؤ الخارج من النظام الهجين سابقاً.

البدائل: يمكن القول أن البدائل أكثر ديناميكية حتى من المعايير، فمن الممكن أن يغيرها المستخدم بشكل مستمر، وقد تكون البدائل خاصة بأسهم أو بعملات عادية أو بعملات رقمية (إجمالاً قد تخص أي بديل يتصرف كأنه سوق مالي فيمكن إدخال الذهب والنفط وأشباه هذه المنتجات أيضاً). نستطيع مناقشة حدود البدائل على الشكل التالي: الشرط الأساسي لتطبيق هذه المصفوفة وجود أكثر من بديل وإلا لا يوجد معنى لها، الشرط الثاني هو استيفاء البدائل الموضوعية في المصفوفة جميع مواصفات كل بديل، والمقصود بهذا الكلام أنه لا يمكن وضع بدائل لا تمتلك نفس المعايير.

الأوزان Weights: توجد عدة طرق لتوزيع المعايير، نختار في نموذجنا طريقة AHP وذلك لعدة أسباب أهمها سهولة تطبيقها وديناميكيةها، فيمكن تغيير الأوزان بشكل سريع نسبياً، كما أنها طريقة تراعي أهمية المعايير بالنسبة لبعضها ولا تخضع بشكل مباشر لتوزيع متحيز أو عشوائي، فنقترح بنموذج بحثنا إعطاء الأولوية للتنبؤ الخارج من النظام الهجين، فحتى لو أراد المستخدم التصرف بشكل عشوائي وإدخال قيم متحيزة أو مأخوذة برأيه الشخصي،

يظل النموذج يرجح التنبؤ الأعلى نسبياً، وفائدة وجود المعايير الأخرى في هذه الحالة، هي الترجيح بين عدة بدائل عندما يكون التنبؤ متقارب جداً، وفي هذه الحالة نلجأ لمعايير أخرى لكسر التقارب الشديد.

7.3. خصائص الحل المقترح

نعرض في هذه الفقرة بعض أهم خصائص الحل المقترح ونفسر سبب وجود هذه الخصائص وضرورتها لحل مشكلة البحث:

القدرة التفسيرية Explanatory Power: يتميز النموذج المقترح بأنه قادر على تفسير الظواهر المترافقة مع هبوط وارتفاع وانقلاب الاتجاه واستمرار اتجاه الأسعار، تم اقتراح خاصية القدرة التفسيرية نتيجة لندرة النماذج التي تقوم بذلك، كما أن العديد من النماذج التي تتميز بوجود قدرة تفسيرية عادة ما تكون دقتها التنبؤية ضعيفة، فأنت بداية فكرة النموذج المقترح من ندرة وجود خاصية التفسير في النماذج المالية، قد يكون ذلك لأن شريحة المستخدمين عادة ما تكون من خبراء ماليين، أو بسبب صعوبة نقل المعرفة من خبير في المجال إلى مهندس المعرفة Knowledge Engineer، كما أن مهندس المعرفة سينقل هذه المعرفة للمبرمجين. هذه السلسلة طويلة نوعاً ما، وتأخذ وقتاً زمنياً طويلاً للقيام بهذه الخطوات، كما أنه إذا أراد رياضي أو مبرمج القيام ببناء نموذج تنبؤي فمن المرجح أن يكون خبيراً بالأدوات وآلية عملها وأمثلة الحل من وجهة نظر تقنية، إلا أنه قد يحتاج وجهات نظر خبراء في مجال المشكلة Problem Domain، وهذا ما يجعل القدرة التفسيرية أحد نقاط قوة النموذج المقترح.

متانة النموذج Model Robustness: يهدف النموذج المقترح أن يكون متيناً، وذلك باستخدام خوارزمية ensemble، وذلك لأن طريقة عمل الخوارزمية ترجح تنبؤ النموذج الأقوى، فإذا كان السوق ذو خصوصية تجعل النظام الخبير أدق من الشبكة العصبونية لسبب ما، مثل عدم وجود معطيات كافية لإدخالها للشبكة، فإن النظام يعتمد بشكل أكبر على النظام الخبير، إلا أن الحالة المتوقعة العادية تقتضي بأن يكون الاعتماد الأكبر على الشبكة العصبونية، ويمكن اعتبار هذه الآلية شبكة أمان للنموذج. يوجد أيضاً عامل أمان آخر وهو صلاحية النموذج للأسهم العادية أيضاً وليس فقط على العملات الرقمية (أي المعطيات التي طبق عليها نموذجنا). كما أن إضافة المصفوفة وديناميكية أوزانها ومعاييرها وبدائلها أيضاً تصب في ميزة متانة النموذج، فيصبح بإمكانه التعامل مع حالات استخدام أكثر بعد هذه الإضافة.

معالجة عدم التأكد Uncertainty Handling: يهدف النموذج لمعالجة عدم التأكد من خلال تقدير بعض المتغيرات النوعية، من خلال تحليل مشاعر السوق عن طريق مؤشر الخوف والجشع Fear and Greed Index. كما يسمح للمستخدم أن يعبر عن معلومات قد تكون مدركة له، إلا أنه صعب إدراكها من قبل النظام أو التعبير عنها بأرقام لإدخالها على النموذج مثل الأوضاع السياسية (كالعقوبات أو التشريعات أو الحروب).

قدرة التعامل مع حجوم معطيات مختلفة: للنظام المقترح القدرة على حجوم مختلفة، مع أنه من المفضل أن يكون دخل النظام من حجم كبير، وذلك لتحسين دقة الشبكة عند تدريبها إلا أنه يمكن حل هذه المشكلة كإجراء بديل، بتدريب الشبكة على معطيات كافية لسوق آخر واختبار النموذج المدرب على المعطيات الموجودة لدينا. يشكل هذا الحل طريقة جيدة لتقادي هذه المشكلة إلا أنه إذا وجدت معطيات كافية للسوق المدروس فقد يكون هذا أفضل

لأداء الشبكة، كونها تستفيد من خصوصية هذا السوق. كما أنه إن وجدت معطيات أقل من حجم مصفوفة الدخل للشبكة العصبونية، فإن النموذج أيضاً يعطي خرج النظام الخبير للمستخدم، فيمكن للنظام الخبير إعطاء خرج للمستخدم حتى لو كان الدخل معطيات يوم واحد فقط، إلا أن هذا الخرج قليل الإفادة ولا يمكن الأخذ به كنصيحة مالية جيدة.

عدم الانحياز Unbiased: كون التنبؤ السعري غير معتمد على العامل البشري فإنه يمكن القول إنه غير منحاز ويمكن قول نفس الشيء على التقارير التي يقدمها النظام الخبير فهي مبنية على قواعد If-Then، فلا يمكن للمستخدم التعديل عليها أو على النتائج إلا إذا كان له إذن سماح للوصول إلى الترميز الأصلي للبرنامج. أخيراً، اعتماد مصفوفة القرار بتثقيها على التنبؤ وعلى رأي المستخدم وتقييمه للبدائل بشكل أقل.

القدرة على التعامل مع عدة بدائل Handling Multiple Alternatives: هذه الميزة قد تبدو حدسية، إلا أننا يمكن اعتبارها ميزة في نموذجنا، وذلك لأن أغلب النماذج التي تعتمد على التحليل التقني TA والتنبؤ السعري، من خلال أدوات بحثنا أو أدوات مشابهة، لا تأخذ بعين الاعتبار تعدد البدائل بل تناقش فكرة الشراء أو البيع لنفس السهم، والنماذج التي تقوم بالمقارنة بين عدة بدائل تعتمد على التحليل الأساسي FA.

8.3. خطوات تنفيذ النموذج

نناقش في هذه الفقرة منهجية التفكير للوصول لهندسة النموذج المقترح، وخطوات العمل التي نتبعها في هذا البحث: **جلب معلومات عن مجال المشكلة:** عند التفكير ببناء قاعدة معرفة فنحن بحاجة لعدة مكونات أولها، المعلومات عن مجال المشكلة، وهي خطوة حساسة تعتمد بناء قاعدة المعرفة عليها، لهذه المرحلة بعض العقبات مثل تعدد مصادر المعرفة وتضارب معلومات بعض المصادر. نحل عقبة تعدد المصادر من خلال مقارنة عدة مصادر خلال عملية البحث، ومن الضروري أن تكون مصادر المعرفة المستخدمة لبناء قاعدة المعرفة مدققة من قبل خبراء آخرين، من نفس المجال وذلك لحل مشكلة تضارب المعلومات، لذا قمنا في هذا البحث بغزلة المعلومات الموجودة عن هذا المجال، واتخاذ مصادر المعلومات، إما من أبحاث أو من كتب منشورة ومدققة، إضافة لمقارنة عدة مصادر للتأكد الإضافي من صحتها. تم استخدام معلومات الأوراق البحثية (Goo et al, 2007)، (Morris, 2006)، (K.H. Lee, 1999) وكتب (Griffioen, 2003)، (Wilder, 1978) لصياغة المعرفة والقواعد في نموذج البحث. **بناء القواعد بصيغة اللغة الطبيعية:** يمكن صياغة القواعد والأنماط أولاً بصيغة اللغة الطبيعية، وذلك لتسهيل عملنا لاحقاً، عند صياغتها بصيغة رياضية، ثم بصيغة الترميز. كما يمكن الاحتفاظ بصيغة اللغة الطبيعية لإظهار القاعدة المستخدمة لمستخدم النظام وشرح مبسط لها، لذا نجد أن لصياغة القواعد باللغة الطبيعية فائدتان، الأولى هي تسهيل مهمة النمذجة لاحقاً بصيغة رياضية، وبصيغة الترميز، والثانية هي إظهار القاعدة للمستخدم النهائي وشرحها له.

بناء القواعد بصيغة رياضية: هذه الخطوة هي بمثابة خطوة انتقالية، فهي تسهل عملية الترميز في المرحلة التالية، الصيغة الشبه رياضية لها مزايا عدة، أهمها أنها غير قابلة لسوء الفهم كما في صيغة اللغة الطبيعية التي بالرغم

من قدرتها التعبيرية العالية، إلا أنه يمكن سوء تفسيرها، وهي غير محددة بمتغيرات كمية إلا أنه بعد عملية التحويل بين الصيغ، يسهل التعامل معها وترميزها لبناء قواعد معرفة يقرأها محرك الاستدلال.

بناء القواعد بصيغة رماز: هنا نقوم بتحويل القواعد الرياضية والمتغيرات والمعادلات إلى كيانات بصيغة الترميز، ويمكن القول أنه يوجد شبه بين الصيغ الثلاث، الرماز يشبه الصيغة الرياضية من ناحية المنطق والرموز المنطقية، إلا أنه يدخل أيضاً بكتابة البرمجة، صيغ تشبه اللغة الطبيعية، ولا سيما بلغة البرمجة المستخدمة في بحثنا Python، وتم استخدامها لأنها غرضية التوجه Object Oriented، كما أنها سهلة القراءة والتفسير، فيمكن لشخص غير اختصاصي أن يفهم الفكرة العامة من البرمجة، نسبياً أفضل من لغات أخرى.

بناء محرك الاستدلال: بعد القيام بالخطوات السابقة، نستخدم القواعد التي قمنا ببنائها ضمن محرك الاستدلال، يقوم محرك الاستدلال المقترح بمطابقة القواعد باستخدام خوارزمية الاستدلال الأمامي Forward Chaining، لأننا نبدأ بالمعطيات التي لدينا، لنرى ما هي قواعد المعرفة التي يمكن مطابقتها تبعاً لذلك، نريد أن نعلم أيضاً ما هي استراتيجية حل النزاعات Conflict Resolution، التي يجب استخدامها. يمكن القول بالاعتماد على الأبحاث السابقة أن أفضل استراتيجية للقيام بذلك هي معدل الإصابة Hit Ratio، فالقاعدة التي تتكرر بشكل صحيح أكثر نعطيها الأولوية.

توجد بعض الأبحاث التي استخدمت استراتيجية التعقيد Complexity، الفكرة بتطبيقها أنه كلما كانت القاعدة أكثر تعقيداً فمن المنطق أن تكون ذات خرج أدق، إلا أن تم نقض هذه الفرضية ببعض الأبحاث فأظهرت النتائج أن الأنماط المؤلفة من فترتين أكثر دقة من الأنماط التي تعتمد على ثلاث فترات زمنية، ولذلك لم نستخدم تلك الاستراتيجية.

اختبار النظام الخبير: نقوم بهذه الخطوة بالتأكد من سلاسة قيام النظام بالعمليات اللازمة وعدم وجود أخطاء برمجية بالدرجة الأولى، ونقوم بإعادة تصحيح الأخطاء حتى إلغائها وعمل النظام بالشكل الطبيعي. الخطوة الثانية هي التأكد من جودة القواعد، فمن المتوقع أن تتفاوت جودة القواعد الموجودة في النظام، فقد تؤدي بعض القواعد بشكل جيد أكثر من المتوقع والعكس صحيح، إلا أن هذه العملية عملية طويلة الأجل، فقد يأخذ تعديل الانحرافات، فترة زمنية طويلة للوصول لقواعد قريبة من الأمثلية، كما يجدر بالقول أنه يمكن إضافة قواعد جديدة والاستغناء عن بعض القواعد ذات الأداء المنخفض، كما يمكن إجراء تغييرات هيكلية على النظام الخبير مثل إضافة مفاهيم عدم التأكد والمنطق الغائم لتحسين أداء النظام في الظروف الاحتمالية وعدم التأكد والتفاوت Volatility المترافق مع طبيعة السوق، توجد عدة طرق لاختبار القواعد مثل مصفوفة عدم التأكد Confusion Matrix، ومعدل الإصابة Hit Ratio وهو ما نستخدمه في بحثنا.

بناء قاعدة المعطيات المستخدمة: عند بناء قاعدة المعطيات يجب أن نراعي عدة أمور، أولها كفاية المعطيات، عدم كفاية المعطيات لا يشكل مشكلة كبيرة بالنسبة لمطابقة القواعد في محرك الاستدلال، إلا أنه يشكل مشكلة كبيرة لتدريب الشبكة العصبونية، فلا يمكن بناءها دون كمية معطيات كافية، ويشكل أيضاً مشكلة عند التأكد من صحة النظام الخبير.

تتميز معطيات نموذجنا المقترح بأن لها بعض الخواص التي تميزها عن قواعد معطيات أخرى، مثل أننا قمنا باستخراج بعض خواص المعطيات من المعطيات الأساسية، بتطبيق دوال رياضية مألوفة مثل استخراج المؤشرات لمعرفة الزخم والاتجاه، وما إذا كان السهم أو العملة تباع أو تشتري بشكل مجحف... لهذه الخواص المستخرجة قدرة تعبيرية عالية يمكن أن تلتقطها الشبكة العصبونية، إضافة للاستفادة من تضخيم المعطيات الذي حصل بطبيعة الحال عند استخراج هذه الخواص.

بناء الشبكة العصبونية: تم الاستفادة عند بناء الشبكة العصبونية من الناحية التصميمية لهندسة شكل الشبكة وآلية عملها من نموذج (Schmitz, 2020) الذي واجه مشكلة التنبؤ السعري المشابهة لبحثنا، إلا أن المعطيات المستخدمة وخرج النموذج مختلف.

عند التفكير ببناء الشبكة العصبونية للتنبؤ السعري توجد العديد من المقاربات المستخدمة مثل GANs أو CNNs أو شبكات المعرفة العميقة، أو الشبكات الاحتمالية، ومن المنطقي استخدام الشبكات العصبونية المتكررة RNN، للقيام بالتنبؤ وذلك لأننا نتعامل مع سلسلة زمنية أي كل نقطة زمنية مرتبطة بالتي قبلها وبالتالي بعدها، لذا يمكن الاستفادة من إعادة إدخال خرج العقد في الطبقات المخفية، وهو مفهوم الذاكرة. أما بالنسبة لمكونات الشبكة فقد قمنا بالاستفادة من النماذج التالية (Vaswani et al, 2017)، (Diniz et al, 2020)، (Kazemi et al, 2019)، ناقشنا في الفقرات السابقة سبب اختيار مكونات الشبكة التي نستعملها في نموذج البحث، إلا أننا سنتوسع أكثر في ذلك لاحقاً.

تدريب الشبكة العصبونية واختبارها: تبدأ الشبكة عند إنشائها بأوزان عشوائية قريبة من الصفر، وبتحيزات قريبة من الصفر أيضاً ويتم تغيير هذه الأوزان والتحيزات بحسب درجة ابتعاد الشبكة عن النتيجة الصحيحة، عند كل إدخال سطر معطيات جديد للشبكة، نغير هذه الأوزان والتحيزات قليلاً للوصول لأدنى قيمة محلية Local Minima، لتابع التكلفة Loss Function وذلك من خلال خوارزمية أمثلة تعمل على مبدأ النزول التدريجي Gradient descent، يوجد خيارات مختلفة لخوارزميات الأمثلة واختيار عدد الحقب epochs، في بحثنا اعتمدنا على خوارزمية أمثلة ADAM، لأنها تدمج بين طريقتي عمل خوارزميات أمثلة أخرى، إلا أننا لا يمكننا القول أن هذه الخوارزمية أفضل من غيرها أو أسوأ من غيرها، وهذا أمر يعتمد على التجريب، ويمكن قول نفس الشيء بالنسبة لعدد الحقب ومعدل التعلم التي نحددها في النموذج كثوابت لبء العمل، فزيادة الحقب مثلاً تزيد من دقة النموذج إلا أنها قد تؤدي إلى إفراط في التناسب overfitting أي أن النموذج ذو أداء عالي جداً على المعطيات التي نستخدمها في التدريب، إلا أنه ذو أداء سيء جداً عند إدخال معطيات جديدة لم يتدرب عليها، أما بالنسبة للاختبار فنقوم الشبكة بتقسيم المعطيات إلى معطيات تدريب، معطيات اختبار، ومعطيات تصديق، وذلك حتى تكون الشبكة غير مألوفة مع معطيات الاختبار. نقوم بعملية الاختبار لكشف الإفراط في التناسب Overfitting، لذا لا يمكننا أن نستغني عن هذه العملية.

دمج خرج الشبكة والنظام الخبير: توجد عدة طرق لدمج خرج نماذج تنبؤية، أحد أهمها مجموعة خوارزميات ensemble، التي تتميز بتعدد صيغها وأنواعها، وسبب اختيارنا لها في بحثنا، هو ملائمة طريقة متوسط الترجيح الموزن للنموذجين لدينا، فترجح هذه الطريقة، النموذج الأفضل الذي يقدم نتائج أدق، وذلك بمراعاة نسبة تفوق

النموذج الأدق، فمثلاً إذا كان النموذج الأول أفضل من الثاني بنسبة 60% فإن النتيجة ترجح النموذج الأول بنفس النسبة. لا يمكن أن ندمج هذه النتائج بدون واجهة مستخدم جيدة لتسهيل تبادل المعلومات، لذا فهي أداة ضرورية في النظام.

بناء مصفوفة قرار موزنة: يمكن الاكتفاء بالنموذج المقترح السابق للقيام بالتنبؤ وأخذ القرار على هذا الأساس إذا كان لدينا بديل وحيد، على سبيل المثال نريد شراء سهم لشركة ما أو عملة رقمية معينة لكننا مترددين بالنسبة للتوقيت، أو نريد القيام بعدد كبير من التداولات (بيع/ شراء)، لذا نحن بحاجة لمعرفة تنبؤ ارتفاع وانخفاض السعر. إلا أنه عندما نريد اتخاذ قرار لعدة بدائل، يمكن مقارنة البدائل من ناحية أفضل تنبؤ، لكن إذا كان التفاوت بين تنبؤ البدائل قليل، أو إذا وجدت معايير أخرى مثل معلومات سياسية أو اقتصادية بلحظة ما، أو تطور تكنولوجي بإحدى العملات، التي لا يمكننا إدخالها إلى النظام أو نمذجتها على شكل متغيرات كمية، هنا نجد أنفسنا بحالة أعقد من مشكلتنا الأصلية، إلا أن أحد الحلول البسيطة والديناميكية التي يمكننا تطبيقها هي طريقة المصفوفة الموزنة، نفضل من وجهة نظر تصميمية أن تكون هذه المصفوفة موزنة لتقليل التحيز من قبل المستخدم حيث نقترح أن يكون وزن المصفوفة الأكبر عند معيار التنبؤ، و توزن المعايير الأخرى المقترحة مثل الظروف السياسية أو التطورات التكنولوجية أو الزخم وما شابه بأوزان أقل بكثير لمنع التحيز.

9.3. خاتمة

قدمنا في هذا الفصل، نموذج NES وهو نظام دعم قرار هجين، يدمج ما بين شبكة عصبونية ونظام خبير قائم على المعرفة في مجال أسواق البورصة، لحل مشكلة بحثنا بطريقة جديدة، وناقشنا في هذا الفصل هيكلية النموذج المتقدمة والمفصلة، إضافة للمكونات التي اخترناها وسبب اختيار هذه المكونات. ثم قمنا بمناقشة خطوات العمل، اللازمة لبناء نموذجنا المقترح. ننتقل في الفصل القادم لفصل المحاكاة وبناء النموذج الأولي الذي يناقش عملية تنفيذ النموذج، وذلك لاختبار أدائه لاحقاً، ومعرفة نقاط ضعفه للتطوير المستقبلي.

الفصل الرابع

المحاكاة وبناء النموذج الأولي

1.4. مقدمة

في هذا الفصل نقوم ببناء نموذج أولي، ومحاكاة حالة عملية لأداء نموذج NES المقترح، نقدم أولاً تفاصيل بيئة تطوير هذا النموذج وسبب اختيار لغة البرمجة والأدوات والمكاتب المرافقة، وتبريرات استخدامها، ثم نتوسع بآلية بناء النموذج من الناحيتين المفاهيمية والترميزية، حيث نهدف أيضاً في هذا الفصل محاكاة طريقة تفكيرنا لحل هذه المشكلة، ونرفق أيضاً هيكلية المكونات المختلفة تفصيلاً.

2.4. بيئة العمل والتطوير

استخدمنا في بحثنا لغة برمجة Python بنسخة 3.10.4، لأنها لغة برمجة غرضية التوجه تدعم مكاتب التعلم الآلي ML بشكل كبير، فتعتبر هذه اللغة في وقت كتابة هذا البحث، اللغة الرائدة في هذا المجال، والميزة الأهم في ذلك أنه يمكن كتابة ترميز النظام الخبير والشبكة العصبونية بنفس اللغة، إضافة لكونها سهلة القراءة والتفسير حتى للقارئ غير الاختصاصيين، نرفق أيضاً في هذه الفقرة المكاتب المستخدمة لبناء النموذج وإصداراتها عند تطبيق نموذجنا، واستخدام كل مكتبة بشكل بسيط.

استخدمنا أيضاً لتدريب الشبكة العصبونية وحدات معالجة الرسومات (GPU) Graphics Processing Unit الخاصة بـ Google وذلك لقدرتها على معالجة كميات كبيرة من المعطيات بشكل آني على التوازي، على عكس وحدات المعالجة المركزية للحواسيب العادية (CPU) Central Processing Units التي تستغرق زمن تدريب طويل جداً، تعتبر GPUs حلاً مناسباً لمشكلة التعقيد الزمني الكبير لدى تدريب الشبكة العصبونية.

الجدول (71) أهم المكاتب المستخدمة لبناء النموذج ونسخها


Simple Abstract About the Library	Version	Library Name
Powerful data structures for data analysis, time series, and statistics	1.3.4	pandas
Download market data from Yahoo! Finance API	0.1.70	yfinance
TensorFlow is an open-source machine learning framework for everyone	2.8.0	tensorflow
Deep learning for humans.	2.8.0	keras
Python plotting package	3.4.3	matplotlib
Expert Systems for Python	1.9.4	experta
An easy to use Python 3 Pandas Extension with 130+ Technical Analysis Indicators	0.3.14b0	pandas-ta
Utilities for the visualization, and visual analysis, of financial data	0.12.8b9	mplfinance
Cryptocurrency historical market price data scrapper	0.6.1	cryptocmd

3.4. بناء النموذج الأولي

في هذه الفقرة نتناول مراحل بنائنا النموذج بالترتيب الزمني لذلك، ونقوم أيضاً بمناقشة بعض الصعوبات وكيفية تجاوزها، إضافة لتبرير استخدام بعض الأدوات والطرق، وعرض بعض أجزاء البرمجة المكتوبة وشرحها باللغة الطبيعية، وبصيغ رياضية لتكوين فهم جيد عن نموذجنا.

1.3.4. جلب المعطيات الخام

نبدأ تفكيرنا من وجهة نظر مستخدم في هذه المرحلة حيث أنه قد تكون متطلبات المستخدم الاستثمار بعمليات رقمية أو أسهم عادية، وهذا ما دعانا إلى استخدام مكتبتين لتلبية هذا المتطلب، المكتبة الأولى هي yfinance، وهي تقوم بجلب معطيات عن أغلب الشركات الهامة المسجلة في الأسواق المالية، خصوصاً الأمريكية منها على الطلب، وبهذا نكون غطينا الشق الأول، أما بالنسبة للعملة الرقمية نستخدم مكتبة cryptocmd التي تقوم بكشط معطيات العملات الرقمية من عدة مصادر وجلبها على شكل واجهة معطيات. كما أنه يوجد أحد المتغيرات التي يمكن الاستفادة منها بقوة ولا يمكن حسابها من المعطيات الأصلية وهي مؤشر الخوف والجشع Fear and Greed index، وهو مؤشر يحسب رياضياً من عدة مصادر بمعادلات متعددة المتغيرات عن طريق تحليل مشاعر المستثمرين الذين يقومون بالتداول. كما أن هذا المؤشر يحسب لأسواق الأوراق المالية والعملات الرقمية كل على حدة ويعطي قيم مختلفة لكل سوق، إلا أنه في السوقين يعطي قيمة تتراوح بين (0 و 100) حيث أن القيم القريبة من الصفر تدل على الخوف الشديد للمستثمرين، وتعتبر المجال تدريجياً لتصل إلى الجشع الشديد في القيم القريبة من 100، وهو مؤشر مفيد للمستثمرين حيث يمكن أن يعكس العديد من المتغيرات في رقم واحد، إضافة إلى أن يمكن تمثيله بشكل بصري سهل التفسير والقراءة نعرضه في الشكل (31) أدناه.



الشكل (31) طريقة عرض مؤشر الخوف والجشع

ما نرى فإنه يعرض القيمة الآنية للمؤشر ويعرض القيم المستقبلية للمقارنة، لذلك يمكن أن نعتبره أداة مفيدة للنظام الخبير حيث يمكن بناء قواعد على أساسه، إضافة لإمكانية عرضه للمستخدم في الواجهة التفاعلية. قمنا باستخدام أداة Jupyter Notebook، وأداة Google Colab لكتابة الرّماز المستخدم في هذا البحث. أما بالنسبة لآلية جلب المعطيات فنعرضها بالرّماز (1) وذلك في حال كانت المعطيات لعملات رقمية أو لمعطيات سوق أوراق مالية تبعاً:

الزّمان (1) طريقة جلب معطيات خام للأسهم والعملات

```
from cryptocomd import CmcScraper

# initialise scraper with time interval for e.g a year from today
scraper = CmcScraper("BTC", "1-2-2018", "18-4-2022")
df = scraper.get_dataframe()
```

```
import yfinance as yf
TSLA_Ticker = yf.Ticker("TSLA-USD")
TSLA_Data = TSLA_Ticker.history(period="max")
```


عرضنا أيضاً هنا حالتين، الأولى إذا كنا نريد رؤية فترة زمنية محددة ما، أو إذا أردنا المعطيات منذ تسجيل الشركة في السوق المالي وحتى أقرب تاريخ (في الخلية الثانية)، ويمكن تعديل رمز السهم والتاريخ لإظهار أي سهم يريده المستخدم. وتظهر النتيجة على الشكل التالي:

الجدول (18) مثال على إطار معطيات خام باستخدام مكتبة Pandas

	Date	High	Low	Open	Close	Volume	Adj Close
0	2010-06-29	5.000000	3.508000	3.800000	4.778000	93831500.0	4.778000
1	2010-06-30	6.084000	4.660000	5.158000	4.766000	85935500.0	4.766000
2	2010-07-01	5.184000	4.054000	5.000000	4.392000	41094000.0	4.392000
3	2010-07-02	4.620000	3.742000	4.600000	3.840000	25699000.0	3.840000
4	2010-07-06	4.000000	3.166000	4.000000	3.222000	34334500.0	3.222000
...	...	...	...	...	...	...	...
2952	2022-03-21	942.849976	907.090027	914.979980	921.159973	27327200.0	921.159973
2953	2022-03-22	997.859985	921.750000	930.000000	993.979980	35289500.0	993.979980
2954	2022-03-23	1040.699951	976.400024	979.940002	999.109985	40225400.0	999.109985
2955	2022-03-24	1024.489990	988.799988	1009.729980	1013.919983	22973600.0	1013.919983
2956	2022-03-25	1021.799988	997.320007	1008.000000	1010.640015	20677200.0	1010.640015

نجد أن المعطيات مهيكلة على شكل تاريخ، السعر الأعلى، الأدنى، الافتتاح، الإغلاق، حجم التداول، الإغلاق المعدل. نستفيد من وجود عدة أسعار لسببين، الأول هو القدرة التعبيرية العالية، فيمكن تحويل هذه الأسعار إلى شموع يابانية ليراها المستخدم كما تفيد في تمييز الأنماط وتفسير حركة السوق من خلال هذه الأنماط وهذا ما نراه لاحقاً، السبب الثاني أن وجود هذه الأسعار بدلاً من سعر وحيد هي إحدى طرق تضخيم المعطيات، ونستفيد من ذلك عند تدريب الشبكة العصبونية. يمكن حذف سعر الإغلاق المعدل (العمود الأخير) وهو يضاف عندما تريد الشركة قسم الأسهم Stock Split، أي جعل كل سهم بمثابة سهمين فتتخفص قيمة السهم للنصف تقريباً، وفي حال عدم وجود ذلك فهو سعر الإغلاق نفسه، وهذا أمر لا يمكن التنبؤ به لأنه قرار شركة داخلي ولا يوجد مغزى من التنبؤ به، كما أنه إذا حذفنا سعر الإغلاق وحافظنا على الإغلاق المعدل، فيظهر للنظام وكأن السعر انخفض للنصف في يوم واحد وهذا يؤدي النموذج من ناحية الدقة والمتانة، لذلك نحذف الإغلاق المعدل. كما أننا نستطيع

تمثيل الشموع اليابانية بيانياً من خلال برمجة صغيرة تقوم بالتمثيل البياني من خلال مكتبة mplfinance، فيمكن إظهار التغيرات السعرية بشكل تفاعلي بالشكل التالي:



الشكل (32) تمثيل التغيرات السعرية بالشموع اليابانية بطريقة تفاعلية باستخدام mplfinance

أما بالنسبة لمؤشر الخوف والجشع يمكننا كشطه عن طريق استخدام API الموقع الرسمي الذي يقوم بحسابه على الشكل التالي.

الرماز (2) كشط مؤشر الخوف والجشع باستخدام API

```
r = requests.get('https://api.alternative.me/fng/?limit=0')
df2 = pd.DataFrame(r.json()['data'])
df2.timestamp = pd.to_datetime(df2.timestamp, unit='s')
df2.set_index('timestamp', inplace = True)
df2 = df2[::-1]
df2
```

نتيجة هذا التميز هي عمود المؤشر باللغة الطبيعية إضافة لقيمتها وموعد تحديثه الذي يمكن الاستغناء عنه.

الجدول (19) إطار معطيات مؤشر الخوف والجشع باستخدام مكتبة Pandas

	value	value_classification
timestamp		
2018-02-01	30	Fear
2018-02-02	15	Extreme Fear
2018-02-03	40	Fear
2018-02-04	24	Extreme Fear
2018-02-05	11	Extreme Fear
...	...	...
2022-05-22	14	Extreme Fear
2022-05-23	10	Extreme Fear
2022-05-24	12	Extreme Fear
2022-05-25	11	Extreme Fear
2022-05-26	12	Extreme Fear

كما يمكن توليد تقارير من مؤشر الخوف والجشع الخاص بالأسواق المالية إلا أننا سنناقش ذلك في مرحلة توليد التقارير.

2.3.4. توليد معطيات مشتقة

المعطيات المشتقة ذات إفادة كبيرة من الناحية التفسيرية وتضخيم المعطيات لذلك فهي من الأجزاء الأساسية من نموذجنا المقترح، تم التركيز عند اختيار مؤشرات مالية لتوليد معطيات مشتقة، ألا يوجد مؤشرات لها نفس المعنى أو تكرار في دلالة المؤشرات لمنع هدر المساحة وزيادة التعقيد الزمني للمعالجة دون قيمة مضافة، نناقش هنا استخدام المؤشرات المالية المختلفة ودلالاتها والبرمجية المستخدمة.

1.2.3.4 تقاطع المتوسطات المتحركة Double Moving Average

نستخدم المتوسطات المتحركة وهي من أشهر أدوات التحليل التقني TA، لدراسة نقاط تقاطعها وتعيينها للاستفادة منها ببناء قواعد المعرفة، ولتمثيلها بيانياً على شكل نقاط يراها المستخدم، وأخيراً تلعب دوراً مهماً في صقل المعطيات Data Smoothing، وتضخيمها. الفكرة من تقاطع المتوسطات المتحركة هي أنه عندما يقطع المتوسط المتحرك قصير الأجل ShortSMA، المتوسط المتحرك طويل الأجل LongSMA، فإنها إشارة للشراء وتسمى في مجال التحليل التقني Golden Cross (التقاطع الذهبي)، والعكس عندما يقطع المتوسط المتحرك طويل الأجل المتوسط المتحرك قصير الأجل فإنها إشارة للبيع، وتسمى في مجال التحليل التقني Death cross (التقاطع المميت)، نعرض في هذه الفقرة البرمجية التي تولد المتوسطات المتحركة، وقد اخترنا في البحث أن يكون المتوسط المتحرك قصير الأجل لثلاثين يوماً 30SMA، وطويل الأجل لمئة يوم 100SMA، ويمكن استخدام فترات زمنية أخرى إلا أن هذه الفترات خيار تصميمي شائع الاستخدام.

الرمز (3) تابع لحساب المتوسطات المتحركة

```
def SMA(dataFrame, period=30):
    return dataFrame['Close'].rolling(window=period).mean()

# print(df)
data1 = pd.DataFrame()
data1['ShortSMA'] = SMA(df, 30)
data1['LongSMA'] = SMA(df, 100)
data1['Close'] = df['Close']
column_list = ['ShortSMA', 'LongSMA', 'Close']
data1[column_list].plot(figsize=(12, 6))
plt.title('death/golden cross')
plt.show()
```

نبني بعدها دالة تقوم بتأشير مناطق البيع والشراء وعرضها للمستخدم لمعرفة النقاط المهمة سابقاً وإذا وجدت نقطة حالية يستفيد منها النظام الخبير لاحقاً لإعطاء نصيحة بالبيع أو الشراء، نعرض جزء من برمجية إظهار النقاط التي نهتم بدراستها، ثم نعرض خرج هذه البرمجية، حيث نرى أن السهم الأخضر للأعلى هي نقطة يجب الشراء عندها، والسهم الأحمر المتجه للأسفل هي نقطة يجب البيع عندها.


الزّمان (4) تابع لإيجاد نقاط مرجحة للبيع والشراء

```
def buy_sell(func_data):
    sigPriceBuy = np.array([], dtype='bool')
    sigPriceSell = np.array([], dtype='bool')

    #if you set a flag to true the program will run continuously untill an event makes it f
    flag = -1-

    for i in range(len(func_data)):
        if func_data['ShortSMA'][i] > func_data['LongSMA'][i]:
            if flag != 1:
                sigPriceBuy = np.append(sigPriceBuy, func_data['Close'][i])
                sigPriceSell = np.append(sigPriceSell, np.nan)
                flag = 1
            else:
                sigPriceBuy = np.append(sigPriceBuy, np.nan)
                sigPriceSell = np.append(sigPriceSell, np.nan)

        elif func_data['ShortSMA'][i] < func_data['LongSMA'][i]:
            if flag != 0:
                sigPriceBuy = np.append(sigPriceBuy, np.nan)
                sigPriceSell = np.append(sigPriceSell, func_data['Close'][i])
                flag = 0
            else:
                sigPriceBuy = np.append(sigPriceBuy, np.nan)
                sigPriceSell = np.append(sigPriceSell, np.nan)
        else:
            sigPriceBuy = np.append(sigPriceBuy, np.nan)
```



الشكل (33) تمثيل نقاط البيع والشراء بيانياً باستخدام مكتبة matplotlib

نستفيد من المتوسطات المتحركة بإضافتها على شكل أعمدة على إطار المعطيات الأصلي، ونضيف أيضاً إشارة للبيع وإشارة للشراء تعطي إحدى القيمتين، ليس رقم (NaN) Not A Number، أو واحد عند وجود إشارة، ويمكن استبدال قيم NaN بصفر. كما أن توليد المتوسطات المتحركة يؤدي إلى فقدان أول 100 قيمة من الأسطر، وهذا أمر سيء، نواجه هذا الأمر بطريقتين، الأولى يمكن اعتبار المتوسط المتحرك لأول 100 يوم هو نفسه سعر الإغلاق، إلا أن هذا الحل غير مرغوب فيه خصوصاً عندما يكون لدينا كمية كبيرة من المعطيات فيمكننا على سبيل المثال، حذف 100 سطر مقارنة بـ 90 ألف سطر، دون أن نكون استغنيين عن معطيات ذات أهمية كبيرة.

الجدول (20) المتوسطات المتحركة وإشارات البيع والشراء باستخدام Pandas

	ShortSMA	LongSMA	Close	sigPriceBuy	sigPriceSell
0	NaN	NaN	40826.214386	NaN	NaN
1	NaN	NaN	39716.954226	NaN	NaN
2	NaN	NaN	40424.483293	NaN	NaN
3	NaN	NaN	40553.463272	NaN	NaN
4	NaN	NaN	39935.516999	NaN	NaN
...	...	...	...	...	...
1533	9905.190755	8882.149316	6955.270020	NaN	NaN
1534	9821.761068	8879.815615	8277.009766	NaN	NaN
1535	9741.814746	8884.396816	9174.910156	NaN	NaN
1536	9652.419759	8885.464912	8830.750000	NaN	NaN
1537	9575.114421	8892.121416	9170.540039	NaN	NaN

2.2.3.4 مؤشر القوة النسبية RSI

نستخدم مؤشر القوة النسبية وهو مؤشر شائع الاستخدام يتراوح ما بين (0 و 100) يحسب رياضياً من خلال نسبة متوسطات التغيرات الإيجابية إلى التغيرات السلبية، نستفيد من مكتبة pandas_ta حيث تساعدنا بحساب هذا المؤشر دون بناء معادلاتها من الصفر، تفسير هذا المؤشر أنه يدل المستخدم على إذا ما كان السهم يباع بشكل مجحف عندما تكون قيمة هذا المؤشر أقل من 30، وهذا ما يدل على أنه وقت مناسب للشراء فعادة ما تتدخل آليات السوق لتعدل الانحرافات وترجع لأوضاع توازنية، (أي انقلاب اتجاه إيجابي)، أما عندما يصل المؤشر لأعلى من 70، فهذا يدل المستخدم على أن السهم أو العملة تتم شراؤها بشكل مجحف، وبالتالي يفضل البيع في هذه الحال (مؤشر لانقلاب اتجاه سلبي). نعرض في هذه الفقرة طريقة التمثيل البياني والبرمجة التي تحسبها وتمثلها بيانياً للمستخدم.

الرمز (5) استخراج وتمثيل مؤشر القوة النسبية بيانياً

```
import pandas_ta as ta

df = pd.read_csv('BTC.csv', header=0)

# Calculate the RSI via pandas_ta
df.ta.rsi(close='Close', append=True)
df.dropna(inplace=True)


# View the result
print(df)
plt.style.use('fivethirtyeight')

ax1 = plt.subplot2grid((10,1), (0,0), rowspan = 4, colspan = 1)
ax2 = plt.subplot2grid((10,1), (0,0), rowspan = 4, colspan = 1)

plt.title('Bitcoin closing price')
ax1.plot(df["Close"], linewidth=2)
plt.show()

plt.title('Relative Strength Index')

ax2.plot(df['RSI_14'], color = 'orange', linewidth=1)
ax2.axhline(30, linestyle = '--', linewidth = 1.5, color = 'green')
ax2.axhline(70, linestyle = '--', linewidth = 1.5, color = 'red')
plt.show()
```



الشكل (34) تمثيل مؤشر القوة النسبية بيانياً باستخدام مكتبة matplotlib

كما نرى من خلال الشكل أعلاه أنه عندما يصل المؤشر للقيم الحدية فإنه يعدل نفسه لذلك تعتبر هذه النقاط مثيرة للاهتمام للمستثمر.

3.2.3.4 المتوسط المتحرك المتسارع EMA

من المنطقي أن تأثير الأحداث القريبة من السعر الآني أكبر على سعر الفترة الزمنية القادمة من الأسعار القديمة، وهذا ما دفع المحللين الماليين لاستعمال معادلات جديدة، تعطي أهمية وبالتالي أوزان أكبر للأسعار القريبة وأهمية أو أوزان أقل للأسعار الأقدم، ومن هنا أتت فكرة المتوسط المتحرك المتسارع. في نموذجنا المقترح لا نستخدم هذا المتوسط في قواعد المعرفة لصعوبة صياغة قواعد لها، إلا أنها آفاق مستقبلية للنموذج المقترح، إلا أن لها استخدام مناسب في الشبكة العصبونية. الأمر الذي يجعل استخدام المتوسط المتحرك المتسارع أمر سهل في النموذج وجود مكتبة pandas_ta التي تقوم بحساب هذا المؤشر دون الضرورة لإدخال المعادلة كمتغيرات يدوية في البرمجة، ونقوم بحسابها لمدة 10 أيام متحركة عبر الزمن من خلال الرّماز التالي.

```
df.ta.ema(close='Close', low='Low', high='High', append=True)
```

حيث أن المعادلة تتطلب السعر الأعلى والأدنى والإغلاق، ونضيف هذا المتغير على قاعدة معطياتنا على شكل عمود جديد.

4.2.3.4 مؤشر الزخم ADX

من العوامل التي يجب أن يأخذها كل خبير مالي بعين الاعتبار هو زخم السوق، أي إذا كان الهبوط أو الصعود حاد، ويمكن تقدير هذه المعلومة من الخبير بمجرد نظرة على الخط البياني ويمكنه رسم خطوط باستخدام الأدوات والبرامج الماليّة لتقدير الميل رياضياً، إلا أن النظام الخبير يتعامل مع دخل على شكل اسطر وأعمدة من معطيات مهيكلة فهو غير مصمم على قراءة الصور أو فهمها. لحل هذه المشكلة نقترح مؤشر ADX الذي يحول الزخم إلى متغير كمي يمكننا الاستفادة منه.

يتوافق مع مؤشر ADX الذي يحدد قوة الزخم مؤشران آخران تابعان له هما: مؤشر الاتجاه السلبي DMN ومؤشر الاتجاه الإيجابي DMP من مؤشرات الزخم. يساعد مؤشر ADX المستثمرين على تحديد قوة الاتجاه، بينما يساعد DMN و DMP في تحديد اتجاه الاتجاه. يحدد مؤشر ADX اتجاهًا قويًا عندما يزيد عن 25 واتجاهًا ضعيفًا عندما يكون أقل من 20.

يمكن استخدام عمليات الانتقال لخطوط DMP و DMN لتوليد إشارات تداول. على سبيل المثال، إذا تجاوز خط DMP فوق خط DMN وكان مؤشر ADX أعلى من 20، أو من الناحية المثلثية أعلى من 25، فهذه إشارة محتملة للشراء. من ناحية أخرى، إذا تقاطع DMN فوق DMP، وكان مؤشر ADX أعلى من 20 أو 25، فهذه فرصة للدخول في صفقة بيع محتملة.

يمكن أيضاً استخدام التقاطعات للخروج من التداولات الحالية، على سبيل المثال، إذا كان الشراء طويلاً، فيجب الخروج عندما يتقاطع DMN فوق DMP. في هذه الأثناء، عندما يكون مؤشر ADX أقل من 20، يشير المؤشر إلى أن السعر عديم الاتجاه وأنه قد لا يكون الوقت المثالي للدخول في صفقة أي أنه يوجد عوامل عدم تأكد عالية. نصيغ هذه المعرفة على شكل صيغ رياضية ثم برمجية عند الوصول لمرحلة بناء النظام الخبير، نستخدم مكتبة pandas_ta للقيام بحساب هذا المؤشر، ومثل المتوسطات المتحركة نحسبه لأول 14 يوم، ثم يتم إلحاقه بالمعطيات. نعرض الآن الجدول الذي نريد إلحاقه لاحقاً بقاعدة المعطيات.

الجدول (21) إطار معطيات مؤشر الزخم باستخدام Pandas

ADX_14	DMP_14	DMN_14
NaN	NaN	NaN
NaN	NaN	NaN
NaN	NaN	NaN
NaN	NaN	NaN
NaN	NaN	NaN
...	...	...
23.829068	12.477332	26.347246
23.239351	16.505829	22.595012
22.563317	15.914357	20.999150
22.389343	14.614832	21.980655
20.798466	20.041412	20.088386

3.3.4. دمج أطر المعطيات

ندمج أطر المعطيات التي استخرجناها من مصادر متنوعة، ضمن إطار واحد وكل سطر من هذا الإطار يشكل دخل ليوم واحد، ندمج جميع أطر المعطيات التي جمعناها في إطار واحد يغذي النموذجين، ويجب تنويه أن الدخل الذي تأخذه الشبكة العصبونية من إطار المعطيات هو عبارة عن سلسلة أطول من دخل النظام الخبير، فمثلاً نقترح أن يكون دخل النظام الخبير هو 3 أيام (فترات زمنية) معاً وذلك لأن أطول نمط تأخذه بغض النظر عن تعقيد مكوناته هو 3 أيام، أما للشبكة العصبونية نقترح أن يكون أصغر دخل لها سلسلة من 128 يوم وهو خيار تصميمي بحت. نناقش لاحقاً معالجة إضافية لإطار المعطيات الأولي ليصبح دخلاً مناسباً للشبكة، إلا أننا نعرض في هذه الفقرة شكل إطار المعطيات الذي قمنا ببنائه بحالة عملية لمعطيات شركة IBM.

الجدول (22) إطار المعطيات بعد تجميعه باستخدام Pandas

Date	Open	High	Low	Close	Adj Close	Volume	ShortSMA	LongSMA	RSI_14	ADX_14	DMP_14	DMN_14	EMA_10
5/24/1962	5.293180	5.430210	5.073295	5.073295	1.178776	4346130	6.051307	6.681708	20.066658	47.722365	8.689008	48.612169	5.569903
5/25/1962	5.073295	5.188018	4.945825	5.079669	1.180257	4503030	6.003718	6.658955	20.425143	49.485980	7.852992	48.998898	5.480770
5/28/1962	5.060548	5.060548	4.525175	4.601657	1.069191	4518720	5.937009	6.632154	14.994167	51.598395	6.347251	54.149648	5.320931
5/29/1962	4.659018	4.933078	4.659018	4.882091	1.134350	4040175	5.879860	6.609592	27.220553	53.559495	5.649940	48.200748	5.241142
5/31/1962	4.971319	5.098789	4.971319	5.003187	1.162487	4322595	5.825685	6.589579	31.783275	54.112913	10.735080	44.739804	5.197877
...	...	...	...	...	...	...	...	...	...	...	...	...	...
5/18/2020	114.608032	116.978966	114.483749	116.214149	106.374672	4399162	115.574570	122.575239	52.100021	12.947491	26.370780	30.590160	114.760086
5/19/2020	115.860420	116.797325	114.856598	115.000000	105.263336	3390191	115.748884	122.434799	50.088327	12.551777	25.407598	29.472867	114.803707
5/20/2020	115.611855	117.084129	115.296364	116.042068	106.217171	4017372	115.954111	122.305449	51.808237	12.103920	24.935591	28.278371	115.028863
5/21/2020	115.669212	116.367111	113.738052	113.881454	104.239494	4184941	115.948693	122.151051	48.106757	12.074862	23.634326	29.895807	114.820243

بهذا نحصل على معطيات مضخمة، لها قدرة تفسيرية، يمكن الاستفادة منها لتوليد تقارير، ومطابقة القواعد ورسم الخطوط البيانية وتدريب الشبكة العصبونية.

4.4. بناء النظام الخبير

نريد في عملية بناء النظام الخبير القيام بنقل المعرفة أولاً من خبير في المجال، وهنا تأتي أهمية القواعد المصاغة مسبقاً من قبل خبراء فنستفيد من الصياغة الرياضية الموضوعية من قبل خبراء سابقين. سنمر في الفقرة القادمة على تفسير القواعد باللغة الطبيعية، إضافة لتمثيل بياني لوضعها على شكل شجرة قرار كبيرة، وكتابة صيغتها البرمجية بلغة Python، باستخدام مكتبة بناء النظم الخبيرة Experta. لكن أولاً نستعرض جدول بالرموز المستخدمة ومعانيها للشموع اليابانية:

الجدول (23) رموز مكونات الشموع اليابانية

الرمز	الدلالة باللغة الانكليزي	الدلالة باللغة العربية
LS t	lower shadow for time period t	الظل السفلي للفترة الزمنية
US t	upper shadow for time period t	الظل العلوي للفترة الزمنية
RB t	real body for time period t	الجسم الحقيقي للفترة الزمنية
O t	Opening price for time period t	سعر الافتتاح للفترة الزمنية
C t	Closing price for time period t	سعر الإغلاق للفترة الزمنية
H t	High price for time period t	السعر الأعلى للفترة الزمنية
L t	Low price for time period t	السعر الأدنى للفترة الزمنية

لبعض الأنماط أسماء مختلفة في المراجع، وهذا أمر قد يسبب اختلاط لبعض الأشخاص إلا أن منطق صياغة القواعد والأنماط هو حدسي إلى حد ما. نعرض في هذه الفقرة جدول طريقة صياغة بعض أشهر أنماط الشموع اليابانية بصيغة رياضية، بعد تقسيمها لأنماط مؤلفة من يوم واحد، يومين وثلاث أيام، كما يوجد معيار آخر للتقسيم، وهو إن كانت الأنماط صاعدة Bullish، أو هابطة Bearish.

الجدول (24) أنماط الشموع اليابانية بصيغة شبه رياضية بحسب (Morris, 2006)

اسم النمط	الصيغة الموافقة
Bullish 1 Day Patterns	
White Marubozu (WM)	$H_1 = C_1 > O_1 = L_1$
Closing White Marubozu (CWM)	$H_1 = C_1 > O_1 > L_1$
Opening White Marubozu (OWM)	$H_1 > C_1 > O_1 = L_1$
Long White Candle (LWC)	$H_1 > C_1 > O_1 > L_1$
Dragonfly Doji (DD)	$H_1 = C_1 = O_1 > L_1$
White Paper Umbrella (WPU)	$H_1 = C_1 > O_1 > L_1 \text{ \& } LS_1 > 2RB_1$
Black Paper Umbrella (BPU)	$H_1 = O_1 > C_1 > L_1 \text{ \& } LS_1 > 2RB_1$
Bullish 2 Day Patterns	
Homing Pigeon (HP)	$O_1 > O_2 > C_2 > C_1 \text{ \& } \text{Downtrend}$
Bullish Engulfing (Bulle)	$C_2 > O_1 > C_1 > O_2 \text{ \& } \text{Downtrend}$
Piercing Line (PL)	$O_1 > C_2 > L_1 > O_2 \text{ \& } C_2 > 0.5(O_1 + C_1) \text{ \& } \text{Downtrend}$
Bullish Harami (BullH)	$O_1 > C_2 > O_2 > C_1 \text{ \& } RB_1 > RB_2 \text{ \& } \text{Downtrend or}$ $C_1 > C_2 > O_2 > O_1 \text{ \& } RB_1 > RB_2 \text{ \& } \text{Downtrend}$
Bullish Kicking (BullK)	$C_2 > O_2 > O_1 > C_1 \text{ \& } \text{Downtrend}$
Bullish 3 Day Patterns	
Three White Soldiers (TWS)	$C_1 > O_1, C_2 > O_2, C_3 > O_3, C_3 > C_2 > C_1, C_1 > O_2 > O_1,$ $C_2 > O_3 > O_2 \text{ \& } \text{Downtrend}$
Three Inside Up (TIU)	$O_1 > C_1, O_1 \geq O_2 > C_1, O_1 > C_2 \geq C_1, C_3 > O_3, C_3 >$ $O_1 \text{ \& } \text{Downtrend}$
Three Outside Up (TOU)	$O_1 > C_1, C_2 \geq O_1 > C_1 \geq O_2, C_2 - O_2 > C_1 - O_1 , C_3 >$ $O_3, C_3 > C_2 \text{ \& } \text{Downtrend}$
Morning Star (MS)	$O_1 > C_1, O_2 - C_2 > 0, C_1 > C_2, C_1 > O_2, C_3 > O_3, C_3 >$ $0.5(O_1 + C_1) \text{ \& } \text{Downtrend}$
Bearish 1 Day Patterns	
Black Marubozu (BM)	$H_1 = O_1 > C_1 = L_1$
Closing Black Marubozu (CBM)	$H_1 > O_1 > C_1 = L_1$
Long Black Candle (LBC)	$H_1 > O_1 > C_1 > L_1$
Opening Black Marubozu (OBM)	$H_1 = O_1 > C_1 > L_1$
Gravestone Doji (GD)	$H_1 > O_1 = C_1 = L_1$
Black Shooting Star (BSS)	$H_1 > O_1 > C_1 = L_1 \text{ \& } US_1 > 2RB_1$
White Shooting Star (WSS)	$H_1 > C_1 > O_1 = L_1 \text{ \& } US_1 > 2RB_1$
Bearish 2 Day Patterns	
Descending Hawk (DH)	$C_1 > C_2 > O_2 > O_1 \text{ \& } \text{Uptrend}$
Bearish Engulfing (BearE)	$O_2 > C_1 > O_1 > C_2 \text{ \& } \text{Uptrend}$
Dark Cloud Cover (DCC)	$O_2 > H_1 > C_2 > O_1 \text{ \& } C_2 < 0.5(O_1 + C_1) \text{ \& } \text{Uptrend}$
Bearish Harami (BearH)	$C_1 > O_2 > C_2 > O_1 \text{ \& } RB_1 > RB_2 \text{ \& } \text{Uptrend or}$ $O_1 > O_2 > C_2 > C_1 \text{ \& } RB_1 > RB_2 \text{ \& } \text{Uptrend}$
Bearish Kicking (BearK)	$C_1 > O_1 > O_2 > C_2 \text{ \& } \text{Uptrend}$
Bearish 3 Day Patterns	
Three Black Crows (TBC)	$O_1 > C_1, O_2 > C_2, O_3 > C_3, C_1 > C_2 > C_3, O_1 >$ $O_2 > O_3, O_1 > O_2 > C_1, O_2 > O_3 > C_2 \text{ \& } \text{Uptrend}$
Three Inside Down (TID)	$C_1 > O_1, C_1 > O_2 \geq O_1, C_1 \geq C_2 > O_1, O_3 > C_3, O_1 >$ $C_3 \text{ \& } \text{Uptrend}$
Three Outside Down (TOD)	$C_1 > O_1, C_1 > O_2 \geq O_1, C_1 \geq C_2 > O_1, O_3 > C_3, C_3 >$ $O_1 \text{ \& } \text{Uptrend}$
Evening Star (ES)	$C_1 > O_1, O_2 - C_2 > 0, C_2 > C_1, O_2 > C_1, O_3 >$ $C_3, C_3 < 0.5(C_1 + O_1) \text{ \& } \text{Uptrend}$

إذا أردنا تفسير أحد الأنماط بشكل عشوائي وليكن نمط Bullish engulfing، فيمكن قراءة النمط بالشكل التالي:

نبدأ بوجود اتجاه عام هابط، ويكون أول شمعة هي شمعة هابطة أي أن سعر الإغلاق كان أقل من سعر الافتتاح إلا أن الشمعة ثنائية تكسر الاتجاه العام بما أنها شمعة صاعدة، وتغطي الشمعة السابقة بشكل كامل أي أن المشترون (الطلب) قد كانوا قادرين على كسر تفضيلات البائعين (العرض)، ويتوقع أن يرتفع السعر في الفترة القريبة جداً.

1.4.4 بناء صفوف للمعرفة

الفكرة من بناء الصفوف classes أنه يوجد صفوف مضمنة ضمن صفوف أخرى فيمكن تمثيلها كهيكلية شجرة تساعدنا لاحقاً في بناء قواعد المعرفة.

صف الشمعة Class Candle: نحتاج لمعلومات كل شمعة تدخل إلى النظام، لذلك نقترح جعلها صف يحتوي على قيم سعر الإغلاق، سعر الافتتاح، السعر الأعلى، السعر الأدنى، وأخيراً اليوم، كما نجعل جميع هذه القيم إلزامية الإدخال، (بالنسبة للأسعار تقبل الفواصل أي Float، وبالنسبة للأيام فأعداد طبيعية integer، فإذا حدث خطأ إدخال، يعالج النظام ذلك، ونكتب برمجية هذه الخطوة على الشكل التالي:

الرمز (6) بناء صف معرفة الشمعة

```
#initializing the class candle
class Candle(Fact):
    open_value = Field(float, mandatory=True)
    close_value = Field(float, mandatory=True)
    high_value = Field(float, mandatory=True)
    low_value = Field(float, mandatory=True)
    day = Field(int, mandatory=True)
```


صف المعلومات الإضافية Class Extra: نضع في هذا الصف جميع المعلومات الإضافية التي قمنا باستخراجها سابقاً والتي سنستفيد منها في بناء قواعد نعرض رماز هذه البرمجية على الشكل التالي:

الرمز (7) بناء صف معرفة المعلومات الإضافية

```
#initializing the class Extra
class Extra(Fact):
    RSI_14 = Field(float, mandatory=True)
    ShortSMA = Field(float, mandatory=True)
    LongSMA = Field(float, mandatory=True)
    sigPriceBuy = Field(int, mandatory=False)
    sigPriceSell = Field(int, mandatory=False)
    ADX_14 = Field(float, mandatory=True)
    DMP_14 = Field(float, mandatory=True)
    DMN_14 = Field(float, mandatory=True)
    Fear_and_Greed_Value = Field(str, mandatory=True)
    day = Field(int, mandatory=True)
```


صفوف الأنماط السعرية Class Price Patterns: يمكن القول عن هذا الصف أنه جذع شجرة القرار وتتفرع عنه أنواع الأنماط السعرية وهي أنماط هبوط Falling Patterns وأنماط صعود Rising Patterns وأنماط محايدة Neutral

Patterns وأنماط استمرار الاتجاه Trend Continuation وأنماط انعكاس الاتجاه Trend Reversal، التي بدورها تقسم إلى قوية أو ضعيفة بحسب صف المعلومات الإضافية class Extra. نستفيد من أدوات التمثيل البياني لسهولة قراءة هذه الصفوف فنحولها على شكل شجرة. نمثل الهيكلية العامة للشجرة بالشكل (35) أدناه، تحت كل فرع من هذه الشجرة توجد العديد من الأنماط المصاغة على شكل قواعد وسنتناولها في الفقرات اللاحقة، لرسم الشجرة الموسعة.



الشكل (35) الشكل العام لشجرة صفوف الأنماط

نستفيد من صفوف معرفة الأنماط لنعطي النصيحة الموافقة للمستخدم، وهي إما الشراء أو البيع أو البيع القوي أو البيع القوي أو عدم التأكد، ويمكن تمثيلها بيانياً بالشكل التالي:



الشكل (36) ربط صفوف مرعة الأنماط بالنصائح للمستخدم

نعرض أيضاً طريقة رماز بناء الصفوف لرؤية طريقة بناءها، فربط الصف بتابع Function يأخذ قيمتين self, value، لاستخدامها لاحقاً في محرك الاستدلال.

الرماز (8) بناء صفوف معرفة أنواع الأنماط

```
class PricePattern():
    pass

class FallingPattern(PricePattern):
    def __init__(self, value):
        self.pattern_value = value

    def __str__(self):
        return 'Falling'

class StrongFallingPattern(FallingPattern):
    def __init__(self, value):
        self.pattern_value = value

    def __str__(self):
        return 'Strong Falling'

class WeakFallingPattern(FallingPattern):
    def __init__(self, value):
        self.pattern_value = value

    def __str__(self):
        return 'Weak Falling'

class RisingPattern(PricePattern):
    def __init__(self, value):
        self.pattern_value = value
```

2.4.4 الأنماط المستخدمة في نموذجنا

نذكر في هذه الفقرة الأنماط التي استخدمناها في نموذجنا المقترح وتصنيف كل منها في صفه المناسب كما نضع لكل نمط قيمة موافقة له تدلنا بشكل نسبي على الأنماط الأكثر فعالية بالنسبة لبعضها البعض. يعبر الترميز أدناه على جميع الأنماط التي يتألف منها نظامنا الخبير المستخدم. القسم الأيسر من الترميز يعبر عن الأنماط البسيطة للشموع اليابانية، دون اللجوء إلى مؤشرات تقنية إضافية لتقوية التنبؤ، أما القسم الأيمن يعبر عن القواعد الأكثر تعقيداً باستخدام النمط الذي ميزناه في القسم الأيسر، ونضيف بعدها شروط إضافية على القاعدة نفسها ليعطينا تنبؤ أكثر موثوقية، فالأنماط في القسم الأيسر ستعطي المستخدم نصيحة بالبيع أو الشراء بكمية قليلة لعدم وجود دلائل كافية، أما الأنماط في القسم الأيمن ستعطي المستخدم نصيحة بالبيع أو الشراء بكمية أكبر لزيادة الثقة، ونحتاج في المرحلة القادمة لصياغة القواعد لكل نمط من الأنماط المذكورة.

الرمز (9) أسماء جميع الأنماط المستخدمة في النظام وتصنيفها

```
class Pattern(enum.Enum):
    Black = FallingPattern(value = 1)
    BigBlack = FallingPattern(value = 2)
    BearishShavenBottom = FallingPattern(value = 2)
    BullishShavenBottom = FallingPattern(value = 2)
    TweezerBottoms = FallingPattern(value = 2)
    ThreeBlackCrows = FallingPattern(value = 3)
    RisingWindow = FallingPattern(value = 3)

    White = RisingPattern(value = 1)
    BigWhite = RisingPattern(value = 2)
    BearishShavenHead = RisingPattern(value = 2)
    BullishShavenHead = RisingPattern(value = 2)
    TweezerTops = RisingPattern(value = 2)
    ThreeWhiteSoliders = RisingPattern(value = 3)

    Doji = NeutralPattern(value = 2)
    SpinningTop = NeutralPattern(value = 2)
    BullishDojiStar = NeutralPattern(value = 3)
    BearishDojiStar = NeutralPattern(value = 3)

    FallingWindow = TrendContinuationPattern(value = 3)
    SeparatingLine = TrendContinuationPattern(value = 3)
    BearFlag = TrendContinuationPattern(value = 5)
    BullFlag = TrendContinuationPattern(value = 5)

    BearHarami = TrendReversalPattern(value = 3)
    BullHarami = TrendReversalPattern(value = 3)
    Hammer = TrendReversalPattern(value = 3)
    HangingMan = TrendReversalPattern(value = 3)
    DarkCloud = TrendReversalPattern(value = 3)
    BullishEngulfing = TrendReversalPattern(value = 5)
    BearishEngulfing = TrendReversalPattern(value = 5)
    EvningStar = TrendReversalPattern(value = 5)
    MorningStar = TrendReversalPattern(value = 5)

    Black_and_falling_indicators = StrongFallingPattern(value = 2)
    BigBlack_and_falling_indicator = StrongFallingPattern(value = 3)
    BearishShavenBottom_and_falling_indicator = StrongFallingPattern(value = 3)
    BullishShavenBottom_and_falling_indicator = StrongFallingPattern(value = 3)
    TweezerBottoms_and_falling_indicator = StrongFallingPattern(value = 3)
    ThreeBlackCrows_and_falling_indicator = StrongFallingPattern(value = 4)
    RisingWindow_and_falling_indicator = StrongFallingPattern(value = 4)

    White_and_rising_indicators = StrongRisingPattern(value = 2)
    BigWhite_and_rising_indicators = StrongRisingPattern(value = 3)
    BearishShavenHead_and_rising_indicators = StrongRisingPattern(value = 3)
    BullishShavenHead_and_rising_indicators = StrongRisingPattern(value = 3)
    TweezerTops_and_rising_indicators = StrongRisingPattern(value = 3)
    ThreeWhiteSoliders_and_rising_indicators = StrongRisingPattern(value = 4)

    FallingWindow_and_falling_indicators = StrongTrendContinuationPattern(value = 4)
    SeparatingLine_and_falling_indicators = StrongTrendContinuationPattern(value = 4)
    BearFlag_and_falling_indicators = StrongTrendContinuationPattern(value = 7)
    BullFlag_and_falling_indicators = StrongTrendContinuationPattern(value = 7)

    BearHarami_and_falling_indicators = StrongTrendReversalPattern(value = 5)
    BullHarami_and_rising_indicators = StrongTrendReversalPattern(value = 5)
    Hammer_and_rising_indicators = StrongTrendReversalPattern(value = 5)
    HangingMan_and_falling_indicators = StrongTrendReversalPattern(value = 5)
    DarkCloud_and_falling_indicators = StrongTrendReversalPattern(value = 5)
    BullishEngulfing_and_rising_indicators = StrongTrendReversalPattern(value = 8)
    BearishEngulfing_and_falling_indicators = StrongTrendReversalPattern(value = 8)
    EvningStar_and_falling_indicators = StrongTrendReversalPattern(value = 8)
    MorningStar_and_rising_indicators = StrongTrendReversalPattern(value = 8)
```

3.4.4 بناء قاعدة المعرفة

نذكر في هذا القسم القواعد بشكل مختصر وتفسيرها وشكلها البياني وطريقة ترميز بعض هذه القواعد لن تذكر جميعها لحجمها الكبير إلا أنه يوجد جزء آخر في ملاحق البحث.

1.3.4.4 أنماط الهبوط وأنماط الهبوط القوية Falling & Strong Falling Patterns

نذكر في هذه الفقرة عن أنماط الهبوط وأنماط الهبوط القوية المستخدمة في قاعدة المعرفة للنظام الخبير. **Black**: هي عبارة عن شمعة سوداء (حمراء)، شرط تحقق هذه القاعدة أن يكون سعر الإغلاق أقل من سعر الافتتاح، يعتبر هذا النمط من أضعف الأنماط وذلك لأنه يعتمد على أن الشمعة القادمة ستكون أيضاً سوداء إلا أن هذا الادعاء غير قوي بعدم وجود دلالات أخرى لتقويته.

الرمز (10) نمط Black

```
@Rule(
    Candle(open_value = MATCH.open, close_value = MATCH.close, day = MATCH.day),
    TEST(lambda open, close: open > close)
)
def black_candle(self, day):
    self.declare(MatchedPattern(pattern = Pattern.Black, day = day))
    print("Black Candle in day", day)
```



الشكل (37) النمط Black

Big Black: هي عبارة عن شمعة سوداء إلا أن حجمها أكبر من ضعف متوسط حجم الشمعة العادية وبالتالي فإن هذا النمط أقوى من الشمعة السوداء العادية، وذلك لأن البائعين استطاعوا كسر نمط متوسط الشمعة السوداء العادية بمقدار الضعف.

الرمز (11) نمط Big Black

```
@Rule(
    MatchedPattern(pattern = Pattern.Black, day = MATCH.day),
    Options(average_black_candle_length = MATCH.avg_black_len),
    Candle(open_value = MATCH.open, close_value = MATCH.close, day = MATCH.day),
    TEST(lambda open, close, avg_black_len: (open - close) >= avg_black_len * 2)
)
def big_black_candle(self, day):
    self.declare(MatchedPattern(pattern = Pattern.BigBlack, day = day))
    print('Big Black Candle in day', day)
```



الشكل (38) النمط Big Black

Bearish Shaven Bottom: الفكرة من هذا النمط أن سعر إغلاق هذا اليوم هو نفسه أدنى سعر وصل له السهم، قد يعني هذا أن في هذا اليوم لم يستطع المشترون أن يكسروا رغبة البائعين بالبيع خلال كامل الفترة الزمنية مما أدى لأن يغلق السوق بنفس أدنى سعر وصل إليه. بالتالي فإن الشراء في هذا اليوم غير محبذ في حال عدم وجود مؤشرات أخرى وهذا لأن السعر قد يستمر بالهبوط إذا لم يستطع المشتريين بكسر هذا التفضيل.



الشكل (39) النمط Bearish Shaven Bottom

Bearish Shaven Head: هذه الشمعة هي شمعة سوداء، قد بدأ سعر اليوم بأعلى سعر قد توصل له ثم ظل يهبط تدريجياً مع انعكاس صغير حيث أن المشترين قد عدلو السعر قليلاً، إلا أن البائعين هم الذين غلبوا المشترين في نهاية المطاف، ويعتبر هذا النمط من الأنماط الضعيفة نسبياً إذا لم يرافقه مؤشرات أخرى.



الشكل (40) النمط Bearish Shaven Head

Tweezer Tops: هذا النمط مكون من شمعتين أي من فترتين زمنيتين، الأولى شمعة بيضاء (خضراء) صاعدة، لها سعر أعلى مختلف عن سعر الافتتاح (أي لها ظل أعلى)، ولا تملك ظل أسفل، والشمعة الثانية مماثلة للأولى إلا أنها شمعة هابطة، تفسر هذا النمط أن السوق أبدى رفض لأعلى سعر وصل له مرتين، مرة عند الشمعة الأولى ومرة عند الشمعة الهابطة، لذا يفضل البيع أو عدم الشراء في هذه المرحلة.



الشكل (41) النمط Tweezer Tops


Three Black Crows: هذا النمط مكون من 3 شموع يابانية هابطة، كل شمعة تكسر أدنى سعر وصل له السوق في الفترة الزمنية السابقة لها، لذلك يعتبر هذا النمط من الأنماط القوية بحد ذاتها إلا أنه يمكن تقويتها بمؤشرات أخرى مثل حجم التداول، كما يوجد وجهتي نظر بالنسبة لهذا النمط، فبعض الخبراء يعتبرونه من أنماط انعكاس الاتجاه، البعض الآخر يعتبره من أنماط الهبوط، إلا أن هذا أقل أهمية لأن النصيحة في جميع الأحوال هي أن يبيع متخذ القرار.



الشكل (42) النمط Three Black Crows

Strong Falling Patterns: النمط القوي الهابط، هو نمط قوي من الأنماط التي ذكرناها سابقاً، إلا أنه أقوى بأحد المؤشرات التقنية التي حسبناها أو أكثر، فمثلاً إذا كان مؤشر الخوف والجشع بدأ بالتناقص (حتى لو كانت قيمته

عالية) أو إذا قطع المتوسط المتحرك طويل الأجل، المتوسط المتحرك قصير الأجل Death Cross وبالتالي يعطي النظام $\text{sigpricesell} = 1$ أو إذا كان مؤشر الزخم ADX قد تخطى قيمة 25، وقيمة DMN أكبر من قيمة DMP، فهذا يعني أن السوق يتحول إلى نزخم هابط كبير، وبالتالي يكون النمط الهابط عبارة عن إشارة تأكيدية للمؤشرات التقنية الأخرى على أن السوق سيكمل بالهبوط.



الشكل (43) شرط تحول النمط الهابط إلى نمط هابط قوي

2.3.4.4 أنماط الصعود وأنماط الصعود القوية Rising & Strong Rising Patterns

نذكر في هذه الفقرة عن أنماط الصعود وأنماط الصعود القوية المستخدمة في قاعدة المعرفة للنظام الخبير. **White**: هي عبارة عن شمعة بيضاء (خضراء)، شرط تحقق هذه القاعدة أن يكون سعر الإغلاق أكبر من سعر الافتتاح، يعتبر هذا النمط من أضعف الأنماط وذلك لأنه يعتمد على أن الشمعة القادمة ستكون أيضاً بيضاء إلا أن هذا الادعاء غير قوي بعدم وجود دلالات أخرى لتقويته.



الشكل (44) النمط White

Big White: هي عبارة عن شمعة بيضاء، إلا أن حجمها أكبر من ضعف متوسط حجم الشمعة العادية وبالتالي فإن هذا النمط أقوى من الشمعة البيضاء العادية، وذلك لأن المشتريين استطاعوا كسر نمط متوسط الشمعة البيضاء العادية بمقدار الضعف.



الشكل (45) نمط Big White

Bullish Shaven Bottom: الفكرة من هذا النمط أن سعر الافتتاح، هو نفسه أدنى سعر وصل إليه سعر السهم في الفترة الزمنية، أي بمعنى آخر البائعون لم يستطيعوا أن يكسروا تقضيلات الشارين أو أن يخفضوا السعر بأي مقدار لصنع ظل سفلي للشمعة، بالتالي من المتوقع أن يظل المشتريين مسيطرين في الفترة الزمنية القادمة خصوصاً إذا كان هناك مؤشرات تقنية أخرى تؤكد من ذلك.



الشكل (46) نمط White Shaven Bottom

Bullish Shaven Head: هذا النمط يبدأ بسعر افتتاح معين وخلال الفترة الزمنية يمر السعر ببعض التقلبات فيغلب البائعون زخم الشارين لفترة معينة ليتشكل ظل سفلي للشمعة، إلا أنه سرعان ما يقوم المشتريين باكتساب زخم قوي يظل مستمراً حتى نهاية الفترة الزمنية فيغلق سعر اليوم مثلاً والمشتريين لم يتوقفوا عن الشراء وهذا ما يسبب عدم وجود ظل علوي للشمعة لذلك من المتوقع أن يرتفع السعر في الفترة الزمنية القادمة، ويمكن أن يكون هذا النمط أقوى بوجود مؤشرات أخرى تدعمه.



الشكل (47) نمط White Shaven Head

Tweezer Bottoms: هذا النمط مكون من شمعتين أي من فترتين زمنييتين، الأولى شمعة سوداء (حمراء) هابطة، لها ظل أسفل، ولا تملك ظل أعلى، والشمعة الثانية مماثلة للأولى إلا أنها شمعة صاعدة، تفسير هذا النمط أن السوق أبدى رفض لأدنى سعر وصل له مرتين على التوالي، مرة عند الشمعة الأولى الهابطة ومرة عند الشمعة الصاعدة، لذا يفضل الشراء في هذه المرحلة لأن السوق أبدى هذا الرفض لأدنى سعر بشكل متتالي.




الشكل (48) نمط White Shaven Head

Three White Soldiers: هذا النمط مكون من 3 شموع يابانية صاعدة، كل شمعة تكسر أعلى سعر وصل له السوق في الفترة الزمنية السابقة لها، لذلك يعتبر هذا النمط من الأنماط القوية بحد ذاتها إلا أنه يمكن تقويتها بمؤشرات أخرى مثل حجم التداول، كما يوجد وجهتي نظر بالنسبة لهذا النمط، فبعض الخبراء يعتبرونه من أنماط انعكاس الاتجاه، البعض الآخر يعتبره من أنماط الصعود، إلا أن هذا أقل أهمية لأن النصيحة في جميع الأحوال هي الشراء بالنسبة لمتخذ القرار.



الشكل (49) نمط Three White soldiers


Strong Rising Patterns: النمط القوي الصاعد، هو نمط قوي من الأنماط التي ذكرناها سابقاً، إلا أنه مقوى بأحد المؤشرات التقنية التي حسبناها أو أكثر، فمثلاً إذا كان مؤشر الخوف والجشع بدأ بالتزايد (حتى لو كانت قيمته الأساسية منخفضة) أو إذا قطع المتوسط المتحرك قصير الأجل، المتوسط المتحرك طويل الأجل Golden Cross وبالتالي يعطي النظام إشارة $\text{sigpriceBuy} = 1$ ، أو إذا كان مؤشر الزخم ADX قد تخطى قيمة 25، وقيمة DMN أكبر من قيمة DMN، فهذا يعني أن السوق يتحلى بزخم صاعد كبير، وبالتالي يكون النمط الهابط عبارة عن إشارة تأكيدية للمؤشرات التقنية الأخرى على أن السوق سيكمل بالصعود.



الشكل (50) شرط تحول النمط الصاعد إلى نمط صاعد قوي

3.3.4.4 أنماط عدم التأكد أو المحايدة Neutral Patterns

نذكر في هذه الفقرة عن أنماط عدم التأكد أو المحايدة المستخدمة في قاعدة المعرفة للنظام الخبير. **Doji**: لهذا النمط قدرة تفسيرية تختلف باختلاف السياق قبل هذا النمط، فهو يحدث عندما يغلق سعر اليوم بسعر قريب جداً من سعر الافتتاح أو نفس سعر الافتتاح ويكون الظل إما لأعلى أو لأسفل. عندما يكون الظل لأسفل يوجد عدم تأكد لكن النمط حيادي أقرب للصاعد حيث أن السعر بدأ عند نقطة معينة، والبائعون يطغون على المشترين، إلا أنه عند نقطة معينة انقلب الاتجاه، فقام المشترين بتعويض الاتجاه خلال باقي الفترة الزمنية حتى أغلق السوق بنفس سعر الافتتاح، فإذا ظل المشترين بنفس الزخم فإنه من المتوقع أن يرتفع السعر. أما عندما يكون الظل لأعلى يوجد عدم تأكد لكن النمط حيادي أقرب للهابط حيث أن السعر بدأ عند نقطة معينة، والمشترين يطغون على البائعين، إلا أنه عند نقطة معينة انقلب الاتجاه، فقام البائعون بتعويض الاتجاه خلال باقي الفترة الزمنية حتى أغلق السوق بنفس سعر الافتتاح، فإذا ظل البائعون بنفس الزخم فإنه من المتوقع أن ينخفض السعر. كما أن هذا النمط معتمد على السياق السابق فمثلاً قد يدل على انقلاب اتجاه سلبي إذا كان ما يسبقه سلسلة صاعدة زخمها جيد، وقد يدل على انقلاب اتجاه إيجابي إذا كان ما يسبقه سلسلة هابطة زخمها جيد. كما يوجد عدة عوامل مثل الزخم قد تساعد في تفسير هذا النمط مثل مؤشر الخوف والجشع، ومؤشر القوة النسبية، لذلك نقوم بعرض هذين المؤشرين مع هذا النمط ومع جميع الأنماط لإعطاء سياق مناسب بحسب الحالة.



الشكل (51) أنماط Doji

Spinning Top: سمي هذا النمط بهذا المسمى لأنه يشبه المغزل، وهو عبارة عن شمعة وحيدة صاعدة أو هابطة إلا أنها تتميز بجسم صغير وظل صغير أيضاً. هذا النمط بحد ذاته فعلاً يعبر عن عدم تأكد في السوق إلا أنه أداة جيدة عند دمجه مع مؤشرات الزخم، فمثلاً إذا كان هناك زخم إيجابي قبل هذا النمط، فهذا قد يكون إشارة لانقلاب الاتجاه، ويفضل البيع. أما إذا كان هناك زخم سلبي قبل هذا النمط، فهذا قد يكون إشارة لانقلاب الاتجاه، ويفضل الشراء.



الشكل (52) نمط Spinning Top

4.3.4.4 أنماط استمرار الاتجاه القوية والضعيفة Strong & Weak Trend Continuation Patterns

نذكر في هذه الفقرة عن أنماط استمرار الاتجاه الضعيفة والقوية المستخدمة في قاعدة المعرفة للنظام الخبير. **Falling window:** هو نمط يتميز بفجوة في السعر في اتجاه السعر الهابط، يحدث هذا النمط عندما يكون سعر افتتاح الشمعة الثانية أصغر من سعر إغلاق الشمعة الأولى تاركاً فجوة على الرسم البياني للسعر، ويعمل كنمط استمراري هبوطي. يحدث هذا النمط في كثير من الأحيان، ولكن كلما زاد النطاق الزمني Ticker، زاد صعوبة العثور على هذا النمط. بمجرد أن يبدأ الاتجاه، فإنه يميل إلى أن يظل مستمراً بحسب الخبراء وتكون النصيحة بالبيع أو عدم الشراء لأن البائعين قد افتتحوا السوق بسعر أقل من سعر إغلاق اليوم السابق، وهذا أمر غير مشجع، ويمكن تقوية هذا النمط بوجود اتجاه للخوف في مؤشر الخوف والجشع إضافةً لزخم أقرب للقوي باتجاه الأسفل.

Rising window: هو نمط يتميز بفجوة في السعر في اتجاه السعر الصاعد، يحدث هذا النمط عندما يكون سعر افتتاح الشمعة الثانية أكبر من سعر إغلاق الشمعة الأولى تاركاً فجوة على الرسم البياني للسعر، ويعمل كنمط استمراري صعودي. يحدث هذا النمط في كثير من الأحيان، ولكن كلما زاد النطاق الزمني Ticker، زاد صعوبة العثور على هذا النمط. بمجرد أن يبدأ الاتجاه، فإنه يميل إلى أن يظل مستمراً بحسب الخبراء وتكون النصيحة بالشراء لأن المشترين قد افتتحوا السوق بسعر أكبر من سعر إغلاق اليوم السابق، وهذا أمر مشجع، ويمكن تقوية هذا النمط بوجود اتجاه خفيف للجشع في مؤشر الخوف والجشع إضافةً لزخم أقرب للقوي باتجاه الأعلى.



الشكل (53) نمط Falling & Rising Window

Bearish Separating Line: في هذا النمط، تكون الشمعة الأولى بيضاء في اتجاه هابط، متبوعة بفتحة فجوة منخفضة في اليوم التالي. شمعة اليوم الثاني هي شمعة سوداء كبيرة، يكون سعر افتتاحها مساوياً لمستوى افتتاح اليوم السابق، ويغلق النمط عند سعر أدنى، يعتبر هذا النمط نادر الحدوث حيث أنه من النادر أن يفتتح السوق بعد شمعة صاعدة بسعر افتتاح اليوم السابق، إلا أنه إذا حدث هذا النمط في اتجاه هابط، فمن المرجح أن يستمر الاتجاه بالهبوط، أي أن البائعين يريدون البيع بقوة.


Bullish Separating Line: في هذا النمط، تكون الشمعة الأولى سوداء في اتجاه صاعد، متبوعة بفتحة فجوة منخفضة في اليوم التالي. شمعة اليوم الثاني هي شمعة بيضاء كبيرة، يكون سعر افتتاحها مساوياً لمستوى افتتاح اليوم السابق، ويغلق النمط عند سعر أعلى، يعتبر هذا النمط نادر الحدوث حيث أنه من النادر أن يفتتح السوق بعد شمعة هابطة بسعر افتتاح اليوم السابق، إلا أنه إذا حدث هذا النمط في اتجاه صاعد، فمن المرجح أن يستمر الاتجاه بالصعود، أي أن المشترون يريدون الشراء بقوة.



الشكل (54) نمط Bullish & Bearish separating line


Bear Flag: في هذا النمط، يكون الشرط الأساسي وجود زخم هابط قوي جداً، يحاول المشترون في هذا النمط كسر هذا الزخم القوي، وقد ينجحون في ذلك لعدة شموع (في حالتنا 3) إلا أن الزخم الهابط سيكمل بنفس المعدل، أي أن البائعون يكسرون هذه الفترة القصيرة من الصعود. من الضروري في هذا النمط أن ننتبه على مؤشر ADX والمؤشر التابع له DMN فيجب أن يكون أكبر من 25، ويمكن أن ننظر على مؤشر الخوف والجشع لتتأكد إذا كان أقرب للخوف والشكل التالي يوضح ذلك بشكل أفضل.

Bull Flag: في هذا النمط، يكون الشرط الأساسي وجود زخم صاعد قوي جداً، يحاول البائعون في هذا النمط كسر هذا الزخم القوي، وقد ينجحون في ذلك لعدة شموع (في حالتنا 3) إلا أن الزخم الصاعد سيكمل بنفس المعدل، أي أن المشترين يكسرون هذه الفترة القصيرة من الهبوط. من الضروري في هذا النمط أن ننتبه على مؤشر ADX والمؤشر التابع له DMP فيجب أن يكون أكبر من 25، ويمكن أن ننظر على مؤشر الخوف والجشع لتتأكد إذا كان أقرب للجشع والشكل التالي يوضح ذلك بشكل أفضل.



الشكل (55) Bear & Bull Flag

Strong trend continuation patterns: عندما نضيف لكل من الأنماط السابقة، مؤشرات أخرى لتقوية صحة النمط فيتحول لنمط قوي، إذا كان النمط الاستمراري صاعد فإن المؤشرات التي تقوي موقعه تقاطع المتوسط المتحرك قصير الأجل مع طويل الأجل يشكل Golden Cross إشارة للشراء $\text{sigpriceBuy} = 1$ ، ويمكن تأكيد الأنماط الصاعدة بمؤشر الزخم، كما يمكن أن يكون السوق بحالة زيادة جشع بمؤشر الخوف والجشع، والعكس صحيح بالنسبة للأنماط الاستمرارية الهابطة فقد نرى Death Cross، وبالتالي $\text{sigpricesell} = 1$ ، كما يكون الزخم قوي بالاتجاه السلبي، والسوق بحالة زيادة خوف في مؤشر الخوف والجشع.



الشكل (56) شروط تحويل نمط الاستمرار لنمط استمرار قوي

5.3.4.4 أنماط انعكاس الاتجاه القوية والضعيفة Strong & Weak Trend Reversal Patterns

يجب التنويه أن الخبراء يوجهون جزء كبير من اهتمامهم لأنماط الانعكاس، وذلك لأنها أكثر أنماط تولد ربح للمستثمر إذا تم تمييزها والاستفادة منها بطريقة صحيحة، لكن بالمقابل فإن هذه الأنماط هي الأكثر خطورة في حال عدم نجاح القرار.

Bear Harami: هو نمط مؤلف من شمعتين الأولى هي شمعة بيضاء كبيرة ويتبعها شمعة سوداء صغيرة إلا أن الشرط لتحقيق هذا النمط وليس غيره، هو أن أسعار الافتتاح والإغلاق للشمعة الثانية يجب أن تكون محتواة في الشمعة الأولى، كما أن أحد شروط تشكيل هذا النمط وجود زخم صاعد قبل الشمعة الأولى يشير إلى أن الأسعار قد تنعكس قريباً إلى الهبوط. يحدد حجم الشمعة الثانية فاعلية النمط، فكلما كانت الشمعة أصغر زادت فرصة

حدوث الانعكاس. يمكن تفسير هذا النمط على أن عند الشمعة الأولى الصاعدة، كان المشترون في أوج الجشع بسبب الزخم الصاعد القوي السابق، إلا أن سعر السهم كان مبالغ بتقديره أو حدثت تغيرات اقتصادية أو سياسية أو تصريح ما، زرع ثقة أصحاب المصلحة والشارين، فعند افتتاح الشمعة الثانية بدأ السعر من نقطة أدنى (ضمن الشمعة الأولى)، وبالنسبة أغلق السوق بسعر أدنى إلا أن كون الشمعة الثانية محتواة بالكامل ضمن الشمعة الأولى، أي أن هناك ظروف عدم تأكد عالية، ومن هنا يبدأ خوف المستثمرين لا سيما شديدي الحساسية، مما يكون إشارة أو دلالة على بدء انعكاس بالاتجاه.

Bullish Harami: هو نمط مؤلف من شمعتين الأولى هي شمعة سوداء كبيرة ويتبعها شمعة بيضاء صغيرة إلا أن الشرط لتحقيق هذا النمط وليس غيره، هو أن أسعار الافتتاح والإغلاق للشمعة الثانية يجب أن تكون محتواة في الشمعة الأولى، كما أن أحد شروط تشكيل هذا النمط وجود زخم هابط قبل الشمعة الأولى يشير إلى أن الأسعار قد تنعكس قريباً إلى الصعود. يحدد حجم الشمعة الثانية فاعلية النمط، فكلما كانت الشمعة أصغر زادت فرصة حدوث الانعكاس. يمكن تفسير هذا النمط على أن عند الشمعة الأولى الهابطة، كان البائعون في أوج الخوف بسبب الزخم الهابط القوي السابق، إلا أن السهم كان مسعر بأقل من قيمته (بحسب الأصول أو الأرباح أو سمعة الشركة) أو حدثت تغيرات اقتصادية أو سياسية أو تصريح ما، زادت من ثقة أصحاب المصلحة والشارين، فعند افتتاح الشمعة الثانية بدأ السعر من نقطة أدنى (ضمن الشمعة الأولى)، وبالنسبة أغلق السوق بسعر أعلى إلا أن كون الشمعة الثانية محتواة بالكامل ضمن الشمعة الأولى، أي أن هناك ظروف عدم تأكد عالية، ومن هنا يبدأ جشع المستثمرين لا سيما شديدي الحساسية للأخبار، مما يكون إشارة أو دلالة على بدء انعكاس بالاتجاه.




الشكل (57) نمط Bull & Bear Harami

Hammer: نمط لفترة واحدة، سمي بهذا الاسم لأنه يشبه المطرقة، تبدأ الفترة الزمنية بسعر افتتاح معين ثم ينخفض السعر، ليصل إلى سعر منخفض جداً، إلا أن المشترون يغيرون مجرى الأحداث فيقومون بالشراء ليصل سعر السهم إلى سعر أعلى من سعر الافتتاح، ويغلق السهم بسعر أعلى من سعر الافتتاح، لتصبح شمعة بيضاء، في هذا النمط يشكل جسم الشمعة جزء ضئيل من الظل (أصغر من نصف الظل) وعادة ما يظهر بعد اتجاه هابط مما يجعله إشارة أن المشتريين قد بدأوا بالتشجع للشراء، وذلك لرفضهم أدنى سعر وصلت له الشمعة خلال الفترة الزمنية.


Hanging Man: في هذا النمط تبدأ الفترة الزمنية بسعر افتتاح معين ثم ينخفض السعر، ليصل إلى سعر منخفض جداً، إلا أن المشترون يغيرون مجرى الأحداث فيقومون بالشراء ليصل سعر السهم إلى سعر أفضل إلا أنه يظل

أدنى من سعر الافتتاح، ويغلق سعر السهم بسعر أدنى من سعر الافتتاح، لتصبح شمعة سوداء، في هذا النمط يشكل جسم الشمعة جزء ضئيل من الظل (أصغر من نصف الظل) وعادة ما يظهر بعد اتجاه صاعد مما يجعله إشارة أن المشتريين قد بدأوا بالانسحاب من الشراء، وذلك لإظهارهم عدم تأكد وخوف بعد فترة زخم صاعد قبلها.



الشكل (58) نمط Hammer & Hanging Man


Dark Cloud : هو نمط انعكاسي هابط مكون من ثلاث شموع، حيث تكون الشمعة الأولى صاعدة أي بيضاء ثم الشمعة الثانية تكون هابطة (أي سوداء) لكنها تفتتح فوق سعر إغلاق الشمعة الأولى، ثم تغلق أسفل نقطة المنتصف للشمعة الصاعدة. يعتبر هذا النمط مهماً لأنه يظهر تحولاً في الزخم من الاتجاه الصاعد إلى الهابط، ويبحث المتداولون عن إشارة إضافية لتأكيد النمط في الشمعة التالية (الثالثة) فإذا كانت أيضاً شمعة هابطة فتعطي إشارة للتأكيد. يدفع المشترون السعر للأعلى عند الافتتاح، لكن البائعين يتولون زمام الأمور في وقت لاحق ويدفعون السعر هابطاً بجدّة. يشير هذا التحول من الشراء إلى البيع إلى أن انعكاس السعر في الاتجاه الهابط قد يكون وشيكاً. إلا أن معظم المتداولين يعتبرون أن نمط Dark Cloud مفيد فقط إذا حدث بعد اتجاه صعودي أو ارتفاع إجمالي في السعر. مع ارتفاع الأسعار، يصبح النمط أكثر أهمية للإشارة إلى تحرك محتمل في الاتجاه الهابط. أما إذا كانت حركة السعر متقلبة، فإن النمط يكون أقل أهمية حيث من المرجح أن يظل السعر متقلباً بعد النمط.



الشكل (59) نمط Dark Cloud

Bullish Doji Star: إذا أردنا تحليل هذا النمط فيمكن القول أنه حدسي، فإنه عبارة عن اتجاه عام هابط لفترة ما، وشمعة ندرسها لتمييز هذا النمط أو تأكيده، وهي شمعة Doji أي شمعة عدم تأكد، إلا أن هذه الشمعة لوحدها لا تعطينا دليل للقيام بأي تصرف، لذلك نحتاج لشمعة هابطة قبلها واتجاه عام هابط يسبقها، وتفسير هذا النمط أن البائعون كانوا متحكمين بسعر السهم لفترة زمنية ما إلا أن أحد العوامل قد تغير وأصبح السوق متردد بفترة الشمعة Doji مما يدل على أنه قد يحدث انقلاب اتجاه نحو الأعلى والنصيحة تكون بالشراء، وإذا أدخلنا في المنطق المستخدم مؤشرات مالية إضافية فيصبح النمط أكثر قوة.

Bearish Doji Star: إذا أردنا تحليل هذا النمط فيمكن القول أنه حدسي، فإنه عبارة عن اتجاه عام صاعد لفترة ما، وشمعة ندرسها لتمييز هذا النمط أو تأكيده، وهي شمعة Doji أي شمعة عدم تأكد، إلا أن هذه الشمعة لوحدها لا تعطينا دليل للقيام بأي تصرف، لذلك نحتاج لشمعة صاعدة قبلها أو اتجاه عام صاعد يسبقها، وتفسير هذا النمط أن المشترون كانوا متحكمين بسعر السهم لفترة زمنية ما، إلا أن أحد العوامل قد تغير وأصبح السوق متردد بفترة الشمعة Doji مما يدل على أنه قد يحدث انقلاب اتجاه نحو الأسفل والنصيحة تكون بالبيع، وإذا أدخلنا في المنطق المستخدم مؤشرات مالية إضافية فيصبح النمط أكثر قوة.



الشكل (60) نمطا Bearish & Bullish Doji Star

Bearish Engulfing: هذا النمط مكون من شمعتين، الشمعة الأولى هي شمعة صاعدة (بيضاء)، والشمعة الثانية هابطة (سوداء)، تتميز الشمعة الثانية بأنها تغطي أو تبتلع كامل حجم الشمعة الأولى، وبالتالي فإن البائعون قد كسرو تفضيلات المشترين بشكل حتمي في هذه الفترة وتكون هنا الإشارة على انقلاب الاتجاه، لا سيما إذا كان الاتجاه الذي يسبق النمط هو اتجاه صاعد.

Bullish Engulfing: هذا النمط مكون من شمعتين، الشمعة الأولى هي شمعة هابطة (سوداء)، والشمعة الثانية صاعدة (بيضاء)، تتميز الشمعة الثانية بأنها تغطي أو تبتلع كامل حجم الشمعة الأولى، وبالتالي فإن المشترين قد كسرو تفضيلات البائعين بشكل حتمي في هذه الفترة وتكون هنا الإشارة على انقلاب الاتجاه، لا سيما إذا كان الاتجاه الذي يسبق النمط هو اتجاه هابط.




الشكل (61) نمطا Bearish & Bullish engulfing

Evening Star: يتكون هذا النمط من 3 شموع، الشمعة الأولى هي شمعة صاعدة، أو شمعة صاعدة كبيرة، الشمعة الثانية هي شمعة عدم تأكد صغيرة، قد تكون Doji أو Spinning Top أو شمعة صغيرة تدلنا على أنه سيحدث تغير، والشمعة الثالثة هي شمعة تأكيدية هابطة، حيث أن تفسير هذا النمط يكون على الشكل التالي في


البداية يكون المشترون هم المتحكمين بالسوق من ناحية السعر والزخم، ثم تتغير مشاعر السوق عند حلول الشمعة الثانية فيظهر اضطراب أو عدم تأكد في هذه الفترة، لتقوم الشمعة الثالثة بتأكيد قرار مشاعر السوق النهائية بالنسبة للتغير السعري، والقرار في هذا النمط هو البيع، أي أنه من الأفضل لأصحاب القرار التريث بالشراء أو البيع إذا كان المستثمر يحتفظ بأسهم من هذا النوع. كما يعتبر هذا النمط من الأنماط القوية.

Morning Star: يتكون هذا النمط من 3 شموع، الشمعة الأولى هي شمعة هابطة، أو شمعة هابطة كبيرة، الشمعة الثانية هي شمعة عدم تأكد صغيرة، قد تكون Doji أو Spinning Top أو شمعة صغيرة تدلنا على أنه سيحدث تغير، والشمعة الثالثة هي شمعة تأكيد صاعدة، حيث أن تفسير هذا النمط يكون على الشكل التالي في البداية يكون البائعون هم المتحكمين بالسوق من ناحية السعر والزخم، ثم تتغير مشاعر السوق عند حلول الشمعة الثانية فيظهر اضطراب أو عدم تأكد في هذه الفترة، لتقوم الشمعة الثالثة بتأكيد قرار مشاعر السوق النهائية بالنسبة للتغير السعري، والقرار في هذا النمط هو الشراء، أي أنه من الأفضل لأصحاب الشراء أو عدم البيع إذا كان المستثمر يحتفظ بأسهم من هذا النوع. كما يعتبر هذا النمط من الأنماط القوية.



الشكل (62) نمطا Morning & Evening Star


Strong Reversal Patterns: يمكن إضافة مؤشرات إضافية لكل أنماط السابقة في هذه الفئة، فإذا أضفنا لأنماط الانعكاس مؤشرات الزخم السابقة لحدوثها، إضافة لكون السوق في حالة تزايد خوف في أنماط الانعكاس الهابطة، أو أن يكون مؤشر القوة النسبية ذو قيمة تقارب الـ 70، أي أن السهم يشتري بشكل مجحف، وبالعكس بالنسبة لأنماط الانعكاس الصاعدة فيكون مؤشر الزخم لصالح الهابط قبل النمط، ويبدأ مؤشر الخوف والجشع بالتحول نحو الجشع، كما يمكن أن يكون السهم لا يتم شراؤه بشكل عادل بمؤشر القوة النسبية وقيمته تقارب الـ 30. نختتم هذه الفقرة بأن هذه الأنماط تعطينا مؤشرات أكبر للشراء والبيع والأرباح والخسائر عند هذه الأنماط هي مضاعفة لذلك نعتبرها نقاط ضرورية للدراسة، إلا أنها أندر تكراراً، خصوصاً الأنماط المعقدة القوية.



الشكل (63) شروط تحويل أنماط الانعكاس لأنماط انعكاس قوية

4.4.4 هيكلية شجرة قرار النموذج

نضع في صف الأنماط السعيرية، الصفوف الدنيا التي شرحناها في الفقرات السابقة، وهي 5 أنماط رئيسية (أنماط الهبوط، أنماط الصعود، أنماط عدم التأكد، أنماط استمرار النمط، أنماط انقلاب الاتجاه)، في كل نمط نميز أنماط شموع يابانية مختلفة مقسمة لمجموعاتها الموافقة، بعد تمييز النمط نتأكد من بضعة شروط إضافية على شكل قواعد if-then rules، نضع النمط في صفه المناسب، ونظهر للمستخدم النهائي، النصيحة الموافقة وهي تأخذ واحدة من هذه القيم (Buy, Big Buy, Sell, Big Sell, indecisiveness) وذلك بالتوافق مع القواعد المحققة، ويظهر للمستخدم التقرير الموافق للنمط المحقق (وهو شرح النمط الذي ذكرناه في الفقرة السابقة)، إضافة للرسوم البيانية التي قمنا بتوليدها بحسب المعطيات المدخلة للنموذج، إلا أن هذه الإضافات غير متعلقة بقاعدة المعرفة لذلك لا نقوم بإضافتها لشجرة القرار. يمكن القول أن شجرة المعرفة هي من أفضل طرق تمثيلها، خصوصاً بعدم وجود العديد من الأوراق، وذلك لقدرتها التعبيرية العالية، فلا يحتاج القارئ خبرة اختصاصية لقراءة وفهم شجرة المعرفة، على عكس القواعد المعرفية التي تصاغ بطريقة رياضية أو بلغة الترميز، حتى إذا أردنا كتابة القواعد باللغات الطبيعية، مع أنها سهلة الفهم إلا أن القارئ يأخذ وقت كبير لفهم القاعدة وتخيّلها، لذا نلجأ للتمثيل البياني على شكل شجرة معرفة أو شجرة قرار. نعرض في هذه الفقرة شجرة المعرفة المقترحة للنموذج الأولي، بالاستفادة من خبراء في مجال المشكلة.



الشكل (64) مخطط شجرة المعرفة للنظام الخبير المقترح

5.4 بناء الشبكة العصبونية

في هذا القسم نعالج طريقة بناء الشبكة العصبونية المقترحة لنموذجنا، نبدأ أولاً بمعالجة المعطيات المحضرة مسبقاً لتصبح مناسبة كدخل للشبكة العصبونية لأن لها بعض الحدود بالنسبة لطبيعة المعطيات التي تقبلها كدخل بدون أن تسبب مشاكل بالتدريب، ثم نقوم ببناء الطبقة الأولى وهي طبقة التضمين الزمني، بعدها نقوم ببناء الطبقة الثانية وهي طبقة محولات الانتباه، التي تتضمن عدة طبقات ضمنية من أصل هندسة طبقة محولات الانتباه، وفي النهاية الطبقة الأخيرة وهي طبقة الخرج.

1.5.4 تحضير المعطيات Data Preparation

مع أننا قمنا بمعالجة المعطيات بشكل جيد في المراحل السابقة وتخلصنا من الأسطر ذات القيم الفارغة، إلا أننا بحاجة لتطبيع المعطيات واستخراج قيم تغييرها النسبي بالنسبة لبعضها البعض، بعد ذلك نقوم بتقسيم المعطيات المتاحة لدينا إلى معطيات تدريب ومعطيات اختبار ومعطيات تأكيد.

نقوم أولاً بتمثيل سعر الإغلاق وحجم التداول على شكل خط بياني وذلك لمقارنتها لاحقاً، بسعر الإغلاق والتداول الحقيقي، الذي هو هدف الشبكة العصبونية المستخدمة، يجب التذكير أن المعطيات المستخدمة هنا هي معطيات عملة بيتكوين الرقمية، كما أننا قمنا بتضخيمها ليتغير السعر كل ساعة بدلاً من كل يوم لنحصل على معطيات كافية لتدريب الشبكة، حيث أننا جربنا مسبقاً تدريبها على معطيات تتغير يومياً إلا أنها لم تكن كافية، فيمكن اعتبار هذه العملية، حلاً لمشكلة عدم كفاية المعطيات، دون المساس بخصوصية المعطيات نعرض في الشكل (65) أدناه التمثيل البياني لتغير سعر الإغلاق عبر الزمن إضافة لحجم التداول.



الشكل (65) سعر إغلاق وحجم تداول عملة بيتكوين الرقمية باستخدام مكتبة matplotlib

الخطوة التالية هي إيجاد التغيرات المئوية لقيم خلايا إطار المعطيات الذي قمنا بتجهيزه، وتعطينا هذه العملية قيم على شكل نسب مئوية للأعلى وللأسفل بحسب اتجاه التغير، نستفيد من خاصية مكتبة pandas، حيث تحسب التغيرات المئوية دون الحاجة للقيام بكتابة المعادلات الرياضية الموافقة لذلك بلغة برمجية، كما نقوم بحذف أي أسطر تحتوي على قيم غير رقمية التي قد تظهر لأحد الأسباب. نعرض الرّماز الذي يقوم بذلك على الشكل التالي:

الرّماز (12) حساب التغير بالنسبة المئوية لإطار المعطيات

```
#Calculate percentage change

df['Open'] = df['Open'].pct_change()
df['High'] = df['High'].pct_change()
df['Low'] = df['Low'].pct_change()
df['Close'] = df['Close'].pct_change()
df['Volume'] = df['Volume'].pct_change()
df['ShortSMA'] = df['ShortSMA'].pct_change()
df['LongSMA'] = df['LongSMA'].pct_change()
df['RSI_14'] = df['RSI_14'].pct_change()
df['ADX_14'] = df['ADX_14'].pct_change()
df['DMP_14'] = df['DMP_14'].pct_change()
df['DMN_14'] = df['DMN_14'].pct_change()
df['EMA_10'] = df['EMA_10'].pct_change()
df.dropna(how='any', axis=0, inplace=True) # Drop all rows with NaN values

df
```

فتعطي إطار معطيات جديد يمكن إظهاره على الشكل التالي:

الجدول (24) جدول يظهر تغير المعطيات بالنسبة المئوية باستخدام Pandas

	Time	Low	High	Open	Close	Volume	ShortSMA	LongSMA	RSI_14	ADX_14	DMP_14	DMN_14	EMA_10
100	1528974660	0.000332	0.000015	-0.000388	0.000739	-0.886556	0.000078	8.481641e-07	3.721193e-01	0.011487	-0.208382	-0.221406	0.000049
101	1528974720	0.000404	-0.000002	0.000402	-0.000002	-0.707311	0.000027	4.176847e-06	-6.223618e-04	0.010543	-0.000996	-0.000996	0.000040
102	1528974780	-0.000005	0.000000	-0.000002	-0.000006	1.016895	0.000027	1.639876e-05	-2.610252e-03	0.010703	-0.002140	0.002017	0.000032
103	1528974840	0.000000	0.000000	-0.000003	0.000005	2.590746	0.000027	1.644515e-05	1.566009e-03	0.009831	-0.002299	-0.002299	0.000027
104	1528974900	0.000005	0.001824	0.000003	0.001243	2.415443	0.000072	2.800416e-05	2.784007e-01	0.147377	1.087722	-0.422878	0.000248
...	...	...	...	...	...	...	...	...	...	...	...	...	...
97719	1535214960	0.000429	0.000022	0.000431	0.000022	-0.669713	-0.000005	-1.977386e-05	6.900603e-03	-0.067237	0.008684	-0.007282	0.000112
97720	1535215020	0.000052	0.000277	0.000298	0.000206	0.302330	0.000002	-1.772263e-05	6.214667e-02	-0.046270	0.104065	-0.088674	0.000129
97721	1535215080	0.000174	-0.000071	-0.000071	0.000000	0.019222	0.000002	-1.773819e-05	-1.110223e-16	-0.045050	-0.000526	-0.000526	0.000106
97722	1535215140	0.000002	0.000071	0.000000	0.000071	2.567295	0.000004	-1.702484e-05	2.111628e-02	-0.037849	0.025059	-0.025841	0.000099
97723	1535215200	0.000070	0.000000	0.000070	0.000000	-0.859125	0.000004	-7.434428e-06	-1.110223e-16	-0.036528	-0.000566	-0.000566	0.000081

الآن نقوم بتقسيم المعطيات بحسب المؤشر لتقسيمها بشكل فعلي في الخطوات اللاحقة، كما نقوم بتطبيع المعطيات التي لدينا بحسب معادلة Min Max scaling وهي على الشكل التالي:

$(\text{Max Value} - \text{Value}) / (\text{Max Value} - \text{Min Value})$ ، ويمكن الاستفادة من مكتبة tensorflow، للقيام بهذه

الخطوة، إلا أننا نقوم بها بشكل يدوي للاحتفاظ بالمعطيات على شكل إطار معطيات، وإلا فتعرض على شكل مصفوفات، وهو أمر لا يؤثر على عملية البرمجة إلا أننا نفضل إظهارها بهذه الطريقة لسهولة القراءة.

نعرض الآن مثال على تطبيع أحد الأعمدة، وبقيّة الأعمدة يمكن تطبيعها بنفس البرمجية ونغير فقط اسم العمود المراد تطبيعه. إضافة لذلك نعرض أيضاً طريقة فصل 10% من المعطيات للتأكد و10% من المعطيات للاختبار.

الرّماز (13) مثال على فصل معطيات الدخل إلى تدريب وتأكّد واختبار

```
'''Create indexes to split dataset'''

times = sorted(df.index.values)
last_10pct = sorted(df.index.values)[-int(0.1*len(times))] # Last 10% of series
last_20pct = sorted(df.index.values)[-int(0.2*len(times))] # Last 20% of series

min_EMA = df[(df.index < last_20pct)]['EMA_10'].min(axis=0)
max_EMA = df[(df.index < last_20pct)]['EMA_10'].max(axis=0)

df['EMA_10'] = (df['EMA_10'] - min_EMA) / (max_EMA - min_EMA)

'''Create training, validation and test split'''

df_train = df[(df.index < last_20pct)] # Training data are 80% of total data
df_val = df[(df.index >= last_20pct) & (df.index < last_10pct)]
df_test = df[(df.index >= last_10pct)]

# Remove date column
df_train.drop(columns=['Time'], inplace=True)
df_val.drop(columns=['Time'], inplace=True)
df_test.drop(columns=['Time'], inplace=True)

# Convert pandas columns into arrays
train_data = df_train.values
val_data = df_val.values
test_data = df_test.values
print('Training data shape: {}'.format(train_data.shape))
print('Validation data shape: {}'.format(val_data.shape))
print('Test data shape: {}'.format(test_data.shape))
```

عندها يمكن إظهار كمية المعطيات التي قسمناها للتدريب والتأكد والاختبار إضافة لشكل الدخل النهائي الذي سيدخل الشبكة العصبونية على الشكل التالي:

الجدول (26) دخل الشبكة العصبونية النهائي باستخدام Pandas

Training data shape: (78100, 12)
Validation data shape: (9762, 12)
Test data shape: (9762, 12)

	Low	High	Open	Close	Volume	ShortSMA	LongSMA	RSI_14	ADX_14	DMP_14	DMN_14	EMA_10
100	0.705977	0.702781	0.698698	0.710094	0.000013	0.503807	0.445826	0.005122	0.109647	0.000259	0.000521	0.620714
101	0.706709	0.702609	0.706693	0.702609	0.000033	0.494936	0.447631	0.003715	0.108398	0.000329	0.000670	0.620243
102	0.702577	0.702625	0.702609	0.702562	0.000228	0.494899	0.454257	0.003707	0.108609	0.000328	0.000672	0.619816
103	0.702625	0.702625	0.702593	0.702672	0.000407	0.494918	0.454283	0.003723	0.107457	0.000328	0.000669	0.619567
104	0.702672	0.721075	0.702656	0.715199	0.000387	0.502736	0.460550	0.004768	0.289347	0.000696	0.000384	0.630818

يمكننا تمثيل المعطيات المقسومة (سعر الإغلاق لأنه الذي نريد التنبؤ به) بعد تطبيعها على الشكل التالي:



الشكل (66) سعر الإغلاق المقسوم بعد تطبيعها باستخدام مكتبة matplotlib

نقسم المعطيات تقسيماً إضافياً على شكل سلاسل من 128 فترة زمنية، أي أن السلسلة الواحدة تتألف من 128 ساعة في حالتنا، ونجمع كل 32 سلسلة معاً على شكل حزمة Batch، تدخل على الشبكة العصبونية كدفعة واحدة، ونذكر أيضاً أن كل سطر من السلسلة يحوي على 12 واصفة Feature، وهي المعطيات الأساسية والمشقة التي قمنا بجلبها وحسابها. نقسم المعطيات بشكل نهائي على شكل حقب epochs، بحالتنا (35 حقة كخيار تصميمي). كما يمكن تعديل هذه الأرقام في المستقبل لمعرفة إذا يمكن تحسين أداء الشبكة.


2.5.4 طبقة التضمين الزمني Time Embedding Layer

طبيعة مسألتنا وكوننا نتعامل مع معطيات سلاسل زمنية، أي أنه يوجد تبعيات زمنية لكل نقطة في الزمن، لقبل النقطة المدروسة ولبعد النقطة المدروسة، ومن إحدى الطرق للتعبير عن هذه الفكرة هي تحويل كل نقطة في الزمن إلى متجه (مصفوفة أحادية البعد)، تمثل القيم في كل متجه، وموقع وأهمية كل نقطة بالنسبة للقيم التي تليها. يمكن اعتبار هذه الطبقة ذات أهمية كبيرة جداً بالنسبة لهيكلية الشبكة، وذلك لأن الطبقة التالية أي طبقة محول الانتباه ستتلقى عدد من السلاسل دفعة واحدة لتتم معالجتها بالتوازي، فإذا لم يكن هناك رابط يصل بين نقاط الزمن المتتالية فيمكن أن تعتبر الشبكة العصبونية أن حدث ما منذ 10 سنوات قد يكون له نفس التأثير على سعر الغد، مثل لو أنه حدث اليوم. لذا يمكن القول أن المحول يتميز بصفة عدم مبالاة لمفهوم الزمن، وطبقة التضمين الزمني هي فقط حل لهذه المشكلة، كما أثبت التضمين الزمني أهمية إدخاله حتى في النماذج التي تأخذ بعين الاعتبار التسلسل الزمني مثل LSTM فحسن الأداء بشكل ملحوظ، وتم تأكيد هذا في عدد من الأوراق البحثية. من أجل التغلب على اللامبالاة الزمنية لطبقة المحول، سننفذ نموذج Time2Vec، مضمون هذا النموذج أنه يجب مراعاة صفتين يتمتع بهما الزمن في السلاسل الزمنية، حيث أننا إذا أردنا أن نمثل الزمن تمثيلاً هادفاً فيجب أن يشمل هذا التمثيل، الأنماط الدورية والأنماط غير الدورية، فمثال على الأنماط الدورية أنه في كل فصل شتاء تزداد معدلات هطول الأمطار، فهذا نمط متكرر كل سنة، ومثال على النمط غير الدوري هو زيادة معدل فتك مرض الإنسان عند تقدمه بالسن. كما يجب أن يكون لتمثيل الوقت ثباتاً في إعادة قياس الوقت، مما يعني أن تمثيل الوقت لا يتأثر بزيادات

زمنية مختلفة، على سبيل المثال (أيام أو ساعات أو ثوان) وآفاق زمنية طويلة. سنشرح الآن بشكل مختصر التابعين الرياضييين اللذان يمثلان الطبيعتين الدورية وغير الدورية للزمن.


$$\mathbf{t2v}(\tau)[i] = \begin{cases} \omega_i \tau + \varphi_i, & \text{if } i = 0. \\ \mathcal{F}(\omega_i \tau + \varphi_i), & \text{if } 1 \leq i \leq k. \end{cases}$$

يتكون المتجه الزمني Time2Vec من مكونين الأول هو تابع خطي على الشكل $\mathbf{t2v}(\tau) = \omega_i \tau + \varphi_i$ حيث أن τ يمثل النقطة الزمنية المدروسة و ω_i تمثل مصفوفة الوزن weight التي تمثل ميل المستقيم الناتج من هذه الدالة. يمثل الشكل أدناه تمثيل ثنائي الأبعاد للتابع الذي يمثل الصفة غير الدورية لتمثيل الزمن.




الشكل (67) تمثيل الصفة غير الدورية للزمن بيانياً

بالنسبة للمكون الثاني يمثل الصفة الدورية للزمن، وهنا نستخدم نفس التابع المذكور أعلاه، إلا أن الفرق هو أنه مغلف ضمن تابع آخر F فيصبح الشكل العام $F(\omega_i \tau + \varphi_i)$ وتكون الدالة F هي إما دالة $\sin$ أو $\cos$ ، تم اختيار هذين التابعين من عدة توابع قد تم تجربتها سابقاً، إلا أفضل أداء كان لهذين التابعين، وهذا أمر حدسي إلى حد ما، وذلك لأننا إذا أردنا التقاط الأنماط الدورية للزمن فنحن بحاجة لتابع دوري أيضاً. يمثل الشكل أدناه تمثيل ثنائي الأبعاد للتابع الذي يمثل الصفة الدورية للزمن.



الشكل (68) تمثيل الصفة الدورية للزمن بيانياً

الآن يبقى علينا أن نمثل ذلك على شكل برمجية تساعدنا لبناء هذه الطبقة، نستخدم للقيام بذلك مكتبة Keras ونستعرض هنا شكل البرمجيّة التي تقوم بذلك.



الشكل (69) دمج التضمين الزمني مع معطيات النموذج

نعرض الآن الرّماز المستخدم لإضافة خصائص التضمين الزمني بطبيعته الدورية وغير الدورية.

الرّماز (14) بناء طبقة التضمين الزمني

```
class Time2Vector(Layer):
    def __init__(self, seq_len, **kwargs):
        super(Time2Vector, self).__init__()
        self.seq_len = seq_len

    def build(self, input_shape):
        '''Initialize weights and biases with shape (batch, seq_len)'''
        self.weights_linear = self.add_weight(name='weight_linear',
                                                shape=(int(self.seq_len),),
                                                initializer='uniform',
                                                trainable=True)

        self.bias_linear = self.add_weight(name='bias_linear',
                                              shape=(int(self.seq_len),),
                                              initializer='uniform',
                                              trainable=True)


        self.weights_periodic = self.add_weight(name='weight_periodic',
                                                  shape=(int(self.seq_len),),
                                                  initializer='uniform',
                                                  trainable=True)

        self.bias_periodic = self.add_weight(name='bias_periodic',
                                               shape=(int(self.seq_len),),
```

3.5.4 طبقة محول الانتباه Attention Transformer Layer

المحولات هي بنية شبكة عصبونية تستخدم آلية الاهتمام الذاتي، مما يسمح للنموذج بالتركيز على الأجزاء ذات الصلة من السلسلة الزمنية لتحسين صفات التنبؤ. تتكون آلية الانتباه الذاتي من طبقة انتباه أحادية الرأس، وتعدد رؤوس الانتباه. آلية الانتباه الذاتي قادرة على ربط جميع خطوات السلاسل الزمنية مع بعضها البعض في وقت واحد، مما يؤدي إلى خلق تفاهات تبعية طويلة المدى. أخيراً، تتم موازنة كل هذه العمليات داخل بنية المحولات مما يسمح بتسريع عملية التعلم.

نبدأ بطبقة الانتباه أحادية الرأس، فتشكل المعطيات ذات ال 12 واصفة التي استخرجناها سابقاً بالإضافة إلى الصفات الزمنية التي حسبناها للتو المدخلات الأولية لطبقة الانتباه أحادية الرأس الأولى فيصبح الدخل ال 14 واصفة لطبقة الانتباه أحادية الرأس. تأخذ طبقة الانتباه أحادية الرأس 3 مدخلات: استعلام، مفتاح، قيمة (Query, Key, Value). بالنسبة لحالتنا، يمثل كل إدخال استعلام ومفتاح وقيمة ال 14 واصفة المستخرجة. يتلقى كل إدخال استعلام ومفتاح وقيمة تحويلًا خطيًا منفصلاً عن طريق المرور عبر طبقات كثيفة فردية. كل طبقة فردية تحتوي على 96 عقدة ناتجة بحالتنا، وهو أيضاً خيار تصميمي، يمكن تعديله مستقبلاً لمقارنة النتائج.



الشكل (70) تمثيل بياني لمصفوفات الانتباه أحادية الرأس

بعد التحول الخطي الأولي، سنقوم بحساب درجة الانتباه (بمعنى آخر الأوزان). تحدد أوزان الانتباه مقدار التركيز الذي يتم التركيز عليه على خطوات السلاسل الزمنية الفردية عند توقع سعر سهم في المستقبل. يتم حساب أوزان الانتباه عن طريق أخذ ضرب مصفوفة الاستعلام Query المحول خطيًا ومصفوفة المفتاح Key، إلا أننا نضطر قبل الضرب، لأخذ مقلوب المصفوفة لأحد المصفوفتين ليصبح شرط ضرب المصفوفات محققاً (عدد أسطر المصفوفة الأولى يساوي عدد أعمدة المصفوفة الثانية). ثم يتم قسمة المنتج النقطي على حجم أبعاد الطبقات الكثيفة السابقة (96)، لتجنب انفجار الأوزان (وهو مصطلح يعبر عن زيادة الأوزان بشكل أسي فيصبح تعقيد المسألة كبير جداً مما يمنع تعلم الشبكة). ينتقل ناتج ضرب المصفوفتين المقسم بعد ذلك عبر دالة SoftMax لإنتاج مجموعة من الأوزان، مجموعها يساوي 1. كخطوة أخيرة، يتم ضرب مصفوفة SoftMax المحسوبة التي تحدد تركيز كل خطوة زمنية مع المصفوفة المحولة v التي تنتهي بالمصفوفة المفردة آلية الانتباه للرأس.


$$= \text{Softmax} \left(\frac{\begin{matrix} \mathbf{q} \\ (32, 128, 96) \end{matrix} \times \begin{matrix} \mathbf{k}^T \\ (32, 96, 128) \end{matrix}}{\sqrt{d_k}} \right) \times \begin{matrix} \mathbf{v} \\ (32, 128, 96) \end{matrix}$$

Attention weights

$$= \begin{matrix} (32, 128, 96) \end{matrix}$$

الشكل (71) تمثيل استخراج أوزان مصفوفة انتباه أحادية الرأس


لزيادة تحسين آلية الانتباه الذاتي، يقترح الباحثون مؤلفو بحث نموذج محولات الانتباه، تنفيذ الانتباه متعدد الرؤوس. وظيفة طبقة الانتباه متعددة الرؤوس هي ربط أوزان الانتباه لطبقات الانتباه أحادية الرأس ثم تطبيق تحويل غير خطي بطبقة كثيفة. يسمح الحصول على إخراج n من طبقات أحادية الرأس بتضمين عدة طبقات أحادية الرأس مستقلة في النموذج. فيصبح قادراً على التركيز على خطوات متسلسلة زمنية متعددة في وقت واحد، كما تؤثر زيادة عدد رؤوس الانتباه على قدرة النموذج على التقاط التبعية بعيدة المدى بشكل إيجابي. يوضح الرسم التوضيحي أدناه سلسلة من 3 طبقات أحادية الرأس.



الشكل (72) دمج 3 مصفوفات أوزان انتباه أحادية الرأس

يتم الآن تجميع آليات الانتباه الفردية والمتعددة (الانتباه الذاتي) في طبقة تضمين المحولات. تشمل كل طبقة تضمين على طبقة فرعية ذاتية الاهتمام وطبقة فرعية تلقائية. تتكون الطبقة الفرعية للتغذية الأمامية من طبقتين كثيفتين مع تابع تنشيط ReLU بينهما.

تتبع كل طبقة فرعية طبقة منبثقة بعد عملية التسرب dropout (وهو مصطلح يعبر عن عدم استخدام كل العصبونات في الطبقات بشكل عشوائي، أي أننا نسرب بعضها ولا نستخدمها، كعملية لتسهيل التعلم لتعميم النموذج وعدم الوقوع في إفراط ملائمة Overfitting)، ويتم تكوين اتصال متبقي عن طريق إضافة إدخال الاستعلام Query الأولي إلى مخرجات الطبقة الفرعية، ونهني كل طبقة فرعية بطبقة تطبيع Normalization توضع بعد إضافة التوصيل المتبقي لتثبيت وتسريع عملية التدريب. نمثل هيكليّة طبقة التضمين في الشكل (73) المعروض أدناه.



الشكل (73) الهيكلية المفصلة لطبقة التضمين encoder

إذا أردنا تلخيص كامل هذه العملية نقوم أولاً بتهيئة طبقة التضمين الزمني بالإضافة إلى 3 طبقات تشفير المحولات أحادية الرأس، ثم نجمعها في مصفوفة واحدة، ونقوم بتكديس طبقات الانحدار على طبقة المحولات الأخيرة، ثم نقوم بعملية التدريب.

5.4 دمج تنبؤ النموذجين

الآن بعد أن أعطى كل نموذج التنبؤ الخاص به، نحتاج إلى طريقة لدمج التنبؤين، نقترح خوارزميات من نمط ensemble، وهي مخصصة لدمج تنبؤ عدة نماذج ولها عدة أنماط مثل التصويت Voting والمتوسطات Averaging والمتوسطات المقتلة Weighted Averaging، والغابات العشوائية Random Forests والتكديس Stacking وغيرها. بما أننا نريد دمج نموذجين فقط وليس أكثر فإننا محكومين بعدد أقل من الطرق، نختار منها طريقة المتوسطات المقتلة Weighted Averaging، الفكرة من استخدام هذه الطريقة دون غيرها هي أنه يمكن الاستفادة من النموذج الذي يقوم بأفضل أداء، فنأخذ المتوسط الحسابي للتنبؤين (تنبؤ بالارتفاع وبالتالي قيمة 1، تنبؤ بالانخفاض وبالتالي قيمة 0) والتقليل يكون بحسب دقة كل نموذج، فمثلاً إذا بخصوصية السوق أو السهم x كان تنبؤ الشبكة 1 ودقة الشبكة 90% وتنبؤ النظام الخبير 1 ودقة النظام الخبير 60% فنقول أن الوزن المأخوذ 90%، فنقل النموذج الأكثر دقة بنسبة دقته مضافاً إليه نسبة الفرق بين دقتي النموذجين. بحسب مثالنا المطروح يصبح وزن النموذج ذو دقة 90% $[0.9 + (0.9 - 0.6)]$ أي أن وزن النموذج ذو دقة 60%، $[0.6 + (0.9 - 0.6)]$ ، ونحسب المتوسط الحسابي الموزن بالمعادلة التالية:

$$WA = \frac{\sum_{i=1}^n w_i X_i}{\sum_{i=1}^n w_i}$$

حيث أن WA المتوسط الحسابي المثلل للتنبؤ، n عدد تنبؤات النماذج (في حالتنا 2)، X القيم التي خرجت من النماذج، w الوزن المقترح لكل خرج. إذا أردنا مناقشة الحالات الممكنة، فإنه عندما يجتمع النموذجين على رأي، فلا يوجد لدينا مشكلة من الأصل ويمكن اعتماد النموذج ذو الدقة الأعلى كمعيار دقة، إلا أنه عندما يختلف النموذجان بالخرج، عندها يرجح النموذج الأكثر دقة بحسب نسبة تفوقه بالدقة، هذه العملية تقلل من دقة أو ثقة النموذج بالخرج إلا أن هذا مناسب تماماً بالنسبة للمستخدمين الذين يريدون تقليل مخاطراتهم بالاستثمارات، فيمكنهم القيام بقرارات تتناسب مع استراتيجيتهم، فإذا كان المستخدم يفضل الاستراتيجيات التي تتضمن مخاطرة فيمكنه الاعتماد على ثقة النموذج الأكثر دقة، أو إذا يريد تقليل المخاطرة للحد الأدنى يمكنه البيع عند تضارب النموذجين بالرأي بغض النظر عن الترجيح لصالح أي نموذج، والشراء عند اتفاق النموذجين بالرأي. كما نقترح عرض خرج كل نموذج على حدة بالإضافة للخرج بعد الدمج، عندها بإمكان المستخدم القيام بقرارات تتناسب مع استراتيجيته، كما أنه قد يصبح قادراً مع الخبرة على تمييز أخطاء النظام الخبير مثلاً، ونستفيد من ذلك كتغذية عكسية من المستخدم لتطوير النموذج، ويمكن قول نفس الشيء بالنسبة للشبكة العصبونية.


6.4 بناء مصفوفة القرار الموزنة وتقدير الأوزان بحسب طريقة AHP

الآن بعد أن أصبح لدينا خرج النموذج النهائي بالنسبة لسهم أو عملة ما، هنا يقوم المستخدم بالحالة الطبيعية بالبيع أو الشراء بحسب المعلومات التي قدمها له النموذج، إلا أنه في أغلب الأوقات يوجد عدة بدائل أو أسهم أو عملات

للاختيار منها، كما توجد عدة من المعايير لمساعدة المستخدم والتي قد تهمه عند تقارب تنبؤ تغيرات أسعار البدائل. هذه المعايير تختلف من مستخدم لآخر، حتى بالنسبة لنفس المستثمر لكن عندما يتغير السوق المدروس أو عند مقارنة بدائل ذات خصائص مختلفة فإن المعايير لا بد أن تختلف.

من وجهة نظر تصميمية، فيمكن القول أنه من المفضل أن تدخل معايير التي لا يمكن إدخالها على النظام الخبير أو على الشبكة العصبونية، وهي غالباً معايير لا يمكن جلب معطياتها بطريقة كمية، إلا أنه يمكن تقديرها بشكل نوعي أو كمي تقريبي، لذلك نقترح إضافة لمعيار التنبؤ وهو المعيار الأول معايير PEST، وهي اختصار للبيئة السياسية والاقتصادية والاجتماعية والتقنية، (PEST: Political, Economic, Social, Technological environment) حيث أن المستخدم بإمكانه تقييم كل بديل بحسب المعايير المذكورة، بحسب المعطيات والمعطيات المتاحة له، فمن الصعب تمثيل التطوير التكنولوجي أو البيئة الاجتماعية بشكل أوتوماتيكي بأرقام لتدخل في الخطوات السابقة، بل هي أرقام تقديرية، يضعها المستخدم بالاعتماد على قراءته للوضع العام من خلال المقالات ووسائل التواصل الاجتماعي وغيرها من مصادر المعرفة شديدة التغير والنقل، التي يصعب أتمتتها، إلا بأدوات معالجة اللغة الطبيعية NLP التي قد تكون من الآفاق المستقبلية لهذا النموذج.

تقدير الأوزان بحسب طريقة AHP: بعد أن حددنا المعايير المقترحة لنموذجنا (مع العلم أنها ديناميكية أي يمكن تغييرها بسهولة)، نقوم الآن بحساب الأوزان من خلال طريقة AHP يحتوي على ثلاثة أجزاء: الجزء الأول: الهدف النهائي أو المشكلة التي نحاول حلها، الجزء الثاني: كل الحلول الممكنة وتسمى بالبدايل، الجزء الثالث: والمعايير التي ستحكم على البدائل بناءً عليها. يوفر AHP إطاراً منطقياً للقرار المطلوب من خلال تحديد معايير وخياراته البديلة وربط هذه العناصر بالهدف العام. نعرض الآن الشكل البياني الذي يمثل استخدام AHP في حالتنا.



الشكل (74) تمثيل طريقة AHP بحالتنا

يقارن أصحاب المصلحة أهمية المعايير اثنان في كل مرة من خلال المقارنات بين الزوجين، على سبيل المثال في حالتنا أي معيار أهم، هل هو التنبؤ أم العوامل الاقتصادية الحالية وبكم هو أهم. يحول AHP هذه التقييمات إلى أرقام والتي يمكن مقارنتها بجمع المعايير الممكنة وفي الخطوة الأخيرة من العملية يتم حساب الأولويات العددية لكل خيار من الخيارات البديلة. الخطوة التالية هي بناء المصفوفة التي تتألف من المعايير على الشكل التالي وتعبئتها:

الجدول (27) الشكل العام لمصفوفة معايير AHP

first step	Prediction	Political	Economic	Social	Technological
Prediction	x11	x12	x13	x14	x15
Political	x21	x22	x23	x24	x25
Economic	x31	x32	x33	x34	x35
Social	x41	x42	x43	x44	x45
Technological	x51	x52	x53	x54	x55

الخطوة الأولى: الآن نريد تعبئة كل خلية بحسب لأهميتها بالنسبة للعنصر المقابل فمثلاً، السطر الأول في العمود تكون قيمته 1 لأن أهمية الغرض بالنسبة لنفسه هو دوماً 1، وبالتالي نملاً القطر الرئيسي ب 1، لتعبئة بقية الخلايا يجب أن نجواب على أسئلة من النمط أما العمود الثاني فيقرأ على الشكل: ما أهمية معيار التنبؤ الخارج من نموذجنا بالنسبة لمعيار الظروف السياسية الحالية (والجواب يكون من 1 ل 9) إذا كان المعيار الأول بنفس أهمية، أو أهم من المعيار الثاني. نعرض الجدول أدناه لشرح المقياس المستخدم في هذه الطريقة:

الجدول (28) مقياس أهمية المعايير بالنسبة لبعضها

Scale	Numerical Rating	Reciprocal
Extremely Preferred	9	1/9
Very strong to extremely	8	1/8
Very strongly preferred	7	1/7
Strongly to very strongly	6	1/6
Strongly preferred	5	1/5
Moderately to strongly	4	1/4
Moderately preferred	3	1/3
Equally to moderately	2	1/2
Equally preferred	1	1

كما يجدر بالذكر أنه بما أن المصفوفة متناظرة حيث أن الأسطر والأعمدة تعبر عن المعايير فقط أي أنه يجب أن تملأ بشكل متناظر أيضاً فمثلاً، إذا كانت قيمة الخلية x12 تسعة، فيجب أن تكون قيمة الخلية x21 واحد على تسعة، ويترجم ذلك على أن أهمية معيار التنبؤ بالنسبة لأهمية معيار البيئة السياسية يكرر مرة أخرى لكن بغير صياغة (أهمية معيار البيئة السياسية بالنسبة لأهمية معيار التنبؤ) وتكون القيمة الرياضية له مقلوب القيمة الأصلية. نعرض الآن نموذج حقيقي منطقي لتعبئة المصفوفة المقترحة.

الجدول (29) قيم أهمية المعايير بالنسبة لبعضها

first step	Prediction	Political	Economic	Social	Technological
Prediction	1	9	7	9	9
Political	1/9	1	1/3	1	2
Economic	1/6	3	1	2	3
Social	1/7	1	1/2	1	2
Technological	1/9	1/2	1/3	1/2	1

نلاحظ أن التنبؤ الخارج عن النموذج هو أهم معيار بالنسبة لنا حيث أن تثقله سيكون أكبر من بقية المعايير مجتمعة، والفكرة من هذه العملية أن المستخدم حتى لو كان تقييمه ل PEST بعيد عن الدقة فإن النظام يريد الاستفادة من التنبؤ بشكل أمثل حيث لا يغلب معيار آخر، إلا إذا كان هناك تقارب شديد بين تنبؤات البدائل، وهذا ما يعطي النموذج متانة نسبية، فإذا أدخل المستخدم بدائل تنبؤ أحدها يغلب البقية فمهما كان تقييمه للعوامل الأخرى فإن الترجيح الأساسي هو لتنبؤ ارتفاع أو انخفاض السعر.

اعتبرنا بشكل أولي أننا نريد النظر إلى سهم شركة عادي فمن المنطقي أن تكون العوامل السياسية بنفس أهمية العوامل الاجتماعية، والعوامل الاقتصادية تتفوق على السياسية والتكنولوجية والاجتماعية بنسب متفاوتة، والعوامل الاجتماعية والسياسية تتغلب على العوامل التكنولوجية. إلا أن بقية التفضيلات يمكن تعديلها بما يناسب الحالة مثلاً عندما نريد النظر إلى أسهم شركات فيختلف التثقل عن عملات رقمية فعندها نزيد من أهمية العوامل التكنولوجية (مثل التطورات الجديدة في سلاسل الكتل) أو العوامل الاجتماعية مثل زيادة التقبل لاستخدام العملات الإلكترونية، وحتى بين أسهم شركات فعندما نقارن بين شركات أغذية يمكن أن ننقل العامل الاجتماعي أكثر والعامل التكنولوجي أقل، كأحد الأمثلة، ولذلك قمنا باختيار طريقة المصفوفة الموزنة فهي ديناميكية من جهة، وسهلة الاستخدام من قبل مستخدم خارجي من جهة أخرى.

الخطوة الثانية: نأخذ نفس هذه المصفوفة ونحولها إلى أرقام عشرية بدلاً من كسرية، ثم نقوم بجمع قيم كل عمود لنحصل على الجدول التالي:

الجدول (30) الخطوة الثانية لاستخراج الأوزان

second step	Prediction	Political	Economic	Social	Technological
Prediction	1.0000	9.0000	7.0000	9.0000	9.0000
Political	0.1111	1.0000	0.3333	1.0000	2.0000
Economic	0.1667	3.0000	1.0000	2.0000	3.0000
Social	0.1429	1.0000	0.5000	1.0000	2.0000
Technological	0.1111	0.5000	0.3333	0.5000	1.0000
sum	1.5317	14.5000	9.1667	13.5000	17.0000

الخطوة الثالثة: نقوم بتقسيم كل خلية على المجموع الموافق (في السطر الأخير) ونضع الناتج في الخلية الموافقة لها، ثم نقوم بجمع خلايا كل سطر فنحصل على وزن كل معيار، للتأكد من صحة العمل نجمع قيم الأوزان فيجب أن يكون الناتج يساوي الواحد.

الجدول (31) الخطوة الثالثة لاستخراج الأوزان

Third Step	Prediction	Political	Economic	Social	Technological	criteria weights
Prediction	0.6528	0.6207	0.7636	0.6667	0.5294	0.6467
Political	0.0725	0.0690	0.0364	0.0741	0.1176	0.0739
Economic	0.1088	0.2069	0.1091	0.1481	0.1765	0.1499
Social	0.0933	0.0690	0.0545	0.0741	0.1176	0.0817
Technological	0.0725	0.0345	0.0364	0.0370	0.0588	0.0478
SUM						1.0000


نلاحظ أنه كما هو متوقع الوزن الأكبر للتنبؤ الخارج من النموذج السابق، يليه الوضع الاقتصادي ثم الاجتماعي والسياسي ثم التكنولوجي بالترتيب، وننوه مرة أخرى أن هذه حالة عملية لاختيار الأوزان بحسب تفضيل المستخدم إلا أنه يمكن تعديل الأوزان عدد المعايير بشكل ديناميكي.

7.4 بناء واجهة استخدام لنظام النموذج المقترح UI

يتفاعل المستخدم مع نظام النموذج من خلال واجهة استخدام تفاعلية يمكنه من خلالها تغيير العملة أو السهم المدروس، وتغيير المدة الزمنية للمعطيات المأخوذة، ليقوم النظام بجلبها وعرضها على شكل مخطط شموع يابانية، كما نقترح استعراض حجم التداول في السوق ليرى المستخدم تغير حجم التداول بتغير السعر كما نعرض أسفله تغير مؤشر القوة النسبية لاستعراض نقاطه الحدية، وهو أمر متعارف عليه بأغلب أنظمة التحليل الفني للأسواق المالية. كما نعرض تحته مؤشر الخوف والجشع بشكله البياني إضافة لقيمته الحالية ودلالته، بعد جلبه من مصدره الموافق باستخدام واجهة التطبيق البرمجية API، أما في القسم الأيسر من الواجهة فنستعرض خرج النظام الخبير وخرج الشبكة العصبونية بشكل منفصل، ثم نعرض دمج التنبؤين بشكل مستقل ليستطيع المستخدم المقارنة وقراءة الفرق بينهما إن وجد. أما على أقصى اليسار يوجد شريط التحكم، لعرض التقارير التي تفسر النتائج، وتعرض رسومات بيانية أخرى، كما أنه يمكن الانتقال لواجهة المقارنة بين عدة بدائل أو الانتقال إلى التقارير التي يولدها النظام، أو تغيير الإعدادات من شريط التحكم أيضاً. ونعرض الواجهة المقترحة للوحة تحكم النظام في الشكل (75).

8.4 خاتمة

قمنا في هذا الفصل بمحاكاة وتنفيذ النموذج الأولي لنظامنا المقترح، بالبداية بجلب المعطيات وتضخيمها واستخدامها لتوليد تقارير ورسوم بيانية ومعالجتها لتكون دخلاً مناسباً للشبكة العصبونية والنظام الخبير. كما قمنا ببناء صفوف معرفة نستفيد منها لبناء قواعد المعرفة وقمنا بتمثيلها بيانياً كما قمنا ببناء الشبكة العصبونية التي تعتمد على طبقة تضمين زمني، وطبقة محولات انتباه مناسبة لمشكلة بحثنا، وأخيراً قمنا ببناء مصفوفة قرار مقترحة مع أوزانها الديناميكية كحالة عملية للنموذج الأولي.



الشكل (75) واجهة المستخدم المقترحة لنظام نموذجنا

الفصل الخامس

التنفيذ والتحقق

1.5 مقدمة

في هذا الفصل نقوم بعرض مناقشة خرج النموذج المقترح وطرق التحقق من صحة النموذج كما نستعرض خوارزمية مقترحة للتأكد من جودة النظام الخبير، بعض معايير التحقق لفعالية الشبكة العصبونية المقترحة. أخيراً نستعرض طريقة التحقق من تناسق مصفوفة القرار من حيث الأوزان. يجدر بالذكر أنه يوجد العديد من طرق التحقق فيوجد بالأدبيات العديد من الأدوات والمعايير المستخدمة إلا أننا نستخدم في هذا الفصل بعض أكثر الطرق شيوعاً.

2.5 اختبار أداء الشبكة العصبونية

في هذه الفقرة نريد التأكد من صحة أداء الشبكة العصبونية، نبدأ بالمقاييس المستخدمة للقيام بذلك فنقترح بالنسبة لدقة التنبؤ إن كان السعر يرتفع أو ينخفض، معيار الدقة Accuracy، وذلك لأن بعض المعايير الأخرى غير مناسبة لهذه العملية، وبالمقابل توجد معايير أخرى لمقارنة مدى اقتراب السعر المتوقع من السعر الحقيقي مثل MAPE و MAE، وهما متوسط القيمة المطلقة لأخطاء التوقع بالنسبة المئوية ومتوسط أخطاء بالقيمة المطلقة بالترتيب. وكلما كان الرقم أقرب للصفر يكون أداء النموذج أفضل، نقوم بعملية اختبار أداء الشبكة والاحتفاظ بالأوزان والانحيازات التي تقلل من تابع التكلفة وهو في حالة التصنيف Sparse Categorical Crossentropy Loss Function، خصوصاً أننا أمام مسألة تصنيف ثنائي، أما عندما جربنا تطبيق الشبكة للتنبؤ بالسعر الحقيقي، وليس بفئة الارتفاع أو الانخفاض فقد استخدمنا تابع تكلفة آخر أكثر مناسبة لهذه الحالة، وهو MSE أي متوسط مربع الأخطاء، أما بالنسبة لعدد الحقب المستخدمة فهو 35 كما ذكرنا سابقاً كخيار تصميمي، ويمكن تعديله لاحقاً لتحسين الأداء تجريبياً، مع مراعاة عدم الوقوع في الإفراط بالتناسب Overfitting، كما أنه نكمل عملية تحسين الأداء عن طريق عملية الضبط الدقيق Fine Tuning، من خلال تغيير بعض العناصر مثل عدد العقد أو معدل التعلم Learning Rate، أخيراً، فمن المتوقع أن يتحسن أداء الشبكة أكثر عند تدريبها بمعطيات أكبر، وذلك بحسب أداء نفس نموذج وهيكلية الشبكة في الدراسات السابقة التي اعتمدنا عليها لبناء النموذج. نرفق الرمز التالي الذي يقوم بتنفيذ الشبكة وحساب تابع التكلفة، وخوارزمية الأمثلة، ومعايير قياس الصحة.

الرمز (15) معايير نموذج الشبكة العصبونية

```
'''Construct model'''


in_seq = Input(shape=(seq_len, 12))
x = time_embedding(in_seq)
x = Concatenate(axis=-1)([in_seq, x])
x = attn_layer1((x, x, x))
x = attn_layer2((x, x, x))
x = attn_layer3((x, x, x))
x = GlobalAveragePooling1D(data_format='channels_first')(x)
x = Dropout(0.1)(x)
x = Dense(64, activation='relu')(x)
x = Dropout(0.1)(x)
out = Dense(2, activation='softmax')(x)

model = Model(inputs=in_seq, outputs=out)

model.compile(
    loss='sparse_categorical_crossentropy',
    optimizer='adam',
    metrics=['accuracy', 'mape']
)

return model
```

بالنسبة لدقة الشبكة من ناحية التصنيف فوصلت دقة النموذج لـ $accuracy: 0.6555$ ، أما بالنسبة لاقتراب النموذج من السعر الحقيقي، فنعرض الشكل (77) الذي يمثل اقتراب السعر المتوقع مع السعر الحقيقي خلال الزمن. كما نعرض تغير قيمة تابع التكلفة في مرحلة التدريب والتحقق بتغير رقم الحقبة، فنلاحظ أن تابع التكلفة ينخفض بشكل كبير، في البداية ليستقر في نهاية التدريب عند قيم قريبة جداً من الصفر ولنكون أكثر دقة فكانت القيم عند $9.4346e-05$ ، وهي قيم جيدة جداً.




الشكل (76) تغير قيمة تابع التكلفة بالنسبة لعدد الحقبة



الشكل (77) مقارنة السعر المتوقع بالسعر الحقيقي باستخدام Matplotlib

نجد أن أداء الشبكة العصبونية يتحسن بشكل متسارع في البداية ثم يصبح غير التحسن ضئيلاً للغاية، أما بالنسبة لتوقع السعر، فيمكن القول أن الشبكة حساسة لارتفاع السعر وانخفاضه، إلا أن أخطاء النموذج تحدث عند تقلب السوق بشكل كبير، وهنا يكون النموذج أقل دقة.

من المتوقع تحسين أداء النموذج حتى تصبح الدقة أكبر عند تدريبه بمعطيات أكبر، فالمعطيات المستخدمة في حالتنا ذات حجم من فئة الميغابايت، إلا أن أوزان وانحيازات نماذج الشبكات العصبونية في الأدبيات الأمثلة في الأدبيات تكون عند تدريبها بمعطيات من فئة الغيغابايت، وتيرابايت، مما يسمح لنا بتطوير النموذج مستقبلاً. ونرفق أدناه تغير متوسط الأخطاء بالنسبة المئوية فنجد أنها تنخفض من 14 تقريباً إلى حدود الرقم 5 عند نهاية التدريب.



الشكل (78) مقارنة MAPE في التدريب والتحقيق

3.5 اختبار أداء النظام الخبير

في خصوصية مسألتنا نقترح خوارزمية لاختبار أداء النظام الخبير، باستخدام معدل الإصابة Hit Ratio المذكورة سابقاً في فصل الدراسة المرجعية (K.H. Lee, 1999)، بشكل ديناميكي وذلك لأن معدل إصابة الأنماط (الدقة) تتغير بحسب تغير السوق، وبحسب القواعد، فالقواعد المقترحة في نظامنا قد تحتاج تحسين، وقد نضيف قواعد جديدة أو نستغني عن قواعد أثبتت عدم فعاليتها، لذلك نريد طريقة مخصصة لاختبار نظامنا المقترح.


1. تبدأ الخوارزمية بقراءة إطار المعطيات الموافق، ثم نقسم إطار المعطيات إلى حزم، كل حزمة مؤلفة من 3 أيام (فترات زمنية)، وذلك لأن تعقيد الأنماط في نظامنا المقترح هو عبارة عن أنماط 3 أيام على الأكثر، هذه الحزم ستشكل لاحقاً دخلاً للنظام الخبير ليكشف عن طبيعة الأنماط الموجودة.
2. في الخطوة التالية نقوم بتشكيل تابع هدف يعطي كخرج إحدى القيمتين (0 أو 1)، حيث أنه إذا كان السعر يرتفع في الحزمة Batch+1، فنضيف على معطيات الحزمة Batch القيمة (1) لنقارنها في المراحل اللاحقة بالتنبؤ الذي يخرج من النظام.

3. نعطي القيمة صفر لثلاث متحولات جديدة، المتغير الأول هو "قيمة الوزن Weight Value"، وهو متغير سيعبر عن الوزن الذي سنعطيه للنمط كما يعبر عن نسبة إصابة النمط بحد ذاته. المتغير الثاني هو متغير "الإصابة hit" كل مرة يتوافق تنبؤ النمط مع الهدف في التابع السابق نضيف (1) على عدد الإصابات. المتغير الثالث هو متغير يعبر عن عدد التنبؤات الكلي بغض النظر إذا كانت ناجحة أم لا، ونسميه "الكلي tot".
4. تدخل الحزمة المؤلفة من معطيات 3 أيام إضافة لقيمة تابع الهدف (0 أو 1) إلى النظام الخبير، ويتعرف النظام الخبير على اسم النمط ونوعه ويعطي قيمة موافقة إما بالشراء أو البيع ويمكن تمثيلها أيضاً بقيمة (0 أو 1).

5. يدخل هذا الخرج ضمن جملة شرطية وهي (هل قيمة التنبؤ تساوي قيمة تابع الهدف؟) إذا كان الجواب نعم، نضيف قيمة (1) لمتغير "الإصابة" ولمتغير "الكلي". أما إذا كان الجواب لا، فنضيف (1) فقط لمتغير "الكلي".
6. في هذه الخطوة نحسب قيمة الوزن (الدقة) بحسب المعادلة التالية $Weight\ Value = hit/tot * 100$ ، ويصبح لدينا الآن قيمة لوزن النمط، وهي قيمة تتغير عبر مرور الزمن بحسب صحة الأنماط، كما تعبر هذه القيمة عن دقة النمط، (إذا أردنا دقة النموذج ككل يمكن أخذ المتوسط الحسابي للأنماط)، كما يمكن أن تساعدنا

هذه الخطوة على حل نزاعات المعرفة مستقبلاً، حيث أنه إذا أمكن تطبيق عدة قواعد بنفس الوقت، يتم تنفيذ القاعدة الموافقة لأعلى وزن، وبما أن الأوزان تتغير باختلاف الزمن، فيصبح النظام الخبير أكثر مراعاة لطبيعة السوق والوضع الراهن له.

7. نضيف الآن لمؤشر الحزمة قيمة (1) للانتقال من الحزمة الأولى للحزمة التالية، ونتأكد بعدها من الشرط التالي: (هل انتهى عدد الحزم في إطار المعطيات؟) إذا كان الجواب لا، فإننا ندخل الحزمة التالية وفق الخطوات التي شرحناها سابقاً (من الخطوة 4 حتى هذه الخطوة)، وتظل هذه الخوارزمية تتكرر في حلقة Loop حتى ينكسر الشرط، أي انتهاء عدد الحزم الموجودة في إطار المعطيات، وعندها يتم إظهار الأنماط الموجودة في النظام وأوزانها الموافقة (أي دقة كل نمط)، وبهذا تنتهي خوارزمية التحقق. نعرض الآن التمثيل البياني لهذه الخوارزمية المقترحة بالشكل التالي:



الشكل (79) خوارزمية اختبار أداء النظام الخبير المقترحة

4.5 اختبار اتساق المصفوفة الموزنة

نريد التأكد من أن المصفوفة التي قمنا ببنائها لا تحوي على تضارب بالنسبة لمنطق توزيعها، وللأهمية النسبية بين كل معيار، ونحسب ذلك من خلال مؤشر الاتساق (CI)، والذي نقوم بحسابه بالخطوات التالية:

- (1) نضرب عناصر أعمدة المصفوفة الأساسية بالأوزان الموافقة ثم نجمع كل عناصر سطر على حدة.
- (2) نضيف عمود جديد على المصفوفة يمثل مجموع الأوزان التي توصلنا إليها (Weighted Sum Value) سابقاً ونقسمه على الوزن الموافق.
- (3) نستخرج المتوسط الحسابي للقيم التي استخرجناها سابقاً فنكون توصلنا قيمة Lambda max بحسب المصفوفة التالية حيث أن n عدد المعايير الموجودة لدينا.

$$\text{Lambda max} = \sum (\text{weighted sum values/criteria weights})/n$$

الجدول (32) جدول يمثل حساب مؤشر الترابط والاتساق CI

Last Step	Prediction	Political	Economic	Social	Technological	Weighted Sum Value	Criteria Weights	Ratio
Prediction	0.6467	0.6653	1.0492	0.7353	0.4306	3.5270	0.6467	5.4543
Political	0.0719	0.0739	0.0500	0.0817	0.0957	0.3731	0.0739	5.047855
Economic	0.1078	0.2218	0.1499	0.1634	0.1435	0.7864	0.1499	5.24648
Social	0.0924	0.0739	0.0749	0.0817	0.0957	0.4186	0.0817	5.124104
Technological	0.0719	0.0370	0.0500	0.0408	0.0478	0.2475	0.0478	5.171852
Average = Lambda Max								5.208918

- (4) لأن بعد حساب Lambda max نريد حساب مؤشر الاتساق وفق القانون التالي، وهو قانون الاتساق الأساسي.

$$\text{Consistency Index (C.I.)} = \lambda_{max} \frac{\lambda_{max} - n}{n - 1}$$

فيكون الناتج في حالتنا، 0.0522294، أخيراً نريد تطبيق قانون نسبة الاتساق باستخدام مؤشر العشوائية Consistency Index، والذي هو بحسب الجداول الإحصائية عند مدخلات (عدد معايير 5) random index= 1.12.

الجدول (33) مؤشر العشوائية بحسب حجم المصفوفة

Matrix size	Random consistency index (RI)
1	0.00
2	0.00
3	0.58
4	0.90
5	1.12
6	1.24
7	1.32
8	1.41
9	1.45
10	1.49

الآن نريد حساب نسبة الاتساق Consistency Ratio وهي النسبة الأخيرة التي نريد استخراجها ونقارنها مع 0.1، حيث أنه يمكن القول أنه يوجد اتساق داخلي عندما تكون قيمته أقل من 0.1 وهو معيار القبول، أما إذا كان أكبر من 0.1 فإن المصفوفة تحتاج للتعديل وهي غير متسقة كفاية، أما إذا كان فوق قيمة 0.9 فيمكن القول أن منطق تشكيل المصفوفة واتساقها عشوائي بالكامل ولا يمكن الاعتماد عليه وبحالتنا القيمة التي حصلنا عليها هي 0.046636، وهي قيمة تعني أنه يوجد تناسق جيد جداً بين الأوزان المقترحة.

$$\text{consistency ratio} = \text{consistency index} / \text{random index} = 0.046634$$

أخيراً يجب التنويه أنه يجب عند تعديل الأوزان المقترحة فمن الضروري القيام بهذه الحسابات مرة أخرى، وهو أمر قمنا بأتمنته، بحال كون المستخدم عقلاني فلا تشكل هذه العملية عائقاً، إلا أنها تمنعه من استخدام المصفوفة في حال كون نسبة الاتساق أكبر من 0.1، وهذا أمر يضيف متانة للنموذج.

الجدول (34) يمثل دلالة مجالات قيم CI

Consistency Index	Interpretation
0	judgements are perfectly consistent
≤ 0.1	consistent enough
≥ 0.1	matrix needs improvement
≥ 0.9	judgements are just about random and are completely untrustworthy

5.5 قيود وتحديات البحث

واجه هذا العمل البحثي صعوبات متعددة أدت لبعض القيود، بدءاً بعدم وجود معطيات ذات حجم كافٍ لتدريب الشبكة العصبونية، فبدأنا بتجربة معطيات تغير السعر اليومية لشركة IBM، بما أنها من الشركات القليلة المدرجة في سوق الأوراق المالية والمستمرة منذ عام 1965، تمثلت قاعدة المعطيات الموافقة لها بما يقارب 9 آلاف نقطة معطيات Data Point، إلا أن الشبكة بعد تدريبها بهذه المعطيات لم تظهر نتائج جيدة ويعود ذلك لتعقيد النموذج المستخدم مما يسبب بطء تدريبه، إلا أن هذا التعقيد نفسه يظهر النتائج الأكثر دقة في الأدبيات عند التعامل مع حجوم معطيات كبيرة جداً Big Data، مما جعل الباحث يبحث عن طرق لتضخيم المعطيات مثل استخراج معطيات مشتقة بالإضافة للمعطيات الأولية التي يتم كشطها من مصادرها. إلا أن هذا لا يكفي مما جعل الباحث مضطراً

للقيام باستخدام معطيات ذات حجم أكبر، وهي في حالتنا العملية معطيات عملة بيتكوين الرقمية، فاستفدنا من إمكانية استخراج التغيرات الساعية للعملة بدلاً من التغيرات اليومية مما جعلنا قادرين على توليد ما يقارب 90 ألف نقطة معطيات Data Point، مما حسن من الأداء بشكل ملحوظ، مع أنه لتدريب نماذج بهذا التعقيد فمن الأفضل تدريب النموذج على معطيات ذات حجم أكبر (من فئة حجم التيرابايت)، إلا أن هذه عقبة أخرى بالنسبة للباحث فحتى لو كنا قادرين على استخدام معطيات بهذا الحجم إلا أن التدريب يحتاج إلى قوة معالجة كبيرة جداً، وهي النقطة المحور الثاني من محددات هذا البحث، فالتعقيد الزمني للتدريب يتطلب معالجات من نوع GPU لاختصار زمن المعالجة، وهذا ما قام به الباحث باستخدام معالجات GPU التابعة لشركة Google، حيث أنها تعطي ميزة استخدام هذه المعالجات بشكل مجاني لكن محدود، أي أنه غير متواصل وبالتالي ينقطع تدريب الشبكة بعد فترة من الزمن ويضطر المستخدم إلى إكمال التدريب بعد فترة زمنية ما، إلا أنها غير محددة من قبل Google وذلك كي لا يستغلها المستخدمون الحقيقيون أو البرمجيات المؤتمتة على شكل Bots. كما أنه توجد حدود زمنية بالنسبة للباحث، فتم العمل على هذا البحث في الفترة الزمنية بين شهر آذار ونهاية شهر حزيران لعام 2022.

الفصل السادس

النتائج والتوصيات

1.6 مقدمة

نعرض في هذا الفصل مجموعة من الخلاصات والقراءات التي توصلنا إليها، إضافة لبعض من التوجهات والآفاق المستقبلية، التي يمكن الاستفادة منها عند تطوير نماذج جديدة تهدف إلى حل مشاكل مشابهة لمشكلة بحثنا، أي مشكلة التنبؤ في السلاسل الزمنية بشكل عام والتنبؤ السعري في الأسواق المالية بشكل خاص.

2.6 خلاصة البحث

قدمنا في هذا العمل البحثي عرضاً تفصيلياً لمشكلة البحث، والتحديات التي تواجهها النماذج التي تحاول حل مشكلة التنبؤ السعري في الأسواق المالية، وبعض أهم المقاربات والتقنيات المستخدمة لمواجهة هذه المشكلة بحسب إطار الأبعاد الأربعة، للاستفادة من مقاربات أبحاث أخرى، وتحليل نقاط قوة وضعف هذه المقاربات للاستفادة منها في بحثنا.

بناءً على ذلك قمنا ببناء نموذج أولي لنظام NES، وهو نظام دعم قرار يعتمد على نظام هجين يدمج بين شبكة عصبونية اصطناعية ونظام خبير، يقومان بالتنبؤ السعري للفترة الزمنية القادمة، ويضاف إلى ذلك مصفوفة قرار موزنة عند التعامل مع عدة بدائل متقاربة بالتنبؤ. الفكرة من هيكليّة النموذج المقترح هي الاستفادة من نقاط قوة الشبكة العصبونية، مثل أدائها العالي عند تدريبها بحجم معطيات كبير، وقدرتها على التقاط أنماط وتبعيات مخفية لا يمكن للإنسان التقاطها. كما يهدف لمواجهة نقاط ضعف الشبكة العصبونية، مثل عدم وجود قدرة تفسيرية للخروج، وذلك من خلال دمجها مع نظام خبير، والذي يقوم بإظهار تقارير تفسيرية تشرح للمستخدم وضع السوق الحالي، ويقوم بإظهار رسومات بيانية لعدة مؤشرات تقنية وللتغيرات السعريّة، بالإضافة لنصيحة نهائية للمستخدم. ندمج بين الخرج النهائي للشبكة العصبونية وبين خرج النظام الخبير عن طريق إحدى خوارزميات ensemble، وهي المتوسط المرجح، وبهذا يقوم النموذج بالاعتماد بشكل أكبر على النموذج الأكثر دقة، ويعطي أهمية أقل للنموذج الأقل دقة، وذلك بالاعتماد على فرق الدقة بينهما، كما يمكن الاستفادة من المتوسط المرجح بأنه يمكن تعديل الخرج ليتناسب مع استراتيجية المستثمر، إذا كان يميل للمخاطرة أم يميل لعدم المخاطرة.

يقوم النظام المقترح بجلب المعطيات المختارة لسهم أو عملة رقمية بشكل تلقائي، ومعالجتها لاستخراج معطيات مشتقة، وهي المؤشرات التقنيّة التي نقوم باستخدامها في القواعد المعرفية في النظام الخبير، أي أنها تضيف قوة تعبيرية للمعطيات الخام من جهة، ومن جهة أخرى نستفيد من المعطيات المشتقة لتضخيم المعطيات الداخلة للشبكة العصبونية وهي بالترتيب المؤشرات التالية (ShortSMA, LongSMA, EMA, ADX, DMN, DMP, F&G, RSI). أما بالنسبة لهيكليّة النظام الخبير فقد قسمنا الأنماط إلى 5 أنواع (هابطة، وصاعدة، وحيدة، واستمرار اتجاه، وانعكاس اتجاه)، من خلالها يقوم النظام بالتنبؤ بانخفاض أو ارتفاع السعر، ويعطي نصيحة للمستخدم إما بالشراء، أو بالبيع، أو بالشراء القوي، أو بالبيع القوي. كما قدمنا خوارزمية تحقق من أداء النظام الخبير، تعطي أوزاناً ديناميكية لكل نمط، ويعبر الوزن بنفس الوقت عن معدل إصابة النمط. أما بالنسبة لهيكليّة الشبكة العصبونية فنقترح طبقة تضمين زمني Time2Vec لتمثيل الزمن بشكل رياضي، ونموذج محولات انتباه Attention

Transformer Model، يقوم بحساب أهمية النمط بالنسبة لبقية الأنماط، ليعطي أخيراً تنبؤاً نهائياً، إما بارتفاع السعر أو بانخفاضه. بالنسبة لتابع التكلفة اخترنا Sparse Categorical Crossentropy، لأننا نواجه مسألة تصنيف، واخترنا تابع تكلفة MSE لمعرفة اقتراب السعر المتوقع للسعر الحقيقي، وبالنسبة لخوارزمية الأمثلة قد اخترنا خوارزمية ADAM. أخيراً يضمن النموذج المقترح، قدرة تنبؤية وتفسيرية في آن واحد كما يمكنه التعامل مع أحجام معطيات مختلفة، بالإضافة إلى أنه قادر على التعامل مع بدائل مختلفة بشكل ديناميكي، أي بتغيير المعايير وعدد البدائل من خلال المصفوفة الموزونة.

3.6 الآفاق المستقبلية

استناداً إلى هذا العمل البحثي، نهدف إلى العمل مستقبلاً على إدخال مفهوم المنطق الغائم إلى النظام الخبير، وذلك لملائمته لطبيعة المشكلة المترافقة مع ظروف عدم تأكد عالية، خصوصاً أن حدود المؤشرات التقنية في الواقع ضبابية وليست حتمية كما عاملناها في نموذجنا المقترح، كما أنه يمكن تحسين القواعد المستخدمة في النظام الخبير بحسب أدائها، ويمكن إدخال مؤشرات تقنية أخرى لصنع قواعد أكثر تعقيداً، كما يمكن تمديد النظام الخبير ليشمل الاستثمارات طويلة الأجل أيضاً، عن طريق إدخال قواعد التحليل الأساسي FA. كما يمكن تحسين النظام الخبير عن طريق إضافة خوارزمية حل نزاعات المعرفة Conflict Resolution، بناءً على خوارزمية حساب الأوزان المقترحة بمعدل الإصابة لكل نمط، فإذا أمكن تطبيق قاعدتين أو أكثر يختار النظام القاعدة الموافقة للوزن الأعلى.

أما بالنسبة للشبكة العصبونية فنهدف لتحسين أدائها بتدريبها على معطيات ذات حجم أكبر، وتجربة تغيير المعلومات مثل عدد الحقب والحزم والسلاسل ومعدل التعلم، للوصول إلى المعلومات المثلى عن طريق القيام بعملية ضبط دقيق Fine Tuning، فهي عملية لا يمكن التنبؤ بنتائجها إلا بتجريب مستمر، كما يمكن تحسين مدخلات الشبكة العصبونية عن طريق إدخال بعض المعلومات الجديدة، مثل مؤشرات تقنية أخرى، ونقترح أيضاً إدخال سعر الذهب والنفط، على أمل أن تلتقط الشبكة التبعيات التي تحدث عند تذبذب السوق بسبب عوامل سياسية أو اقتصادية، بحكم أن هذه السلع شديدة التأثير بأي تغيير. نقترح أيضاً أن يكون خرج النظام الخبير هو دخل إضافي للشبكة العصبونية على شكل قيمتي تنبؤ ومعدل إصابة، فتستفيد منه عند القيام بعملية التنبؤ.

نقترح أيضاً دمج شبكة عصبونية أخرى مع نظامنا المقترح، ونقوم الشبكة الجديدة بتحليل مشاعر السوق عن طريق معالجة اللغة الطبيعية NLP، من وسائل التواصل الاجتماعي، ومقالات الكترونية تتعلق بالعملة أو السهم المدروس باستخدام تقنيات كشط المعطيات Data Scrapping، لزيادة قدرة فهم النموذج لمشاعر السوق، فكلما ازداد حجم المعطيات وجودتها وقدرتها التعبيرية، يتحسن أداء الشبكة.

نقترح أيضاً ربط خرج النموذج السابق بشبكة أخرى أو خوارزميات تداول، تشكل ما يسمى بروبوت تداول Trading Bot يأخذ خرج التنبؤ كدخل له، ويقوم بقرار البيع والشراء عند استيفاء شروط معينة، ويمكن تدريبه باستخدام برامج المحاكاة Simulation، لتقليل مخاطرة الاستخدام، أما بالنسبة للمفاضلة بين البدائل فيمكن تحسينها باستخدام نماذج أخرى أو باستخدام معايير ثابتة تأخذ عوامل المخاطرة بشكل كمي حقيقي وليس بتقدير من المستخدم، كما يمكن تحسين هذه العملية بجعلها مؤتمتة أيضاً.

المراجع

- Smith, B. M., & Smith, B. M. (2004). In A history of the global stock market: From ancient rome to Silicon Valley (pp. 13–15). essay, University of Chicago.
- Braudel, F. (1982). Civilization and capitalism. 15th-18th century: The Wheels of Commerce. Collins.
- Rajan, R. G., & Zingales, L. (2003). The great reversals: The politics of financial development in the Twentieth Century. *Journal of Financial Economics*, 69(1), 5–50. [https://doi.org/10.1016/s0304-405x\(03\)00125-9](https://doi.org/10.1016/s0304-405x(03)00125-9)
- Griffioen, G. A. (2003). Technical analysis in financial markets. SSRN Electronic Journal. <https://doi.org/10.2139/ssrn.566882>
- Hayes, A. (2022, March 14). What is technical analysis. Investopedia. Retrieved May 8, 2022, from <https://www.investopedia.com/terms/t/technicalanalysis.asp>
- Toussaint, G. T. (2014). *Machine Intelligence and Pattern Recognition*. North-Holland.
- Nison, S. (1991). Japanese candlestick charting techniques: A contemporary guide to the ancient techniques of the Far East. Prentice Hall.
- Tharavanij, P., Siraprapasiri, V., & Rajchamaha, K. (2017). Profitability of candlestick charting patterns in the Stock Exchange of Thailand. *SAGE Open*, 7(4), 215824401773679. <https://doi.org/10.1177/2158244017736799>
- Morris, G. L., & Litchfield, R. (2006). *Candlestick charting explained: Timeless Techniques for trading stocks and futures*. McGraw-Hill.
- Goo, Y.-J & Chen, Dar-Hsin & Chang, Y.-W. (2007). The application of Japanese candlestick trading strategies in Taiwan. *Investment Management and Financial Innovations*. 4. 49-79.
- Horton, M. J. (2009). Stars, crows, and doji: The use of candlesticks in stock selection. *Quarterly Review of Economics and Finance*, 49, 283-294
- Rouf, N., Malik, M. B., Arif, T., Sharma, S., Singh, S., Aich, S., & Kim, H.-C. (2021). Stock market prediction using Machine Learning Techniques: A decade survey on methodologies, recent developments, and Future Directions. *Electronics*, 10(21), 2717. <https://doi.org/10.3390/electronics10212717>
- Hayes, A. (2022, March 5). What is a stock Investopedia. Retrieved May 7, 2022, from <https://www.investopedia.com/terms/s/stock.asp>
- Marshall, B. R., Young, M. R., Rose, L. C. (2006). Candlestick technical trading strategies: Can they create value for investors? *Journal of Banking & Finance*, 30, 2303-2323.
- Lu, T.-H., Shiu, Y.-M. (2012). Tests for two-day candlestick patterns in the emerging equity market of Taiwan. *Emerging Markets Finance & Trade*, 48(Suppl. 1), 41-57.
- Fama, E. F. (1995). Random walks in stock market prices. *Financial Analysts Journal*, 51(1), 75–80. <https://doi.org/10.2469/faj.v51.n1.1861>
- Segal, T. (2022, February 8). What is fundamental analysis Investopedia. Retrieved May 10, 2022, from <https://www.investopedia.com/terms/f/fundamentalanalysis.asp>
- Chopra, R., & Sharma, G. D. (2021). Application of artificial intelligence in stock market forecasting: A Critique, review, and research agenda. *Journal of Risk and Financial Management*, 14(11), 526. <https://doi.org/10.3390/jrfm14110526>
- Geisser, S. (2019). *Predictive inference*. Chapman & Hall/CRC.
- Feigenbaum, E. A. (1992). *Expert Systems with Applications. A Personal View of Expert Systems: Looking Back and Looking Ahead*.

- Lebowitz, M. (1983). Memory-based parsing. *Artificial Intelligence*, 21, 363– 404.
- Newell, A., & Simon, H. A. (1972). *Human problem solving*. Englewood Cliffs, NJ: Prentice–Hall.
- Cheng, B., & Titterington, D. M. (1994). Neural networks: A review from a statistical perspective. *Statistical Science*, 9(1). <https://doi.org/10.1214/ss/1177010638>
- Lawrence, J., & Luedeking, S. (1994). *Introduction to neural networks*. California Scientific Software.
- Chen, J. (2022, February 8). Neural network definition. Investopedia. Retrieved May 11, 2022, from <https://www.investopedia.com/terms/n/neuralnetwork.asp>
- Pang, X., Zhou, Y., Wang, P., Lin, W., & Chang, V. (2018). An innovative neural network approach for stock market prediction. *The Journal of Supercomputing*, 76(3), 2098–2118. <https://doi.org/10.1007/s11227-017-2228-y>
- Chen, J.-H., & Tsai, Y.-C. (2020). Encoding Candlesticks as images for pattern classification using Convolutional Neural Networks. *Financial Innovation*, 6(1). <https://doi.org/10.1186/s40854-020-00187-0>
- Ankita Patil, Abhay Rajpure, Abhinav Thool, Saurabh Gheware, & Abhishek Moolya. (2022). Stock market prediction using LSTM. *International Journal of Advanced Research in Science, Communication and Technology*, 483–486. <https://doi.org/10.48175/ijarsct-3336>
- Vaswani, A., Shazeer, N., & Parmar, N. (2017). Attention Is All You Need. *Conference on Neural Information Processing Systems (NIPS 2017)*, Long Beach, CA, USA. <https://doi.org/doi.org/10.48550/arXiv.1706.03762>
- Rosenblatt, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, 65(6), 386.
- Goodfellow, I., Bengio, Y., & Courville, A. (2017). *Deep learning*. The MIT Press.
- Stanford University. (2020). Convolutional neural networks for computer vision. github cs231 neural networks 1 lecture. Retrieved May 15, 2022, from <https://cs231n.github.io/neural-networks-1/>
- Jain, V. (2019, December 30). Everything you need to know about "activation functions" in Deep learning models. Medium. Retrieved May 15, 2022, from towardsdatascience.com/everything-you-need-to-know-about-activation-functions-in-deep-learning-models
- Scarff, B. (2021, January 12). Understanding backpropagation. Medium. Retrieved May 15, 2022, from <https://towardsdatascience.com/understanding-backpropagation>
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533–536. <https://doi.org/10.1038/323533a0>
- Kwiatkowski, R. (2021, May 24). Gradient descent algorithm-a deep dive. Medium. Retrieved May 15, 2022, from <https://towardsdatascience.com/gradient-descent-algorithm-a-deep-dive>
- H. Koontz, C. O'Donnell. (1955) *Principles of Management: An Analysis of Managerial Functions*.
- Peterson, M. (2017). *An introduction to decision theory*. Cambridge University Press.
- Velasquez, Mark & Hester, Patrick. (2013). An analysis of multi-criteria decision-making methods. *International Journal of Operations Research*. 10. 56-66.
- Sprague, R. H., & Watson, H. J. (1996). *Decision support for Management*. Prentice Hall.
- Louw, R. E., & Sauter , V. (2002). *Decision Support Systems in Information Systems Analysis*. University of Missouri St. Louis.
- Saaty (2008). Multiple criteria decision making for sustainable energy and Transportation Systems: Proceedings of the 19th International conference on multiple Criteria decision Making, Auckland, New Zealand, 7th-12th January 2008. Springer

- Sammut-Bonnici, T., & Galea, D. (2015). Pest analysis. Wiley Encyclopedia of Management, 1–1. <https://doi.org/10.1002/9781118785317.weom120113>
- C. Rolland, C. Ben Achour, C. Cauvet, J. Ralyté, A. Sutcliffe, N-A. M. Maiden, M. Jarke, P. Haumer, K. Pohl, E. Dubois and P. Heymans, “A Proposal for a Scenario Classification Framework”, Requirements Engineering Journal (REJ) , vol. 3, no, pp. 23-47. 1998.
- McDermott, J., & Forgy, C. (1976). Production system conflict resolution strategies. <https://doi.org/10.21236/ada037771>
- Russell, S. J., Norvig, P., & Davis, E. (2022). Artificial Intelligence: A modern approach. Pearson Educación.
- Casanova, I. J. (2012). Portfolio investment decision support system based on a fuzzy inference system. Studies in Computational Intelligence, 183–196. https://doi.org/10.1007/978-3-642-27534-0_12
- MARTINSSON, F. I. L. I. P. (2017). Short-Term Stock Market Prediction Based on Candlestick Pattern Analysis. EXAMENSARBETE INOM TEKNIK.
- Zopounidis, C., Doumpos, M., & Matsatsinis, N. F. (1997). On the use of knowledge-based decision support systems in Financial Management: A survey. Decision Support Systems, 20(3), 259–277. [https://doi.org/10.1016/s0167-9236\(97\)00002-x](https://doi.org/10.1016/s0167-9236(97)00002-x)
- Lee, K. H., & Jo, G. S. (1999). Expert system for predicting stock market timing using a candlestick chart. Expert Systems with Applications, 16(4), 357–364. [https://doi.org/10.1016/s0957-4174\(99\)00011-1](https://doi.org/10.1016/s0957-4174(99)00011-1)
- Murkute, A., & Sarode, T. (2015). Forecasting market price of stock using Artificial Neural Network. International Journal of Computer Applications, 124(12), 11–15. <https://doi.org/10.5120/ijca2015905681>
- Gandhmal, D. P., & Kumar, K. (2019). Systematic analysis and review of Stock Market Prediction Techniques. Computer Science Review, 34, 100190. <https://doi.org/10.1016/j.cosrev.2019.08.001>
- Nison, S. (2001). Japanese candlestick charting techniques: A contemporary guide to the ancient techniques of the Far East. Prentice Hall.
- Li, X. (2019). DP-LSTM: Differential Privacy-inspired LSTM for Stock Prediction Using Financial News. Cornell University. <https://doi.org/10.48550/arXiv.1912.10806>
- Indika, A., Warusamana, N., Welikala, E., & Deegalla, S. (2021). Ensemble stock market prediction using SVM, LSTM, and linear regression. <https://doi.org/10.36227/techrxiv.16626019.v1>
- Fama, Sharpe William. 1970. Efficient capital markets: A review of theory and empirical work: Discussion. The Journal of Finance 25: 383–417. [Google Scholar] [CrossRef]
- Rolland, C. & Achour, C. & Cauvet, Corine & Sutcliffe, Alistair & Jarke, Matthias & Haumer, P. & Pohl, Klaus & Dubois, Eric & Namur, P.. (1998). A Proposal For A Scenario Classification Framework.
- Aljoumaa, Kadan. “Modélisation intentionnelle et annotation sémantique pour la réutilisation de services métiers PASiS: Publishing And Searching of Intentional Services. (intentional modeling and semantic annotation for business services reuse).” (2011).
- Libertex. (2022, March 31). What is IBEX 35 index and all about trading the index? Libertex.org. Retrieved April 13, 2022, from <https://libertex.org/blog/what-is-ibex-35-index>
- Chen, J. (2021, May 19). National Stock Exchange of India Limited (NSE). Investopedia. Retrieved April 13, 2022, from https://www.investopedia.com/terms/n/national_stock_exchange.asp
- Tretina, K. (2021, December 9). What is the S&P 500? how does it work? Forbes. Retrieved April 13, 2022, from <https://www.forbes.com/advisor/investing/what-is-sp-500/>
- NASDAQ stock market definition. Nasdaq. (n.d.). Retrieved April 13, 2022, from <https://www.nasdaq.com/glossary/n/nasdaq-stock-market>

- Young, J. (2022, March 25). Financial Times Stock Exchange Group (FTSE) offers specialized indices. Investopedia. Retrieved April 13, 2022, from <https://www.investopedia.com/terms/f/ftse.asp#citation-2>
- Kenton, W. (2021, September 13). Korean composite stock price indexes (KOSPI). Investopedia. Retrieved April 13, 2022, from <https://www.investopedia.com/terms/k/kospi.asp>
- Ardabili, S., Mosavi, A., & Várkonyi-Kóczy, A. R. (2019). Advances in machine learning modeling reviewing hybrid and ensemble methods . <https://doi.org/10.20944/preprints201908.0203.v1>
- Lavarkas, Raw Data. (n.d.). Encyclopedia of Survey Research Methods. <https://doi.org/10.4135/9781412963947.n447> (2008)
- Kitchin, R. (2017). The Data Revolution: Big Data, Open Data, Data Infrastructures & their consequences. Sage.
- S. Praveen, and U. Chandra, “Influence of Structured, Semi-Structured, Unstructured data on various data models”, International Journal of Scientific and Engineering Research , vol. 8 no. 12, pp. 67-69, 2017.
- Caterina Marchionn .Introduction to robust estimation and hypothesis testing. (2022). <https://doi.org/10.1016/c2019-0-01225-3>
- Shiller, R. J., Fischer, S., & Friedman, B. M. (1984). Stock prices and Social Dynamics. Brookings Papers on Economic Activity, 1984(2), 457. <https://doi.org/10.2307/2534436>
- Fama, E. F. (1965). The Behavior of Stock-Market Prices. The Journal of Business, 38(1), 34–105. <http://www.jstor.org/stable/2350752>
- Huang, J.-Z., Huang, W., & Ni, J. (2019). Predicting bitcoin returns using high-dimensional technical indicators. The Journal of Finance and Data Science, 5(3), 140–155. <https://doi.org/10.1016/j.jfds.2018.10.001>
- Arratia, A., Avalos, G., Cabaña, A., Duarte-López, A., & Renedo-Mirambell, M. (2021). Sentiment analysis of Financial News: Mechanics and Statistics. *Data Science for Economics and Finance*, 195–216. https://doi.org/10.1007/978-3-030-66891-4_9
- Haykin, S., & Hakin, S. (n.d.). The Neural Networks a comprehensive foundation.
- Guresen, E., & Kayakutlu, G. (2011). Definition of artificial neural networks with comparison to other networks. *Procedia Computer Science*, 3, 426–433. <https://doi.org/10.1016/j.procs.2010.12.071>
- Adankon, M. M., & Cheriet, M. (2009). Support Vector Machine. *Encyclopedia of Biometrics*, 1303–1308. https://doi.org/10.1007/978-0-387-73003-5_299
- Kumari, K., & Yadav, S. (2018). Linear Regression Analysis Study. *Journal of the Practice of Cardiovascular Sciences*, 4(1), 33. https://doi.org/10.4103/jpcs.jpcs_8_18
- Murshed, B.A.H.; Al-Ariki, H.D.E.; Mallappa, S. Semantic Analysis Techniques using Twitter Datasets on Big Data: Comparative. Analysis Study. *Comput. Syst. Sci. Eng.* 2020, 35, 495–512.
- Xianya, J.; Mo, H.; Haifeng, L. Stock Classification Prediction Based on Spark. *Procedia Comput. Sci.* 2019, 162, 2citation43–250.
- Lin, L.; Cao, L.; Wang, J.; Zhang, C. The applications of genetic algorithms in stock market data mining optimization. *Manag. Inf. Syst.* 2004, 10, 273–280.
- Kim, Y.; Ahn, W. Oh, K.J. Enke, D. An intelligent hybrid trading system for discovering trading rules for the futures market using rough sets and genetic algorithms. *Appl. Soft Comput.* 2017, 55, 127–140.
- Zadeh, L. A. (1965). Fuzzy sets. *Information and Control*, 8(3), 338–353. [https://doi.org/10.1016/s0019-9958\(65\)90241-x](https://doi.org/10.1016/s0019-9958(65)90241-x)

- Nair, B. B., Dharini, N. M., & Mohandas, V. P. (2010). A stock market trend prediction system using a hybrid decision tree-neuro-fuzzy system. 2010 International Conference on Advances in Recent Technologies in Communication and Computing. <https://doi.org/10.1109/artcom.2010.75>
- Wilder, J. W. (1978). New Concepts in Technical Trading Systems. Trend research.
- Appel, G. (1985). The moving average convergence-divergence trading method: Advanced version. Scientific Investment Systems.
- Shiller, R. J. (2001). Market volatility. MIT Press.
- Hepple, L. W. (2001). Multiple regression and spatial policy analysis: George Udny Yule and the origins of Statistical Social Science. *Environment and Planning D: Society and Space*, 19(4), 385–407. <https://doi.org/10.1068/d291>
- Gil Kalai. Learnability and rationality of choice. *Journal of Economic theory*, 113(1):104– 117, 2003.
- Hutto, C.J. & Gilbert, E.E. (2014). VADER: A Parsimonious Rule-based Model for Sentiment Analysis of Social Media Text. Eighth International Conference on Weblogs and Social Media (ICWSM-14). Ann Arbor, MI, June 2014.
- PERKINS, J. A. C. O. B. (2017). Natural language processing: Python and Nltk. PACKT Publishing.
- Lischner, Ray (2000). Delphi in a nutshell: a desktop quick reference (1st ed.). Sebastopol, CA: O'Reilly and Associates. ISBN 1565926595.
- Harris, C. R., Millman, K. J., van der Walt, S. J., Gommers, R., Virtanen, P., Cournapeau, D., ... Oliphant, T. E. (2020). Array programming with NumPy. *Nature*, 585, 357–362. <https://doi.org/10.1038/s41586-020-2649-2>
- J. D. Hunter, "Matplotlib: A 2D Graphics Environment", *Computing in Science & Engineering*, vol. 9, no. 3, pp. 90-95, 2007.
- Chollet, F., & others. (2015). Keras. GitHub. Retrieved from <https://github.com/fchollet/keras>
- Hillion, P., & Suominen, M. (2004). The manipulation of closing prices. *Journal of Financial Markets*, 7(4), 351–375. <https://doi.org/10.1016/j.finmar.2004.04.002>
- Dean, J & others. (2016). Tensorflow: A system for large-scale machine learning. In 12th USENIX Symposium on Operating Systems Design and Implementation (pp. 265–283).
- Gramfort, A., Michel, V., Thirion, B., Grisel, & others. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12(Oct), 2825–2830.
- Jacob, Elin. (2004). Classification and Categorization: A Difference that Makes a Difference. *Library Trends*. 52.
- Van Rossum, G., & Drake Jr, F. L. (1995). Python reference manual. Centrum voor Wiskunde en Informatica Amsterdam
- Stroustrup, B. (2000). The C++ programming language. Pearson Education India
- Austerlitz, H. (2003). Computer programming languages. *Data Acquisition Techniques Using PCs*, 326–360. <https://doi.org/10.1016/b978-012068377-2/50013-9>
- Jensen, K., & Wirth, N. (2012). PASCAL user manual and report: ISO PASCAL standard. Springer Science & Business Media.
- HAZAN, E. L. A. D. (2022). gradient descent. In *Introduction to online convex optimization*. essay, MIT PRESS.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533–536. <https://doi.org/10.1038/323533a0>

- Kingma, Diederik & Ba, Jimmy. (2014). Adam: A Method for Stochastic Optimization. International Conference on Learning Representations.
- Vallverdú, J. (2014). What are simulations? an epistemological approach. *Procedia Technology*, 13, 6–15. <https://doi.org/10.1016/j.protcy.2014.02.003>
- Vandeput, N. (2021, July 30). *Forecast KPI: RMSE, Mae, Mape & Bias*. Medium. Retrieved July 2, 2022, from <https://towardsdatascience.com/forecast-kpi-rmse-mae-mape-bias-cdc5703d242d>
- Mistrik, R. K. Bahsoon, R. Kazman, and Y. Zhang, “Architecture Model. In *Economics-Driven Software Architecture*”, Elsevier , 2014
- McLeish, D. L. (2005). *Monte Carlo Simulation and Finance*. J. Wiley.
- Scott, G. (2022, April 4). How to use the Investopedia Simulator. Investopedia. Retrieved April 25, 2022, from <https://www.investopedia.com/how-to-use-the-investopedia-simulator-5221184>
- PETER, B. R. U. C. E. P. E. T. E. R. B. R. U. C. E. A. N. D. R. E. W. G. E. D. E. C. K. (2020). *Practical statistics for data scientists 50+ essential concepts using r and python;50+ essential concepts using r and python*. O'REILLY MEDIA, INCORPORA.
- McKinney, W., & others. (2010). Data structures for statistical computing in python. In *Proceedings of the 9th Python in Science Conference (Vol. 445, pp. 51–56)*
- Tuovila, A. (2022, February 8). What are a company's earnings? Investopedia. Retrieved April 30, 2022, from <https://www.investopedia.com/terms/e/earnings.asp>
- O'Donoghue, C., Leach, R. H., & Hynes, S. (2017). Simulating earnings in dynamic microsimulation models. *New Frontiers in Microsimulation Modelling*, 381–412. <https://doi.org/10.4324/9781315248066-15>
- Brousselle, A., Benmarhnia, T., & Benhadj, L. (2016). What are the benefits and risks of using return on investment to defend public health programs? *Preventive Medicine Reports*, 3, 135–138. <https://doi.org/10.1016/j.pmedr.2015.11.015>
- Halkjelsvik, & Peters. (2018). *Time predictions*. Springer International Publishing.
- P. Duchessi and S. Belardo, Lending Analysis Support System (LASS): An Application of a Knowledge-Based System to Support Commercial Loan Analysis, *IEEE Transactions on Systems, Man, and Cybernetics* 17, No. 4 (1987) 608-616.
- Schmitz, J. (2020, September 16). Stock predictions with state-of-the-art transformer and time embeddings. Medium. Retrieved May 22, 2022, from <https://towardsdatascience.com/stock-predictions-with-state-of-the-art-transformer-and-time-embeddings>
- Diniz, P., Junior, D. A., Diniz, J. O., de Paiva, A. C., Silva, A. C., Gattass, M., Quevedo, R., Michelon, D., Siedschlag, C., & Ribeiro, R. (2022). Time2Vec Transformer. *Proceedings of the 37th ACM/SIGAPP Symposium on Applied Computing*. <https://doi.org/10.1145/3477314.3507275>
- Kazemi, S. M. et al (2019). Time2Vec: Learning a Vector Representation of Time. Cornell University of Computer Science.

الملاحق

الملحق الأول (النظام الخبير)

نرفق بعض قواعد أنماط الشموع اليابانية التي تشكل قاعدة المعرفة المستخدمة في النظام الخبير تمت صياغتها بشكل رماز:

الرماز (16) نمط 3White Soldiers

```
@Rule(
    MatchedPattern(pattern = Pattern.White, day = MATCH.day1),
    Candle(open_value = MATCH.open_day1, day = MATCH.day1),
    MatchedPattern(pattern = Pattern.White, day = MATCH.day2),
    Candle(open_value = MATCH.open_day2, day = MATCH.day2),
    TEST(lambda day1, day2: day2 > day1),
    TEST(lambda open_day1, open_day2: open_day2 == open_day1 + 1),
    MatchedPattern(pattern = Pattern.White, day = MATCH.day3),
    Candle(open_value = MATCH.open_day3, day = MATCH.day3),
    TEST(lambda day2, day3: day3 > day2),
    TEST(lambda open_day2, open_day3: open_day3 == open_day2 + 1)
)
def three_white_soldiers(self, day1, day2, day3):
    self.declare(MatchedPattern(pattern = Pattern.ThreeWhiteSoldiers, day = day1, last_day = day3, size = 3))
    print('Three White Soldiers pattern in days:', day1, day2, day3)
```

الرماز (17) نمط 3Black Crows

```
@Rule(
    MatchedPattern(pattern = Pattern.Black, day = MATCH.day1),
    Candle(open_value = MATCH.open_day1, day = MATCH.day1),
    MatchedPattern(pattern = Pattern.Black, day = MATCH.day2),
    Candle(open_value = MATCH.open_day2, day = MATCH.day2),
    TEST(lambda day1, day2: day2 == day1 + 1),
    TEST(lambda open_day1, open_day2: open_day2 < open_day1),
    MatchedPattern(pattern = Pattern.Black, day = MATCH.day3),
    Candle(open_value = MATCH.open_day3, day = MATCH.day3),
    TEST(lambda day2, day3: day3 == day2 + 1),
    TEST(lambda open_day2, open_day3: open_day3 < open_day2)
)
def three_black_crows(self, day1, day2, day3):
    self.declare(MatchedPattern(pattern = Pattern.ThreeBlackCrows, day = day1, last_day = day3, size = 3))
    print('Three Black Crows pattern in days:', day1, day2, day3)
```

الرماز (18) نمطا Bearish Shaven Bottom و Rising Window

```
@Rule(
    MatchedPattern(pattern = Pattern.White, day = MATCH.day1),
    MatchedPattern(pattern = Pattern.White, day = MATCH.day2),
    TEST(lambda day1, day2: day2 == day1 + 1),
    Candle(close_value = MATCH.close_day1, day = MATCH.day1),
    Candle(open_value = MATCH.open_day2, day = MATCH.day2),
    Options(rising_window_threshold = MATCH.rw_th),
    TEST(lambda close_day1, open_day2, rw_th: (open_day2 - close_day1) > rw_th)
)
def rising_window(self, day1, day2, close_day1, open_day2):
    self.declare(MatchedPattern(pattern = Pattern.RisingWindow, day = day1, size = 2))
    print('Rising Window pattern in days:', day1, day2, "and the gap is: ", (open_day2 - close_day1))

@Rule(
    MatchedPattern(pattern = Pattern.Black, day = MATCH.day),
    Candle(close_value = MATCH.close, low_value = MATCH.low, day = MATCH.day),
    TEST(lambda close, low: close == low)
)
def bearish_shaven_bottom_candle(self, day):
    self.declare(MatchedPattern(pattern = Pattern.BearishShavenBottom, day = day))
    print('Bearish Shaven Bottom Candle in day:', day)
```

الزّمان (19) أنماط Bearish/Bullish Shaven Head, Tweezer Bottoms

```

@Rule(
    MatchedPattern(pattern = Pattern.Black, day = MATCH.day),
    Candle(open_value = MATCH.open, high_value = MATCH.high, day = MATCH.day),
    TEST(lambda open, high: open == high)
)
def bearish_shaven_head_candle(self, day):
    self.declare(MatchedPattern(pattern = Pattern.BearishShavenHead, day = day))
    print('Bearish Shaven Head Candle in day:', day)

@Rule(
    MatchedPattern(pattern = Pattern.White, day = MATCH.day),
    Candle(close_value = MATCH.close, high_value = MATCH.high, day = MATCH.day),
    TEST(lambda close, high: close == high)
)
def bullish_shaven_head_candle(self, day):
    self.declare(MatchedPattern(pattern = Pattern.BullishShavenHead, day = day))
    print('Bullish Shaven Head Candle in day:', day)

@Rule(
    MatchedPattern(pattern = Pattern.BearishShavenBottom, day = MATCH.day1),
    MatchedPattern(pattern = Pattern.BullishShavenBottom, day = MATCH.day2),
    TEST(lambda day1, day2: day2 == day1 + 1),
    Candle(close_value = MATCH.close_day1, day = MATCH.day1),
    Candle(open_value = MATCH.open_day2, day = MATCH.day2),
    Options(tweezers_limit = MATCH.tw_1),
    TEST(lambda close_day1, open_day2, tw_1: abs(close_day1 - open_day2) <= tw_1)
)
def tweezer_bottoms(self, day1, day2):
    self.declare(MatchedPattern(pattern = Pattern.TweezerBottoms, day = day1, size = 2))
    print('Tweezer Bottoms pattern in days:', day1, day2)

```

الزّمان (20) نمطا Doji, Bullish Doji Star

```

@Rule(
    Candle(open_value = MATCH.open, close_value = MATCH.close, day = MATCH.day),
    Options(doji_limit = MATCH.dj_l),
    TEST(lambda open, close, dj_l: abs(open - close) <= dj_l)
)
def doji_candle(self, day):
    self.declare(MatchedPattern(pattern = Pattern.Doji, day = day))
    print('Doji Candle in day:', day)

@Rule(
    MatchedPattern(pattern = Pattern.BigBlack, day = MATCH.day1),
    Candle(close_value = MATCH.close_day1, day = MATCH.day1),
    MatchedPattern(pattern = Pattern.Doji, day = MATCH.day2),
    Candle(open_value = MATCH.open_day2, close_value = MATCH.close_day2, day = MATCH.day2),
    TEST(lambda day1, day2: day2 > day1),
    TEST(lambda close_day1, open_day2, close_day2: close_day1 >= open_day2 and close_day1 >= close_day2),
    MatchedPattern(pattern = Pattern.BigWhite, day = MATCH.day3),
    Candle(open_value = MATCH.open_day3, day = MATCH.day3),
    TEST(lambda day2, day3: day3 > day2),
    TEST(lambda open_day2, close_day2, open_day3: open_day3 >= open_day2 and open_day3 >= close_day2)
)
def bullish_doji_star(self, day1, day2, day3):
    self.declare(MatchedPattern(pattern = Pattern.BullishDojiStar, day = day1, size = 3))
    print('Bullish Doji Star in days:', day1, day2, day3)

```

الملحق الثاني (الشبكة العصبونية)

نرفق آلية تسلسل عمل الشبكة العصبونية خلال التدريب التي تظهر كخرج عند تنفيذ رماز الشبكة.

الجدول (35) تسلسل عمل الشبكة العصبونية باستخدام مكتبة TensorFlow

Model: "model"

Layer (type) Connected to	Output Shape	Param #
=====		
input_1 (InputLayer) []	[(None, 128, 12)]	0
time2_vector (Time2Vector) ['input_1[0][0]']	(None, 128, 2)	512
concatenate (Concatenate) ['input_1[0][0]', 'time2_vector[0][0]']	(None, 128, 14)	0
transformer_encoder (Transform ['concatenate[0][0]', erEncoder) 'concatenate[0][0]', 'concatenate[0][0]']	(None, 128, 14)	188756
transformer_encoder_1 (Transfo ['transformer_encoder[0][0]', rmerEncoder) 'transformer_encoder[0][0]', 'transformer_encoder[0][0]']	(None, 128, 14)	188756
transformer_encoder_2 (Transfo ['transformer_encoder_1[0][0]', rmerEncoder) 'transformer_encoder_1[0][0]', 'transformer_encoder_1[0][0]']	(None, 128, 14)	188756
global_average_pooling1d (Glob ['transformer_encoder_2[0][0]'] alAveragePooling1D)	(None, 128)	0
dropout (Dropout) ['global_average_pooling1d[0][0]']	(None, 128)	0
dense (Dense) ['dropout[0][0]']	(None, 64)	8256

```


dropout_1 (Dropout)                (None, 64)                0
['dense[0][0][0]']

dense_1 (Dense)                     (None, 2)                  65
['dropout_1[0][0]']

=====
Total params: 575,101
Trainable params: 575,101
Non-trainable params: 0

```

كما نعرض طريقة أخرى لعرض آلية تسلسل عمل الشبكة العصبونية عن طريق شجرة في الشكل التالي:



الشكل (80) عرض تسلسل عمل الشبكة العصبونية كشجرة باستخدام مكتبة TensorFlow

الملحق الثالث (حالة عملية)

نرفق هنا حالة عملية عن تغيرات أسعار 3 أيام ونعرض التقارير المقترحة التي يولدها النظام، ونشرح النمط المحقق في اليوم الأخير Spinning Top وهي المعلومات الإضافية تشرح وضع السوق لكن لا نظهرها في واجهة التحكم المقترحة:

الرمز (21) حالة عملية لدخل وخرج النظام الخبير

```
Extra(RSI_14 = 60, sigPriceBuy = 0, sigPriceSell = 0, ADX_14 = 27, DMP_14 = 22 DMN_14 = 20 Fear_and_Greed_Value = 69 day = 1)
Extra(RSI_14 = 55, sigPriceBuy = 0, sigPriceSell = 0, ADX_14 = 30, DMP_14 = 23 DMN_14 = 17 Fear_and_Greed_Value = 72 day = 2)
Extra(RSI_14 = 58, sigPriceBuy = 0, sigPriceSell = 0, ADX_14 = 29, DMP_14 = 21 DMN_14 = 18 Fear_and_Greed_Value = 71 day = 3)
```

```
es = StockExpert()
es.reset()
es.declare(Candle(open_value = 555.47, close_value = 559.26, high_value = 559.26, low_value = 550.73, day = 1))
es.declare(Candle(open_value = 555.03, close_value = 560.30, high_value = 569.96, low_value = 551.62, day = 2))
es.declare(Candle(open_value = 553.30, close_value = 542.10, high_value = 555.85, low_value = 539.42, day = 3))
```

```
es.run()
```

```
Black Candle in day 3
Bearish Spinning top in day: 3
Big Black Candle in day 3
White Candle in day 2
Big White Candle in day 2
White Candle in day 1
Big White Candle in day 1
Bullish Shaven Head Candle in day: 1
The Predicted status is Rising With a total probability of: 0.6153846153846154
```

Spinning Top: سمي هذا النمط بهذا المسمى لأنه يشبه المغزل، وهو عبارة عن شمعة وحيدة صاعدة أو هابطة إلا أنها تتميز بجسم صغير وظل صغير أيضاً. هذا النمط بحد ذاته فعلاً يعبر عن عدم تأكد في السوق إلا أنه أداة جيدة عند دمجها مع مؤشرات الزخم، فمثلاً إذا كان هناك زخم إيجابي قبل هذا النمط، فهذا قد يكون إشارة لانقلاب الاتجاه، ويفضل البيع. أما إذا كان هناك زخم سلبي قبل هذا النمط، فهذا قد يكون إشارة لانقلاب الاتجاه، ويفضل الشراء.



الشكل (81) نمط Spinning Top في هذه الحالة العملية

نلاحظ أن قيمة مؤشر القوة النسبية بحدود الطبيعية إلا أنها أقرب لتوجه المشتريين، حيث أنه أقل من 70، أي لم يصل بعد حتى سعر السهم لمرحلة الشراء بشكل مجحف، كما أنه لا يوجد تقاطع للمتوسطات المتحركة، إلا أنه إذا نظرنا للزخم نجد أن قيمته أكبر من 25 أي أنه زخم قوي، أما اتجاه هذا الزخم هو اتجاه إيجابي لأن قيمة DMP أكبر من قيمة DMN، أخيراً نجد أن قيمة مؤشر الخوف والجشع هي أقرب للجشع فهي بين قيمتي 69 و71، وبالتالي بعد دمج نمط Spinning Top والذي هو نمط عدم تأكد مع المؤشرات الفنية الأخرى، ننصح المستخدم بالبيع إذا كان يريد تقليل المخاطرة لأنه قد يكون مؤشر لانقلاب الاتجاه من إيجابي إلى سلبي.