



وزارة التعليم العالي والبحث العلمي
المركز الجامعي بمغنية
معهد العلوم الاقتصادية والتجارية وعلوم التسيير
قسم العلوم الاقتصادية



أطروحة مقدمة لنيل شهادة الدكتوراه في العلوم الاقتصادية

تخصص: اقتصاد وتسيير المؤسسة

بعنوان :

استخدام الشبكات العصبية ذات دوال الأساس الشعاعي

للتنبؤ بأسعار الذهب العالمية

دراسة تطبيقية: 2000-2020

إشراف الأستاذ الدكتور

ساهد عبدالقادر

إعداد الطالب:

قهوي حسن

أعضاء اللجنة المناقشة

- | | | | |
|----------------------|----------------------|----------------------|----------------|
| د. تيريش محمد | أستاذ محاضر "أ" | المركز الجامعي مغنية | رئيساً |
| أ.د. ساهد عبدالقادر | أستاذ التعليم العالي | المركز الجامعي مغنية | مشرفاً ومقرراً |
| أ.د. شكوري سيدي محمد | أستاذ التعليم العالي | المركز الجامعي مغنية | ممتحننا |
| أ.د. مكيديش محمد | أستاذ التعليم العالي | المركز الجامعي مغنية | ممتحننا |
| د. قادري محمد | أستاذ محاضر "أ" | جامعة سيدي بلعباس | ممتحننا |
| د. بن مسعود نصرالدين | أستاذ محاضر "أ" | جامعة عين تمونشنت | ممتحننا |

السنة الجامعية: 2021-2022

أطروحة مقدمة لنيل شهادة الدكتوراه

في العلوم الاقتصادية

تخصص: اقتصاد وتسيير المؤسسة

بعنوان:

استخدام الشبكات العصبية ذات دوال الأساس الشعاعي

للتنبؤ بأسعار الذهب العالمية

دراسة تطبيقية: 2000-2020

إشراف الأستاذ الدكتور

ساهد عبدالقادر

إعداد الطالب:

قهوي حسن

السنة الجامعية: 2021-2022



إهداء

الى من قال الله فيهما

﴿وَخَفِضْ لَهُمَا جَنَاحَ الذَّلِيلِ مِنَ الرَّحْمَةِ وَقُلْ رَبِّ إِزْحَمُهُمَا كَمَا رَبَّيْتَنِى صَغِيرًا﴾

[الإسراء 24]

الوالدين الكرمين؛ حفظهما الله سبحانه وتعالى ورعاهما .

الى الحرم المصون، التي كانت نعم العون في أصعب الظروف

الى أبنائي كل باسمه..

الى أفراد العائلة صغيرا وكبيرا..

الى من مدّ لي يد العون..

الى كل هؤلاء أهدي هذا العمل التواضع

حسن قهوي

شكر وتقدير

الحمد لله الذي أسبغ عليّ نعمه ظاهرة وباطنة حتى وفقني لإتمام هذه الدراسة، فلك الحمد زني حتى ترضى.

وإصالة والسلام الأتمان الأكملان على النبي العزيزي محمد بن عبد الله. وبعد؛ تحية تقدير وعرفان إلى أستاذي الفاضل، الأستاذ الدكتور ساهد عبدالقادر على إرشاداته وملاحظاته العلمية القيّمة، فله مني كل الشكر والعرفان والامتنان على حسن التوجيه والإفادّة، وأسأل الله أن يبارك له في عمله، وينفع به، وأن يجزيه خير الجزاء ويمنحه حسن الثواب.

والشكر موصول إلى كل من أ.د. عبدالرهميم شبي، وأ.د. بشكوري سيد محمد وأ.د. مكيديش محمد وإلى الدكتور محمد تربش، وإلى الدكتور محمد باحسن. كما أتقدم بشكري الجزيل إلى اللجنة المناقشة المكونة من الدكتور المحترمين الذين كلّفوا أنفسهم عناء قراءة هذه الأطروحة، لإبداء ملاحظاتهم العلمية القيّمة، فجزاهم الله خير الجزاء.

وإلى من وقعت عيناه على طور هذه الأطروحة.

الفهارس العامة

فهرس المحتويات

i	الواجهة الخارجية
ii	الواجهة الداخلية
iii	البسمة
iv	الاهداء
v	الشكر والتقدير
vi	الفهارس العامة
i	فهرس المحتويات
v	فهرس الجداول
vi	فهرس الأشكال
أ	المقدمة العامة
22	الفصل الأول أسعار الذهب العالمية
23	مقدمة
24	1-1: ماهية الذهب
24	1-2 وحدة الوزن للذهب
25	1-3: تاريخ حركة أسعار الذهب
30	1-4: العوامل المؤثرة على سعر الذهب
33	1-4-2: اتجاه السياسة النقدية
33	1-4-3: العلاقة بين أسعار الصرف واسعار الذهب
34	1-4-4: العلاقة بين أسعار الفائدة الحقيقية واسعار الذهب
35	1-4-5: العلاقة بين أسعار النفط وأسعار الذهب
36	1-4-6: العلاقة بين أسعار الذهب والأسهم
37	1-4-7: العلاقة بين أسعار الذهب والتضخم
37	1-5: الدراسات السابقة
43	1-6: الذهب ملاذ آمن للمستثمرين
43	1-7: الأسباب التي تدفع البنوك المركزية للاستثمار في الذهب
44	1-8: أهمية الذهب في الاقتصاد
45	1-9: الذهب في الجزائر
46	خلاصة

47	الفصل الثاني: نماذج ARIMA
48	تمهيد
49	1-2: دراسة وتحليل السلاسل الزمنية
49	1-1-2: تعريف السلسلة الزمنية
49	2-1-2: مكونات السلاسل الزمنية
50	1.2.1.2: الاتجاه العام <i>Thend</i>
50	2.2.1.2: التغيرات الموسمية Seasonal Variations
50	3.2.1.2: التغيرات الدورية Cyclical Variations
50	4.2.1.2: التغيرات العشوائية Randomor Stochastic
52	2-2: طرق تحديد واكتشاف مركبات السلسلة الزمنية
52	1-2-2: اختبار "دانيال" لكشف مركبة الاتجاه العام
53	2-2-2: اختبار Kruskal-Wallis لكشف المركبة الموسمية (الفصلية)
54	3-2: تحليل السلاسل الزمنية العشوائية
54	1-3-2: السلاسل الزمنية المستقرة وغير المستقرة
54	2-3-2: السلسلة الزمنية ذات الاستقرار التامة
55	3-3-2: السلاسل الزمنية ضعيفة الاستقرار
55	4-2: دراسة استقرار السلسلة الزمنية
56	1-4-2: دالة الارتباط الذاتي
57	2-4-2: دالة الارتباط الذاتي الجزئي
58	3-4-2: اختبار جذر الوحدة للاستقرار
59	5-4-2: اختبار ديكي فولر Dickey - Fuller test
60	6-4-2: اختبار ديكي فولر المطور The augmented Dickey - Fuller test
61	7-4-2: اختبار Kwiatkowski-Phillips-Schmidt-Shin (KPSS)
62	8-4-2: اختبار Phillips and Perron (pp)
63	5-2: منهجية بوكس-جنكينز
63	1-5-2: نموذج الانحدار الذاتي (AR)
64	2-5-2: نموذج المتوسط المتحرك MA
65	3-5-2: نموذج الانحدار الذاتي والمتوسط المتحرك (ARMA)
66	4-5-2: نموذج الانحدار الذاتي والأوساط المتحركة المتكاملة (ARIMA)
67	5-5-2: مراحل منهجية بوكس و جنكينز
75	6-2: نماذج الانحدار الذاتي المشروط بعدم تجانس تباينات الأخطاء ARCH

75	7-2 : نماذج تعميم الانحدار الذاتي المشروط بعدم تجانس تباينات الأخطاء GARCH
77	8-2 اختبارات نماذج GARCH
77	1-8-2: اختبار الارتباط الذاتي <i>Liung – Box</i>
77	2-8-2 : اختبار أثر ARCH
78	9-2: تقدير معاملات نموذج GARCH
79	10-2: التنبؤ في نماذج ARCH و GARCH
79	1-10-2: التنبؤ باستخدام نموذج ARCHP
79	2-10-2 : التنبؤ باستخدام نماذج <i>GARCHp, q</i>
81	الخلاصة :
82	الفصل الثالث الشبكات العصبية الاصطناعية
83	مقدمة
84	1-3: مفهوم الشبكات العصبية الاصطناعية وفلسفتها
85	2-3 : الشبكة العصبية البيولوجية
88	3-3: الشبكة العصبية الاصطناعية
90	4-3: تعريف الشبكات العصبية الاصطناعية
91	5-3 : مراحل ظهور وتطور الشبكات العصبونية الاصطناعية:
93	6-3 : تطبيقات الشبكات العصبية الاصطناعية :
96	7-3: مكونات الشبكة العصبية الاصطناعية :
101	8-3 : نموذج رياضي لخلية عصبية:
103	9-3 : البنية المعمارية للشبكة العصبية :
107	10-3 : خوارزميات التعلم في الشبكات العصبية الاصطناعية :
111	11-3: خوارزميات التعليم المستخدمة لتدريب الشبكات العصبية :
115	12-3 : إجراءات تصميم الشبكات العصبية الاصطناعية :
117	13-3 : التنبؤ باستخدام الشبكات العصبية الاصطناعية :
118	13-2 : نماذج الذكاء الاصطناعي :
119	14-3 : بعض النماذج المستخدمة في التنبؤ :
121	15-3 : مميزات وحدود استخدام الشبكات العصبية الاصطناعية :
123	خلاصة :
124	الفصل الرابع: الشبكات العصبية ذات دالة الأساس الشعاعي والنماذج الهجينة
125	1-4 : الشبكة العصبية دالة الأساس الشعاعي : Radial Basis Function Network
125	تمهيد:

125: دوال الأساس : 1-1-4
126: أنواع دوال الأساس الشعاعي الأكثر استخداما : 2-1-4
127: الشبكة العصبية دالة الأساس الشعاعي : 3-1-4
139: النماذج الهجينة : 2-4
146: خلاصة :
148: الجانب التطبيقي 5 الفصل الخامس:
149: 1-5 : البيانات وبعض الاحصائيات الوصفية :
161: 9-5 : التنبؤ باستخدام نموذج $ARIMA(1,1,0) - GARCH(1,1)$:
163: 2-5 : التنبؤ باستخدام الشبكات العصبية الاصطناعية :
182: 4-5 : مقارنة بين القيم الفعلية مأخوذة باللوغاريتم والقيم المتنبأ بها باستخدام النماذج السابقة :
186: الخاتمة العامة
192: قائمة المصادر والمراجع
193: أولا المراجع باللغة العربية
196: ثانيا: المراجع باللغة الأجنبية
208: قائمة المختصرات
209: الملخصات

فهرس الجدول

- الجدول 4-1: ميزات الشبكة العصبية RBF&MLPNN 127
- الجدول 5-1: الإحصاءات الوصفية لبيانات الشهرية لأسعار الذهب العالمية 149
- الجدول 5-2: الإحصاءات الوصفية لبيانات الشهرية للوغار يتم الطبيعي لأسعار الذهب العالمية 150
- الجدول 5-3: اختبار ديكي-فولر المطور لفحص استقرارية السلسلة الزمنية 152
- الجدول 5-4: اختبار فيليبس بيرون لفحص استقرارية السلسلة الزمنية 153
- الجدول 5-5: اختبار استقرارية السلسلة الزمنية ذات الفروق الأولى باستخدام اختبار ديكي-فولر 153
- الجدول 5-6: نتائج اختبار استقرارية السلسلة الزمنية ذات الفروق الأولى باستخدام اختبار فيليبس بيرون 154
- الجدول 5-7: نتائج تقدير النموذج $ARIMA(11,1,0)$ 156
- الجدول 5-8: نتائج اختبار تجانس التباين لبواقي النموذج المقدر 158
- الجدول 5-9: نتائج اختبار معنوية معاملات النموذج $ARIMA11, 1, 0 - GARCH1, 1$ 159
- الجدول 5-10: نتائج اختبار تجانس التباين لبواقي النموذج المقدر $ARIMA(11,1,0)-GARCH(1,1)$ 160
- الجدول 5-11: نتائج تقسيم البيانات 164
- الجدول 5-12: يبين مجموع مربعات الأخطاء ونسبة الخطأ البالغة في مرحلة التدريب ومرحلة الاختبار 166
- الجدول 5-13: نتائج تقسيم البيانات 169
- الجدول 5-14: يبين مجموع مربعات الأخطاء ونسبة الخطأ البالغة في مرحلة التدريب ومرحلة الاختبار 171
- الجدول 5-15: المقاضلة بين نموذج $(ARIMA-GARCH)$ ونماذج الشبكات العصبية $(MLPNN,RBF)$ 173
- الجدول 5-16: نتائج تقسيم البيانات 174
- الجدول 5-17: يبين مجموع مربعات الأخطاء ونسبة الخطأ البالغة في مرحلة التدريب ومرحلة الاختبار لنموذج الهجين 177
- الجدول 5-18: نتائج تقسيم البيانات 177
- الجدول 5-19: يبين مجموع مربعات الأخطاء ونسبة الخطأ البالغة في مرحلة التدريب ومرحلة الاختبار لنموذج الهجين 180
- الجدول 5-20: المقاضلة بين نموذج Zhang الهجين ونموذج $(Kashei\&Bijary,2011)$ الهجين المعمم 180
- الجدول 5-21: قيم معيار المقاضلة بين النماذج الخمسة 181

فهرس الأشكال

- الشكل 1-1: يبين العلاقة بين الطلب على الذهب وأسعار الذهب..... 32
- الشكل 2-1: مخطط عمليات نماذج ARIMA & GARCH..... 80
- الشكل 3-1: عينة التركيب البيولوجي العصبي للخلايا العصبية ووصلاتها..... 87
- الشكل 3-2: يبين مكونات الشبكات العصبية الاصطناعية وعلاقتها بالشبكة العصبية الحيوية..... 89
- الشكل 3-3: يبين أشهر دوال التنشيط..... 100
- الشكل 3-4: يبين أشهر دوال التنشيط..... 102
- الشكل 3-5: يبين معمارية الشبكة العصبية وحيدة الطبقة..... 105
- الشكل 3-6: يبين معمارية الشبكة العصبية متعددة الطبقات:..... 105
- الشكل 3-7: يبين الشبكات العصبية الاصطناعية ذات التغذية الأمامية..... 106
- الشكل 3-8: يبين الشبكات العصبية الاصطناعية ذات التغذية العكسية..... 107
- الشكل 3-9: يبين آلية التعلّم المراقب..... 110
- الشكل 3-10: يبين آلية التعلّم غير المراقب..... 110
- الشكل 3-11: خوارزمية التدريب شبكة الانتشار الخلفي..... 114
- الشكل 3-12: الخطوات المتبعة في تصميم الشبكات العصبية الاصطناعية..... 116
- الشكل 3-13: تصنيف الشبكات العصبية الاصطناعية الأكثر استخداما..... 119
- الشكل 3-14: يبين معمارية شبكات بيرسبترون متعدد الطبقات (MLPNN)..... 120
- الشكل 4-1: يبين هيكل الشبكة العصبية دالة الأساس الشعاعي (RBFNN)..... 130
- الشكل 4-2: العملية الرياضية للشبكة العصبية دالة الأساس الشعاعي (RBFNN)..... 131
- الشكل 4-3: يبين عملية التعلّم في الشبكة العصبية دالة الأساس الشعاعي (RBFNN)..... 134
- الشكل 4-4: يوضح خطوات التنبؤ لنموذج (Zhang) الهجين..... 142
- الشكل 4-5: يبين خطوات التنبؤ باستخدام نموذج (Khashei & Bijari) الهجين المعمم..... 145
- الشكل 5-1: التمثيل البياني للسلسلة الزمنية الأصلية لأسعار الذهب الشهرية..... 151
- الشكل 5-2: السلسلة الزمنية لأسعار الذهب الشهرية بعد إدخال اللوغاريتم الطبيعي..... 151
- الشكل 5-3: دالتي الارتباط الذاتي والارتباط الذاتي الجزئي..... 155
- الشكل 5-4: دوال الارتباط الذاتي والجزئي للبواقي لنموذج المقدر..... 157
- الشكل 5-5: اختبار Jarque-Bera لسلسلة بواقي عملية التقدير..... 158

- الشكل 5-6: يوضح القيم التنبؤية بالتباين الشرطي وكذلك رسم بياني للتنبؤ بالتباين الشرطي باستخدام نموذج GARCH(1, 1)، وكذلك يبين تقييم جودة التنبؤ باستخدام النموذج المقدر لمرحلة التدريب..... 161
- الشكل 5-7: يوضح القيم التنبؤية بالتباين الشرطي وكذلك رسم بياني للتنبؤ بالتباين الشرطي باستخدام نموذج GARCH(1, 1)، وكذلك يبين تقييم جودة التنبؤ باستخدام النموذج المقدر لمرحلة الاختبار..... 162
- الشكل 5-8: نموذج الشبكة العصبية لبيانات أسعار الذهب التي تم إدخال عليها اللوغاريتم الطبيعي (LGP) 165
- الشكل 5-9: القيم الأصلية مع القيم المتنبأ بها..... 167
- الشكل 5-10: المخطط البياني للبواقي والقيم المتنبأ بها..... 168
- الشكل 5-11: نموذج الشبكة العصبية لبيانات أسعار الذهب التي تم إدخال عليها اللوغاريتم الطبيعي (LGP) 170
- الشكل 5-12: : القيم الأصلية مع القيم المتنبأ بها..... 171
- الشكل 5-13: المخطط البياني للبواقي والقيم المتنبأ بها..... 172
- الشكل 5-14: معمارية الشبكة العصبية (RBF)..... 176
- الشكل 5-15: معمارية الشبكة العصبية (RBF)..... 179
- الشكل 5-16: تمثيل بياني لسعر الذهب الشهري الفعلي مأخوذة باللوغاريتم والقيم المتنبأ بها باستخدام النماذج السابقة..... 183

القرمة العامة

يعتبر الذهب أحد أعلى سلع التعدين في العالم، ومن بين أوائل المعادن التي استخرجها الإنسان؛ حيث كان للذهب خاصية مثيرة للاهتمام لكونه سلعة، أي نقوداً ومنتجاً في نفس الوقت. ونظراً لأنه كان دائماً منتجاً مقبولاً عالمياً وهو في حد ذاته مخزن للقيمة، فقد اتخذت الغالبية العظمى من البلدان حول العالم المعدن كقاسم مشترك لجميع المعاملات الاقتصادية، وزيادة عن ذلك، أنه يلبي باستمرار جميع المتطلبات التي يجب أن تكون عليها السلعة الجيدة؛ فهو متين (غير قابل للصدأ، وهو معدن "خامل")، وله قيمة سوقية عالية، ومحمول ومتجانس (أي لطالما كانت جيدة مع مزايا على أي وسيلة تبادل أخرى). كما يتميز الذهب بصفات فريدة تميزه عن باقي السلع الأخرى من خلال مساهمته في النمو الاقتصادي للعديد من البلدان في جميع أنحاء العالم، حيث عرف تطبيق الذهب على نطاق واسع في العديد من الوظائف كالصناعة المستخدمة في الصحة والإلكترونيات والصناعات الكيماوية.

وعلاوة على ذلك فالذهب يمتلك أهمية استراتيجية؛ كونه يحافظ على قوته الشرائية في جميع الظروف، كما يمكن الاعتماد عليه في البيئات غير المؤكدة سياسياً واقتصادياً، حيث اعتبر السلعة الوحيدة أو أحد أكثر أدوات الاستثمار المفضلة التي تحتفظ بقيمتها خلال فترات الأزمات الاقتصادية والمالية والسياسية⁽¹⁾ حيث يمكن تحويله بسهولة إلى نقد وتتحرك عائداته في الاتجاه المعاكس لعائدات الأوراق المالية، وكما يرتبط ارتباطاً وثيقاً بالعوائد على جميع أدوات الاستثمار. فنظراً لهذه الأهمية الاستراتيجية للذهب وحقائقه أنه يعتبر مخزناً مهماً للقيمة للأغراض الرسمية، فقد أصبح الذهب عنصراً رئيساً من الأصول الاحتياطية الدولية للبلدان.

وقد أستخدم لسنوات كأداة احتياطية ووسيلة للتبادل، حيث شكّلت أساس النظام النقدي بين 1870-1930 وكانت أداة احتياطية قابلة للتحويل بالكامل إلى الدولار الأمريكي في الفترة 1944-1973⁽²⁾. ففي أوائل السبعينيات تم التخلي على قابلية تحويل الدولار إلى الذهب فضعفت وظيفته النقدية ولكن استمرت وظيفته كأصل مالي⁽³⁾.

(1) Khan, M. M. A. (2013). Forecasting of gold prices (Box Jenkins approach). *International Journal of Emerging Technology and Advanced Engineering*, 3(3), 662-670.p622.

(2) Yurdakul, F., & Sefa, M. (2015). An Econometric Analysis of Gold Prices in Turkey. *Procedia economics and finance*, 23, 77-85.p79.

(3) Bilgin, M. H., Gozgor, G., Lau, C. K. M., & Sheng, X. (2018). The effects of uncertainty measures on the price of gold. *International Review of Financial Analysis*, 58, 1-7.p 2.

وبعد ذلك تم التخلي عن الذهب كأداة احتياطية وأصبح يستخدم كأداة ادخار فردية وجزء من احتياطات في البنوك المركزية والتي تحقق به العديد من الاغراض كضمان أموال المودعين ودائني الديون الخارجية وأصحاب العملة، كما تستخدم البنوك المركزية أيضا احتياطات الذهب للسيطرة على التضخم وكذلك تستخدمه من أجل الدفاع على عملاتها⁽¹⁾، كما أن بعض الدول واجهت به مشاكل مع ميزان المدفوعات، حيث استخدمت الذهب كحماية ضد القروض⁽²⁾.

ففي مرحلة الثمانينيات والتسعينيات فقد الذهب جاذبيته كأداة استثمارية في الأسواق المالية سريعة التطور، وفي العقد الأول من القرن الحادي والعشرين دفع الاقتصاد بسعر الذهب إلى الأعلى نتيجة الخوف وعدم اليقين الملحوظ مع الاضطرابات في الأسواق المالية أو بعبارة أخرى عدم اليقين في النظام العالمي المالي مما جذب انتباه المستثمرين مرة أخرى وتحويله إلى الأصل الأكثر جاذبية للمستثمرين خلال جميع فترات الأزمات. حيث اعتبر استثمار (ملاذ آمن) للمستثمرين بسبب السيولة العالية فيه وكذلك السلعة الأكثر جاذبية وقيمة حول العالم كاستثمار ذو عائد آمن نظرا لخصائصه الفريدة وكوسيلة تحويط في تنويع المحفظة، أي تغير دور الذهب من مخزن القيمة إلى الاستثمار الآمن ضد الخسائر المالية ومخاطر التضخم، أي اعتبر كأصل استثماري يستخدم كأداة لإدارة المخاطر في التحوط. ويستثمر المستثمرون فيه لتقليل خسائرهم المحتملة⁽³⁾، ومن ثم فإن سعر الذهب هو يعتبر مرآة للوضع الاقتصادي العالمي⁽⁴⁾.

بما أن سعر الذهب مدفوع بالعرض والطلب مثله مثل العديد من السلع الأساسية في عالم اليوم، ونظرا لارتفاع الطلب والعرض المحدود ازدادت أسعار الذهب بشكل بارز في هذا العصر كونها تلعب دورًا مهمًا في الأنظمة الاقتصادية والنقدية⁽⁵⁾، وبما أن سعر الذهب يتعرض لتحويلات

(1) Pitigalaarachchi, P. A. A. C., Jayasundara, D. D. M., & Chandrasekara, N. V. (2016). Modeling and forecasting Sri Lankan gold prices. *International Journal of Sciences: Basic and Applied Research*, 27(3), 247-260.p 247.

(2) Santika, I. W. K. G., Sa'adah, S., & Yunanto, P. E. (2021). Gold price prediction using Convolutional Neural Network-Long Short-Term Memory (CNN-LSTM). *Kinetik: Game Technology, Information System, Computer Network, Computing, Electronics, and Control*.p 231.

(3) Tripathy, N. (2017). Forecasting Gold Price with Auto Regressive Integrated Moving Average Model. *International Journal of Economics and Financial Issues*, 7(4).p 324.

(4) Quarm, R. S., & Busharads, M. O. E. (2020). Modeling and Forecasting Gold Prices (No. u5mz6). *Center for Open Science*.p 2.

(5) Aye, G., Gupta, R., Hammoudeh, S., & Kim, W. J. (2015). Forecasting the price of gold using dynamic model averaging. *International Review of Financial Analysis*, 41, 257-266.p 2.

كبيرة ومفاجئة قد تؤثر على الأسواق عالمياً ولذا ففهم العوامل التي تؤثر على تقلب أسعار الذهب أمر مهم من الناحيتين الاقتصادية والمالية حيث لا يمكن التحكم في سعر الذهب ، ولكن يمكن تقديره والتنبؤ به لتطوير قرارات مستقبلية. فلذا أصبح التنبؤ بسعر الذهب أمراً مهماً للغاية، حيث يتعامل الذهب بشكل مختلف عن المعادن الأخرى من حيث حركة الأسعار والإنتاج، لذلك من الضروري تطوير نموذج تنبؤ يعكس هيكل سوق الذهب⁽¹⁾.

كما يمكن أن تكون المساهمة في التنبؤ بسعر الذهب بطريقة جيدة مهمة للمستثمرين أو الاقتصاديين أو السياسيين أو أي وكيل يرى الذهب كمؤشر على الأداء المستقبلي للاقتصاد العالمي.

الإشكالية:

يعتبر التنبؤ وظيفية إدارية لتسهيل عملية اتخاذ القرار. ولذا يعد التنبؤ بالأسعار جزءاً لا يتجزأ من عملية صنع القرار الاقتصادي. حيث يمكن استخدام التنبؤات بعدة طرق من أجل تحديد السياسات الحكومية المثلى أو لصنع القرار الاعمال، وبما أن سعر الذهب يتطلع نحو المستقبل وأسعار اليوم تعتمد بشدة على مستقبل العرض والطلب . فيعد التنبؤ بأسعار الذهب من أكثر القضايا المهمة في الاقتصاد المالي اليوم كما أن التنبؤ الدقيق بسعر الذهب لا يساعد صانعي السياسة النقدية فحسب، بل سيساعد أيضاً مديري صناديق التحوط وكذلك بالنسبة للمستثمرين وأيضاً للازدهار الاقتصادي والاجتماعي في الوقت الحاضر، حيث تم استخدام نماذج رياضية مختلفة للتنبؤ بأسعار الذهب في العديد من الدراسات مثل نماذج *ARIMA* ونماذج *GARCH* والتي تعتبر من بين الأساليب أكثر شيوعاً في التنبؤ في العقود الثلاثة الماضية في تحليل السلسلة الزمنية العشوائية، حيث أكد العديد من الباحثين أن استخدامها في التنبؤ يعطي نتائج جيدة وأكثر دقة⁽²⁾.

حيث الافتراض الأساسي عند تطبيق هذا النماذج هو اعتبار السلاسل الزمنية خطية وتتبع توزيعاً إحصائياً معيناً مثل التوزيع الطبيعي ورغم ذلك، فغالبا ما تكون بيانات السلاسل الزمنية تتميز بعدم الخطية، مثل السلاسل الزمنية الاقتصادية والمالية⁽³⁾.

(1) Tripathy, N. (2017). Forecasting Gold Price with Auto Regressive Integrated Moving Average Model. *International Journal of Economics and Financial Issues*, 7(4).p 324.

(2) Yang, X. (2018). The Prediction of Gold Price Using ARIMA Model. *Advances in Social Science, Education and Humanities Research*, 196(2), 273-276.p276.

(3) Uche-Ikonne Okezie, O., Offorha Bright, C., & Ukomah Henry, I. (2020). Forecasting monthly prices of gold using artificial neural network. *Journal of Statistical and Econometric Methods*, 9(3), 19-28.p22.

ومن أجل معالجة هذا الأمر تعتبر الشبكات العصبية الاصطناعية كبديل للتنبؤ بالسلاسل الزمنية غير الخطية للتغلب على مشاكل الخطية وعدم الاستقرار حيث بينت العديد من الدراسات تفوقها على هذه النماذج من حيث الدقة والأداء⁽¹⁾، مما دفع إلى استخدامها للتنبؤ بالسلاسل الزمنية في العديد من المجالات مثل الأسواق المالية واستهلاك المياه والكهربائية والتنبؤ بالطقس .

وتعتبر الشبكات العصبية دالة الأساس الشعاعي (*Radial Basis Function Network*) أحد أهم أنواع الشبكات العصبية الاصطناعية المستخدمة في التنبؤ .

وبناءً على ما سبق طرحه قمنا بصياغة إشكالية الموضوع في السؤال التالي:

ما مدى فعالية الشبكة العصبية ذات دوال الأساس الشعاعي في التنبؤ بأسعار الذهب العالمية؟

وانطلاقاً من هذه الإشكالية وبغرض الإلمام بجميع جوانب الموضوع ارتأينا إلى تقسيم الإشكالية إلى عدة أسئلة ثانوية والتي سنحاول الإجابة عليها من خلال البحث وهي كالآتي:

- ما مدى إمكانية منهجية بوكس - جنكنز في صياغة نموذج جيد ملائم للتنبؤ بأسعار الذهب العالمية للفترة الزمنية الممتدة من 01 جانفي 2000 إلى 31 ديسمبر 2020؟
- ما مدى كفاءة الشبكة العصبية ذات دالة الأساس الشعاعي في التعامل مع مختلف السلاسل الزمنية للحصول على تنبؤات دقيقة للتنبؤ بأسعار الذهب العالمية للفترة الزمنية الممتدة من 01 جانفي 2000 إلى 31 ديسمبر 2020؟
- كيف يمكن استخدام الشبكة العصبية ذات دالة الأساس الشعاعي لتحديد أسعار الذهب العالمية للفترة الزمنية الممتدة من 01 جانفي 2000 إلى 31 ديسمبر 2020؟
- ما مدى فعالية النماذج الهجينة للتنبؤ بأسعار الذهب العالمية؟

الفرضيات :

- ولمعالجة إشكالية البحث اعتمادنا على الفرضيات التالية:
- الشبكة العصبية ذات دالة الأساس الشعاعي تعطي تنبؤات دقيقة إذا كانت السلسلة الزمنية غير خطية.

(1) Mombeini, H., & Yazdani-Chamzini, A. (2015). Modeling gold price via artificial neural network. *Journal of Economics, business and Management*, 3(7), 699-703.p699.

- تعطي الشبكة العصبية ذات دالة الأساس الشعاعي تنبؤات دقيقة مقارنة مع نموذج (ARIMA) والشبكة العصبية متعددة الطبقات *Perceptron*.
- النموذج الهجين بين *ARIMA-RBFNN* يعطي تنبؤات دقيقة.

أهداف الدراسة :

- تسعى هذه الدراسة إلى تحقيق الاهداف التالية :
- دراسة سلوك أسعار الذهب العالمية خلال فترة الدراسة.
- تحديد مبدا طريقة الشبكة العصبية ذات الأساس الشعاعي (*RBNN*).
- بناء نموذج الشبكات العصبية ذات دالة الأساس الشعاعي (*RBNN*) للتنبؤ بأسعار الذهب العالمية.
- تطبيق نموذج *MLPNN* للتنبؤ بأسعار الذهب العالمية.
- استخدام نموذج *ARIMA* للتنبؤ بأسعار الذهب العالمية.
- التحقق من مدى دقة وفعالية نموذج الشبكات العصبية ذات دالة الأساس الشعاعية مقارنة بنموذج *MLPNN* ونموذج *ARIMA* وذلك وفقا لمعيا دقة التنبؤ وممثل في جذر متوسط مربعات الأخطاء *RMSE*.
- تطبيق النماذج الهجينة للتنبؤ بأسعار الذهب العالمية.

أهمية الدراسة :

تتجلى أهمية الدراسة إلى تزويد صانعي القرار الاقتصادي بالمعلومات المستقبلية حول قضايا مهمة ويمكن اعتبار التنبؤ بأسعار الذهب من أكثر القضايا المهمة في الاقتصاد المالي. ومن جهة أخرى تنبع أهمية الدراسة في استخدام نماذج *ARIMA* و *ANN* والنماذج الهجينة للتنبؤ وبناء نموذج السلاسل الزمنية المناسبة. كما تناولت هذه الدراسة النظر في نهج جديدة يعد الانسب للتنبؤ بأسعار الذهب، الا وهي الشبكة العصبية ذات الأساس الشعاعي (*RBNN*) كونها تعد اداة مهمة للغاية للتنبؤ وبالإضافة إلى النماذج الهجينة التي أتبثت جدارتها في دقة التنبؤ.

حدود الدراسة :

تتمثل حدود هذه الدراسة فيما يلي :

- **الحدود المكانية :** تتمثل الحدود المكانية لهذه الدراسة في أسعار الذهب العالمية.
- **الحدود الزمانية :** تم الاعتماد البيانات الشهرية لاسعار الذهب العالمية للفترة الممتدة من 2000-01-01 إلى 2020-12-31 (بالدولار الأمريكي لكل أوقية) وتتكون من 252 مشاهدة لسعر الذهب الشهري، حيث تم الحصول على هذه البيانات من موقع البنك الدولي.

أسباب اختيار الموضوع :

- يعود سبب إختيار هذه الموضوع إلى جملة من الأسباب واهمها :
- الرغبة في البحث مجال الذهب خاصة اسعاره كونه عرف اهتمام كبير من طرف الباحثين في هذا المجال .
- توضيح مدى اهمية التنبؤ في المجال الاقتصادي إلى تزويد صانعي القرار الاقتصادي بالمعلومات المستقبلية حول قضايا مهمة.
- ومن بين أسباب اختيار هذا الموضوع تعود إلى ندرة الدراسات المتعلقة بأسعار الذهب باللغة العربية.

منهج البحث :

للإجابة عن إشكالية البحث ومحاولة اختبار مدى صحة الفرضيات التي تقوم عليها هذه الدراسة سيتم الاعتماد في دراستنا على المنهج الوصفي التحليلي والتقني في ما يتعلق بالجانب النظري للموضوع من خلال فهم مكونات الموضوع وإخضاعه للدراسة الدقيقة وتحليل جل أبعاده بشكل من التوضيح والتفسير. أما فيما يخص الجانب التطبيقي من الدراسة فتم الاعتماد على منهج دراسة الحالة. أما بالنسبة للأدوات والأساليب المستخدمة في الدراسة هي: SPSS 25، EVIEWS 11.

الدراسات السابقة :

▪ التنبؤ باستخدام النماذج القياسية :

▪ دراسة (Juma'at, 2021) (1)

هدفت هذه الدراسة إلى التنبؤ بأسعار الذهب باستخدام طريقة *Box – Jenkins* وطريقة انحدار السلاسل الزمنية كنموذج سببي للتنبؤ. البيانات المستخدمة في هذه الدراسة هي الأسعار اليومية من 25 مارس 2011 إلى 23 ماي 2011 ومن أجل المقارنة بين هذين النموذجين من أجل التقييم تم الاعتماد على متوسط الانحراف المطلق *MAD* ومتوسط النسبة المئوية للخطأ المطلق *MAPE*، اظهرت النتائج إلى أن طريقة انحدار السلاسل الزمنية أنتجت قيمة أصغر لـ *MAD* و *MAPE* مقارنة بنموذج *ARIMA(0,2,1)*.

▪ دراسة (Sahed, 2020) : (2)

تناولت هذه الدراسة إلى استخدام نموذج الانحدار الضبابي المتكامل (*FARIMA*) والمتوسط المتحرك للتنبؤ بأسعار الذهب، وكان الهدف الرئيسي هو تقدير المعلمات الكسرية باستخدام طريقة الانحدار الضبابي لـ *TANAKA*. حيث تم قياس دقة التنبؤ بطريقة *FARIMA* ومقارنتها مع طريقة *ARIMA* باستخدام متوسط مربع الخطأ (*MSE*) وجذر متوسط مربع الخطأ (*RMSE*) للفترة الزمنية من 2010 إلى 2018. كما تم توقع أسعار الذهب باستخدام الطريقتين للسنة 2019. أظهرت النتائج أن نماذج *FARIMA* أكثر كفاءة من نماذج *ARIMA* في التنبؤ بأسعار الذهب.

▪ دراسة (Yang X.T, 2019) (3)

تركز هذه الدراسة على أرقام أسعار الذهب من شهر جوان 2013 إلى شهر جويلية 2018 وفقاً لمجلس الذهب العالمي، وتهدف إلى التنبؤ وتحليل سعر الذهب اليومي للدولار الأمريكي في النصف الأول من شهر جويلية 2018 من خلال إنشاء نموذج *ARIMA*. تستخدم هذه الدراسة

(1) Juma'at, N., & Sazeli, Z. A. (2021). Comparison between Causal Model and Time Series Model to Forecast Gold Prices. *Multidisciplinary Applied Research and Innovation*, 2(1), 156-163.

(2) Sahed, A., Mekidiche, M., & Kahoui, H. (2020). Fuzzy Auto-Regressive Integrated Moving Average (*FARIMA*) Model for Forecasting the Gold Prices. *Journal of Smart Economic Growth*, 5(1), 1-13.

(3) Yang, X. (2019, January). The Prediction of Gold Price Using *ARIMA* Model. In *2nd International Conference on Social Science, Public Health and Education (SSPHE 2018)* (pp. 273-276). Atlantis Press.

أيضاً BIC و AIC و PAC و AC لتقدير دقة النماذج. بينت النتائج التجريبية أن $ARIMA(3,1,2)$ هو أفضل نموذج للتنبؤ بسعر الذهب بالدولار الأمريكي.

دراسة (HALIM, 2019) (1) :

هدفت هذه الدراسة إلى تحديد أفضل نموذج للتنبؤ بأسعار سلع الذهب بالإضافة إلى التنبؤ بأسعار سلع الذهب العالمية في 2018 وذلك باستخدام منهجية *Box-Jenkins*. تم الحصول على البيانات المستخدمة في هذه الدراسة من موقع *Investing.Com* من عام 2015 حتى عام 2017. أظهرت النتائج أن نموذج $ARIMA(1,1,1)$ هو أفضل نموذج للتنبؤ بأسعار السلع الذهبية على أساس متوسط نسبة الخطأ المطلق ($MAPE$). حيث بلغت قيمة $MAPE$ لنموذج $ARIMA(1,1,1)$ 0.02%، حيث تثبت هذه القيمة أن التنبؤ باستخدام نموذج $ARIMA(1,1,1)$ هو أفضل توقع لأن قيمة $MAPE$ أقل من 10%.

دراسة (Yang X., 2018) (2)

ارتكزت هذه الدراسة على رقم أسعار الذهب من شهر جويلية 2013 إلى شهر جوان 2018، حيث هدف إلى التنبؤ وتحليل سعر الذهب اليومي للدولار الأمريكي في النصف الأول من شهر جويلية 2018 من خلال إنشاء نموذج $ARIMA$ ، تم استخدام معايير AC و PAC و AIC و BIC لتقدير دقة النماذج. أظهرت النتائج التجريبية أن نموذج $ARIMA(3,1,2)$ هو أفضل نموذج للتنبؤ بسعر الذهب بالدولار الأمريكي.

دراسة (Tripathy, 2017) (3):

تناولت هذه الدراسة التنبؤ بسعر الذهب في الهند باستخدام نموذج الانحدار الذاتي والمتوسطات المتحركة ($ARIMA$) على مدى فترة 25 عاما من يوليو 1990 إلى فبراير 2015. كما تستخدم الدراسة عدة معايير من أجل تقييم دقة النموذج وهي كالتي: متوسط الخطأ المطلق (MAE).

(1) NUR ATIKAH KHALID AND NURFADHLINA ABDUL HALIM.(2019). GOLD PRICE FORECASTING USING BOX-JENKINS METHOD. *Universiti Malaysia Terengganu Journal of Undergraduate Research* . Volume 1 Number 3, Julai 2019: 15-27.

(2) Yang, X. (2018). The Prediction of Gold Price Using ARIMA Model. *Advances in Social Science, Education and Humanities Research*, 196(2), 273-276.

(3) Tripathy, N. (2017). Forecasting Gold Price with Auto Regressive Integrated Moving Average Model. *International Journal of Economics and Financial Issues*, 7(4).

جذر متوسط مربع الخطأ، النسبة المئوية القصوى للخطأ المطلق، والخطأ المطلق الأقصى ($Max AE$)، ومتوسط نسبة الخطأ المطلق ($MAPE$). أظهرت نتائج الدراسة إلى أن نموذج $ARIMA(0,1,1)$ هو أنسب نموذج يُستخدم للتنبؤ بأسعار الذهب الهندية نظرًا لاحتوائه على الأقل على $Max AE$ و MAE ، حيث تشير الدراسة إلى أن سعر الذهب في الشهر الماضي له تأثير كبير على سعر الذهب الحالي. كما تعتبر نتيجة الدراسة مهمة بشكل خاص للمستثمرين والاقتصاديين ومنظمي السوق وواضعي السياسات لفهم فعالية سعر الذهب لاتخاذ قرارات استثمارية أفضل وابتكار أدوات أفضل لإدارة المخاطر.

دراسة (Ho, 2017):⁽¹⁾

تتناول هذه الدراسة التنبؤ بأسعار الذهب في فيتنام باستخدام نموذج $ARIMA$ الذي طوره جورج بوكس وجويليم جنكينز 1976، حيث توصلت الدراسة إلى استنتاج مفاده كيف يمكن للمستثمرين تجنب المخاطر المتعلقة بتقلب الأسعار في السوق الدولية مع الذهب، وكذلك كيف سيؤثر هذا التطور على أسعار الذهب في فيتنام في السوق الآجلة. كما يعتبر نموذج $ARIMA(5,1,5)$ ممتاز في هذه الحالة حيث يبلغ الخطأ المتوقع حوالي 3.46%.

دراسة (Ali, 2016):⁽²⁾

هدفت هذه الدراسة للتنبؤ بسعر الذهب اليومي باستخدام منهجية $Box-Jenkins$ حيث تم استخدام مجموعة بيانات دولارات الولايات المتحدة للأونصة من 02 يناير 2014 إلى 3 يوليو 2015 للغرض التنبؤ. أظهرت النتائج أن نموذج $ARIMA(1,1,0)$ ونموذج $ARIMA(0,1,1)$ قريبة من كل منهما أخرى للتنبؤ بسعر الذهب اليومي حسب معيار اختيار النموذج (SBC و AIC)، تكشف القيم المتنبئة أن نموذج $ARIMA(0,1,1)$ أكثر كفاءة من $ARIMA(1,1,0)$ على أساس معايير اختيار النموذج: متوسط الخطأ المطلق (MAE)، متوسط النسبة المئوية للخطأ المطلق ($MAPE$) وجذر متوسط مربع الخطأ ($RMSE$).

(1) Ho, T. T., Phan, D., Nguyen, V. N., & Sipko, J. (2017). Application of ARIMA model to forecast gold price in Vietnam. 11th International Days of Statistics and Economics.

(2) Ali, A., Ch, M. I., Qamar, S., Akhtar, N., Mahmood, T., Hyder, M., & Jamshed, M. T. (2016). Forecasting of daily gold price by using Box-Jenkins methodology. International Journal of Asian Social Science, 6(11), 614-624.

دراسة (Naz, 2016) (1)

هدفت هذه الدراسة إلى استخدام نماذج *ARIMA* المعروفة بمنهجية *Box - Jenkins* للتنبؤ بأسعار الذهب الهندية لتقدير معاملات النموذج المناسب من أجل تطوير نموذج أحادي المتغير، حيث تم استخدام البيانات الشهرية لمدة 38 عامًا (من جانفي 1979 إلى فيفري 2017)، بينت النتائج إلى أن نموذج *ARIMA(1,1,1)* هو النموذج المناسب في إطار منهجية *Box Jenkins* لتحديد النموذج، وتقدير المعلمات، والفحص التشخيصي والتنبؤ بالأسعار المستقبلية مما يساعد في التنبؤ بالقيم المستقبلية للذهب.

دراسة (Guha, 2016) (2)

هدفت هذه الدراسة إلى تطبيق نموذج السلاسل الزمنية *ARIMA* للتنبؤ بسعر الذهب المستقبلي في الهندي استنادًا إلى البيانات السابقة من نوفمبر 2003 إلى يناير 2014 للتخفيف من مخاطر شراء الذهب، ومن ثم إعطاء دليل إرشادي للمستثمر عند شراء أو بيع المعدن الأصفر. بينت النتائج أن نموذج *ARIMA* يساعدنا في التنبؤ بالقيم المستقبلية للذهب. إلى أن هناك قيود معينة في التنبؤ بالبيانات باستخدام نموذج *ARIMA*. حيث تستخدم هذه التقنية في المدى قصير فقط من أجل اكتشاف الاختلاف البسيط في البيانات. ففي حالة التغير المفاجئ، في مجموعة البيانات (عندما يكون الاختلاف كبيرًا) في حالة التغير في السياسات الحكومية أو عدم الاستقرار الاقتصادي (الانهيار الهيكلي) وما إلى ذلك، يصبح من الصعب التقاط الاختلافات الدقيقة، ومن ثم يصبح هذا النموذج غير فعال للتنبؤ كون التنبؤ بهذه الطريقة يعتمد على افتراض البيانات التاريخية الخطية ولكن لا يوجد دليل على أن سعر الذهب خطي بطبيعته.

دراسة (Khan, 2013) (3) :

- (1) Naz, F., & Ahmad, Z. (2016). Forecasting of Indian Gold Prices Using Box Jenkins Methodology. *Journal of Indian Studies*, 2(1), 75-83.
- (2) Guha, B., & Bandyopadhyay, G. (2016). Gold price forecasting using ARIMA model. *Journal of Advanced Management Science*, 4(2).
- (3) Khan, M. M. A. (2013). Forecasting of gold prices (Box Jenkins approach). *International Journal of Emerging Technology and Advanced Engineering*, 3(3), 662-670.

هدفت هذه الدراسة إلى محاولة لتطوير نموذج تنبؤ لأسعار الذهب. من خلال استخدام منهجية *Box-Jenkins* المعروفة بنماذج الانحدار الذاتي المتكامل والمتوسطات المتحركة (*ARIMA*) لبناء نموذج التنبؤ. حيث تم أخذ بيانات نموذجية لأسعار الذهب (بالدولار الأمريكي للأونصة) من 02 يناير 2003 إلى 1 مارس 2012. تم استخدام البيانات حتى 2 يناير 2012 لبناء النموذج بينما تم استخدام الباقي للتنبؤ بسعر الذهب وتحقيق من دقة النموذج ولاختبار دقة التنبؤ، يتم حساب جذر متوسط مربع الخطأ، ومتوسط الخطأ المطلق، ومتوسط النسبة المئوية للخطأ المطلق. تشير النتائج إلى أن نموذج $ARIMA(0,1,1)$ هو الأنسب للتنبؤ بسعر الذهب.

دراسة (MOHAMED, 2011)⁽¹⁾:

هدفت هذه الدراسة إلى تطوير نماذج الانحدار الذاتي المشروط غير المتجانسة المعمم (*GARCH*) والانحدار الذاتي والمتوسطات المتحركة المتكاملة (*ARIMA*) لإنتاج تنبؤات قصيرة المدى لأسعار الذهب. تم تطوير نموذج *GARCH* نظرًا لقدرته على التقاط التقلبات من خلال عدم ثبات التباين الشرطي بينما يتم استخدام التنبؤات التي ينتجها نموذج *ARIMA* كمعيار. تستند مقارنة التوقعات التي تنتجها نماذج *GARCH & ARIMA* إلى مقياسين للأداء: نسبة الخطأ المطلق (*MAPE*) وجذر جذر متوسط مربع الخطأ (*RMSE*)، يتم إجراء التحليلات باستخدام برنامج *Minitab* و *E-Views*، بينت النتائج أن نموذج *GARCH* هو طريقة محتملة للتنبؤ ببيانات يوم التداول لأسعار الذهب.

دراسة (Ismail, 2009)⁽²⁾:

هدفت هذه الدراسة إلى تطوير نموذج تنبؤي لتوقع أسعار الذهب على أساس عوامل اقتصادية مثل التضخم وحركات أسعار العملات وغيرها. حيث تم استخدام نموذج الانحدار الخطي المتعدد (*MLR*) الذي يعد الأنسب لفهم أسعار الذهب كون هذا النموذج يقوم بدراسة العلاقة بين متغير تابع واحد ومتغير مستقل واحد أو أكثر، كما هو الحال مع سعر الذهب باعتباره المتغير الوحيد التابع. أخذ النموذج الأول في الاعتبار جميع المتغيرات المستقلة الممكنة، والثاني تناول فقط بعض المتغيرات

(1) Mohamed, s. N. H. B. (2011). *Short-term forecast of gold price using generalized autoregressive conditional heteroscedastic (Doctoral dissertation, University Technology Malaysia*

(2) Ismail, Z., Yahya, A., & Shabri, A. (2009). *Forecasting gold prices using multiple linear regression method. American Journal of Applied Sciences, 6(8), 1509.*

المستقلة (مؤشر مكتب أبحاث السلع، وسعر صرف اليورو / السلع، وأذون الخزانة) أثناء التنبؤ. بينت النتائج أن النموذج الثاني له مستوى عال من دقة التنبؤ مقارنة بالنموذج الأول.

▪ التنبؤ بأسعار الذهب باستخدام الشبكات العصبية الاصطناعية :

إنّ الدراسات التي تناولت التنبؤ أو نمذجة أسعار الذهب باستخدام الشبكات العصبية الاصطناعية قليلة.

دراسة (Uche-Ikonne Okezie, 2020)⁽¹⁾ :

هدفت هذه الدراسة إلى تركيب شبكة عصبية اصطناعية لسلسلة أسعار الذهب. كانت البيانات المستخدمة هي أسعار الذهب الشهرية بالدولار الأمريكي والسنت لكل أونصة تروي من أكتوبر 2004 إلى فبراير 2020. فمن بين 17 بنية شبكة عصبية اصطناعية مقترحة، تم اختيار $ANN(2,6,1)$ الشبكة العصبية 2 و6 و1 من الخلايا العصبية في طبقات الإدخال والمخفية من خلال حصوله على أقل خطأ، وهو خطأ مربع متوسط (MSE) ومتوسط خطأ مطلق (MAE). تم تأكيد كفاية النموذج المختار بشكل أكبر من خلال الفحص البياني للقيم الفعلية لأسعار الذهب وتلك التي تنبأ بها النموذج بالإضافة إلى تحليل البياني للباقي، وأخيراً تم إجراء التنبؤات باستخدام الشبكة المختارة. تشير التوقعات إلى انخفاض أسعار الذهب في الأشهر المقبلة.

دراسة (Mahat, 2019)⁽²⁾ :

تناولت هذه الدراسة التنبؤ بسعر الذهب الماليزي باستخدام الشبكة العصبية الاصطناعية (NN)، حيث يتم تنفيذ نماذج التنبؤ باستخدام برنامج *Alyuda Neurointelligence*. تم استخدام بيانات أسعار الذهب الشهرية من يناير 2013 حتى مارس 2018 وتطبيقها على النماذج ومقارنة مقاييس الخطأ الخاصة بهم.

(1) Uche-Ikonne Okezie, O., Offorha Bright, C., & Ukomah Henry, I. (2020). Forecasting monthly prices of gold using artificial neural network. *Journal of Statistical and Econometric Methods*, 9(3), 19-28.

(2) Mahat, N., Yusuf, A. M., & Raseli, S. S. (2019). Forecasting Malaysia gold's price by using neural networks. *Jurnal Intelek*, 14(2), 126-134.

بينت النتائج أن خوارزمية التدرج ((CGA Conjugate Gradient Algorithm)) تم اختيارها كأفضل خوارزمية للشبكة العصبية للتنبؤ بسعر الذهب كونها أعطت أقل قيمة لمتوسط مربع الخطأ MSE ومن تم استنتاج أن خوارزمية CGA يمكنها التنبؤ بسعر الذهب بدقة أكبر في ماليزيا.

دراسة (Krishna, 2019) (1) :

هدفت هذه الدراسة إلى تطوير نموذج تنبؤي للتنبؤ بأسعار الذهب اليومية في الهند بدقة عالية. تم جمع الأسعار التاريخية للذهب من 1 جانفي 2014 إلى 24 جويلية 2018، تم استخدام نموذج الانحدار الذاتي والمتوسطات المتحركة المتكاملة (ARIMA) والشبكات العصبية الاصطناعية (ANN) للتنبؤ بأسعار الذهب اليومية في الهند، تم تقييم أداء نموذج التنبؤ باستخدام متوسط الخطأ المطلق (MAE)، والنسبة المئوية للخطأ المطلق (MAPE) وجذر متوسط الخطأ التربيعي (RMSE). أظهرت النتائج أن نموذج الشبكات العصبية الأمامية (FFNN) يتفوق على نموذج ARIMA التقليدي.

دراسة (Nor, 2017) (2) :

هدفت هذه الدراسة إلى مقارنة الأداء التنبؤي بين الشبكة العصبية وطريقة التنبؤ بالسلاسل الزمنية الكلاسيكية أي نماذج المتوسطات المتحركة المتكاملة الموسمية ذات الانحدار الذاتي باستخدام بيانات أسعار الذهب. وتم استخدام معيار متوسط الانحراف المطلق وجذر متوسط مربع الخطأ وخطأ النسبة المئوية المطلقة لتقييم دقة التنبؤ. بينت النتائج أن نموذج MLP أنتجت أكثر التنبؤات دقة عندما تم استخدام تحويل Box – Cox كعلاج مسبق للبيانات.

دراسة (Sivalingam, 2016) (3) :

تناولت هذه الدراسة إلى التنبؤ بأسعار الذهب المستقبلية باستخدام خوارزمية تعلم جديدة تسمى Learning ELM والتي تتمتع بإمكانية تعلم جيدة وقدرة على التعميم. الفترة المستخدمة للدراسة من 1 جانفي 2000 إلى 31 أبريل 2014. ولكون أن سعر الذهب مرتبط بسلع أخرى، يتم إعطاء أربع سلع مثل البيانات التاريخية لأسعار الذهب وأسعار الفضة وأسعار النفط الخام ومؤشر

(1) Krishna, K. M., Reddy, N. K., & Sharma, M. R. Forecasting of Daily Prices of Gold in India using ARIMA & FFNN Models.

(2) Nor, M. E., Safuan, H. M., Shab, N. F. M., Asrul, M., Abdullah, A., Mohamad, N. A. I., & Lee, M. H. (2017, May). Neural network versus classical time series forecasting models. In AIP Conference Proceedings (Vol. 1842, No. 1, p. 030027). AIP Publishing LLC.

(3) Sivalingam, K. C., Mahendran, S., & Natarajan, S. (2016). Forecasting gold prices based on extreme learning machine. International Journal of Computers Communications & Control, 11(3), 372-380.

ومن أجل التأكد من فعالية هذه الخوارزمية تم مقارنتها مع شبكات التغذية الأمامية بدون تغذية عكسية، وشبكات الانتشار الخلفي للخطأ، ونموذج تعلم *ELM*. بينت النتائج أن تعلم *ELM* يؤدي بشكل أفضل من الطرق الأخرى.

دراسة: (Mombeini, 2015) (1)

تناولت هذه الدراسة استخدام نموذج الشبكة العصبية الاصطناعية (*ANN*) لنمذجة سعر الذهب، ومقارنتها بالنموذج الإحصائي *ARIMA* (المتوسط المتحرك الانحدار التلقائي). يتم استخدام مقاييس الأداء الثلاثة، معامل التحديد (R^2)، جذر متوسط مربع الخطأ (*RMSE*)، الخطأ المطلق (*MAE*)، لتقييم أداء النماذج. بينت النتائج أن نموذج *ANN* يتفوق على نموذج *ARIMA* من حيث معايير الأداء المختلفة أثناء مرحلتي التدريب والتحقق.

دراسة (Moradi, 2015): (2)

تناولت هذه الدراسة التنبؤ بسعر الذهب باستخدام الشبكة العصبية *GMDH* والشبكة العصبية متعددة الطبقات *Perceptron (MLP)*، وكذلك تحديد النموذج الأفضل باستخدام معايير تقييم الأداء. أظهرت النتائج وفقاً لمعايير تقييم الأداء أن الشبكة العصبية *GMDH* لها قدرة عالية للتنبؤ بسعر الذهب مقارنة مع الشبكة العصبية *MLP*.

دراسة (ألفت فتحي سالم أبو عابدة، 2015) (3):

هدفت هذه الدراسة إلى استخدام منهجية *Box-Jenkins (B-J)* المعروفة بنماذج *ARIMA* والشبكات العصبية الاصطناعية للتنبؤ بأسعار الذهب العالمية من خلال من خلال دراسة وتحليل بيانات السلسلة الزمنية لمؤشر أسعار الذهب العالمية في الفترة الزمنية من يناير 1985م إلى ديسمبر 2014م والذي يمثل 360 مشاهدة حيث كانت الأسعار بالدولار الأمريكي للأونصة.

(1) Mombeini, H., & Yazdani-Chamzini, A. (2015). Modeling gold price via artificial neural network. *Journal of Economics, business and Management*, 3(7), 699-703

(2) Moradi, H., Joka, I., & Forouzantabar, A. (2015). Modelling and forecasting gold price using *GMDH* neural network. *Indian Journal of Fundamental and Applied Life Sciences*, 5(1), 30-41

(3) ألفت فتحي سالم أبو عابدة (2015)، استخدام الطرق الإحصائية في التنبؤ بأسعار الذهب العالمية، رسالة ماجستير، كلية الاقتصاد والعلوم الإدارية، جامعة الأزهر، غزة.

ومن خلال تطبيق منهجية (B - J) أسلوب الانحدار الذاتي والمتوسطات المتحركة التكاملية توصلت الدراسة إلى أن النموذج الأمثل لتمثيل البيانات من بين نماذج ARIMA هو النموذج $ARIMA(2,1,1)$ وقد تم اختيار هذا النموذج بناء على استخدام المعايير الإحصائية حيث استخدم معيار AIC بينما عند استخدام أسلوب الشبكات العصبية الاصطناعية ANN النموذج $MLPNN(2-2-1)$ هو الأفضل من بين نماذج الشبكات العصبية لتمثيل البيانات حيث تم اختيار هذا النموذج بناء على المعايير BIC ومعيار AIC وتمت المفاضلة بين هذين الأسلوبين من حيث دقة التنبؤ وكفاءته، باستخدام معيار AIC. بينت النتائج الإحصائية إلى أن نموذج الشبكات العصبية الاصطناعية $MLPNN(2-2-1)$ هو النموذج الأمثل. وبناءً على تلك النتائج تم الاعتماد عليه في التنبؤ بالقيم المستقبلية لسلسلة أسعار الذهب العالمية.

دراسة (Kocak, 2014): (1)

يعد الذهب كأداة استثمار مهمة خاصة في الدول النامية، لذا يعتبر التنبؤ بعائد الذهب من المواضيع التي جذبت انتباه المستثمرين وعرفت مؤخرًا دراسات مكثفة، ولهذا السبب يتم استخدام طرق مختلفة للتنبؤ بعائد الذهب وتتم مقارنة فعالية هذه الطرق.

فالغرض من هذه الدراسة هو التنبؤ بعائد الذهب باستخدام الشبكات العصبية الاصطناعية ونماذج GARCH، فترة الدراسة امتدت من فيفري 2014 إلى جوان 2014، تم الحصول على السلسلة من بورصة الذهب التركية. بينت النتائج أن الشبكات العصبية الاصطناعية ANN قدمت نتائج أقل نجاحًا مقارنة بطريقة GJR GARCH.

دراسة (Yazdani-Chamzini, 2012): (2)

هدفت هذه الدراسة إلى استخدام نظام الاستدلال العصبي الضبابي التكيفي (ANFIS) ونموذج الشبكة العصبية الاصطناعية (ANN) لنمذجة سعر الذهب، ومقارنتها بالنموذج الإحصائي ARIMA

(1) Kocak, H., & Un, T. (2014). Forecasting the gold returns with artificial neural network and time series. *International Business Research*, 7(11), 139-152.

(2) Yazdani-Chamzini, A., Yakhchali, S. H., Volungevičienė, D., & Zavadskas, E. K. (2012). Forecasting gold price changes by using adaptive network fuzzy inference system. *Journal of Business Economics and Management*, 13(5), 994-1010.

(نموذج الانحدار الذاتي المتكامل والمتوسط المتحرك). تم استخدام مقاييس الأداء الثلاثة، معامل التحديد، (R^2) جذر متوسط مربع الخطأ $(RMSE)$ ، الخطأ المطلق (MAE) ، لتقييم أداء النماذج الثلاثة. أظهرت النتائج أن نموذج $ANFIS$ يتفوق على نموذج ANN و $ARIMA$ ، من حيث معايير الأداء المختلفة أثناء مرحلتي التدريب والتحقق. كما أظهر تحليل الحساسية أن تغيرات أسعار الذهب تعتمد بشكل كبير على قيم أسعار الفضة وأسعار النفط.

▪ التنبؤ باستخدام النماذج الهجينة :

دراسة (Salisu، 2021) (1) :

هدفت هذه الدراسة إلى تقييم دور الذهب كملاذ آمن أو تحوط ضد مخاطر أسعار النفط الخام باستخدام نموذج $(VARMA-GARCH)$ غير متماثل (asymmetric)، تم استخدام البيانات اليومية من جانفي 2016 إلى أوت 2020. لحساب تأثير جائحة $COVID-19$ ، تم تقسيم البيانات إلى قسمين: القسم الأول يتضمن فترات قبل الجائحة والقسم الثاني أثناءها. أظهرت النتائج التجريبية أن الذهب يمثل ملاذا آمنا ومهما ضد مخاطر أسعار النفط. كما أنّ التحليلات المثلى للمحفظة والتحوط التي تم إجراؤها تؤكد أيضا فعالية التحوط للذهب ضد المخاطر المرتبطة بالنفط. تم تأكيد متانة نتائج أيضا باستخدام ثلاثة معادن ثمينة بارزة أخرى - الفضة والبلاطين والبلاديوم. بينت النتائج أنّ استخدام الذهب والمعادن الثمينة الأخرى كأدوات لإعادة موازنة المحفظة لتقليل المخاطر المرتبطة بعائدات النفط المتقلبة مفيدة للمستثمرين ومديري المحافظ.

دراسة (Pannakkong، 2019) (2) :

هدفت هذه الدراسة إلى تطبيق نمودجا هجين جديدا للتنبؤ يجمع بين نموذج الانحدار الذاتي والمتوسطات المتحركة $(ARIMA)$ والشبكة العصبية الاصطناعية (ANN) مع دمج المتوسط المتحرك والمؤشر الموسمي السنوي لتصدير الكسافا في تايلاند (أي النشا الأصلي والنشا المعدل والساغو)، تم إجراء التجارب الشاملة للتحقق من المعلمات المناسبة للنموذج المقترح بالإضافة إلى نماذج التنبؤ الأخرى التي تمت مقارنتها، حيث تم مقارنة النموذج المقترح مع نموذج $ARIMA$ و ANN والنماذج الهجينة

(1) Salisu, A. A., Vo, X. V., & Lawal, A. (2021). Hedging oil price risk with gold during COVID-19 pandemic. *Resources Policy*, 70, 101897.

(2) Pannakkong, W., Huynh, V. N., & Sriboonchitta, S. (2019). A novel hybrid autoregressive integrated moving average and artificial neural network model for cassava export forecasting. *International Journal of Computational Intelligence Systems*, 12(2), 1047-1061

الأخرى، ومن أجل المقارنة بين هذه النماذج تم استخدام متوسط مربع الخطأ (MSE)، ومتوسط الخطأ المطلق (MAE) ومتوسط نسبة الخطأ المطلق (MAPE) لقياس دقة التنبؤ. أظهرت النتائج التجريبية أن النموذج المقترح يعطي أقل خطأ في جميع المقاييس الثلاثة للنشا الأصلي والنشا المعدل والتي تعتبر من المنتجات الرئيسية المصدرة للكسافا (98٪ من إجمالي حجم الصادرات)، وكما أعتبر نموذج Khashei و Bijari أفضل نموذج للساجو (2٪ من إجمالي حجم الصادرات)، ولهذا يمكن استخدام النموذج المقترح كطريقة توقع بديلة لأصحاب المصلحة الذين يتخذون قرارا في تجارة الكسافا الدولية للحصول على دقة أفضل في التنبؤ بالتصدير المستقبلي للنشا الأصلي والنشا المعدل والتي تشكل غالبية إجمالي الصادرات.

دراسة (bin Khamis, 2018)(1):

هدفت هذه الدراسة لمقارنة أداء التنبؤ للشبكة العصبية الاصطناعية والنموذج الهجين للشبكة العصبية الاصطناعية والخوارزمية الجينية. بيانات السلاسل الزمنية المستخدمة هي السعر الشهري لكل أونصة من الذهب بالدولار الأمريكي من عام 1987 إلى 2016. تم اقتراح شبكة عصبية اصطناعية مدربة بواسطة خوارزمية الانتشار الخلفي ونموذج التنبؤ الهجين للشبكة العصبية الاصطناعية والخوارزميات الجينية. حيث تستخدم الخوارزمية الجينية لتحسين الخلايا العصبية الاصطناعية للشبكة العصبية. تم استخدام ثلاثة مقاييس دقة تنبؤية وهي الخطأ المطلق جذر متوسط مربع الخطأ ومتوسط خطأ النسبة المئوية المطلقة لمقارنة دقة التنبؤ بالشبكة العصبية الاصطناعية والهجين للشبكة العصبية الاصطناعية ونموذج التنبؤ بالخوارزمية الجينية.

تم مقارنة ملائمة النموذج باستخدام معامل التحديد. أظهرت النتائج أن النموذج الهجين للشبكة العصبية الاصطناعية تفوق على الشبكة العصبية الاصطناعية مدربة بواسطة خوارزمية الانتشار الخلفي من حيث دقة التنبؤ.

دراسة (Yussof, 2016)(2):

هدفت هذه الدراسة إلى التنبؤ بأسعار الذهب الماليزي، المعروف باسم Kijang Emas باستخدام النموذج الهجين المتضمن الشبكة العصبية الاصطناعية (ANN) ونموذج GARCH، يتم استخدام تقديرات

(1) bin Khamis, A., & Yee, P. H. (2018). A Hybrid Model of Artificial Neural Network and Genetic Algorithm in Forecasting Gold Price. *European Journal of Engineering and Technology Research*, 3(6), 10-14

(2) Yussof, F. N. M., Ahmad, M. H., & Osman, H. (2016). Modelling and Forecasting Malaysian Gold Price Using Hybrid ANN-GARCH. In *International Mathematical Forum* (Vol. 11, No. 6, pp. 287-294).

التقلب التي تم الحصول عليها بواسطة نموذج $GARCH$ كأحد متغيرات الإدخال في ANN . يتم تقييم أداء النماذج عن طريق حساب معايير المعلومات (AIC)، الخطأ المطلق (MAE) وجذر متوسط مربع الخطأ ($RMSE$)، أظهرت النتائج أن النموذج الهجين $ANN - GARCH$ هو نموذج أفضل مقارنة مع النماذج الفردية.

دراسة (Yaziz S. R.-J.-G.-2., 2015) (1):

هدفت هذه الدراسة إلى تحليل أولي لأسعار الذهب وتقلباته حيث ارتكزت على أداء نماذج $Box-Jenkins$ الهجينة جنباً إلى جنب مع $GARCH$ في تحليل أسعار الذهب والتنبؤ بها. تم استخدام صيغة $Box-Cox$ كطريقة لتحويل البيانات نظراً لأفضل ممارساتها المحتملة في تطبيع البيانات وتثبيت التباين وتقليل التغايرية باستخدام سلسلة بيانات أسعار الذهب اليومية لمدة 41 عاماً. تبين من خلال النتائج أن النموذج الهجين المقترح $GARCH - ARIMA$ يعطي أداء أفضل في التنبؤ بسعر الذهب. حيث أظهرت هذه النتيجة قوة $GARCH$ في التعامل مع التقلبات في سعر الذهب بالإضافة إلى التغلب على القيود غير الخطية في نمذجة $Box-Jenkins$.

دراسة (Kristjanpoller، 2015) (2):

تناولت هذه الدراسة إلى توسيع مجال الأنظمة الخبيرة والتنبؤ والنمذجة من خلال تطبيق شبكة عصبية اصطناعية (ANN) على طريقة $GARCH$ لتوليد $ANN - GARCH$. يتم تطبيق نموذج $ANN - GARCH$ الهجين للتنبؤ بتقلب أسعار الذهب (الفوري والمستقبلي). أظهرت النتائج تحسناً عاماً في التنبؤ باستخدام $ANN - GARCH$ مقارنة بطريقة $GARCH$ وحدها.

دراسة: (Yaziz S. R.-G.-6., 2013) (3)

(1) Yaziz, S. R., Azizan, N. A., Ahmad, M. H., Zakaria, R., Agrawal, M., & Boland, J. (2015, February). Preliminary analysis on hybrid Box-Jenkins-GARCH modeling in forecasting gold price. In AIP Conference Proceedings (Vol. 1643, No. 1, pp. 289-297). American Institute of Physics.

(2) Kristjanpoller, W., & Minutolo, M. C. (2015). Gold price volatility: A forecasting approach using the Artificial Neural Network-GARCH model. Expert systems with applications, 42(20), 7245-7251.

(3) Yaziz, S. R., Azizan, N. A., Zakaria, R., & Ahmad, M. H. (2013, December). The performance of hybrid ARIMA-GARCH modeling in forecasting gold price. In 20th International Congress on Modelling and Simulation, Adelaide (pp. 1-6).

تبحث هذه الدراسة في أداء تهجين السلاسل الزمنية أحادية المتغير المحتملة على وجه التحديد نماذج $ARIMA$ مع نموذج التقلب الفائق، $GARCH$ يتكامل مع صيغة تحويل $Box - Cox$ في تحليل وتوقع أسعار الذهب. حيث يتم استخدام تحويل $Box - Cox$ كتحويل للبيانات نظرًا لقوتها في تطبيع البيانات، واستقرار التباين وتقليل التغايرية. أظهرت النتائج التجريبية إلى أن النموذج الهجين المقترح $ARIMA - GARCH$ قد حسن دقة التقدير والتنبؤ بخمسة أضعاف مقارنة بطريقة التنبؤ المحددة مسبقًا. تشير النتائج إلى أن الجمع بين $ARIMA$ (القوة والمرونة) و $GARCH$ (قوة النماذج في التعامل مع التقلبات والمخاطر في سلسلة البيانات) لديه القدرة على التغلب على القيود الخطية والبيانات في نماذج $ARIMA$ ، وبالتالي فإن النموذج الهجين $ARIMA - GARCH$ هو نهج جديد وواعد في نمذجة أسعار الذهب والتنبؤ بها.

دراسة (Khashei, 2010)⁽¹⁾:

هدفت هذه الدراسة إلى تطبيق نماذج الانحدار الضبابي لبناء نموذج هجين جديد من الشبكات العصبية الاصطناعية من أجل الحصول على نموذج أكثر دقة من الشبكات العصبية الكلاسيكية وخاصة في الحالات تكون البيانات تاريخية فيها غير كافية، حيث في هذا النموذج تستخدم الأعداد المبهمة كقيم معاملات للشبكات العصبية الاصطناعية (الأوزان والتحيزات)، بدلا من استخدام القيم الواضحة وهذا من أجل إظهار مدى ملائمة وفعالية النموذج المقترح للتنبؤ بالسلسلة الزمنية، تم تطبيق النموذج المقترح على مشكلة التنبؤ بأسعار الذهب وتم مقارنة أدائها مع النماذج المكونة له. أظهرت النتائج التجريبية أن النموذج المقترح يعد طريقة فعالة لتحسين دقة التنبؤ، ولهذا يمكن تطبيقه كنموذج بديل مناسب للتنبؤ وخاصتا عند الحاجة إلى دقة أعلى في التنبؤ.

(1) Khashei, M., & Bijari, M. (2010). Gold price forecasting using hybrid artificial neural networks with fuzzy regression model. *Advances in Industrial Engineering*, 44(1).

التعليق على الدراسات السابقة:

لقد عرف التنبؤ بأسعار الذهب العديد من الدراسات والأعمال والتي تناولت عدة جوانب مختلفة، من خلال تطبيق اساليب قياسية مختلفة، حيث نلاحظ أنه هناك دراسات اعتمدت على النماذج الاحصائية في التنبؤ بأسعار الذهب العالمية وبينت انها تعطي نتائج جيدة ويمكن الاعتماد عليها في عملية التنبؤ واخرى استخدمت الشبكات العصبية وبينت أنها تعطي نتائج مرضية وتنبؤات قريبة جدا من الواقع، ودراسات أخرى هدفت إلى المقارنة بين النماذج الاحصائية والشبكات العصبية الاصطناعية حيث جُلّ هذه الدراسات أعطت الأفضلية للشبكات العصبية، وهناك من استخدمت النماذج الهجينة من أجل التنبؤ وبيّنت النتائج أنها تعطي نتائج أفضل مقارنة مع النماذج الفردية.

وبناءً على الدراسات السابقة فتمثلت مساهمتنا في الدراسة الحالية في النقاط التالية:

- استخدام نوع من الشبكات العصبية الاصطناعية التي تم تطبيقها في العديد من المجالات حيث اعطت نتائج واعدة خاصة في مجال التنبؤ ألا وهي الشبكة العصبية دالة الأساس الشعاعي والتي تعد نوع من الشبكات العصبية ذات التغذية الأمامية.
- تطبيق نوع من النماذج الهجينة والذي لم يسبق تطبيقه في التنبؤ بأسعار الذهب ألا وهو: نموذج $ARIMA - ANN$ الهجين المعمم (Khashei & Bijary 2011) ومقارنته مع نموذج (Zhang 2003) من خلال الجمع بين نماذج $ARIMA$ والشبكة العصبية دالة الأساس الشعاعي ($RBFFNN$). وأخير استخدام خمسة نماذج من أجل التنبؤ بأسعار الذهب الشهرية.

هيكل الدراسة :

تم تنظيم هذه الدراسة على النحو التالي :

مقدمة عامة : اشتملت على تمهيد حول موضوع الدراسة، مشكلة الدراسة، فرضيات الدراسة، أهداف وأهمية الدراسة، حدود الدراسة، مبررات اختيار الموضوع، منهج الدراسة، الدراسات السابقة، مساهمات الدراسة.

الفصل الأول : تم فيه التطرق إلى ماهية الذهب ووحدة الوزن للذهب، كما تم تقديم تاريخ

حركة أسعار الذهب بالإضافة إلى العوامل التي تؤثر على الذهب، الدراسات السابقة التي تناولت

هذه العوامل، وكذلك تم التطرق إلى مفهوم ملاذ آمن للمستثمرين والاسباب التي تدفع البنوك المركزية للاستثمار في الذهب، أهمية الذهب في الاقتصاد واخيرا إلى الذهب في الجزائر.

الفصل الثاني: تضمن المفاهيم الأساسية العامة للسلاسل الزمنية وأهميتها وبعض الأساليب

القياسية المستخدمة للتنبؤ بها، تم التركيز على استخدام نماذج ARIMA المعروفة بمنهجية Box-Jenkins.

الفصل الثالث: يستعرض هذا الفصل بالتفصيل الشبكات العصبية الاصطناعية (ANN)

والنظرية الأساسية الكامنة وراء بناء بنية الشبكات العصبية الاصطناعية كما يعرض أيضا تطبيقات ANN ومزاياها وعيوبها.

الفصل الرابع: تضمن هذا الفصل الشبكة العصبية دالة الأساس الشعاعي محل الدراسة

بالإضافة إلى النماذج الهجينة.

الفصل الخامس: عرض تطبيق الاساليب المقترحة في هذه الدراسة على سعر الذهب ونتائج التنبؤ.

عرض نتائج المقارنة بين النماذج الفردية والنموذج الهجين.

الخاتمة العامة: عرض اهم الاستنتاجات هذه الدراسة والتوصيات ومقترحات للعمل المستقبلي.

الفصل الأول:
أسعار الذهب العالية

مقدمة:

منذ أن تم التخلي عن «نظام بريتون وودز / *Système de Bretton Woods*» من جانب واحد من قبل الولايات المتحدة الأمريكية في 1971، بدأ سعر الذهب في التقلب بشكل ملحوظ؛ بعدما كانت جميع عملات الدول الأعضاء مرتبطة سابقاً بالدولار الأمريكي والذي كان محددًا بسعر ثابت يقدر بـ 35 دولاراً مقابل أونص من الذهب. وأصبح الدولار عملة الزامية وعرف هذا الحدث باسم «صدمة نيكسون»، الذي خلق وضعاً جديداً أصبح فيه الدولار الأمريكي عملة احتياطية تستخدمها الكثير من الدول. وبالإضافة إلى هذا التحول في النظام النقدي العالمي، أصبح الذهب أصلاً سائلاً يتم تداوله بكميات كبيرة وتكرار عالٍ وبأسعار متذبذبة للغاية في جميع أنحاء العالم.

فالذهب يُعد من بين جميع المعادن الثمينة، السلعة الرائدة عالمياً؛ حيث تظل قيمة الذهب ثابتة أو مرتفعة بغض النظر عن فترات الأزمات الاقتصادية أو المالية أو السياسية، ففي الواقع للذهب قيمته المعيارية الخاصة التي لا تتأثر بسهولة بأي أزمة.

فقد حافظت دول مختلفة على احتياطياتها من الذهب وعززتها، وتم الاعتراف بها كدول ثرية ومتقدمة، ففي الوقت الحاضر يتم الاحتفاظ بالمعادن الثمينة مثل الذهب لدى البنوك المركزية في جميع البلدان لضمان إعادة سداد الديون الخارجية، وكذلك للسيطرة على التضخم، وبالإضافة إلى ذلك فإنه يعكس أيضاً القوة المالية للدول.

فالجزائر وهي إحدى أغنى دول عالم وخاصة الدول العربية من حيث الموارد الطبيعية، مثل البترول تعتبر حالياً من بين أكبر منتجي النفط في العالم وإفريقيا، حيث يعد المصدر الرئيس للدخل وكذلك سلعة التصدير الرئيسة في البلاد، حيث إن النفط يمثل أكثر من 80% من صادرات الجزائر، فالنفط يساهم بـ 98% من إجمالي ناتج الجزائر، بالإضافة إلى الغاز والحديد والفوسفات والزنك والرصاص والزنبق والباريت والملح والرخام وكذلك الذهب والألماس.

فتعتبر الجزائر من بين الدول الغنية بالذهب حيث يقدر احتياط الذهب بالجزائر بـ 173.60 طن، مما يجعلها تصدر المرتبة الثالثة عربياً بعد المملكة العربية السعودية ولبنان والمرتبة 26 عالمياً.

1-1: ماهية الذهب :

يعتبر الذهب من بين أوائل المعادن التي استخرجها الإنسان، حيث يعد عنصرًا فلز كيميائيًا، يتميز بلونه الأصفر المحمر قليلاً، تم اكتشافه لأول مرة في حالته الطبيعية في الجداول والأنهار في جميع أنحاء العالم، كما يوجد على هيئة حبيبات داخل الصخور أو على شكل عروق في باطن الأرض، وغالبا ما يختلط الذهب مع معادن أخرى كالنحاس والرصاص، ويحمل الرقم الذري 79 والرمز "Au" في الجدول الدوري وهو مشتق من الكلمة اللاتينية القديمة (*Aurum*)⁽¹⁾. تتميز هذا المعدن الأصفر بمكانة كبيرة في مختلف الثقافات والحضارات القديمة والحالية كمعدن مقدس وامتلاك ثمين، ويمكن أن يُعزى هذا الموقف بأن هذا المعدن أُنتج داخل كل تلك الحضارات والثقافات إلى فكرة أنه ينظر إليه كعنصر لا يمكن الاستغناء عنه بسبب خصائصه الفريدة، فلم يقتصر هذا الموقف العظيم على فكرة كونه مقدسا فحسب، بل انتقل استخدامه إلى تصنيع المجوهرات الثمينة حتى تم تقديمه أخيرا إلى الاقتصاد كحامل للقيمة، وكما يشكل قاعدة نقدية مستخدمة من قبل صندوق النقد الدولي، إضافة إلى استخدامه من لدن البنوك المركزية في جميع أنحاء العالم كاحتياطات لضمان أموال المودعين وكذلك من أجل السيطرة على التضخم⁽²⁾.

1-2: وحدة الوزن للذهب :

الوحدة المستخدمة للوزن في الذهب والفضة هي الأونصة (*Ounce*) ويعود أصل هذه التسمية إلى بلدة (*Troyes*) الفرنسية التي كان يقام بها سوق تجاري سنوي وكانت وحدة الوزن السائدة في هذا السوق هي الأونصة وتساوي 31.1034768 غرام أي مايعادل 32.1507465 اونصة في الكيلوغرام⁽³⁾.

(1) اوات سردار وادي، سامية خالد حسن: (2012)، التنبؤ بأسعار الذهب وذلك باستخدام سلاسل ماركوف وطريقة الامكان الأعظم (MLE)، كلية الإدارة والاقتصاد -قسم الاحصاء- جامعة صلاح الدين، مجلة دنانير / العدد 43 ص 3.

(2) Al-Ameer, M., Hammad, W., Ismail, A., & Hamdan, A. (2018). The relationship of gold price with the stock market: The case of Frankfurt Stock Exchange. *International Journal of Energy Economics and Policy*, 8(5), 357-371.p 358.

(3) Jawad, B. K. (2019). The effect of VIX index volatility on the S & P 500 index and gold prices. *The iraqi magazinje for managerial sciences*, 15(60),p 36.

3-1 : تاريخ حركة أسعار الذهب :

على مدار تاريخ البشرية، كان أحد أهم الأدوار التي لعبها الذهب هو دور النقود، ووسيلة للتبادل ومخزن للقيمة ووحدة حساب، ومع ظهور العملات الورقية الحديثة فقد الذهب دوره كوسيط للتبادل ووحدة حساب، ومع إنهيار نظام «بريتون وودز» لسعر الصرف الثابت، فقد استمر الذهب في لعب دور الركيزة الحقيقية التي يتم تقييم جميع الأموال الأخرى عليها، وبالإضافة إلى جانب استخدامه في الزينة والصناعة في الوقت الحالي، فيبدو أن الذهب قد فقد معظم دوره النقدي حيث تمثل دوره فقط كمخزن للقيمة أو كاستثمار.

ورغم ذلك تشير التحليل الدقيقة لديناميكيات إلى حقيقة أسعار الذهب، أنه كلما تمّ تحدي هيمنة العملات الرئيسة في العالم، إما عن طريق الأحداث الجيوسياسية، مثل الحروب والفوضى والاضطرابات السياسية أو عن طريق تخفيض القيمة، وكذلك آثار مشاكل التضخم وميزان المدفوعات فقد شهدنا عودة ظهور الذهب إلى دوره.

وعليه، سوف نتطرق إلى الأحداث التاريخية التي أثرت بعمق على أسعار الذهب العالمية.

بدأ تاريخ الذهب منذ حوالي 5000 سنة في مصر والنوبة، وهي منطقة تقع في الجزء الشمالي من السودان، حيث استخدمه الإنسان في التجارة كرمز للثروة. وفي سنة 1500 ق.م اعترف التجار في الشرق الأوسط بالذهب كوسيط قياسي للتبادل، وفي عام 1091م تم تقنين المنشورات الذهبية كنقود في الصين.

أما الرومان فقد بدؤوا استخدام الذهب بشكل متكرر في القرن الأول قبل الميلاد، حيث مثلت Aureus العملة الذهبية والتي كان وزنها حوالي (8 غرام)، وخلال هذه الفترة التي ازدهرت فيها مصر وروما كان الإنتاج السنوي من الذهب حوالي طن سنويا .

إن التّحول الرئيس في تاريخ تداول الذهب والفضة الحديث بدأ في سنة 1713م، عندما كانت الفضة هي العملة المسيطرة في إنجلترا قبل التّحول إلى العمل بالذهب، إذ كانت الفضة تستخدم كعملة في إنجلترا وكان يطلق عليها اسم الجنيه الاسترليني أي النّجمة .

أما في ما يخص الذهب، فقط بدأت إنجلترا في التجارة فيه فقط مع احتلال الهند وتأسيس شركة الهند الشرقية، وقد ظهر الذهب في صورة عام 1717 عندما زادت التجارة بين إنجلترا وفرنسا، وقررت هذه الأخيرة استبدال الذهب بالسلع، ففي نفس الفترة تم صك حوالي أربعة ملايين جنيه ذهب في إنجلترا وبدأ ما يسمى **بعصر معيار الذهب**، مما بوأ إنجلترا مركزا لتجارة الذهب، مع العلم أنه في عام 1844م كان بنك إنجلترا أول بنك مركزي يتبنى معيار الذهب (معيار الذهب هو نظام نقدي حيث يتم ربط كمية الأوراق المطبوعة باحتياطي الذهب للبنك المركزي، حيث أسعار الصرف في هذا النظام ثابتة في جميع البلدان مع بعضها البعض ومن أجل الحفاظ ثبات أسعار الصرف هذه، تضطر البنوك المركزية إلى تعديل أسعار الفائدة)، وبحلول عام 1890م اعتمد معظم العالم معيار الذهب، فيمكن تفسير الشعبية المتزايدة للمعيار الذهبي من خلال تأثيرات الشبكة، حيث في بادئ الأمر، واجهت الدول التي رفضت التكيف مع المعيار الذهبي صعوبات في جذب الأموال وثانيا كانت الشركات التي كانت تمارس نشاطا تجاريا في بلد بمعيار الذهب قادرة على القيام بتخطيط استثماري أفضل بسبب انخفاض تقلبات التضخم.

فالعيب الأكبر لهذا النظام، هو احتمال زعزعة الاستقرار في البلدان التي تعاني من عجز تجاري، حيث إذا كان هناك عجز تجاري بين دولتين فيلزم على البنوك المركزية إلى حله عن طريق تبادل العجز بالذهب، فعندما يعرف سكان بلد أنه هناك عجزا تجاريا فإنهم غالبا ما يدفعون بالبنك لاستبدال نقودهم الورقية بالذهب قبل نقلها إلى الدولة الأخرى مما قد يؤدي ذلك إلى زعزعة استقرار البلدان التي عانت بالفعل من انخفاض النشاط الاقتصادي.

فقد تم اعتماد الذهب والفضة من قبل إنجلترا والولايات المتحدة الأمريكية كمعيار ثنائي المعدن لعمليتهما في أوائل سنة حيث تم تداول الذهب في ذلك الوقت بسعر 19.30 دولارا للأونصة، فلم يتغير هذا حتى سنة 1834، ثم عرف سعر الذهب قدر بـ 20.67 دولار للأونصة .

وفي سنة 1914، مع اندلاع الحرب العالمية الأولى، قررت إنجلترا ترك المعيار الذهب، فتمكنوا بذلك من تمويل الحرب بطباعة المزيد من النقود الورقية، وتم شحن أطنان من الذهب إلى الولايات

المتحدة الأمريكية مقابل تزويدها بالسلع والخدمات، وبعد الحرب العالمية الأولى بذلت الولايات المتحدة وانجلترا بعض المحاولات الجادة للعودة إلى المعيار الذهبي، ورغم ذلك لم تنجح أي من المحاولات، كما ارتبطت حركة سعر الذهب بعد أن طلبت دول الشرق الأوسط وخاصة المملكة العربية السعودية في سنة 1933م الذهب مقابل النفط ونتيجة لذلك ارتفعت أسعار الذهب إلى 32.32 دولار؛ فمنذ ذلك الحين كان لسوق النفط تأثيراً على أسعار حركة الذهب، كما كانت هناك حركة أخرى لأسعار الذهب، فبحلول نهاية الحرب العالمية الثانية تم إنشاء نظام نقدي جديد بين 44 دولة يسمى بنظام بريتون وودز، حيث ترتبط جميع العملات بالدولار والدولار مرتبط بالذهب كان أول تكافؤ ثابت 35 دولاراً للأونصة.

في سنة 1971م، علق الرئيس ريتشارد نيكسون قابلية تحويل الدولار إلى ذهب، بموجب نظام بريتون وودز لسعر الصرف الثابت، حيث تم تثبيت قيم جميع العملات بالنسبة للدولار، والذي كان بدوره قابلاً للتحويل إلى ذهب بسعر 35 دولاراً للأونصة، حيث يتطلب هذا النظام من الولايات المتحدة الاحتفاظ بما يكفي من الذهب لتغطية حجم الدولار في التداول العالمي، أدى تعليق إمكانية تحويل الدولار إلى ذهب مؤقتاً على الأقل إلى وضع هذا الطلب على الذهب موضع تساؤل، ثم بعد ذلك أتت مرحلة محاولة إنقاذ نظام بريتون وودز بموجب اتفاقية سميثسونيان حيث تم التوقيع عليه في ديسمبر 1971م، بتخفيض قيمة الدولار للتحويل إلى ذهب بقيمة 38 دولاراً للأونصة، استمرت اتفاقية سميثسونيان حتى يناير 1973 ثم بعد جولة أخرى من تخفيض قيمة الدولار، إنهار نظام بريتون وودز أخيراً في مارس 1973 وأفسح المجال للنظام الحالي لأسعار الصرف العائمة، حيث تركت بعض الدول الأوروبية تعويم سعر صرفها مقابل الدولار وانتهت قابلية تحويل الدولار مقابل الذهب ففقد الذهب في ظل هذه الظروف خاصيته كونه وسيلة للتبادل وأصبح أداة ادخار وجزءاً من احتياطات البنوك المركزية⁽¹⁾، وكانت آخر عملة تم فصلها عن الذهب هي الفرنك السويسري في 2000⁽²⁾.

(1) Toraman, C., Basarir, Ç., & Bayramoglu, M. F. (2011). Determination of factors affecting the price of gold: A study of MGARCH model. *Business and Economics Research Journal*, 2(4), 37-50.p 38.

(2) Sujit, K. S., & Kumar, B. R. (2011). Study on dynamic relationship among gold price, oil price, exchange rate and stock market returns. *International journal of applied business and economic research*, 9(2), 145-165.p 165.

مع العلم أنه مُنِعَ المواطنون الأمريكيون من امتلاك العملات الذهبية والسبائك الذهبية بشكل خاص. في سنة 1933 وفي ديسمبر 1974، وقَّع الرئيس جيرالد فورد على مشروع قانون "للسماح لمواطني الولايات المتحدة بشراء الذهب أو الاحتفاظ به أو بيعه أو التعامل معه بطريقة أخرى في الولايات المتحدة أو في الخارج" فاعتبر هذا التاريخ حدثاً رئيساً آخرًا في سوق الذهب العالمية. يتداول سوق الذهب بشكل أساسي في العقود الآجلة للذهب. بدأت ورصة نيويورك للسلع (COMEX) التداول الآجل في الذهب في فبراير 1975 وأصبحت هذه البورصة واحدة من أهم مراكز تداول عقود الذهب الآجلة في العالم، ومن ثم اعتبر شهر فبراير 1975 تاريخاً مهماً آخرًا في تاريخ سوق الذهب. وفي سنة 1979 ارتفع سعر الذهب من 250 دولار إلى 400 دولار للاونصة في نفس السنة، حيث قام «بول فولكر» رئيس مجلس إدارة البنك الفيدرالي الأمريكي بتغيير السياسة الفدرالية من التحكم في أسعار الفائدة إلى التحكم في المعروض النقدي. كما ارتفع الذهب إلى 850 دولار في 1980 نتيجة غزو أفغانستان من قبل الاتحاد السوفياتي سابقاً مما أدى إلى ارتفاع النفط وارتفاع التضخم. وفي شهر مارس 1982 قدمت اللجنة تقريرها الرافض للعودة إلى معيار الذهب. ولهذا يعتبر مارس من سنة 1982 تاريخاً مهماً في تاريخ الذهب. في سنة 1982 انخفض إلى 296 دولار بسبب سياسة عرض النقود وكذلك قوة الدولار الأمريكي مما جعل أسعار الفائدة أعلى من أي وقت مضى. من سنة 1983-1989 عرف سعر الذهب عدة تقلبات وكانت بين 400 دولار و500 دولار. في سنة 1990 ارتفع إلى 450 دولار بسبب حرب الخليج حتى سنة 1996. في أواخر 1996 انخفض سعر الذهب وهذا راجع للعديد من الأحداث بما في ذلك ازدهار الاقتصاد العالمي في أوروبا والولايات المتحدة الأمريكية وسوق الأسهم وزيادة عن ذلك ارتفعت قيمة الدولار الأمريكي وأصبح العملة الأكثر تفضيلاً للاستثمار في العالم وأغلق الذهب عند 387 دولار. ومن 1998 إلى 2002 عرف سعر الذهب عدة تقلبات وهذا راجع لعدة أسباب.

في نهاية 2003 ارتفع إلى 416.25 دولار وهذا راجع للعديد من الأحداث؛ منها الحرب على العراق من قبل الولايات المتحدة الأمريكية وكذلك عرف الدولار الأمريكي انخفاضا ...
في 2005 ارتفع سعر الذهب إلى 536.50 دولار نتيجة ارتفاع أسعار النفط جراء إعصار كاترينا حيث ذكر مجلس الذهب العالمي⁽¹⁾ في تقرير التسلسل الزمني لاسعار الذهب إن الطبيعة تعد عاملا آخر في ارتفاع أسعار الذهب.

كما ارتفع إلى 833.75 دولار في سنة 2007، وهذه الزيادة الهائلة في أسعار الذهب راجعة إلى الزيادة في الطلب على الذهب من قبل المستثمرين الباحثين على استثمار آمن وكذلك استخدامه كوسيلة للتحويط من التضخم من قبل الولايات المتحدة ودول أخرى. ومن كل هذا فاندفاع الأفراد لشراء الذهب كاستثمار والتحويط ضد التضخم والأمن ضد المخاطر الجيوسياسية والمالية يساهم في ارتفاع أسعار الذهب⁽²⁾.

وفي سنة 2008 ارتفع سعر الذهب بمعدلات أعلى من أي وقت مضى حيث فاقت 1000 دولار أمريكي للأونصة فاعتبرت هذه الفترة من أهم فترة في تاريخ سوق الذهب وذلك راجع للزمة المالية للرهن العقاري في الولايات المتحدة الأمريكية مع استمرار ارتفاع معدلات التضخم وضعف الدولار الأمريكي أمام العملات الأخرى وخاصة اليورو، حيث بدأ السوق ينظر إلى الذهب باعتباره استثمارا جيدا بشكل متزايد. وحافظ على قيمته خلال أزمة الديون الأوروبية، وبحلول عام 2013 بدأت الأسعار في الانخفاض لكنها ظلت مستقرة نسبيا بشكل عام بين 1200-1400 دولار⁽³⁾.

ففي أواخر سنة 2019 فقد هزّ تفشي فيروس COVID-19 الأسواق المالية، حيث خلق مخاوف واسعة النطاق من أن النمو الاقتصادي العالمي سوف ينهار، مما دفع العديد من المستثمرين الابتعاد عن سوق الأسهم والسعي بدل ذلك إلى شراء أصول الملاذ الآمن (الذهب)، حيث أفادت

(1) مجلس الذهب العالمي: في شهر جانفي يناير 1987، اجتمعت بعض شركات تعدين الذهب الرائدة في العالم وأنشأت مجلس الذهب العالمي بهدف إدارة سلسلة توريد الذهب العالمية وتحفيز الطلب العالمي على الذهب.

(2) Matroushi, S. M. (2011). *Hybrid computational intelligence systems based on statistical and neural networks methods for time series forecasting: the case of gold price (Doctoral dissertation, Lincoln University)*, p 12-13-14.

(3) Ehsan, Z. A. (2020). *A Vector Error Correction model analysis of gold prices-how will COVID-19 impact the price of gold?. Available at SSRN 3644893.p 1.*

التقارير أن الذهب حافظ على سعر منصف خلال الأوبئة الخمسة المعروفة خلال الفترة من 1957 إلى 2009.⁽¹⁾

فإن تأثير الفيروس على سوق الذهب كان إيجابياً، حيث وجد أن العدد المتزايد لحالات الإصابة بفيروس كورونا العالمي يرتبط بزيادة أسعار الذهب، وهو ما يمكن أن يعزى إلى عدم اليقين بشأن الظروف الاقتصادية المستقبلية التي أنشأها الفيروس، وحقيقة أن الذهب باعتباره أصلاً آمناً في أوقات الاضطراب الاقتصادي؛ فارتفعت أسعار الذهب من 1517.3 دولاراً أمريكياً إلى 1712.39 دولاراً أمريكياً للأونصة⁽²⁾، ففي نهاية 2020 بلغ سعر أونصة الذهب 1887.6.

4-1 : العوامل المؤثرة على سعر الذهب :

تتأثر أسعار الذهب بشكل أساسي بثلاثة عوامل: الاحتياطيات المؤكدة من الذهب وأسعار الطاقة والأسواق المالية وعوامل الاقتصاد الكلي، فالأحداث الخاصة التي لها تأثير على أسعار الذهب لها علاقة بإحدى المجموعات الثلاث المذكورة، فعلى سبيل المثال الأسواق المالية العالمية في حالة من عدم اليقين من حيث ثقة المستثمرين فيه، والأزمة المالية لعام 2008 في الولايات المتحدة، إضافة إلى احتياطيات الذهب إلى المعروض من المعدن في السوق⁽³⁾.

توجد عدة عوامل اقتصادية كلية ضخمة تؤثر بطريقة أو بأخرى على تحركات وتقلبات بعضها البعض كثيراً، ونظراً لأن أي تغيير في أي متغير من شأنه أن يؤدي إلى تأثير في آخر، لذلك من المهم النظر أو معالجة هذه المتغيرات الاقتصادية.

ومن بين هذه العوامل التي تؤثر مباشرة على أسعار الذهب نجد على سبيل المثال: سعر الصرف، ومعدل التضخم، ونمو الاقتصاد، والانكماش، أسعار المستهلكين، ومعدلات البطالة، وعائدات مؤشر الأسهم، وأسعار سندات الخزنة، وأسعار الفائدة، الخ.....

(1) Uche-Ikonne Okezie, O., Offorha Bright, C., & Ukomah Henry, I. (2020). Forecasting monthly prices of gold using artificial neural network. *Journal of Statistical and Econometric Methods*, 9(3), 19-28.p 20.

(2) Yousef, I., & Shehadeh, E. (2020). The impact of the COVID-19 on gold price volatility. *Int J Econ Bus Adm*, 8(4), 353-64.P363.

(3) Gutiérrez, M., Franco, G., & Campuzano, C. (2013). Gold prices: Analyzing its cyclical behavior. *Lecturas de Economía*, (79), 113-142.p 115.

سوف نتطرق إلى العوامل التي تؤثر على تحركات أسعار الذهب (العوامل الكلية الأكثر ارتباطاً بأسعار الذهب).

1-4-1: الطلب على الذهب وعرض الذهب⁽¹⁾:

▪ الطلب على الذهب :

يمثل الكمية العالمية من الذهب المشتراة بسعر معين، وهو أساس للاستهلاك والايدياع والاستثمار وأيضا يستخدم من طرف البنوك المركزية كاحتياطات رسمية كحماية من المخاطر المالية، أما بالنسبة للمستثمرين فالذهب يعتبر استثمارة ويستخدم كتحويط ضد التضخم. وعادة أسعار الذهب تحددها التنمية الاقتصادية الدولية .

ومن المحتمل أن تكون عوامل الطلب مدججة في الفئات التالية:

- سكان العالم، الناتج المحلي الإجمالي العالمي.
- نمو مستويات معيشة السكان.
- سياسة البنوك المركزية.
- أسعار الصرف مقابل الدولار الأمريكي.
- التطور التكنولوجي.
- المضاربة والآثار الأخرى .

وباختصار يكون الطلب على الذهب من الجهات التالية:⁽²⁾

▪ طلب الاحتياطي على ذهب البنك المركزي: تعتبر البنوك المركزية في الدولة، وصندوق

النقد والحكومات أكبر حامل للذهب في العالم .

▪ الطلب على الذهب كأداة تحوط:

يكون دور الذهب مهما جدا عندما يكون هناك اضطراب مالي وسياسي. فعندما يكون هناك

عدم استقرار مالياً أو سياسياً، قد يشتري المستثمرون الذهب كملاذ آمن، مع مخاطر ائتمانية منخفضة والتي تكون شديدة السيولة في أوقات الأزمات .

(1) Simáková, J. (2011). Analysis of the relationship between oil and gold prices. Journal of finance, 51(1), 651-662.p654-655.

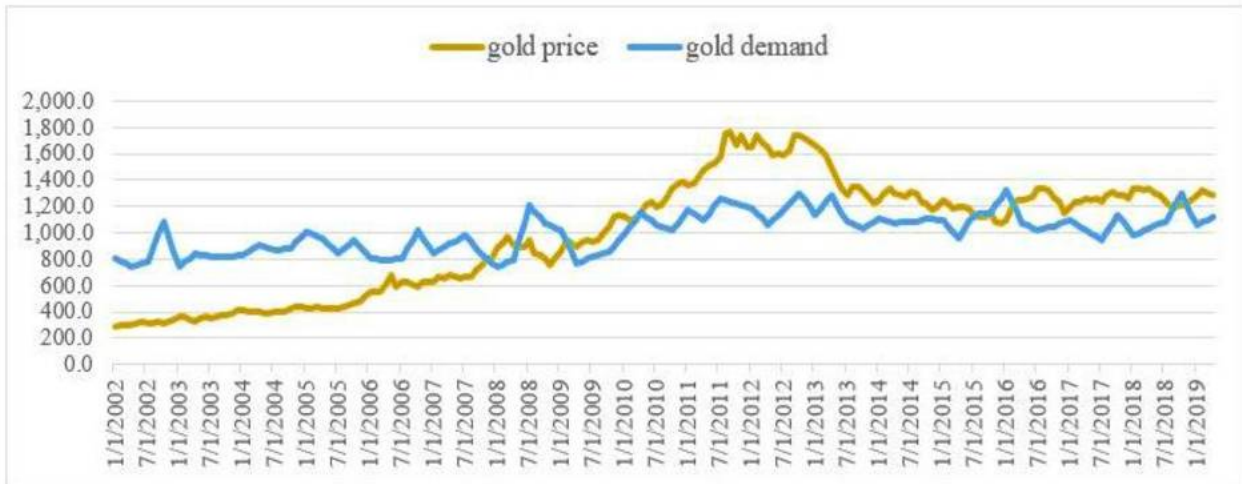
(2) Madhushan, R. M. K., Rathnayaka, R. M. A. C., Sandaruwan, T. M. D. M., Maduranga, A. D., & Gunarathne, a. v. c. h. relationship between gold price and determinants of gold price in sri lanka.p 5.

▪ طلب الصناعي على الذهب:

▪ طلب المجوهرات على الذهب:

فعلى مدار 6000 عام تم استخدام الذهب في المجوهرات، ويعود السبب لندرتهما وتصميمهما الميكانيكي ومقاومتها للتآكل ولونها، حيث تم استخدام المزيد من الذهب كرقائق ذهبية (رقائق الذهب رقيقة من موجة الضوء المرئية)، والإطارات، والكتب، والأثاث، وكما يمكن أيضا استخدامها للأسطح غير المعدنية والعناصر المعمارية.

نلاحظ من خلال الشكل أدناه أن التغيرات الشهرية في أسعار الذهب والطلب على الذهب من جانفي 2002 إلى جانفي 2019. توضح علاقة إيجابية بين سعر الذهب والطلب على الذهب .
الشكل 1-1: يبين العلاقة بين الطلب على الذهب وأسعار الذهب.



Source : Farhat, S., & Ghalayini, L. (2020). Modeling and Forecasting Gold Prices.p14.

▪ عرض الذهب :

هو ذلك المقدار العالمي من الذهب المعروض من الذهب بسعر معين وهو يشمل إجمالي إنتاج المناجم وإعادة تدوير الذهب، وبصفة عامة توجد ثلاثة مصادر رئيسية للذهب تدخل السوق . المصادر هي التعدين وإعادة التدوير والمبيعات في القطاع الرسمي، حيث يمثل تدوير الذهب حوالي ثلث جميع عمليات التسليم ذهباً معاد تدويره وهذا راجع إلى تراجع مستوى إنتاج الذهب من قبل شركات تعدين الذهب، كما أن البنوك المركزية تقوم ببيع احتياطياتها المتزايدة من الذهب وتعتبر أحد

المصادر الرئيسة لإمداد الذهب في العالم، حيث تساعد هذه الظروف على تلبية الطلب المتزايد والحفاظ على استقرار أسعار الذهب نسبيا.

حيث يلخص المجلس الذهب العالمي العوامل الرئيسة التي تؤثر على المبلغ الإجمالي لهذه السلعة إلى هذه الفئات :

- التقدم التقني والتكنولوجي في تعدين الذهب .
- احتياطات الذهب العالمية المؤكدة والذهب المعاد تدويره والودائع الجديدة .
- النظام النقدي في كل بلد .
- عوامل سياسية.
- عوامل قصيرة المدى: كوارث طبيعية، نزاعات سياسية وعسكرية.

1-4-2 : اتجاه السياسة النقدية :

التنفيذ المحدد للسياسة النقدية يتضمن زيادة نسبة احتياطي الودائع، ورفع معدل الخصم وسياسة السوق المفتوحة، قد يكون لتنفيذ السياسة النقدية تأثير أيضا على المعروض من النقود. فيمكن أن تؤدي زيادة المعروض النقدي إلى انخفاض القوة الشرائية للعملة فانخفاض القوة الشرائية للعملة يؤدي بدوره إلى ارتفاع سعر الذهب والعكس صحيح، قد يؤدي انخفاض المعروض من النقود إلى زيادة القوة الشرائية وانخفاض سعر الذهب. ومن ناحية أخرى، ينعكس تشديد السياسة النقدية عادة في زيادة أسعار الفائدة في السوق. فزيادة أسعار الفائدة تجعل أسعار الذهب ترتفع⁽¹⁾ .

1-4-3 : العلاقة بين أسعار الصرف وأسعار الذهب⁽²⁾ :

تعد التغيرات في أسعار صرف العملات احد عوامل الاقتصاد الكلي التي تؤثر على تغيرات أسعار الذهب، ففي حالة انخفاض قيمة العملة يؤدي إلى زيادة الطلب على الذهب مما يؤدي إلى

(1) Ngmerty, R. K. (2019). *Effects of Macroeconomic Variables on Gold Prices in Ghana (Doctoral dissertation, University of Ghana)*.p 7.

(2) Sinton, J. (2014, April). *An empirical investigation of the causal relationship between gold price, exchange rate changes and jakarta composite index. World Business and Social Science Research Conference, Hotel Crowne Plaza Republique, Paris, France*,.p 2.

ارتفاع سعر الذهب نفسه (مثلا يفضل المستثمرون عادة اختيار الذهب كمخزن للقيمة مما يؤدي إلى ارتفاع سعر الذهب).

السبب الآخر هو عندما ينخفض سعر صرف الدولار الأمريكي أيضا يؤدي إلى ارتفاع أسعار الذهب. (فمثلا عندما ينخفض سعر صرف الدولار الأمريكي مقابل عملة دولة ما، يدفع المستثمرون ببيع الدولار الأمريكي ثم شراء الذهب الذي يعتبر قادرا على حماية قيمة أصولهم). أي يؤدي تقلب أسعار صرف الدولار في كثير من الأحيان إلى وظائف تحوط قوية لأسعار الذهب، وزيادة على ذلك يميل سعر الذهب المقوم بالدولار الأمريكي إلى الارتفاع بعد انخفاض قيمة الدولار⁽¹⁾.

ومن جهة أخرى إذا زادت قيمة الدولار الأمريكي مقابل العملات الأخرى فسوف تنخفض قيمة العملات الأخرى، وبالتالي فإن الأشخاص الذين لديهم عملات أخرى سيدفعون أكثر لشراء الذهب من الولايات المتحدة أو في بعض الأحيان لا يمكنهم حتى شراء الذهب، وبالتالي ينخفض الطلب على الذهب مما يقلل من أسعار الذهب، ولهذا هناك علاقة عكسية بين الذهب وسعر الصرف الأمريكي كما يمكن أن تتغير هذه العلاقة العكسية أحيانا إلى علاقة إيجابية، اعتمادا على أوضاع الدول الأخرى، فإذا كانت عملات الدول الأخرى تواجه مشاكل اقتصادية أو انكماشًا، فلن يتمكن أصحاب هذه العملات من شراء الذهب أو الاستثمار فيه. حتى لو انخفضت قيمة الدولار الأمريكي. وبالتالي فإن الطلب على الذهب وسعره سيكونان منخفضين في نفس الوقت الذي يكون فيه الدولار منخفضا أيضا⁽²⁾.

1-4-4 : العلاقة بين أسعار الفائدة الحقيقية وأسعار الذهب :

يعد سعر الفائدة الحقيقي عاملا آخرًا يؤثر على أسعار الذهب، ويرتبط إلى حد ما بالتضخم، فظنرا لأن أسعار الفائدة المرتفعة تجعل السندات والاستثمارات الأخرى أكثر جاذبية، وتزيد من تكلفة

(1) Beckmann, J., Czudaj, R., & Pilbeam, K. (2015). Causality and volatility patterns between gold prices and exchange rates. *The North American Journal of Economics and Finance*, 34, 292-300.p 1.

(2) Op.cit. Al-Ameer, M., Hammad, W., Ismail, A., & Hamdan, A. (2018). p361.

الفرصة البديلة لحيازة الذهب مما يؤدي إلى تحول المحفظة، فيجب أن يتبع ذلك ضعف في الذهب، كذلك تؤدي زيادة أسعار الفائدة إلى زيادة قيمة الدولار مما يدفع سعر الذهب إلى الانخفاض، وبالتالي يتوقع أن يكون لأسعار الفائدة تأثير على أسعار الذهب⁽¹⁾.

1-4-5 : العلاقة بين أسعار النفط وأسعار الذهب :

يعتبر الذهب والنفط من أهم السلع الإستراتيجية وكذلك من أهم السلع في الأسواق المالية التي يتم تداولها على نطاق واسع في جميع أنحاء العالم، وقد أثارا جدلا واسع النطاق في الأوساط الاقتصادية والسياسية العالمية عدة مرات نظراً لخصائص وعناصر هاتين السلعتين التي قادتهما إلى قمة الأسواق العالمية، حيث يلعب النفط باعتباره المادة الخام الأكثر تبادلا وعاملا مهما لتحديد الإنتاج الصناعي وكما يؤثر على جميع قطاعات الاقتصاد بشكل مباشر أو غير مباشر ومن جهة أخرى الذهب باعتباره المعدن النفيس والذي يتم تقييمه كعملة عالمية ويستخدم للتزين (المجوهرات) واستثمار وكسلعة، دورا مركزيا في تشكيل الاقتصاد.

فتاريخيا بدأت العلاقة بين الذهب والنفط أو الترابط بين هتين السلعتين في عام 1933، حيث كان منتجو النفط الخام من الشرق الأوسط يطالبون بالذهب مقابل النفط الخام، ونظرا لتطورات هائلة في أعقاب العديد من الأحداث التاريخية التي شهدتها أسواق الذهب والنفط لم يتم التحقق من العلاقة الرئيسية بين السلعتين إلا على مستوى السداد، ففي الوقت الحاضر يتم تسعير كل من النفط الخام والذهب والسلع الأخرى بالدولار الأمريكي⁽²⁾.

فإذا ناقشنا العلاقة بين أسعار النفط وأسعار الذهب في بيئة تضخمية، ففي الواقع يتأرجح المستوى العام للأسعار بشكل مباشر مع التغيرات في أسعار النفط. أي ضغط تصاعدي أو تنازلي على أسعار النفط ينعكس في النهاية على المستوى العام للأسعار في أي بلد، فالارتباط بين أسعار الذهب وأسعار النفط مرتبط بالمستوى العام للأسعار في الاقتصاد. وأي ضغط تصاعدي في أسعار النفط

(1) *Op.cit. Ngmerty, R. K. (2019)..p8.*

(2) *Suthikul, W. (2021). The Interrelation between Prices of Gold and Crude Oil. UBRU International Journal, 1(1), 22-28.p22.*

سيزيد من المستوى العام للأسعار ويؤدي في النهاية إلى رفع أسعار الذهب في الاقتصاد. ومنه فالعلاقة بين أسعار النفط والذهب هي ايجابية، أي ارتفاع في أسعار النفط سيؤدي في النهاية إلى رفع أسعار الذهب⁽¹⁾.

ويعتبر كل من الذهب والنفط "أصلا مثبتا بالدولار"، مما يعني أن كلا السلعتين يتم تحديدهما أو تسعيرهما بالدولار الأمريكي، لذلك عادة عندما يرتفع الدولار الأمريكي فسعر كل من الذهب والنفط سينخفض، وبما أن الذهب والنفط هما "أصول مثبتة بالدولار"، فإن لهما علاقة قوية جدا، فكلمة عرف الدولار تقلب، فإن كلا الأصلين سيتقلبان معا في الاتجاه المعاكس للدولار⁽²⁾.

1-4-6: العلاقة بين أسعار الذهب والأسهم:

عامل رئيسي آخر هو أن أداء الذهب يقارن في الغالب بالأسهم، فعلى الرغم من اختلاف فئات الأصول هذه بشكل أساسي، فيعتبر البعض الذهب كمخزن للقيمة ليس له نمو بينما تعتبر الأسهم عائدا على القيمة، فيعد الذهب بمثابة مصدرا بديلا للاستثمار في حالة سوق الأسهم الهابط أو المتقلبة، ونظرا لأن كلا من الذهب والأسهم غالبا ما يكونان بديلين لبعضهما البعض، فتوجد بشكل عام علاقة عكسية بين الذهب وأسعار الأسهم لأنه مع ارتفاع أسعار الذهب يبدأ المستثمرون في الاستثمار في الذهب وبالتالي تنخفض أسعار الأسهم والعكس صحيح، عندما يتباطأ الاقتصاد مع انخفاض عائدات سوق الأسهم، يسحب المستثمرون أموالهم من الأسهم ويستثمرون في الذهب حتى ينتعش الاقتصاد، ورغم ذلك ينظر إلى الذهب على أنه الأصل الذي يجب الاحتفاظ به خلال فترات عدم اليقين والأزمات⁽³⁾.

ففي الأزمة المالية العالمية 2007-2009 فقد انخفض سعر السهم بشكل حاد بينما ارتفع سعر الذهب. ويرجع ذلك أساسا إلى رغبة المستثمرين في التحول نحو الذهب الذي يمثل ملاذا آمنا لهم⁽⁴⁾.

(1) Irshad, H., Bhatti, G. A., Qayyum, A., & Hussain, H. (2014). Long run Relationship among Oil, Gold and Stock Prices in Pakistan. *Journal of Commerce* (22206043), 6(4),p10.

(2) Op.cit. Al-Ameer, M., Hammad, W., Ismail, A., & Hamdan, A. (2018). p 361.

(3) Srinivasan, P. (2014). Gold Price, Stock Price and Exchange rate Nexus: The Case of India. *Romanian Economic Journal*, 17(52),p 79.

(4) Farhat, S., & Ghalayini, L. (2020). *Modeling and Forecasting Gold Prices*.p17.

1-4-7 : العلاقة بين أسعار الذهب والتضخم :

يعتبر معدل التضخم أحد العوامل الرئيسة التي تؤثر على سوق الذهب، إذ توجد علاقة إيجابية بين سعر الذهب والتضخم؛ ففي ظل وجود التضخم سيتجه سعر الذهب في نمط متزايد حيث يصبح الذهب خياراً أفضل للمستثمرين خلال أوقات التضخم.

أثناء عدم اليقين الاقتصادي على سبيل المثال التضخم، فعندما تزداد تكلفة المعيشة، يفضل المستثمر الاحتفاظ بالذهب كتحوط ضد التضخم لأن الذهب يعمل كمخزن للقيمة ولذلك تتضح العلاقة الإيجابية بين سعر الذهب ومعدل التضخم⁽¹⁾.

ونظراً لارتباط الذهب بالدولار الأمريكي فقد أثرت أسعار الفائدة الأمريكية على أسعار الذهب، فكلما تنخفض أسعار الفائدة تزداد أسعار الذهب وعندما يرتفع التضخم تزداد أسعار الذهب (الذي يتأثر بتقلبات أسعار النفط⁽²⁾)، ولهذا يعتبر معدل التضخم رابطاً مهماً بين النفط والذهب، فتؤثر أسعار النفط على أسعار الذهب بشكل غير مباشر من خلال معدل التضخم كعامل حاسم في الاقتصاد يمكن أن تؤثر أسعار النفط على معدل التضخم كثيراً، لذلك عندما ترتفع أسعار النفط سيزداد معدل التضخم مما يؤدي إلى ارتفاع أسعار الذهب⁽³⁾.

1-5 : الدراسات السابقة :

تم إجراء العديد من الدراسات لتحديد العوامل التي تؤثر على سعر الذهب :

▪ دراسة (Sjaastad، 2008)⁽⁴⁾ :

هدفت هذه الدراسة إلى البحث في العلاقات النظرية والتجريبية بين أسعار الصرف الرئيسية وأسعار الذهب باستخدام بيانات الخطأ التنبؤي، ومن بين أمور أخرى وجد أنه منذ حل نظام بريتون وودز النقدي الدولي كانت أسعار الصرف العائمة بين العملات الرئيسية مصدراً رئيسياً لعدم استقرار

(1) Op.cit. Madhushan, R. M. K., Rathnayaka, R. M. A. C., Sandaruwan, T. M. D. M., Maduranga, A. D., & Gunarathne, A. V. C. H. p 8.

(2) Baber, P., Baber, R., & Thomas, G. (2013). Factors affecting Gold prices: a case study of India. Proc. Evolving Management Paradigms in Manufacturing and Service Sectors.p6.

(3) Op.cit. Al-Ameer, M., Hammad, W., Ismail, A., & Hamdan, A. (2018). p 361.

(4) Sjaastad, L. A. (2008). The price of gold and the exchange rates: Once again. Resources Policy, 33(2), 118-124.

الأسعار في سوق الذهب العالمية، ونظرا لأن سوق الذهب العالمي يبدو الآن خاضعا لسيطرة كتلة الدولار الأمريكي، فإن ارتفاع قيمة هذا الدولار أو انخفاضه سيكون له تأثيرات قوية على سعر الذهب مقارنة بالعملات الأخرى. حيث تبين من خلال النتائج التي تم التوصل إليها من هذه الدراسة انها تختلف إلى حد ما عن تلك التي تم الحصول عليها في دراسة سابقة لنفس الموضوع.

▪ دراسة (Mishra، 2010) (1).

تصبح أسواق الأسهم في بلد ما أكثر حساسية لكل من العوامل المحلية والخارجية وأحد هذه العوامل هو سعر الذهب، حيث جذب تقلب أسعار الذهب في الآونة الأخيرة انتباه العديد من الباحثين والأكاديميين والمحللين.

هدفت هذه الدراسة إلى البحث في تقلب أسعار الذهب والعلاقة السببية بين أسعار الذهب وعوائد سوق الأسهم في الهند. مع الأخذ في الاعتبار أسعار الذهب المحلية وعائدات سوق الأوراق المالية بناء على NSE، تبحث الدراسة في السببية Granger في نموذج تصحيح الخطأ المتجه للفترة من أبريل 2001 إلى مارس 2011، توفر النتائج التجريبية دعما للعلاقة السببية العكسية بين المتغيرات المختارة وتشير إلى أن أسعار الذهب تسبب عوائد سوق الأوراق المالية وعوائد سوق الأوراق تسبب أسعار الذهب في الهند خلال فترة الدراسة. وتشير النتائج إلى أن الحركة المشتركة لأسعار الذهب وأسعار الأسهم حتى خلال فترة الأزمة المالية العالمية وما بعدها. دفعت سكان الهند في اعتبار الذهب ليس فقط كمجوهرات ولكن أيضا وسيلة مهمة للاستثمار مثل الاستثمار في السندات والأسهم.

▪ دراسة (Toraman، 2011) (2)

الهدف الرئيسي من هذه الدراسة هو تحديد العوامل المؤثرة على أسعار الذهب. تتضمن الدراسة بيانات شهرية من جوان 1992 ومارس 2010. أسعار النفط، وسعر الصرف في الولايات المتحدة، ومعدل التضخم في الولايات المتحدة، وبيانات الفائدة الحقيقية في الولايات المتحدة مدرجة في

(1) Mishra, P. K., Das, J. R., & Mishra, S. K. (2010). Gold price volatility and stock market returns in India. *American Journal of Scientific Research*, 9(9), 47-55.

(2) Toraman, C., Basarir, Ç., & Bayramoglu, M. F. (2011). Determination of factors affecting the price of gold: A study of MGARCH model. *Business and Economics Research Journal*, 2(4), 37-50.

النموذج كمتغيرات، تم تحليل المتغيرات التي يعتقد أنها تؤثر على أسعار الذهب باستخدام نموذج MGARCH، حيث يتم أخذ الفروق الأولى في سعر الصرف في الولايات المتحدة الأمريكية وأسعار الفائدة الحقيقية واستخدام سلسلة عوائد المتغيرات الأخرى. يتم تقدير نموذج MGARCH بواسطة نموذج الارتباطات الشرطية الثابتة (Constant Conditional Correlations) كونها تعطي أفضل النتائج لتقدير المعاملات. ووفقاً للنتائج التجريبية تم العثور على أعلى ارتباط بين أسعار الذهب وسعر الصرف في الولايات المتحدة بشكل سلبي.

ثانياً، يوجد ارتباط إيجابي بين أسعار الذهب وأسعار النفط.

▪ دراسة (Trivedi، 2012) : (1)

هدفت هذه الدراسة إلى محاولة استكشاف العلاقة بين أسعار الذهب وأساسيات الاقتصاد الكلي في الهند بشكل تجريبي باستخدام طريقة اختبار الحدود للتكامل المشترك أو إجراء التأخر الموزع الذاتي (ARDL). تشير الاختبارات للتكامل المشترك إلى وجود علاقة طويلة الأمد بين أسعار الذهب ومتغيرات الاقتصاد الكلي، أي الناتج المحلي الإجمالي الحقيقي، وسعر الفائدة، وأسعار الأسهم، وسعر الصرف الفعلي الحقيقي وأسعار الذهب العالمية. بينت المعاملات المقدرة للعلاقة طويلة الأجل أن سعر الصرف الفعلي الحقيقي وأسعار الذهب العالمية لهما إشارات سالبة وموجبة على التوالي، وكلاهما معنوي عند مستوى 1٪، المتغيرات الأخرى غير ذات دلالة إحصائية، وبالتالي فإن نتائج العلاقة طويلة الأجل تثبت أن سعر الصرف وأسعار الذهب العالمية هما المحددان الرئيسيان لأسعار الذهب في الهند.

▪ دراسة (Omag، 2012) : (2)

نتيجة الأزمة الأخيرة في الأسواق المالية نتجا عنها تزايد أهمية الذهب كمعدن ثمين، وبالتالي فقد أثرت آثار تداول الذهب وأسعاره بشكل كبير على تدفق الأموال في النظام المالي. ففي هذا السياق، تم إبراز وظيفة الذهب بين الأصول البديلة بسبب قيمته ومصادقيته. حيث تناوات هذه

(1) Trivedi, P., & Behera, S. R. (2012). The Macroeconomic Determinants Gold Prices in India: An ARDL Approach. *Journal of International Economics* (0976-0792), 3(2).

(2) Omag, A. (2012). An observation of the relationship between gold prices and selected financial variables in Turkey. *Muhasebe ve finansman dergisi*, (55).

الدراسة العلاقة بين أسعار الذهب والمؤشرات المالية المختارة في تركيا من جانفي 2002 إلى كانون ديسمبر 2011 مع نموذج الانحدار. بينت النتائج أن هناك علاقة إيجابية بين أسعار الذهب الوطنية ومؤشر بورصة اسطنبول 100 وسعر الصرف بين الليرة التركية والدولار.

▪ (Tufail, 2013) (1):

بعنوان تحليل العلاقة بين التضخم وأسعار الذهب: دليل من باكستان، تناولت هذه الدراسة إلى صياغة معادلة تضخم جديدة لامكانية التقاط الآثار المحتملة للذهب وأسعار الأسهم على التضخم في باكستان. حيث هدفت إلى تقييم خصائص التحوط من التضخم للذهب مقارنة بالأصول الأخرى مثل العقارات والأوراق المالية في البورصة والممتلكات بالعملات الأجنبية، بتطبيق تقنيات السلاسل الزمنية للاقتصاد القياسي (نماذج التكامل المشترك وتصحيح خطأ المتجه) على بيانات 1960-2010، وجد أن الذهب هو المحدد المحتمل للتضخم في باكستان، ومن ناحية أخرى فإنه يوفر أيضا تحوطا كاملا ضد التضخم غير المتوقع، أما الأصول العقارية هي أكثر من مجرد تحوط كامل ضد التضخم المتوقع، على الرغم من تفوق الأوراق المالية في البورصة على الذهب والعقارات كتحوط ضد التضخم غير المتوقع، كما تثبت العملة الأجنبية أنها وسيلة تحوط غير معنوية ضد التضخم، وبالنظر إلى الطبيعة المزدوجة للعلاقة بين الذهب والتضخم، من المهم بشكل متزايد أن تقوم الحكومة بمراقبة وتنظيم سوق الذهب في باكستان. علاوة على ذلك ينبغي تشجيع الاستثمار في سوق الأسهم من قبل الحكومة بالنظر إلى أن تضخم أسعار الأصول لا يمثل مشكلة حرجة لباكستان.

▪ دراسة (bin Sukri, 2015) (2):

بعنوان العلاقة بين عوامل اقتصادية كلية مختارة وأسعار الذهب في ماليزيا. تناولت هذه الدراسة إلى دراسة العلاقة بين عوامل الاقتصاد الكلي المختارة وسعر الذهب في ماليزيا. ومن بين عوامل الاقتصاد الكلي (المتغيرات المستقلة) لهذه الدراسة أسعار النفط الخام، وسعر

(1) Tufail, S., & Batoool, S. (2013). An analysis of the relationship between inflation and gold prices: evidence from Pakistan. *The Lahore journal of economics*, 18(2), 1.

(2) Bin Sukri, M. K. A. (2015). *The relationship between selected macroeconomic factors and gold price in malaysia*.

صرف العملة رينجت، الناتج المحلي الإجمالي الماليزي (GDP) الحقيقي، ومعدل التضخم الماليزي في فترة ربع سنوية من عام 2005 إلى عام 2014، حيث تم استخدام الانحدار الخطي المتعدد (MLR) لتحديد عوامل الاقتصاد الكلي التي تؤثر على سعر الذهب في ماليزيا ومعامل الارتباط لتحليل العلاقة بين المتغيرات وتم تحليل جميع البيانات باستخدام برنامج SPSS 20 .

أظهرت النتائج أنه هناك علاقة إيجابية ذات دلالة إحصائية بين سعر النفط الخام وسعر الذهب بالرغم من وجود علاقة سلبية ذات دلالة إحصائية بين سعر صرف الرينجت الماليزي وسعر الذهب، كما بينت النتيجة بين الناتج المحلي الإجمالي الماليزي الحقيقي علاقة إيجابية معنوية مع تأثير منخفض على سعر الذهب، يظهر معدل التضخم علاقة سلبية ذات دلالة ولا يؤثر على سعر الذهب في ماليزيا.

▪ دراسة (Isa, 2015)(1):

ارتكزت هذه الدراسة على التحقيق في متغيرات الاقتصاد الكلي التي تؤثر على أسعار الذهب في ماليزيا باستخدام البيانات الشهرية من 2014 إلى 2018، حيث استخدمت هذه الدراسة ارتباط بيرسون واختبارات الانحدار الخطي المتعدد لتحديد معنوية العلاقات والتأثيرات بين المتغيرات المستقلة، وهي أسعار الفائدة ومعدلات التضخم وسعر النفط الخام وأسعار الصرف مع المتغير التابع وهو سعر الذهب. أظهرت النتائج إلى أن سعر الفائدة له تأثير سلبي كبير على أسعار الذهب في حين أن معدل التضخم وأسعار النفط الخام وسعر الصرف لها تأثير إيجابي كبير على سعر الذهب في ماليزيا على التوالي.

▪ دراسة (Gokmenoglu, 2015)(2):

تعتبر العلاقة المتبادلة بين الأسواق المالية وأسواق السلع من أكثر القضايا صعوبة بالنسبة للمستثمرين. قد يؤثر التقلب في أحد الأسواق على مؤشر أسعار السوق الأخرى .

(1) Isa, M. A. M., Latif, R. A., Nasrul, F., Zaharum, Z., & Ariff, m. k. relational study between macroeconomic variables and gold price: latest malaysian evidence

(2) Gokmenoglu, K. K., & Fazlollahi, N. (2015). The interactions among gold, oil, and stock market: Evidence from S&P500. *Procedia Economics and Finance*, 25, 478-488

فتناولت هذه الدراسة إلى اختبار ما إذا كان سعر الذهب وأسعار النفط وتقلب أسعار الذهب (GVZ) وتقلب أسعار النفط (OVX) لهما تأثير كبير على مؤشر أسعار سوق الأسهم (GSPC) أو لا. ومن أجل القيام بهذه الدراسة ونظراً لخصائص البيانات، تم استخدام مقارنة التكامل المشترك ARDL للتحقق من العلاقة طويلة الأجل بين OVX وGVZ؛ كوكلاء لمؤشرات تقلب سوق النفط والذهب ومؤشر أسعار السوق S & P500. بينت نتائج الدراسة إلى وجود توازن طويل الأجل بين المتغيرات قيد التحقيق واتضح أن مؤشر أسعار البورصة S & P500 يتقارب مع مستوى توازنه على المدى الطويل بنسبة 1.2% من سرعة التعديل اليومي من خلال مساهمة أسعار سوق النفط والذهب وتقلباتها.

▪ دراسة (Eryiğit، 2017) (1)

هدفت هذه الدراسة إلى فحص المتغيرات التي قد تكون مرتبطة بأسعار الذهب. حيث تم تقسيم هذه المتغيرات إلى مجموعتين: المعادن الثمينة والطاقة. ووفقاً لنتائج اختبارات جذر الوحدة (الاستقرارية) واختبارات التكامل المشترك، تم إنشاء نموذج الانحدار الذاتي المتجه (VAR) للكشف عن التفاعل قصير المدى بين أسعار الذهب والمعادن الثمينة، وتم استخدام نموذج تصحيح الخطأ المتجه (VECM) للكشف عن العلاقة بين أسعار الذهب وأسعار الطاقة. أشارت نتائج تحليل VAR إلى أن أسعار الذهب لها علاقة قصيرة المدى بأسعار الفضة. أسعار معدن البلاتين لها ارتباط قصير الأجل بأسعار الذهب والفضة، وهناك علاقة قصيرة المدى بين أسعار الفضة وأسعار البلاتينيوم. وفقاً لنتائج تحليل VECM ليس لأسعار البنزين والنفط الخام ارتباطات طويلة الأجل مع أسعار الذهب، لكن أسعار الذهب والنفط الخام لها علاقة طويلة الأجل بأسعار البنزين.

(1) Eryiğit, M. (2017). Short-term and long-term relationships between gold prices and precious metal (palladium, silver and platinum) and energy (crude oil and gasoline) prices. *Economic research-Ekonomska istraživanja*, 30(1), 499-510.

1-6 : الذهب ملاذ آمن للمستثمرين :

ملاذ آمن في الاستثمار يعرف بأنه الاستثمار في الأصول التي يتوقع أن تحتفظ بقيمتها أو تزداد قيمتها أثناء اضطرابات الأسواق (1).

يعتبر الذهب أحد أعلى الاستثمارات وأكثرها شعبية من بين جميع المعادن الثمينة، حيث اشارت العديد من الدراسات حول استثمار في الذهب إلى أنه أحد أهم أدوات الاستثمار للتنوع وكذلك يمتلك قيمة جوهرية وهو مخزن للقيمة.

كما يخلق أيضا ميزة في التنوع، فيعد تنوع المحفظة أمرا ضروريا في الأسواق العالمية المتنوعة، حتى لو كان ضمن تصنيفات مختلفة للأصول. بالنسبة لبعض المستثمرين على الأقل، ينظر إلى الاستثمار في الذهب على أنه تحوط جيد ضد المخاطر أو ملاذ آمن ضد تحركات سوق الأسهم (2).

ويمكن ارجاع ذلك لمجموعة من الخصائص وهي :

- بينت الأدلة التجريبية بعدم وجود علاقة ارتباط بين عوائد الأصول المالية والذهب، حيث يمكن أن يرتبط الافتقار إلى الارتباط بعوائد الأصول المالية التي تعتمد على متغيرات الاقتصاد الكلي، في حين أن عائد الذهب مستقل.
- يعد الذهب عامل تنوع ممتاز للمحفظة، ويعتبر ملاذا آمنا وتوطا ضد المخاطر.
- إلى جانب اعتماد الأسهم والسندات مع متغيرات الاقتصاد الكلي، فهي أيضا معرضة للمخاطر فالاستثمار في الذهب أكثر فائدة من الاستثمار في الأسهم.

1-7 : الأسباب التي تدفع البنوك المركزية للاستثمار في (3) الذهب (4) :

توجد هناك عدة أسباب مختلفة لاستثمار البنوك المركزية في الذهب، ووفقا لمجلس الذهب

العالمي فأهمها :

(1) Op. cit .Jawad, B. K. (2019). p368.

(2) Op.cit.Al-Ameer, M., Hammad, W., Ismail, A., & Hamdan, A. (2018). P 360.

(3) Dierinck, B., Frömmel, M., Schrauwen, B., & Hermans, M. (2012). Determinants of the gold price. Unievrsiteit Gent.p17.

(4) Op.cit.Uche-Ikonne Okezie, O., Offorha Bright, C., & Ukomah Henry, I. (2020).p 20

- يعمل الذهب كتحوط ضد التضخم، لهذا تستخدم البنوك المركزية احتياطات من الذهب للسيطرة على التضخم.
- الذهب يمنح الثقة في جميع أنحاء العالم ولهذا تحتفظ البنوك المركزية في جميع أنحاء العالم لضمان أموال المودعين ودائني الديون الخارجية وحاملي العملات.
- يقدم الذهب ميزة التنوع.
- التغييرات في النظام النقدي العالمي لا تؤثر على الذهب.
- يوفر الذهب الأمان المادي في حالة حظر الأصول الأخرى على الحسابات.
- لا يتأثر سعر الذهب بالقرارات الحكومية الخاطئة بعكس العملات المعرضة لقرارات خاطئة من قبل الحكومات.
- يقوم الذهب بتقوية الوضع المالي للبلد.

8-1 : أهمية الذهب في الاقتصاد⁽¹⁾ :

لطالما اعتبر الذهب أحد أتمن السلع الموجودة في هذا العالم ويعتبر رمزا للثروة والقوة والازدهار، فمن وجهة النظر الاقتصادية والمالية، تعتبر التحركات في أسعار الذهب مثيرة للاهتمام ومهمة. كما للذهب أهميته في العالم المالي، فإنّ المستثمرين الذين لديهم خطط استثمار يعتبرون الذهب في محافظتهم كقوة لهم. وعليه يمكن توضيح هته الأهمية في النقاط التالية:

- تقوم كل من الدول والأفراد بتنوع أصولهم بالذهب.
- تقوم الأسواق العالمية بمراقب أسعار الذهب عن كثب وتقييم مركزه.
- العديد من عملات الدول حول العالم مدعومة بالذهب.
- الذهب عالمي وبغض النظر عن البلد الذي تذهب إليه أو ما تفعله أسواق العملات، فإنّ الذهب له نفس القيمة ولديه قبول كبير.

(1) Ahmed, F., Kashif, M., & Feroz, F. (2017). Dynamic relationship between gold prices, oil prices, exchange rate and stock returns: Empirical evidence from Pakistan. *NUML International Journal of Business & Management*, 12(1), 109-126.p 111.

9-1 : الذهب في الجزائر :

تعتبر الجزائر من أغنى الدول في العالم وخاصة في الدول العربية من حيث الموارد الطبيعية، مثل البترول، فهي حاليا من أكبر منتجي النفط في العالم وخاصة إفريقيا، فهو يعد المصدر الرئيسي للدخل وكذلك سلعة التصدير الرئيسية في البلاد، فالنفط يمثل أكثر من 80% من صادرات الجزائر ويساهم بـ 98% من إجمالي ناتج الجزائر، فضلا إلى الغاز والحديد والفوسفات والزنك والرصاص والزنبق والباريت والملح والرخام وكذلك الذهب والألماس.

فالجزائر من بين الدول الغنية بالذهب، فاحتياط الذهب بالجزائر يقدر بـ 173.60 طن، مما يجعلها تتصدر المرتبة الثالثة عربيا بعد المملكة العربية السعودية ولبنان، والمرتبة 26 عالميا وفقا لتقرير مجلس احتياطي الذهب العالمي لشهر مارس 2021.

خلاصة :

يعد الذهب المعدن الثمين الذي لعب دورا مهما في المجتمع البشري، واعتبر مصدرا للثروة، فبدأ استخدامه في صناعة المجوهرات الثمينة التي لا تزال تشكّل القسم الأكبر منه - المتداولة حاليا في الاقتصاد - وبعد ذلك تم استخدامه ليكون ناقلا للقيمة في نظام المقايضة إلى نظام النقود الحالي حيث بدأ في تصنيع العملات المعدنية. أي اعتبر الذهب كأصل له طبيعة هجينة: سعة وكوسيلة للتبادل ومخزن للقيمة، مما يجعله أقرب إلى المال .

خلال القرن التاسع قامت الولايات المتحدة الأمريكية - والعديد من البلدان الأخرى - بتثبيت عملتها وتثبيت أسعار صرفها على قدر كبير من الذهب (نظام بريتون وود) وفي سنة 1971 انتهى هذا النظام، فتم تعيين الدولار الأمريكي كعملة عائمة حرة (نقود ورقية) وبالتالي إدخال نظام العملة الورقية والذي يتم التداول به في الوقت الحالي كما يمثل الوضع الحالي للاقتصاد.

فالذهب لا يزال الآن يعتبر أداة مالية تحتفظ بخصائص سلعة وأصل نقدي، كما أنه لا يزال يعتبر أحد الأصول والسلعة الهامة والرائدة في سوق المعادن والقطاعات الصناعية، وكذلك ممتلكات شخصية ثمينة، كما أن الذهب يعتبر وسيلة استثمار عالية السيولة وينظر إلى الذهب على أنه مخزن للقيمة وكذلك يعد بمثابة تحوط ضد التضخم، وأصل مهم في تخصيص المحفظة ودوره في الأزمات لأن الذهب يخلق تحوطا لتنويع المخاطر المتزايدة في السوق أثناء الأزمات.

كما تحتفظ البنوك المركزية والمؤسسات المالية الدولية بكمية كبيرة من الذهب للتنويع والأمن الاقتصادي.



الفصل الثاني:

نماذج ARIMA

تمهيد :

في الحياة العملية غالباً ما نواجه معطيات إحصائية تتغير بمرور الزمن، ولهذا وجب علينا دراسة هذه التغيرات من أجل معرفة أسبابها ونتائجها، ويرجع الاهتمام الكبير بموضوع السلاسل الزمنية إلى الحصول على نظام تنبؤ موثوق به يمكن الاعتماد عليه في تفسير كثير من الظواهر في مختلف مجالات الحياة، وهذا النظام التنبؤي يتطلب بناء نماذج دقيقة تسمى بنماذج السلاسل الزمنية .

يعد موضوع تحليل السلاسل الزمنية من الأساليب الإحصائية المهمة والمستخدم في تفسير سلوك الظواهر لأغراض التنبؤ بما سيحدث في مستقبل هذه الظواهر بأقل خطأ ممكن، ومن هنا يأتي دور السلاسل الزمنية للمساهمة في بناء الخطط والبرامج المستقبلية، وزيادة عن ذلك فإن التقنيات الحديثة والمتطورة للحاسبات الالكترونية والبرمجيات الجاهزة للسلاسل الزمنية عرفت تطورات سريعة مما ساهم بتوسيع تطبيقاتها في مختلف المجالات⁽¹⁾ .

وهناك العديد من الدراسات والبحوث التي اعتمدت السلاسل الزمنية والقيم التاريخية للظواهر المختلفة هدفت أساساً إلى تحليل السلاسل الزمنية وإيجاد صيغ رياضية يمكن استخدامها للتنبؤ المستقبلي بسلوك هذه الظاهرة، ويعتبر أسلوب بوكس-جنكينز أحد الأساليب المستخدمة لبناء النماذج المختلفة في تحليل السلاسل الزمنية، ويقصد بنماذج بوكس-جنكينز تلك المنهجية التي طبقت على السلاسل الزمنية عام (1970) حيث تميزت هذه المنهجية عن باقي الأساليب الأخرى بقدرتها على النمذجة والتنبؤ بالظواهر العشوائية، كما تقدم حلول شاملة لجميع مراحل تحليل السلاسل الزمنية ابتداء من مرحلة اختيار النموذج المبدئي الملائم مروراً بتقدير معالم النموذج وطرائق إيجاد المعلمات، وتليها مرحلة الاختبار والتدقيق للنموذج، لنصل إلى المرحلة الأخيرة وهي مرحلة التنبؤ (تقييم النموذج) لإيجاد القيم المستقبلية.

(1) هاله فاضل حسين، & حسبية كامل مثنى. (2013). "تنبؤ المناخى بإنتاج محصول الحنطة لفترة من (1986-2010) باستخدام نماذج السلاسل الزمنية الخطية. -Al-Nahrain Journal of Science, 16(3), 48-61, ص. 48.

2-1: دراسة وتحليل السلاسل الزمنية:**2-1-1: تعريف السلسلة الزمنية :**

السلسلة الزمنية هي عبارة عن مجموعة من المشاهدات التي تتولد على التوالي خلال الزمن أو هي مجموعة من المشاهدات المرتبطة مع بعضها ويتم تسجيلها خلال فترات زمنية معينة غالباً ما تكون متساوية⁽¹⁾. وقد تنقسم السلسلة الزمنية حسب سلوكها إلى السلسلة الزمنية الموسمية وغير الموسمية، كما قد تصنف إلى سلسلة زمنية مستقرة أي أن المشاهدات لجميع الفترات الزمنية تكون خصائصها الاحتمالية متوازنة ولا تتأثر بالزمن أو غير مستقرة أي أن الخصائص الاحتمالية تكون غير مستقرة وتتأثر بالزمن، وتعرف السلسلة الزمنية رياضياً بأنها متتابعة من المتغيرات العشوائية مُعرّفة ضمن الفضاء الاحتمالي متعدد المتغيرات ومؤشر بالدليل (t) والذي يعود إلى مجموعة دليله T ويرمز للسلسلة الزمنية عادة بالرمز $\{x(t); t \in T\}$ ⁽²⁾.

قد تتكون السلسلة الزمنية من متغيرين أحدهم متغير الاستجابة والثاني متغير الزمن ويرمز لهما في هذه الحالة كالآتي: $x = f(t)$ ، وأما إذا كانت هنالك عوامل أخرى تؤثر على الظاهرة ففي هذه الحالة تكون السلسلة كالآتي: $x = f(t, y_1, y_2, \dots, y_m)$ ⁽³⁾.

2-1-2: مكونات السلاسل الزمنية:

إن التغيرات التي تطرأ على ظاهرة ما خلال فترة من الزمن فهي جراء عدة عوامل، ولا يمكننا أن نرجع سبب هذا التغير إلى عامل واحد من هذه العوامل وإنما يكون نتيجة هذه العوامل مجتمعة، وبتحليلنا للسلسلة الزمنية نتعرف على مقدار هذه التغيرات وإدراك طبيعتها واتجاهها ويصبح بالإمكان القيام بالتقديرات والتنبؤات المستقبلية الضرورية⁽⁴⁾، وهذه المركبات أو مكونات التغير تتضمن أربعة عوامل هي⁽⁵⁾:

(1) TH, M. (2008). Using ARIMA model to forecasting with production of electrics in Australia. AL-Anbar University journal of Economic and Administration Sciences, 1(2).p2.

(2) AL-Sharoot, M. H., & Saheb, D. A. (2014). Forecasting of electricity power consumption in AL-Qadisiya province by using time series models & Artificial neural networks models. Journal of Al-Qadisiyah for computer science and mathematics, 6(1), 9-26.p2.

(3) NS. Dr. Ali Nasser Hussein, (2017) Use the Time Series for the period (2006-20016) to predict Rainfall in Iraqresearcher. Economic Sciences, 12(47).p104.

(4) شيخي محمد، 'طرق الإقتصاد القياسي، مجازات وتطبيقات، دار ومكتبة حمد للنشر والتوزيع، عمان، الطبعة الأولى، 2012، ص:196.

(5) Pazvakawambwa, G. T. (2017). A time-series forecasting model for Windhoek Rainfall, Namibia.P2.

1.2.1.2 : الاتجاه العام *Thend*:

الاتجاه هو ببساطة السلوك الأساسي طويل الأجل أو نمط البيانات أو السلسلة. ونعني به النمو الصيغي للظاهرة حيث يعبر عن تطور متغير ما عبر الزمن سواء كان هذا التطور يميل موجب أو سالب، أي نتيجة لتأثيرات مثل النمو السكاني وتضخم الأسعار والتغيرات الاقتصادية العامة، حيث تكون المشاهدات في السلسلة الزمنية تابعة للزمن الذي يحدد خاصيتها أو سمتها الرئيسية وهي العلاقة الزمنية قد تأخذ أشكالاً مختلفة، والذي يرمز له T_t .

2.2.1.2 : التغيرات الموسمية Seasonal Variations :

ونعني بها التغيرات التي تحدث بانتظام في وحدات زمنية متعاقبة والتي تنجم عن تأثير عوامل خارجية، أو بعبارة أخرى هي تقلبات تحدث خلال فترات أقل من سنة وتكرر على نفس الوتيرة كل سنة، مثل زيادة في استهلاك المياه في الصيف بسبب دفء الطقس، ويرمز لها S_t .

3.2.1.2 : التغيرات الدورية Cyclical Variations :

تعتبر التغيرات الدورية تغيرات تشبه التغيرات الموسمية إلا أنها تتم في فترات أطول نسبا من الفترات الموسمية، عادة ما تكون بسبب أحداث غير متوقعة أو غير متوقعة مثل تلك المرتبطة بالدورة التجارية للارتفاع الحاد في التضخم أو سعر السهم، وبالإضافة إلى ذلك فالفرق الرئيسي بين الاختلاف الموسمي والدوري هو حقيقة أن الأول له طول ثابت ويتكرر عند فترات منتظمة، في حين أن الأخير يختلف في الطول، وزيادة عن ذلك يكون طول الدورة في المتوسط أطول من طول الموسمية حيث يكون حجم الدورة عادة أكثر تقلباً من التغير الموسمي، ويرمز لها C_t .

4.2.1.2 : التغيرات العشوائية Random Stochastic :

هي تلك التي تحدث بصفة غير منتظمة وبسبب عوامل فجائية والتي لا يمكن اعتبارها موسمية أو دورية، حيث لا يمكن التنبؤ بوقوعها أو تحديد نطاق تأثيرها حيث ينشأ عن أسباب عارضة لم تكن

في الحسبان مثل الحروب، الكوارث الطبيعية ...، كما يمكن أن تسيطر هذه التقلبات على الحركات والتي ستخفي كل من الاتجاه والموسمية⁽¹⁾، ويرمز لها بالرمز I_t .

كما يتطلب تحليل السلاسل الزمنية إلى مكوناتها من أجل تحديد نموذجاً لها، وهذا يعني تحديد العلاقة بين مكونات السلسلة الزمنية، وبالنظر إلى تأثيرات هذه المكونات الأربعة يتم استخدام نوعين مختلفين من النماذج بشكل عام لسلسلة زمنية تُعرف بالنموذج الضربي والنموذج التجميعي، ويمكن تمثيل هذه النماذج على النحو التالي⁽²⁾:

$$y_t = T + S + C + I \quad \text{النموذج التجميعي :}$$

$$y_t = T * S * C * I \quad \text{النموذج الضربي :}$$

حيث يعتمد النموذج الضربي بافتراض أن المكونات الأربعة للسلسلة الزمنية ليست بالضرورة مستقلة ويمكن أن تؤثر على بعضها البعض، بينما في النموذج التجميعي يفترض أن المكونات الأربعة مستقلة عن بعضها البعض.

فانطلاقاً من حساب الوسط الحسابي والانحراف المعياري يمكن معرفة طبيعة النموذج، فتكون السلسلة عبارة عن نموذج تجميعي إذا كان الوسط الحسابي والانحراف المعياري ثابتين عبر الزمن، وفي حالة العكسية نقول: عن السلسلة أنها تشكل نموذج ضربي، وعند إجراء تعديلات على النموذج الجدائي نحصل على نموذج تجميعي أو باستخدام الأسلوب البياني وتكون وفق هذه الطريقة السلسلة الزمنية عناصرها تجميعية لما تنحصر ذبذبتها بين خطين متوازيين، أي أن هذه الهزات ثابتة الشدة، بينما السلسلة الجدائية تكون ذبذباتها غير ثابتة الشدة (تباين متزايد أو متناقص) وبالتالي تقع بين خطين منفرجين⁽³⁾.

(1) Amponsah, S. K., Otoo, D., & Todoko, C. A. K. (2015). Time series analysis of water consumption in the Hohoe municipality of the Volta region, Ghana. *International Journal of Applied Mathematics Research*, 4(2), 393.p21.

(2) Hira, F. I., Maruf, M. F., & Hossain, A. (2018). Stock market prediction using time series analysis (Doctoral dissertation, BRAC University).p9

(3) جبريل محمد صديق. (2017) استخدام أساليب تحليل السلاسل الزمنية للتنبؤ بالمصابين بمرض الملاريا: دراسة حالة مستشفى ودمدني التعليمي، السودان 2010-2015 (Doctoral dissertation, University of Gezira). ص. 7.

2-2: طرق تحديد واكتشاف مركبات السلسلة الزمنية :

من أجل الكشف وتحديد مركبات السلسلة الزمنية نستعين بطريقتين⁽¹⁾ تتمثل:

الطريقة الأولى: في استعمال الطريقة البيانية والتي تتطلب دقة كبيرة في عرض بيانات السلسلة الزمنية وذلك راجع للصعوبة الكبيرة التي يلقاها الباحث في كشف مركباتها في الكثير من الحالات، فبصفة عامة إذا كان اتجاه السلسلة الزمنية نحو الأعلى أو نحو الأسفل مع انتظام وتقارب في ذبذباتها يمكن القول: أن شكل السلسلة الزمنية تجميحي متزايد أو متناقص⁽²⁾، بينما تنعكس المركبة الدورية في الشكل البياني على هيئة قمم أو انخفاضات بشكل منتظم يسمح لنا بتحديد فترة حدوث هذه الظاهرة، وأما المتغيرة العشوائية تتمثل في التذبذب الحاصل على مستوى السلسلة، أما المتغيرة الفصلية تتضح من خلال الانتظام الموجود في تسجيل قيمة على الفصل الأخير لكل سنة، أو انخفاض في كل بداية سنة جديدة⁽³⁾.

أما الطريقة الثانية: فتمثل في طريقة الاختبارات الإحصائية التي تستخدم كذلك للكشف وتحديد هذه المركبات ونذكر منها: اختبار "دانيال" لكشف مركبة الاتجاه العام واختبار "كريسكال واليس" لكشف المركبة الموسمية.

2-2-1: اختبار "دانيال" لكشف مركبة الاتجاه العام⁽⁴⁾ :

يعتبر هذا الاختبار أقوى وأدق بكثير من الاختبار البياني، يستعين بمعامل الارتباط لسبيرمان بين ترتيبين :

$$R_t = f(t) , \quad t = 1, \dots, T$$

ومعامل الارتباط يعرف بـ:

(1) عدالة عجال، استخدامات العمليات العشوائية ونماذج الشبكات العصبية في التنبؤ الاقتصادي، ودورها في دراسة الآفاق المستقبلية للواقع التقني والتسويقي للمؤسسة الصناعية بالجزائر (2) *Doctoral dissertation, Université Mohamed Ben Ahmed d'Oran*، ص 23.

(2) هتهات & سعيد. (2006). دراسة إقتصادية وقياسية لظاهرة التضخم في الجزائر، (*Doctoral dissertation*) روقلة، جامعة قاصدي مرباح. كلية الحقوق والعلوم الإقتصادية) ص 136.

(3) شيخي محمد. مرجع سابق. ص 199.

(4) مولود حشان: نماذج وأساليب التنبؤ قصير المدى، ديوان المطبوعات الجامعية، الجزائر، ص 27.

$$r_s = \frac{COV(R_t, t)}{\sqrt{VAR(R_t) \cdot VAR(t)}} = \frac{\sum_{t=1}^T (R_t - \bar{R})(t - \bar{t})}{\sum_{t=1}^T (t - \bar{t})^2} = 1 - \frac{\sigma \sum_{t=1}^T d_t^2}{T(T^2 - 1)}$$

حيث d_t تمثل الفرق بين الترتيب التصاعدي والزمني أي $d_t = (R_t - t)$ ويكون الاختبار

كالآتي:

فرضيات الاختبار: (السلسلة عشوائية) لا يوجد اتجاه عام: H_0

(السلسلة غير عشوائية) يوجد اتجاه عام: H_1

القرار: بعد إيجاد معامل سيرمان r_s ، يتم رفض فرضية العدم H_0 حسب حجم العينة:

في حالة حجم العينة صغير $(T \leq 30)$ ، $r_s > r_{\alpha/2}$.

في حالة حجم العينات الكبيرة $(T > 30)$ ، $|Z| > Z_{\alpha/2}$.

حيث: $Z = \frac{r_s - \mu_{rs}}{\sigma_{rs}}$ و $\mu_{rs} = 0$ و $\sigma_{rs} = \frac{1}{\sqrt{T-1}}$.

2-2-2: اختبار Kruskal-Wallis لكشف المركبة الموسمية (الفصلية) (1):

ويتم تطبيق هذا الاختبار بعد إزالة مركبة الاتجاه قبل محاولة الكشف عن المركبة الفصلية.

فرضيات الاختبار: لا توجد مركبة فصلية: H_0

توجد مركبة فصلية: H_1

وتُختبر هذه الفرضيات بالعلاقة التالية:

$$KW = \frac{12}{T(T+1)} \left[\sum_{i=1}^p \frac{R_i^2}{n_i} \right] - 3(T+1) \rightarrow \chi^2_{(p-1)}$$

حيث:

R_i تمثل مجموع رتب المشاهدات المقابلة للفصل i .

n_i تمثل عدد المشاهدات المقابلة للفصل i .

p تمثل الدورة، حيث تساوي 4 في المشاهدات الفصلية و12 في المشاهدات الشهرية وهكذا إذا

كان n_i أكبر من 5 وفرضية العدم صحيحة فإنه يمكن أن يتبع KW التوزيع χ^2 بدرجة $(p-1)$.

(1) خليدة دلهوم، "أساليب التنبؤ بالمبيعات دراسة حالة"، مذكرة مقدمة لنيل شهادة الماجستير في العلوم التجارية، جامعة الحاج لخضر- باتنة- كلية العلوم الاقتصادية وعلوم التسيير، 2008-2009، ص. 86.

القرار: رفض H_0 إذا كان $KW > x_{(p-1)}^2$.

2-3: تحليل السلاسل الزمنية العشوائية:

يعد موضوع تحليل السلاسل الزمنية من المواضيع الإحصائية المهمة، التي تعرف سلوك الظواهر وتفسيرها عبر حقب زمنية محددة، ويشترط أن تكون السلسلة الزمنية مستقرة؛ أي أن خصائصها الرياضية والإحصائية لا تعتمد على الزمن، ويبقى هذا الشرط مهماً، كون هذا المفهوم (الاستقرارية) يلعب دوراً مركزياً في النظرية العملية، نظراً لأن أغلب الظواهر لها سلوك غير مستقر، ولهذا يجب قبل دراسة وتحليل أي ظاهرة اقتصادية، لابد من التأكد أولاً من وجود اتجاه عام في السلسلة الزمنية، وحسب طبيعة تطور السلسلة يمكننا أن نميز بين سلاسل زمنية مستقرة وأخرى غير مستقرة⁽¹⁾.

2-3-1: السلاسل الزمنية المستقرة وغير المستقرة:

تكون السلسلة الزمنية مستقرة إذا كانت في موازنة إحصائية، ونعني بهذا أن السلسلة الزمنية تمتلك وسطاً حسابياً مع تباين ثابتين مع استمرار الزمن، وكذلك تكون السلسلة الزمنية مستقرة عند عدم ظهور أي اتجاه عام وتذبذبات مختلفة في شكل السلسلة، ولذلك يمكن التمييز بين نوعين من السلاسل الزمنية المستقرة⁽²⁾: سلاسل زمنية ذات استقرارية تامة وسلاسل زمنية ذات استقرارية ضعيفة.

2-3-2: السلسلة الزمنية ذات الاستقرارية التامة⁽³⁾:

تكون السلسلة الزمنية تامة الاستقرار، إذا كانت دالة التوزيع للمتغيرات العشوائية لا تتغير مع الزمن، وبعبارة أخرى أن التوزيع الاحتمالي المشترك لقيم السلسلة الزمنية تعتمد على الإزاحة بين قيم السلسلة ولا تعتمد على القيم الحقيقية لها، أي أن:

(1) عمار شهاب أحمد. (2017). استخدام نماذج السلاسل الزمنية للتنبؤ بكمية صادرات العراق النفطية لعامي 2016-2017. *Journal of*

Baghdad College of Economic sciences University, (52). ص 419

(2) زيان إحسان كريم حمدي. (2013). استخدام نماذج *Box-Jenkins* للتنبؤ بالمبيعات (دراسة تطبيقية في معمل سمنت كركوك). مجلة جامعة كركوك للعلوم الإدارية والاقتصادية المجلد (3) العدد (2013). ص 192.

(3) إيمان محمد المشهداني وجاسم محمد كاظم. (2016). استعمال نماذج بوكس وجنكنز للتنبؤ بأعداد المرضى المصابين بمرض التهاب الكبد الفيروسي في العراق. ص 412.

$$Y_{t1}, Y_{t2}, \dots, Y_{tn} = Y_{t1} + K, Y_{t2} + K, \dots, Y_{tn} + K$$

2-3-3: السلاسل الزمنية ضعيفة الاستقرارية (1):

تكون السلسلة ذات استقرارية ضعيفة، أو ذات استقرارية من الدرجة الثانية، إذا كان متوسطها وتباينها ثابتاً بمرور الزمن، وتعتمد قيمة التغير بين فترتين فقط على الإزاحة (k) بين الفترتين. ومنه فإن:

$$E(Y_t) = \mu \quad \text{القيمة المتوقعة } Z_t \text{ ثابتة}$$

$$\text{cov}[Y_t, Y_{t+k}] = Y_k \quad \text{دالة التغير الذاتي يعتمد على الإزاحة (K)}$$

وبناءً على ما سبق فتكون السلسلة الزمنية تتحقق الاستقرارية التامة بتوافر ثلاثة شروط وهي (2):

$$E(Y_t) = \mu \quad \text{عندما تكون قيمة المتوسط الحسابي ثابتة}$$

$$\text{Var}(y_t) = \sigma_z^2 = \hat{\gamma}_0 \quad \text{قيمة التباين ثابتة}$$

حيث تمثل $\hat{\gamma}_0$ تباين السلسلة الزمنية ويكون ثابتاً ولا تعتمد على قيم t وتقديره:

$$\hat{\gamma}_0 = \frac{1}{n} \sum_{t=1}^n (y - \bar{y})^2$$

وأخيراً دالة التباين المشترك الذاتي Autocovariance تمثل دالة فرق الزمن المشترك:

$$\text{cov}(Y_t, Y_{t+k}) = E[(Y_t - \mu)(Y_{t+k} - \mu)] = \text{cov}(Y_{t+k}, Y_{t+k+s}) = \gamma(k)$$

2-4: دراسة استقرارية السلسلة الزمنية:

يمكن التحقق أو الكشف عن استقرارية السلسلة الزمنية عن طريق استخدام دوال الارتباطات الذاتية أو استخدام الاختبارات الإحصائية لمعرفة هل أن مشاهدات السلسلة الزمنية تتصف بالاستقرارية.

(1) حضري خولة (2015)، استخدام السلاسل الزمنية من خلال منهجية بوكس جينكينز في اتخاذ القرار الانتاجي دراسة حالة مطاحن الرياض سطيف

وحدة تقرب-في الفترة (2013-2008) Doctoral dissertation, Université Mohamed Khider-(Biskra) ص 43.

(2) Fatima Abdul Hamid Jawad Al Bermani. (2019). Using Time Series for Predict the Standard Numbers for Residential Rent in Iraq for the Years 2018-2021. Al-Rafidain University College For Sciences, (45). P 81.

2-4-1: دالة الارتباط الذاتي :

إن الارتباط الذاتي مقياس يقيس درجة العلاقة بين قيم السلسلة مع نفسها لمدة زمنية بفرق إزاحات مختلفة، وتعد دالة الارتباط الذاتي (ACF) صفة مميزة للعملية العشوائية فهي واحدة من الوسائل المهمة التي تستعمل لمعرفة سلوك السلسلة الزمنية ومدى استقراريتها وذلك من خلال ارتداد زمني متعاقب K (1)، وكما تستخدم أيضًا للحصول على تقديرات تقريبية للمعاملات (باستخدام معادلات: Yule-Walker)، والتي تكون مفيدة في مرحلة التقدير لتوفير قيم البداية للإجراءات التكرارية المستخدمة أثناء تقدير المعلمات النهائية (2)، وتعطى بالصيغة الرياضية كالآتي (3):

$$p_k = \frac{cov(x_t, x_{t-k})}{\sqrt{var(x_t)var(x_{t-k})}} = \frac{\gamma_k}{\gamma_0}$$

حيث :

p_k يشير إلى معامل الارتباط الذاتي للسلسلة المستقرة عند الفجوة k ويقاس الارتباط الخطي بين المتغيرات على نفس السلسلة الزمنية والتي تبعد عن بعضها البعض بفجوة زمنية مقدارها k .
 γ_k هو التغير الذاتي عند الفجوة الزمنية k للسلسلة الساكنة.

γ_0 تباين السلسلة الساكنة.

وتكون السلسلة الزمنية مستقرة إذا كان لها معامل ارتباط ذاتي مساويا للصفر أو قريب منه وبمعنى آخر انخفاض الارتباطات الدانية كلما ارتفعت k ، في حين غير المستقرة لها فروق معنوية تقترب من الصفر بعد الفترة السابعة أو الثامنة.

(1) إيمان محمد المشهداني وجاسم محمد كاظم. (2016). مرجع سابق. ص 413.

(2) Paretkar, P. S. (2008). Short-Term Forecasting of Power Flows over Major Pacific Northwestern Interties: Using Box and Jenkins ARIMA Methodology (Doctoral dissertation, Virginia Tech).p27.

(3) Zain, S. H. (2018). Using the ARIMA method in forecasting money Supply in the Iraqi economy. Gulf Economist, 34(35).p118

ومن أبرز خصائص دالة الارتباط الذاتي هي (1):

$$1-\rho_0 = 0.$$

$$2-\rho_k = \rho - k.$$

$$3-|\rho_k| \leq 1.$$

2-4-2: دالة الارتباط الذاتي الجزئي :

إن دالة الارتباط الذاتي الجزئي تقيس درجة الارتباط بين Y_t و Y_{t+k} عندما يكون تأثير التأخيرات الزمنية الأخرى على Y مستقرة. يتم تحديد دالة الارتباط الذاتي الجزئي (PACF) التي يُشار إليها بمجموعة من الارتباطات الذاتية الجزئية عند فترات تأخر مختلفة k بواسطة $(r_{kk}, k = 1, 2, 3, \dots)$. يتم تحديد مجموعة الارتباطات الذاتية الجزئية عند فترات تأخر مختلفة k بواسطة (2):

$$r_{kk} = \frac{rk - \sum_{j=1}^{k-1} rk - 1, jr k - 1}{1 - \sum_{j=1}^{k-1} rk - 1, jr k}$$

حيث :

$$r_{kk} = r_{k-1, j} - r_{kk} r_{k-1, k-1} \text{ و } j = 1, 2, \dots, k - 1.$$

تعتبر الارتباطات الذاتية الجزئية على وجه التحديد، مفيدة في تحديد ترتيب نموذج الانحدار الذاتي. الارتباط الذاتي الجزئي لعملية $AR(P)$ هو صفر عند التأخر $p + 1$ وكذلك أكبر. مجال الثقة التقريبي 95% للارتباطات الذاتية الجزئية هو عند $\pm 2/N$.

(1) Nihad Sharif Khalaf and Heba Hani Abdullah(2012) Modeling the time series of the mean of monthly temperature in Samraa City. Tikrit Journal of Administration and Economics Sciences, 8(25).p144.

(2) Amponsah, S. K., Otoo, D., & Todoko, C. A. K. (2015). Time series analysis of water consumption in the Hohoe municipality of the Volta region, Ghana. International Journal of Applied Mathematics Research, 4(2), 393. P395.

2-4-3: اختبار جذر الوحدة للاستقرارية :

لا تعمل اختبارات الجذر الحدودي فقط على كشف مركبة الاتجاه العام، بل إنها تساعد على تحديد الطريقة المناسبة لجعل السلسلة مستقرة، ومن أجل فهم هذه الاختبارات لابد من التفريق بين نوعين من النماذج الغير المستقرة⁽¹⁾.

(أ) أنواع النماذج غير المستقرة :

1- النموذج TS (Trend-Stationary) :

تعد سلاسل غير مستقرة لها معادلة اتجاه عام فضلاً عن نموذج عشوائي مستقر بوسط حسابي

صفر وتباين ثابت، وتأخذ الشكل: $Y_t = f_t + \varepsilon_t$

حيث تشير f_t إلى دالة كثير الحدود للزمن (خطية أو غير خطية)، و ε_t إلى التشويش الأبيض. ويتم تمثيل النموذج TS الذي يعد الأبسط وأكثر شيوعاً أو انتشاراً بدالة كثير الحدود من الدرجة (1)، ويكتب بالشكل التالي⁽²⁾:

$$Y_t = a_0 + a_1 t + \varepsilon_t$$

يعد النموذج TS هذا غير مستقر كون متوسطه $E[Y_t]$ مرتبط بالزمن، ومن أجل جعله مستقراً نقوم بمعرفة \hat{a}_0, \hat{a}_1 المقدرة، وبعد ذلك نطرح المعالم المقدرة $\hat{a}_0 + \hat{a}_1 t$ من قيمة Y_t عند الزمن t ، حيث في هذا النوع من النمذجة يكون التأثير الناتج عن الصدمة (أو عدة صدمات عشوائية) في الزمن t مؤقتاً.

2- النموذج DS (Defference-Stationary) :

تعتبر هذه النماذج بسلاسل غير مستقرة ذات اتجاه عام عشوائي وتتميز بوجود جذر الوحدة مرة واحدة على الأقل⁽³⁾، ولجعلها مستقرة نقوم بتطبيق مرشح الفروق الأولى⁽⁴⁾:

$$(1 - D)^d Y_t = \beta + \varepsilon_t$$

حيث: ε_t عملية ثابتة، β ثابت حقيقي، و D يمثل معامل التأخير، أما d هي درجة الفروقات. وغالباً ما يتم تمثيل هذه النماذج باستخدام الفرق الأولى ($d = 1$)، وتكتب على الشكل:

(1) Hashem, F. (2020). Analysis of time series to predict the numbers of pupils in the first grade of primary school using of the Box Jenkins ((applied study in the governorate of Basra)). Economic Sciences, 15(59).p 100.

(2) Bourbonnais, R. (2015). Économétrie-9e édition: Cours et exercices corrigés. Dunod.p245

(3) Hashem, F. (2020), Op-cit, p 101.

(4) Bourbonnais, R. (2015) ,Op-cit,p246.

$$(1 - D) Y_t = \beta + \varepsilon_t$$

إن إدخال الثابت β في نموذج DS يسمح بتحديد نموذجين مختلفتين⁽¹⁾:

إذا كانت $\beta = 0$: يسمى النموذج DS بدون مشتقة ويكتب من الشكل:

$$Y_t = Y_{t-1} + \varepsilon_t$$

وبما أن ε_t عبارة عن تشويش بيضاء، فإن نموذج DS هذا يسمى نموذج السير العشوائي (Random Walk Model)، ويستخدم كثيرا لتحليل كفاءة الأسواق المالية.

إذا كانت $\beta \neq 0$: يسمى النموذج DS بالمشتقة ويكتب من الشكل:

$$Y_t = Y_{t-1} + \beta + \varepsilon_t$$

2-4-5: اختبار دكي فولر Dickey - Fuller test :

تعتبر اختبارات دكي - فولر واحدة من بين الأساليب المعاصرة المستعملة لفحص استقرارية السلسلة الزمنية، ويتحقق شرط الاستقرار فيها عندما تكون جذور الوحدة للسلسلة تقع داخل دائرة الوحدة⁽²⁾.

$$\Delta X_t = \alpha_1 X_{t-1} + e_t$$

$$\Delta X_t = \alpha_0 + \alpha_1 X_{t-1} + e_t$$

$$\Delta X_t = \alpha_0 + \alpha_1 X_{t-1} + B_t + e_t$$

حيث :

Δ يدل عن معامل الفروق الأولى، أي $\Delta X_t = X_t - X_{t-1}$.

e_t سياق التشويش الأبيض.

α_0 تمثل الحد الثابت، و B_t تمثل الاتجاه الزمني.

(1) هتهات السعيد، 2006، مرجع سابق، ص. 142.

(2) عثمان نقار - منذر العواد، منهجية Box-Jenkins في تحليل السلاسل الزمنية والتنبؤ دراسة تطبيقية على أعداد تلاميذ الصف الأول من التعليمية الأساسي في سورية، مجلة جامعة دمشق للعلوم الاقتصادية والقانونية - المجلد 27 العدد الثالث - 2011، ص. 129.

اختبار الفرضيات :

الفرضية العدمية لهذا الاختبار هي : $H_0: \alpha_1 = 0$ (وجود جذر وحدوي أي عدم استقرار السلسلة الزمنية) أما الفرضية البديلة فهي : $H_1: \alpha_1 < 0$. تقارن احصائية الاختبار $t = \frac{\alpha_1}{SE(\alpha_1)}$ مع القيم النظرية التي وضعها Dickey and Fuller في الجدول .

إن اختبار Dickey and Fuller البسيط يقتصر على نماذج انحدار ذاتي من المرتبة (1)(1)

2-4-6: اختبار دكي فولر المطور The augmented Dickey - Fuller test :

يعد اختبار ديكى - فولر المطور امتداد لاختبار ديكى فولر البسيط لنماذج السلاسل الزمنية الأكبر والأكثر تعقيداً،، وعلاوة على ذلك فإن اختبار Dickey-Fuller البسيط يقتصر فقط لعملية الانحدار الذاتي من الرتبة $AR(1)$

ويعتمد الاختبار على المعادلات التالية الآتية (2):

نموذج ذو حد ثابت واتجاه عام

$$\Delta y_t = \alpha + \beta_t + \theta y_{t-1} + \sum_{i=1}^k \gamma \Delta y_{t-1} + \varepsilon_t$$

نموذج ذو ثابت

$$\Delta y_t = \alpha + \theta y_{t-1} + \sum_{i=1}^k \gamma \Delta y_{t-1} + \varepsilon_t$$

نموذج محدود (بدون حد ثابت واتجاه زمني)

$$\Delta y_t = \theta y_{t-1} + \sum_{i=1}^k \gamma \Delta y_{t-1} + \varepsilon_t$$

حيث :

$H_0: \theta = 0$ الفرضية العدمية .

$H_1: \theta < 0$ الفرضية البديلة .

في حالة قبول الفرضية العدمية فيدل على عدم ثبات السلسلة بسبب وجود جذر الوحدة، وإذا تم قبول الفرضية البديل، فإن السلاسل الزمنية ثابتة.

(1) يسر محمود محمد الحاج. (2017). استخدام الطرق الإحصائية في التنبؤ بكميات الأسماك المنتجة في قطاع غزة (Doctoral dissertation), ص 33.
(2) Wang, Z. (2007). Study the relationship between real exchange rate and interest rate differential-United States and Sweden.p7

في النماذج الثلاثة السابقة قمنا بإضافة عدد مناسب من حدود الفرق المبطأة (ΔY_{t-j+1}) من أجل التخلص من الارتباط الذاتي (Autocorrelation) لحد الخطأ وبالتالي تصبح (ε_t) غير مرتبطة ذاتيا وتتميز بالخواص المرغوبة لتشويش الأبيض، ولتحديد عدد الفجوات الزمني p يتم عادة استخدام معايير مثل (Schwarz، Akaike) (1).

7-4-2: اختبار Kwiatkowski-Phillips-Schmidt-Shin (KPSS)

تم اقتراح هذا الاختبار من لدن Kwiatkowski & Al (1992)، حيث يختلف عن الاختبارات الأخرى، فيفترض في هذا الاختبار أن تكون السلسلة مستقرة في ظل فرضية العدم، ويفترض وجود اتجاه خطي، حيث يستخدم إحصائيات اختبار مضاعف لاغرانج (2). ويتم تطبيق هذا الاختبار وفق المراحل التالية (3):

$$y_t = \xi_t + r_t + \varepsilon_t$$

حيث :

r_t تمثل السير العشوائي، أي $r_t = r_{t-1} + \mu_t$ ، حيث يفترض r_t أن تكون $r_t \sim i. i. d(0, \sigma_\mu^2)$ ، أما ξ_t فهو اتجاه ثابت محدد، و ε_t تمثل الخطأ المستقر.

نقوم بحساب المجموع الجزئي للبواقي من نموذج الانحدار وتكون كالآتي :

$$S_t = \sum_{i=1}^t \hat{\varepsilon}_i, t = 1, 2, \dots, T$$

ثم نقدر التباين الطويل الأجل S_1^2 بنفس طريقة اختبار فليبس وبيرون.

نحسب إحصائية اختبار KPSS للفرضية العدمية وفق العلاقة التالية :

$$LM = \frac{\sum_{t=1}^T S_t^2}{T^2 \hat{\sigma}_\varepsilon^2}$$

(1) Chafik Arbach et al (2011), Les testes de causalité & cointégration dans l'analyse des séries temporelles, Tishreen University Journal for Research and Scientific Studies -Economic and Legal Sciences Series Vol. (33) No. (5) 2011.p82.

(2) Suleiman, S., Usman, U., & Adamu, U. (2015). Modeling and forecasting the crude oil price in Nigeria. Nov. Journals, 2(1), 1-13.p3.

(3) AIDOO, E. (2011). Forecast performance between sarima and setar models: An application to ghana inflation rate.p7.

وأخيراً نرفض الفرضية العدمية (الاستقرارية): إذا كانت الإحصائية المحسوبة LM أكبر من القيمة المجدولة.

2-4-8: اختبار Phillips and Perron (pp)

يتمثل أحد القيود الرئيسة لاختبار ADF في أنه يقوم على افتراض أن شروط الخطأ موزعة بشكل مستقل ومتماثل، مما يجعل هذا الافتراض لا يصح في كثير من الحالات، يعد اختبار فيليبس-بيرون (PP) من بين الاختبارات المستخدمة لاختبار استقرارية السلسلة الزمنية، حيث يعتمد على نفس معادلات التقدير المستخدمة في اختبار ديكي فولر البسيط (DF)، إلا أنه يختلف عن اختبار (DF) كونه يقوم بالتحكم في الارتباط المتتالي ذو الرتبة العالية في السلسلة من جهة ومن جهة أخرى يقوم بتخفيف افتراضات ADF للاستقرارية والتجانس من خلال طريقة معالجة وجود الارتباط الذاتي للبواقي وكذلك عدم التجانس، إذ يقوم اختبار (PP) بتعديل اختبار Dickey-Fuller غير البارامترية للتأكيد على الارتباط الذاتي الموجود في معادلة (DF) والتي من شأنها تحيز المعاملات⁽¹⁾. ويجري اختبار فيليبس-بيرون PP في خمسة مراحل⁽²⁾:

استخدام طريقة المربعات الصغرى OLS لتقدير النماذج الثلاثة لاختبار (DF) وحساب الإحصائيات المرافقة.

تقدير تباين قصير الأجل $\hat{\sigma}^2 = \frac{1}{n} \sum_{t=1}^n \varepsilon_t^2$ ، تمثل الباقي المقدر.

تقدير المعامل المصحح المسمى بالتباين طويل الأجل وفقاً للصيغة التالية:

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{t=1}^n \varepsilon_t^2 + 2 \sum_{i=1}^L \left(1 - \frac{i}{L+1}\right) + \frac{1}{n} \sum_{t=1}^n \hat{\varepsilon}_t \hat{\varepsilon}_{t-1}$$

من أجل تقدير هذا التباين الطويل الأجل من الضروري إيجاد عدد التباطؤ وفقاً للصيغة

$$\text{التالية: } L \approx 4 \left(\frac{N}{100}\right)^{2/9}$$

(1) Sethare, L. (2002). *Empirical foundations of monetary policy in Botswana*. p125.

(2) Sebha, M. A., & Alaswed, H. A. (2018). مقترنة بعض اختبارات جذر الوحدة في الكشف عن استقرار السلاسل الزمنية باستخدام المحاكاة. *Sebha University Journal of pure & Applied sciences (JOPAS)*, 17(2), p27.

حساب إحصائية فيليب وبيرون : $PP = \sqrt{K} * \frac{(\hat{\phi} - 1)}{\hat{\sigma}_{\hat{\phi}}} + \frac{n(K-1)\hat{\sigma}_{\hat{\phi}}}{\sqrt{K}}$ حيث $K = \frac{\hat{\sigma}^2}{s_1^2}$

وأخيراً مقارنة القيمة الإحصائية المحسوبة مع الجدولة والمأخوذة من جداول ماك كينون.

2-5: منهجية بوكس - جنكينز :

لقد اكتسبت نماذج ARIMA المعروفة بمنهجية Box and Jenkins التي طورت سنة (1976) استخداماً واسعاً في العديد من المجالات وقد تم إثبات قوتها ومرونتها في تحليل السلاسل الزمنية على نطاق واسع من بين طرق التنبؤ بالسلاسل الزمنية الخطية كونها تفترض بقوة أن قيم البيانات المستقبلية مرتبطة خطأً بقيم البيانات الحالية والسابقة وبهذه الطريقة، فإنها تعطي نتائج عالية الدقة في تقدير السلاسل الزمنية الثابتة، وقبل التطرق إلى هذه المنهجية تجدر الإشارة التي تلك النماذج المستخدمة ضمن هذه المنهجية .

2-5-1: نموذج الانحدار الذاتي (AR) (1)

هو تمثيل لنوع من العمليات العشوائية، والهدف من استخدامه هو وصف لعمليات معينة متغيرة بمرور الوقت في بيانات السلاسل الزمنية، يحدد نموذج الانحدار الذاتي أن قيمة المتغير الحالية تعتمد خطأً على قيمه السابقة وعلى الخطأ العشوائي وبالتالي، فإن النموذج في شكل معادلة فروق عشوائية.

والصيغة العامة لنموذج الانحدار الذاتي من الدرجة (p) الذي يرمز له $AR(p)$ هي :

$$X_t = C + \varphi_1 X_{t-1} + \dots + \varphi_p X_{t-p} + \varepsilon_t$$

$$X_t = C + \sum_{i=1}^p \varphi_i X_{t-i} + \varepsilon_t$$

حيث أن :

$\varphi_1, \dots, \varphi_p$: تمثل معاملات نموذج الانحدار الذاتي التي يتطلب تقديرها وكذلك تصف اثر تغير

كل من $X_t, X_{t-1} \dots X_{t-p}$.

(1) Bakar, N. A., & Rosbi, S. (2017). Autoregressive integrated moving average (ARIMA) model for forecasting cryptocurrency exchange rate in high volatility environment: A new insight of bitcoin transaction. *International Journal of Advanced Engineering Research and Science*, 4(11), 237311.p132.

C : تمثل ثابت النموذج.

ε_t تمثل متغيرات العشوائية أو ما يسمى بعملية التشويش الأبيض (White noise) غير مرتبطة مع بعضها بوسط حسابي صفر وتباين ثابت القيمة رمزه σ_{ε}^2 .

كما يمكن استخدام نموذج الانحدار الذاتي لتمثيل السلسلة المستقرة وغير المستقرة وان شروط استقرار النموذج يجب أن تقع جذور المعادلة خارج حدود دائرة الوحدة، أي أن تكون محصورة بين $(-1 < \varphi_p < 1)$ (1).

ودالة الارتباط الذاتي للنموذج $AR(p)$ تكون متناقصة بشكل أسي أو بشكل موجات جيبيّة متضائلة، أما دالة الارتباط الجزئي فإنها تنقطع عند الصفر بعد الإزاحة p وبها تحدد رتبة النموذج. وبهذه الخاصية يحدد نوع النموذج ورتبته (2).

2-5-2 : نموذج المتوسط المتحرك (MA) (3)

يمكن من خلال الأخطاء العشوائية في الفترة الحالية والفترات السابقة الحصول على قيمة السلسلة الزمنية في الزمن t ، ومن خلال هذه العملية نحصل على ما يسمى بنموذج المتوسطات المتحركة، في هذا النموذج يعبر عن القيمة السلسلة الحالية بدلالة القيمة الحالية للأخطاء والأخطاء السابقة وقيم المعلمات، أي أن النموذج يعتمد على الخطأ العشوائي للنموذج.

والصيغة العامة لنموذج المتوسط المتحرك من الدرجة (q) الذي يرمز له $MA(q)$ هي :

$$X_t = C + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t$$

$$X_t = C + \sum_{j=1}^q \theta_j \varepsilon_{t-j} + \varepsilon_t$$

حيث :

$\theta_1, \theta_2, \dots, \theta_q$: تمثل معاملات النموذج.

C : تمثل ثابت النموذج.

(1) سعدية عبد الكريم طعمه. (2012). استخدام تحليل السلاسل الزمنية للتنبؤ بأعداد المصابين بالأورام الخبيثة في محافظة الانبار. مجلة جامعة الانبار للعلوم الاقتصادية والادارية، 4(8)، 371-393. ص 376.

(2) Fatima Abdul Hamid Jawad Al Bermeni. (2019). Op.cit, p82.

(3) Taherifard, E. (2019). Load and Demand Forecasting in Iraqi Kurdistan using Time series modelling.p8

ε_t تمثل الخطأ العشوائي ويتوزع توزيعاً بشكل طبيعي ومستقل بوسط صفر وتباين ثابت σ^2 (1).

أما بالنسبة لدالة الارتباط الذاتي لنموذج المتوسط المتحرك فتتقطع عند الصفر بعد الإزاحة q وبها تحدد رتبة النموذج، أما بالنسبة فإن دالة الارتباط الذاتي الجزئي فإنها تتناقص بشكل أسّي أو بشكل موجات جيبيّة متضائلة (2).

2-5-3 : نموذج الانحدار الذاتي والمتوسط المتحرك (ARMA)* :

تعد نماذج الانحدار الذاتي والمتوسّطات المتحركة (ARMA) كأداة مفيدة وقوية لوصف ديناميات سلسلة زمنية، فمن خلالها يمكن تقدير القيمة القادمة لسلسلة زمنية كمجموعة خطية من القيم التي لوحظت بالفعل. حيث يعتمد حساب معاملات هذه المجموعة الخطية، وهي معاملات النموذج، على السلاسل الزمنية نفسها، بحيث يتم شرح كل قيمة من قيم السلسلة بواسطة الجمع الخطي لبعض قيمه السابقة، وهذا في أفضل طريقة ممكنة.

وبهذا توصف نماذج الانحدار الذاتي والمتوسّطات المتحركة عن مزيج من المتوسّطات المتحركة وسيرورة الانحدار الذاتي، ويرمز لها بالرمز $ARMA(p, q)$ ، ومن خصائص هذه النماذج أنها سيرورة سببية ومستقرة وقابلة للانعكاس (3)، حيث تعطى بالصيغة الرياضية التالية (4):

$$X_t = C + \varepsilon_t + \sum_{i=1}^p \varphi_i X_{t-p} + \sum_{j=1}^q \theta_j \varepsilon_{t-q}$$

حيث :

X_t تمثل السلسلة المراد وصفها، أما C فهي قيمة ثابتة، $(\varphi_1, \varphi_2, \dots, \varphi_p)$ تشير إلى معاملات عملية AR ، و $(\theta_1, \theta_2, \dots, \theta_q)$ تدل على معاملات عملية MA وأخيراً (ε_t) فهي عملية التشويش الأبيض.

(1) Taheri Tizro, A., Ghashghaie, M., Georgiou, P., & Voudouris, K. (2014). Time series analysis of water quality parameters. *Journal of Applied Research in Water and Wastewater*, 1(1), 40-50.p43.

(2) Fatima Abdul Hamid Jawad Al Bermeni. (2019). *Op.ci,t* p83.

* Autoregressive Moving Average Model.

(3) Hosseinipoor, S. (2016). Forecasting Natural Gas Prices in the United States Using Artificial Neural Networks.p27

(4) Gomes, P., & Castro, R. (2012). Wind speed and wind power forecasting using statistical models: autoregressive moving average (ARMA) and artificial neural networks (ANN). *International Journal of Sustainable Energy Development*, 1(1/2).p43.

وعادة يتم معالجة نماذج ARMA باستخدام عامل التأخير الإزاحة، ويتم تعريف عامل التأخر أو الانزياح الخلفي على أنه $LX_t = X_{t-1}$ وتستخدم كثيرات حدود عامل التأخير أو كثيرات الحدود المتأخرة لتمثيل نماذج ARMA على النحو التالي⁽¹⁾:

$$AR(p) \text{ model} : \varepsilon_t = \varphi(L)X_t$$

$$MA(q) \text{ model} : X_t = \theta(L)\varepsilon_t$$

$$ARMA(p, q) \text{ model} : \varphi(L)X_t = \theta(L)\varepsilon_t$$

حيث :

$$\varphi(L) = 1 - \sum_{i=1}^p \varphi_i L^i \text{ و } \theta(L) = 1 + \sum_{j=1}^q \theta_j L^j$$

ε_t تمثل سلسلة الأخطاء العشوائية المستقلة وذات توزيع طبيعي بمتوسط حسابي يساوي الصفر وكذا تباين ثابت σ_ε^2 ، أما شرط الاستقرار والانعكاسية فان لعملية $AR(p)$ خاصية مهمة تتمثل في قابلية الانعكاس، أي يمكن دائماً كتابة عملية $AR(p)$ من حيث عملية $MA(\infty)$. بينما لكي تكون عملية $MA(q)$ قابلة للانعكاس، يجب أن تقع جميع جذور المعادلة $\theta(L=0)$ خارج دائرة الوحدة، وتُعرف هذه الحالة بشرط الانعكاس لعملية MA . وفي حالة ما إذا وقع الجذر داخل دائرة الوحدة فيصبح النموذج غير مستقر، ومن خلال أخذ الفروق المناسبة ليصبح مستقرًا فيطلق عليها نماذج ARIMA⁽²⁾.

2-5-4: نموذج الانحدار الذاتي والأوساط المتحركة المتكاملة (ARIMA):*

يعد نموذج الانحدار الذاتي والأوساط المتحركة المتكاملة، (ARIMA) لاسيما في الإحصاء والاقتصاد القياسي وخاصة في تحليل السلاسل الزمنية بمثابة تعميم لنموذج الانحدار الذاتي والمتوسط المتحرك (ARMA). وتطبق منهجية Box-Jenkins التي سميت على اسم الإحصائيين جورج يطبق Box and Gwilym Jenkins نماذج ARIMA للعثور على أفضل ملائمة لسلسلة زمنية للقيم السابقة

(1) Adhikari, R., & Agrawal, R. K. (2013). An introductory study on time series modeling and forecasting. arXiv preprint arXiv:1302.6613.p20.

(2) Yuan, C., Liu, S., & Fang, Z. (2016). Comparison of China's primary energy consumption forecasting by using ARIMA (the autoregressive integrated moving average) model and GM (1, 1) model. Energy, 100, 384-390.p386.

* Autoregressive Integrated Moving Average model.

لهذه السلسلة وهذا من أجل إجراء تنبؤات ويتم تطبيقها في بعض الحالات التي تظهر فيها البيانات دليلاً على عدم الاستقرار في السلسلة، ولهذا يجب تحويلها إلى سلسلة مستقرة قبل بناء النموذج الرياضي وذلك بأخذ الفروق (d) حيث تكون خطوة الاختلاف الأولية (المقابلة للجزء "المتكامل" من النموذج) من أجل لإزالة عدم الاستقرار. ويشار إلى النموذج عمومًا على أنه نموذج $ARIMA(p, d, q)$ حيث p و d و q هي أعداد صحيحة غير سالبة تشير إلى ترتيب أجزاء الانحدار التلقائي والمتكاملة والأوساط المتحركة من النموذج على التوالي⁽¹⁾.

والمعادلة العامة للفروق المتتالية عند الاختلاف d ل X_t هي كما يلي⁽²⁾:

$$\nabla^d X_t = (1 - \beta)^d X_t$$

حيث d تمثل ترتيب الفرق وعادة ما يكون 1 أو 2، و B هو عامل الإزاحة إلى الخلف. أما الفرق

المتالي في التأخر لمرة واحدة يساوي :

$$\nabla^1 X_t = (1 - \beta)X_t = X_t - X_{t-1}$$

وبشكل عام يمكن كتابة نموذج $ARIMA(p, d, q)$ على النحو التالي :

$$\phi(\beta)(1 - \beta)^d X_t = \theta(\beta)w_t$$

2-5-5 : مراحل منهجية بوكس وجنكينز :

لقد خصص علم الإحصاء مجالاً منفرداً في تحليل البيانات الزمنية ومن أجل التنبؤ لا بد من وجود طريقة مناسبة، ومن بين هذه الطرق طريقة بوكس - جنكينز. فقدم العالمان بوكس وجنكينز في عام 1970 منهجية حديثة تعتبر بداية حقيقية لتحليل السلاسل الزمنية فكانت سبباً للتطور الهائل في هذا المجال وهذه المنهجية لا تشترط الاستقلال بين قيم السلسلة بل على العكس فأنها تستغل نمط الارتباط بين المشاهدات في عملية النمذجة والتنبؤ ومنها نحصل على مدد ثقة عالية الدقة للقيم المستقبلية لذا يمكن اعتبارها نظام تنبؤ كاملاً موثوقاً به⁽³⁾، وتعتمد هذه المنهجية على دراسة نظامية للسلاسل الزمنية حيث تحتوي على خوارزمية تقوم بتوضيح الخطوات التفصيلية بدءاً من البيانات المتوفرة وصولاً إلى مرحلة التنبؤ علماً بأن هناك خطوات لا يمكن أن تتكرر وهي توفر البيانات وفحص إستقرارية السلسلة أما

(1) Todoko, C. A. K. (2013). *Time series analysis of water consumption in the hohoe municipality of the volta region of ghana (Doctoral dissertation)*.p29.

(2) Alsharif, M. H., Younes, M. K., & Kim, J. (2019). *Time series ARIMA model for prediction of daily and monthly average global solar radiation: The case study of Seoul, South Korea. Symmetry, 11(2), 240.p5.*

(3) Nyoni, T. (2018). *Box-Jenkins ARIMA approach to predicting net FDI inflows in Zimbabwe.p6.*

بقية الخطوات الأخرى فتكون تكرارية أساسية. وانطلاقاً مما سبق فتتضمن منهجية بوكس - جنكينز أربعة مراحل أساسية وهي (1) :

مرحلة التحديد (التعرف)، مرحلة التقدير، مرحلة التشخيص، ومرحلة التنبؤ .

1) مرحلة التحديد (التعرف)

تعد مرحلة التعرف من أصعب المراحل في منهجية بوكس - جنكينز، باعتبارها مرحلة أساسية ومهمة في بناء نموذج السلسلة الزمنية، إذ نبحث فيها على النموذج الذي يلائم السلسلة الزمنية التي بحوزتنا في عائلة ARIMA، حيث نقوم بتحديد واختيار رتبة النموذج الملائمة (p, d, q) ، حيث تشير كل من p إلى رتبة الانحدار الذاتي التي يجب إدراجها في النموذج المبدئي الملائم و q يشير إلى رتبة المتوسطات المتحركة التي يجب أن يشملها النموذج الملائم و d يشير إلى رتبة أو درجة الفروق الضرورية لإرجاع السلسلة مستقرة⁽²⁾.

ومن أجل تحديد رتب النموذج نعلم على دالة الارتباط الذاتي ودالة الارتباط الذاتي الجزئي التي اقترحت في منهجية بوكس - جنكينز⁽³⁾.

فيتم تحديد d من خلال فحص سكون السلسلة الزمنية الأصلية، فإذا كانت السلسلة غير ساكنة يكون لها اتجاه عام متزايد أو متناقص فيتم اخذ الفرق الأول أو الأول والثاني وهكذا حتى تصبح السلسلة ساكنة⁽⁴⁾. كما يمكن استخدام عدة أساليب للكشف عن سكون مثل اختبار جذر الوحدة لديكي فول - فولر المطور ومعاملات دالة الارتباط الذاتي autocorrelation function والتي تحسب عند الفجوة k وتتراوح قيم معامل الارتباط الذاتي بين (-1) و (1) .⁽⁵⁾

فبعد تحقيق استقرار السلسلة الزمنية تبدأ مرحلة تحديد قيمة المعلمتين (p, q) لنموذج ARIMA وهذا باستخدام دالة الارتباط الذاتي ودالة الارتباط الذاتي الجزئي كما ذكرنا سابقاً وبعد ذلك يتم

(1) Khan, M. M. A. (2013). Forecasting of gold prices (Box Jenkins approach). *International Journal of Emerging Technology and Advanced Engineering*, 3(3), 662-670.p.664

(2) Walid Bashishi, Salim Majkh, & Hamza Baali. Using models Box-Jenkins ARIMA forecasting of The exchange rate of the dollar against the Algerian dinar.p114.

(3) Guha, B., & Bandyopadhyay, G. (2016). Gold price forecasting using ARIMA model. *Journal of Advanced Management Science*, 4(2).p118

(4) Yasseen, F. J. (2011). Economic forecasting in wheat acreage in Iraq by using ARIMA model for period (2007-2015). *Anbar Journal of Agricultural Sciences*, 9(2).p6 .

(5) بختاوي فاطيمة الزهراء تحليل فورييه وتقنية الشبكات العصبية الاصطناعية ونماذج ARIMA للتنبؤ باستهلاك الطاقة الكهربائية -دراسة حالة مؤسسة سونلغاز - مقاطعة سعيدة- أطروحة دكتوراه في العلوم الاقتصادية، جامعة تلمسان، الجزائر، (2019)، ص 45.

مطابقة معاملات الارتباط الذاتي والجزئي مع السلوك النظري لدالتي الارتباط الذاتي والارتباط الذاتي الجزئي فإذا كان: بيان دالة الارتباط الذاتي تتناقص تدريجياً وبشكل أسي أو سلوك دالة الجيب المتضائلة، وبيان دالة الارتباط الذاتي الجزئي ينقطع بعد الإزاحة (p)، فإن النموذج الملائم للبيانات هو $AR(p)$.

وإذا كان بيان دالة الارتباط الذاتي ينقطع بعد الإزاحة (q)، وبيان دالة الارتباط الذاتي الجزئي تتناقص تدريجياً وبشكل أسي أو سلوك دالة الجيب المتضائلة، يمكن القول أن النموذج الملائم للبيانات هو $MA(q)$. وفي حالة بيان دالة (ACF) و ($PACF$) تتناقصان تدريجياً وبشكل أسي أو سلوك دالة الجيب المتضائلة، فإن النموذج الملائم للبيانات من نوع $ARMA(p, q)$ (1).

وأما إذا كانت الارتباطات الذاتية الجزئية تهبط كلاهما إلى الصفر بصورة أسيّة فإن النموذج هو نموذج $ARIMA$ (2).

2) تقدير معالم النموذج :

بعد مرحلة تشخيص النموذج وتحديد رتبته (p, d, q)، يتوجب تقدير معالم هذا النموذج بإحدى طرائق التقدير التي تتميز بالكفاءة، حيث أن تقدير معالم النموذج الانحدار الذاتي لا تطرح أي مشكلة بعد تحديد درجة ونوع النموذج، أما في حالة نموذج $ARIMA$ فإن تقدير المعالم يصبح معقداً وتوجد عدة خوارزميات مقترحة لتقدير النموذج، ومنها طريقة الإمكان الأعظم (المعقولة) وطريقة المربعات الصغرى (3).

كما تختلف البرامج الإحصائية فيما بينها لتقدير معاملات النموذج بحسب الطريقة المتبعة، ولذلك تعطي نتائج متباينة للنموذج نفسه، حيث تختلف طرق التقدير حسب نوع النموذج: (4) في حالة نموذج $AR(p)$: يكون أسلوب التقدير غير خطي وفي الغالب هو معظميه الاحتمال (Maximum Likelihood) أو نستخدم العلاقة الموجودة بين الارتباط الذاتي ومعاملات النموذج (Yule-walker).

(1) Tuama, S. A. (2012). Using Analysis of Time Series to Forecast numbers of The Patients Malignant Tumors in Anbar Provinc with. AL-Anbar University journal of Economic and Administration Sciences, 4(8), p380.

(2) ياسر محمود محمد الحاج. (2017). مرجع سابق، ص. 46.

(3) Fatima Abdul Hamid Jawad Al Bermani. (2019). Op.cit, p84.

(4) تاهمي نادية. دور أساليب التنبؤ في التخطيط المستقبلي للتوزيع ودعم تنافسية المؤسسة الإنتاجية الجزائرية-دراسة حالة عينة من المؤسسات الإنتاجية (Doctoral dissertation).- جامعة محمد بو ضياف المسيلة، معهد العلوم التجارية. ص. 59.

في حالة النماذج $MA(q)$ و $ARMA(p,q)$: تقدير معالم هذه النماذج معقدة لأنها غير خطية والحد العشوائي غير منظور وبالتالي فهي تطلب طرق تقدير تكرارية، وعليه يكون أسلوب التقدير غير خطي وفي معظمه الاحتمال، وكذلك طريقتي البحث التشابكي وغوس نيوتن .

3) مرحلة التشخيص واختبار النموذج :

فبعد التعرف على النموذج المبدئي وتقدير معالمه تأتي المرحلة الثالثة والمتمثلة في فحص النموذج المختار والتأكد من أنه النموذج الصحيح، ويتم ذلك بالتأكد من أن النموذج خالٍ من تركيبة الارتباط الذاتي أو تركيبة المتوسط المتحرك أو بعبارة أخرى التأكد من أن حد الخطأ لهذا النموذج مطابق لشروط حد الخطأ الأبيض (Noise White)، ويتم عادة فحص النموذج عن طريق معاملات الارتباط الذاتي ومعاملات الارتباط الذاتي الجزئي للبقايا في النموذج المقدر وليس السلسلة الأصلية⁽¹⁾.

وفي ما يلي بعض الاختبارات التي تجرى على النموذج المختار مدى ملاءمته وصلاحيته لتمثيل

البيانات وهي :

3-1: اختبار معنوية معاملات النموذج:

وتتم هذه العملية باستخدام إحصائية الاختبار ($T - student$) وذلك للتحقق من معنوية معالم النموذج إحصائياً أي أنها تختلف عن الصفر، فإذا كانت غير معنوية فلا بد من استبعاد إحدى رتب $(AR), (MA)$. (2)

بالنسبة إلى $AR(p)$:

$$t_c = \frac{|\hat{\theta}_p|}{\sqrt{\text{var}(\hat{\theta}_p)}} \rightarrow N(0,1)$$

أما بالنسبة إلى $MA(q)$:

$$t_c = \frac{|\hat{\theta}_q|}{\sqrt{\text{var}(\hat{\theta}_q)}} \rightarrow N(0,1)$$

(1) الغنام، حمد بن عبد الله، (2003) " تحليل السلسلة الزمنية لمؤشر أسعار الأسهم في المملكة العربية السعودية باستخدام منهجية بوكس وجنكينز"، كلية العلوم الإدارية، جامعة الملك سعود، المملكة العربية السعودية، ص 12 .

(2) Tuama, S. A. (2012). Using Analysis of Time Series to Forecast numbers of The Patients Malignant Tumors in Anbar Provinc with. AL-Anbar University journal of Economic and Administration Sciences, 4(8),p381.

فنقبل المقدر إذا كانت قيمة $(t_c \geq 1.96)$ ونرفض فرضية انعدامه والعكس صحيح .

3-2: تحليل البواقي ؛

من الضروري التأكد من خلو بواقي النموذج من الارتباط الذاتي أو تركيبة المتوسط المتحرك، أي أن يكون حد الخطأ في النموذج مطابق لشروط التشويش الأبيض (*White noise*)، ويستخدم اختبار الارتباط الذاتي للبواقي للتحقق من صحة النموذج، بحيث يتم التأكد من أن بواقي النموذج غير مرتبطة مع بعضها البعض وتباينها ثابت مع تغير الزمن،⁽¹⁾ حيث يستخدم عدة اختبارات نذكر منها :

▪ اختبار استقلالية ليونغ _ بوكس (*Ljung-Box*) :

يعد اختبار *Ljung-Box* من الاختبارات الإحصائية التي تستخدم للتحقق من عدم وجود ارتباط ذاتي بين الأخطاء العشوائية (البواقي)، إحصائية هذا الاختبار معطاة على النحو التالي (2):

$$\tilde{Q}(r) = n(n+2) \sum_{i=1}^m \frac{r_k^2}{(n-k)}$$

حيث مقياس اختبار \tilde{Q} يتبع توزيع χ^2 .

هو عدد المشاهدات m هو أقصى عدد من التأخيرات (درجة الحرية) .

r_k هي دالة الارتباط الذاتي (ل k تأخير)، ويتم إعطائها بواسطة:

$$r_k = \frac{\sum_{i=k+1}^n a_i a_{i-k}}{\sum_{i=1}^n a_i^2}$$

▪ فرضيات اختبار *Ljung - Box* هي:

$H_0: r_1, r_2, \dots, r_n = 0$ (لا يوجد ارتباط ذاتي للبواقي).

$H_1: r_i \neq 0$ (يوجد ارتباط ذاتي للبواقي).

ومن أجل أخذ القرار نقوم بمقارنة (\tilde{Q}) المحسوبة بـ χ^2 الجدولية عند مستوى ثقة معين، فإذا

كان (Q) المحسوبة أصغر من الجدولية فهنا نقبل الفرضية العدمية .

(1) Boudrioua, M. S. (2019). Modeling and forecasting the Algiers Stock Exchange returns using the Box-Jenkins methodology.p7.

(2) Mbaye, A., Ndiaye, M., Ndioune, D., Diaw, M., Traoré, V., Ndiaye, A., ... & Ndiaye, P. (2019). ARMA model for short-term forecasting of solar potential ARMA model for short-term forecasting of solar potential: application to a horizontal surface on Dakar site A. Mbaye et al, ARMA model for short-term forecasting of solar potential.p3.

كما توجد عدة اختبارات التي يجب إجراؤها على النموذج نفسه، للتحقق من كفاءته وأفضلية ملائمتة، بغرض استعماله للتنبؤ، وللقيام بذلك يوجد عدة معايير تستخدم لهذا الغرض، ومن أهمها نجد معيار أكاي للمعلومات (Akaike Informati Criteria (AIC)، ومعيار شوارتز Schwarz Bayesian Criterion (SBC)، ويتم استخدام هذين المعيارين لمقارنة النماذج المختارة المناسبة لنفس السلسلة، حيث يعد النموذج الذي يحتوي على قيم AIC و SBC أصغر مناسباً بشكل أفضل من الناحية الإحصائية.

▪ معيار أكاي للمعلومات (Akaike Informati Criteria (AIC):

يعتمد معيار Akaike على البحث عن الرتب المثلى p و q للبيانات، ويأخذ الصيغة التالية (1):

$$\hat{\sigma}^2 = \frac{1}{T} \sum_{t=0}^N (\varepsilon_t - \bar{\varepsilon}_t)^2 \quad AIC = n \log \hat{\sigma}^2 + 2M$$

حيث M عدد المعلمات في النموذج:

أفضل نماذج $ARIMA(p, q)$ هو النموذج الذي يعطي أقل قيمة لمعيار أكاي .

▪ معيار شوارتز Schwarz Bayesian Criterion (SBC):

$$SBC = T \ln \left(\sum \sigma^2 \right) + n \ln(T)$$

حيث n تشير إلى عدد المعالم المقدرة في النموذج، T عدد المشاهدات، σ الخطأ العشوائي، ويتم

اختيار النموذج الذي يعطي أقل قيمة لمعيار AIC و SBC.

▪ معيار حنان-كوين Hannan-Quinn Criterion (H, Q):

إن معيار حنان-كوين والذي يرمز له باختصار (H, Q) يعد معيار جديد لتحديد رتبة النموذج

المدرس اقترحه الباحثان في علم 1979 ويأخذ الصيغة الآتية (2):

$$H - Q(M) = \ln(\hat{\sigma}^2_\epsilon) + 2MC \ln \frac{\ln n}{n}; \quad C > 2$$

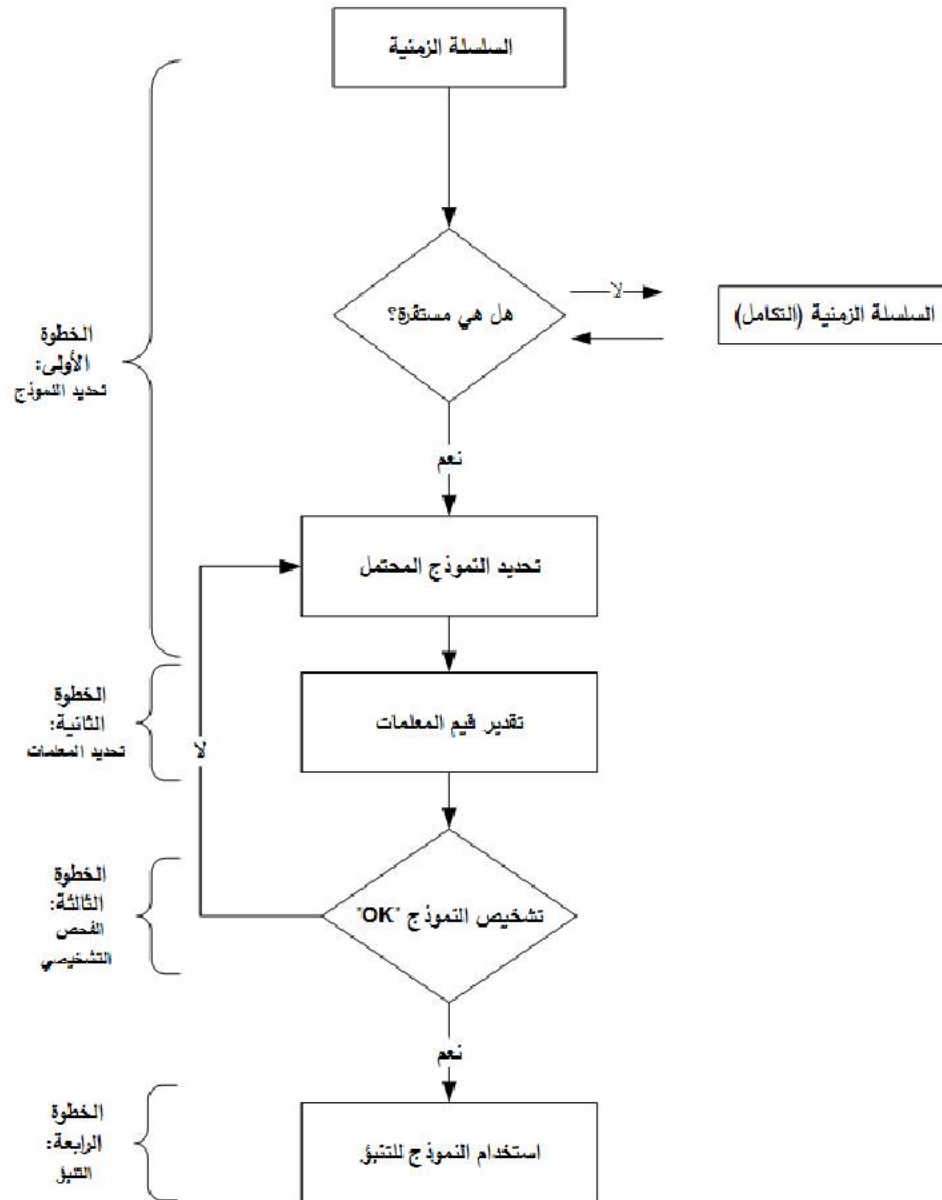
(1) MBAYE, A. (2019). ARMA model for short-term forecasting of solar potential: application to a horizontal surface of Dakar site. OAJ Materials and Devices, 4(1), p 35.

(2) ساهد عبد القادر، استخدام البرمجة بالأهداف في تحليل الانحدار المبهم للتنبؤ بأسعار البترول، أطروحة دكتوراه في العلوم الاقتصادية، تخصص إدارة العمليات والإنتاج، جامعة تلمسان، الجزائر، (2012-2013)، ص 28.

4) التنبؤ :

يعتبر التنبؤ المرحلة الأخيرة من مراحل منهجية بوكس وجنكينز وهو عادة الهدف النهائي من تحليل السلاسل الزمنية، والتي يمكن الانتقال إلى هذه المرحلة إلى بعد أن يجتاز النموذج المبدئي كافة الاختبارات والفحوص التي سبقت، فإذا لم يتمكن النموذج المبدئي أن يجتاز هذه الفحوص والاختبارات بكفاءة فإنه يجب العودة من جديد إلى المرحلة الأولى (مرحلة التعرف) وقراءة دالتي الارتباط الذاتي والارتباط الذاتي الجزئي بتمهل وإمعان واختيار نموذج مبدئي ثاني، فإذا اجتاز هذا النموذج الثاني كافة الفحوص والاختبارات التشخيصية تنتقل إلى مرحلة التنبؤ، ونفس الشيء إذا لم يجتاز هذا النموذج الفحوص والاختبارات بكفاءة نعود مرة أخرى إلى المرحلة الأولى لاختيار نموذج ثالث، وتكرر هذه العملية حتى نتحصل على نموذج يجتاز جميع الفحوص والاختبارات بكفاءة والشكل التالي يوضح العملية المتكررة وفق مراحل منهجية Box-Jenkins :

الشكل (1-2) : مراحل منهجية Box-Jenkins



Source : HepSen, A., & Vatansever, M. (2011). Forecasting future trends in Dubai housing market by using Box-Jenkins autoregressive integrated moving average. International Journal of Housing Markets and Analysis.p214

2-6: نماذج الانحدار الذاتي المشروط بعدم تجانس تباينات الأخطاء ARCH :

يعد ثبات التباين عبر الزمن شرطاً أساسياً في نماذج الانحدار الذاتي والمتوسطات المتحركة، وفي الواقع العملي نجد فرضية ثبات التباين لا تتحقق وخاصة في السلاسل الزمنية، مثل أسعار الذهب التي تعرف تقلبات كثيرة نظراً لارتباطها بالزمن، وهذا ما قد يؤثر خاصة على الاختبار الإحصائية للقوة التنبؤية من جهة ومجالات الثقة التنبؤية المقدرة من جهة أخرى، فقبل تقديم نماذج ARCH كانت لا توجد هناك طريقة دقيقة متاحة للتنبؤ بالتباين، فنماذج ARCH هي أول أداة تصف تموجات الانحراف المعياري وتحسبه باستخدام قيم ثابتة للتقلبات الماضية⁽¹⁾، ففي سنة 1982 اقترح Engel أول نموذج ارتباط ذاتي مشروط بعدم تجانس تباينات البواقي، حيث يمكن نمذجة التباين خلال الزمن، لذلك علينا أن نأخذ بعين الاعتبار أن التباين المشروط قد يكون متأثراً إلى حد كبير بقيم مربعات سلسلة البواقي للفترات السابقة، ومن خلالها يمكن توضيح عدم التجانس المشروط في بيانات السلسلة وتقديم تفسير لاستمرار التدبدبات فيها، وتأخذ معادلة نماذج ARCH الصيغة التالية (2) :

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2$$

حيث :

σ^2 تمثل التباين المشروط و $\alpha_0 \geq 0; \alpha_i \geq 0$ وهي معالم النموذج .

ومن أجل أن يكون السياق ARCH(q) سياقاً مستقراً يجب أن يكون لدينا : $\sum_{i=1}^q \alpha_i < 1$.

2-7: نماذج تعميم الانحدار الذاتي المشروط بعدم تجانس تباينات الأخطاء GARCH (3) :

يعد نموذج GARCH بمثابة تعميم الانحدار الذاتي المشروط بعدم ثبات التباين، ويعتبر أكثر شمولاً من الناحية العملية واقترح سنة 1986 من طرف Tim Bollerslev، ويستخدم على نحوٍ واسعٍ

(1) فائق لقوي، محمد شخي، استخدام نماذج ARCH لنمذجة تقلبات أسعار الأسهم في سوق المال السعودي - دراسة حالة شركة 'تحاد اتصالات السعودية' - (2017) ص. 3.
 (2) شادي اسديعل، التباين، طارق عبد العزيز الدوب، دراسة أثر 'صدمة' الإيجابية والسلبية على تقلبات عوائد بورصة الكويت وسوق دبي المالي باستخدام نماذج عائلة GARCH، المجلة العلمية لاقتصاد والإعمال، 9(3) (2020)، 638-650 ص. 641.
 (3) /ورد عبد العزيز كوجك (2018)، التنبؤ بعوائد المحافظ الاستثمارية باستخدام نموذج الانحدار الذاتي المشروط بعدم ثبات التباين /ARCH/ (دراسة تطبيقية على سوق عملن المالي)، رسالة ماجستير في التمويل وإمصاريف، ص. 70 .

في عمليات التداول والتحوّط والاستثمار، وذلك بهدف التنبؤ بالتقلبات المستقبلية اعتماداً على التباينات الماضية وتقلباتها (التباين نفسه)، وذلك بشكل أعم وأكثر سهولة من نموذج ARCH، حيث تمثل (q) رتبة الطرف ARCH في نموذج الانحدار الذاتي المشروط بعدم ثبات التباين المعمم، أما (p) فتتمثل رتبة الطرف GARCH وذلك لأن التباين الشرطي المتوقع يعتمد على:

التمثيلات السابقة لمربعات بواقي معادلة المتوسط المقدرة بواسطة ARMA حيث:

$$\sigma_{t-1}^2; i = 1, 2, \dots, q$$

تمثل حد ARCH في النموذج المعمم.

التمثيلات السابقة للتباين نفسه $\sigma_{t-j}^2; j = 1, 2, \dots, p$ وهو يمثل حد GARCH.

ومنه يمكن تمثيل السياق $GARCH(p, q)$ في الصيغتين التاليتين⁽¹⁾:

$$a_t = \sigma_t \epsilon_t$$

حيث ϵ_t هو سلسلة متغير يمثل عملية عشوائية مستقل ويتبع توزيعاً متساوياً (iid) متوسطه

الحسابي صفر وتباينه يساوي الواحد الصحيح.

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^q \alpha_i a_{t-i}^2 + \sum_{i=1}^p \beta_i \sigma_{t-i}^2$$

حيث σ_t^2 التباين الشرطي لسلسلة، والتي تعطى تحت القيود:

$$0 < \alpha_0$$

$$\sum_{i=1}^{\max(p,q)} (\alpha_i + \beta_i) < 0$$

بالإضافة إلى أن β_i و α_i هي معاملات النموذج ARCH و GARCH على التوالي.

(1) ساهد عبدالقادر، فهوي حسن، التنبؤ بأسعار البترول باستخدام النموذج الهجين ARIMA - GARCH للمدة (2000 - 2020)، مجلة نور الدراسات الاقتصادية، 2020، مجلد 06، العدد 10، ص 313

2-8: اختبارات نماذج $GARCH$ (1)

2-8-1: اختبار الارتباط الذاتي (Liung - Box):

يعتبر هذا الاختبار من الاختبارات التي تستخدم في اختبار عشوائية أخطاء السلسلة الزمنية وذلك من خلال حساب معاملات الارتباط الذاتي للبواقي لمجموعة من الإزاحات، وتكتب فرضية الاختبار بالصيغة التالية:

$$H_0: p_1 = p_2 = \dots = p_k \dots = p_m = 0 \rightarrow \forall k = 1, 2, \dots, m$$

$$H_1: p_1 \neq 0 \text{ For some values of } k$$

أما إحصاءات الاختبار فيمكن حسابها باستخدام الصيغة الآتية:

$$Q_{(m)} = n(n+2) \sum_{k=1}^m \frac{\hat{p}_k^2}{n-k} \rightarrow \chi_{(m-p)}^2$$

حيث:

n : تمثل حجم العينة.

m : تمثل عدد الإزاحات للارتباط الذاتي.

p : عدد المعلمات المقدرة في النموذج.

\hat{p}_k^2 : يمثل مقدرات معاملات الارتباط الذاتي للبواقي السلسلة.

تقارن إحصاءات الاختبار $Q_{(m)}$ مع القيم الجدولية لاختبار مربع كاي بدرجة حرية $(m-p)$ وعند مستوى المعنوية α فإذا كان $\chi_{\alpha}^2(m-p)$ أكبر من $Q_{(m)}$ يعني ذلك عدم رفض الفرضية H_0 ، أي أن الأخطاء عشوائية ولا يوجد تأثير لـ $ARCH$ ، والعكس صحيح.

2-8-2: اختبار اثر $ARCH$:

يستخدم هذا الاختبار لاختبار عشوائية أخطاء السلسلة الزمنية، أي اختبار أن الأخطاء تتبع توزيع طبيعي متماثل مستقل، من خلال تمثيل T من قيم مربعات الأخطاء العشوائية لنموذج $GARCH$

(1) رتيعة محمد، وسام حسيني (2019)، دراسة سلوك سلسلة الزمنية لمؤشر الأسعار العالمية للغذاء باستخدام نماذج $GARCH$. مجلة الدراسات الاقتصادية المعاصرة، المجلد 40 / العدد: 2 (2019)، ص 57-70، ص 63.

في نموذج انحدار بحد ثابت، ومن ثم اختبار وجود تأثير للارتباط الذاتي، وتكتب فرضية الاختبار بالصيغة التالية :

$$H_0: \alpha_i = 0 \text{ for } (i = 1, 2, \dots, p)$$

$$H_1: \alpha_i \neq 0$$

أما اختبار الإحصائية فيمكن حسابها باستخدام الصيغة الآتية:

$$ARCH(LM_{cal}) = T * R^2 \rightarrow x_{(p)}^2$$

حيث :

T : تمثل عدد المشاهدات المدروسة.

R^2 : معامل التحديد للنموذج الآتي: $\varepsilon_t^2 = \alpha_0 + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2$.

ε_t : تمثل بواقي نموذج ARIMA.

تقارن إحصاءات الاختبار مع القيم الجدولية لاختبار مربع كاي بدرجة حرية (p) أي $x_{(p)}^2$ وعند مستوى المعنوية α فإذا كانت القيمة المحسوبة أكبر من القيمة الجدولية نرفض الفرضية العدمية H_0 أي لا يوجد تأثير ل ARCH والعكس صحيح.

9-2: تقدير معالم نموذج GARCH⁽¹⁾ :

من أجل تقدير معالم نموذج الانحدار الذاتي المشروط بعدم التجانس المعمم نستخدم طريقة الإمكان الأكبر، Maximum Likelihood Method حيث يتم تحديد دالة الإمكان الأكبر بالاعتماد على التوزيع العشوائي لخطأ النموذج، ففي حالة كان الخطأ العشوائي للنموذج يتوزع توزيعاً طبيعياً معيارياً أو توزيع $T - student's$ ، وفي حالة كان الخطأ العشوائي للنموذج يتوزع توزيعاً طبيعياً فإن دالة الإمكان الأكبر ستكون بالصيغة التالية :

$$L(r^t / \theta) = -\frac{N}{2} \log(2\pi) - \frac{1}{2} \sum_{t=1}^N \log \sigma_t^2 - \frac{1}{2} \sum_{t=1}^N \frac{\varepsilon_t^2}{\sigma_t^2}$$

$\theta = (\mu, \alpha_0, \alpha_1, \beta_1)$ متجه المعالم المراد تقديرها إذا كان النموذج من الدرجة الأولى أي :

(1) عبد المنعم احمد عبد الوهاب، طارق محمد الرشيد، أمينة محمد عمر " قياس اثر مؤشر سوق الخرطوم للأوراق المالية على أرباح المصارف السودانية باستخدام منهجية نماذج GARCH خلال الفترة 2013-2017 "، مجلة الدراسات العليا - جامعة النيلين (مج14)، (ع 56 - 2)، 07/ 15، 2019/، ص 310 - 311.

$$r_t = \mu + a_t$$

$$a_t = \sigma_t \varepsilon_t \quad ; \varepsilon_t \sim iidN(0,1)$$

$$\sigma_t^2 = \alpha_0 + \alpha_1 a_{t-1}^2 + \beta_1 \sigma_{t-1}^2$$

وفي حالة أن الخطأ كان يتوزع توزيع *Student't* المعياري فان دالة الإمكان ستكون بالصيغة التالية:

$$L(r_t/\theta) = \sum_{t=1}^N \log \left[\frac{\Gamma[(v+1)/2]}{\sqrt{\Gamma(v-2)}\Gamma(v/2)} \right] \frac{1}{2} \log \sigma_t^2 - \frac{v+1}{2} \log \left[1 + \frac{\varepsilon_t^2}{v-2} \right]$$

حيث أن $\theta = (\mu, \alpha_0, \alpha_1, \beta_1, v)$ متجه المعلمات المراد تقديرها إذا كان نموذج GARCH

من الدرجة الأولى، وللحصول على تقديرات النموذج يتم اشتقاق دالة الإمكان بالنسبة للمعلمات المراد تقديرها.

10-2: التنبؤ في نماذج ARCH و GARCH (1)

1-10-2: التنبؤ باستخدام نموذج ARCH(P)

يمكن استخدام العلاقة الآتية للتنبؤ بالتباين للخطأ العشوائي واستخدامه لتحسين المجالات

التنبؤية باستخدام العلاقة التالية:

$$h_\varepsilon^2(t+m) = \alpha_0 + \sum_{i=1}^m \alpha_i h_\varepsilon^2(t+m-1)$$

2-10-2: التنبؤ باستخدام نماذج GARCH(p, q)

التنبؤ باستخدام نماذج $GARCH(p, q)$ يأخذ الصيغة التالية:

$$h_\varepsilon^2(t+m) = \alpha_0 + \sum_{i=1}^p \alpha_i \varepsilon_t^2 + \sum_{j=1}^q \beta_j h_{t-j+m}$$

حيث:

m : أفق التنبؤ.

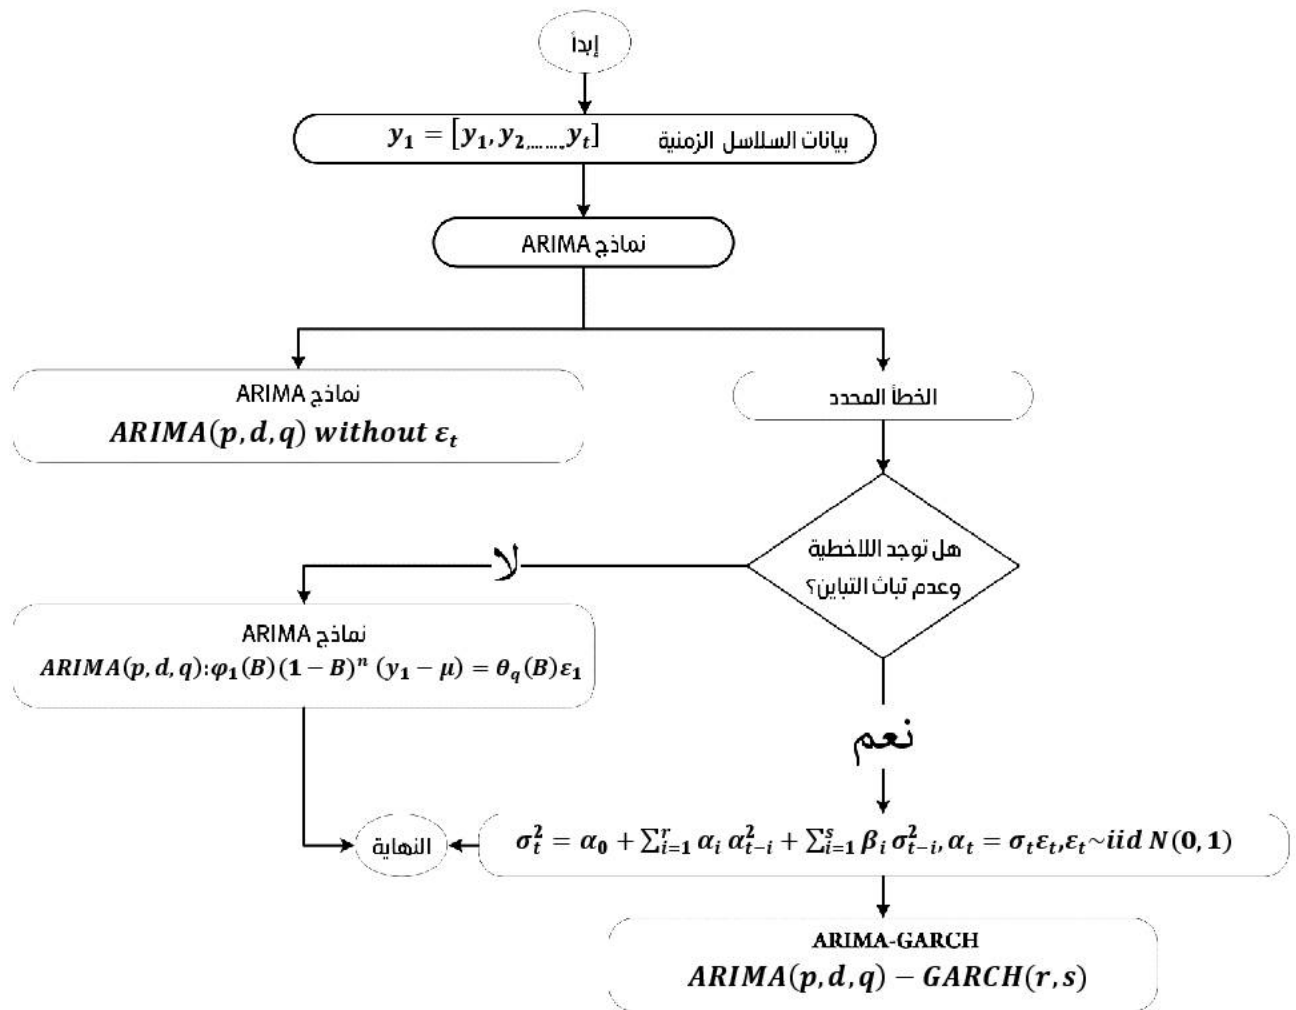
ويمكن حساب مجالات التنبؤ باستخدام المجال التالي وهذا عند مستوى معنوية 5%:

$$[\hat{y}_{t+m} \pm 2 \cdot \hat{h}_{t+m}]$$

والشكل الموالي يوضح خطوات عمليات نماذج ARIMA & GARCH

(1) ميكيدش محمد، ساهد عبد القادر، دراسة قياسية لأسعار البترول باستخدام نماذج GARCH، مجلة الاقتصاد المعاصر، العدد 03 افريل 2008، ص 171 - 189، ص 180.

الشكل 2-1: مخطط عمليات نماذج ARIMA & GARCH



Source: Yaziz, S. R., & Zakaria, R. (2019, November). ARIMA and Symmetric GARCH-type Models in Forecasting Malaysia Gold Price. In Journal of Physics: Conference Series (Vol. 1366, No. 1, p. 012126). IOP Publishing .p3.

الخلاصة :

رغم المساهمة الكبيرة لمختلف النماذج الخطية، مثل نماذج *ARIMA* للسلاسل الزمنية، في نمذجة الكثير من الظواهر الاقتصادية، من خلال إعطائها صورة رياضية للتنبؤ بالقيم المستقبلية؛ إلا أن ما يؤخذ على هذه الصيغ الخطية أنها لا تستطيع أن تترجم الصفة الحركية لهذه الظواهر.

ففي سنة 1982 اقترح *Engle* نموذج غير خطي للسلاسل الزمنية يعبر فيها عن الانحدار الذاتي والذي يتضمن تباين شرطي غير متجانس باستعمال معلومات سابقة يسمى بنموذج انحدار ذاتي مشروط بأخطاء غير متجانسة (*ARCH*)، وعممت هذه النماذج إلى نموذج انحدار ذاتي مشروط بأخطاء غير متجانسة المعممة (*GARCH*)، حيث الهدف منها هو نمذجة التباين وعرفت استخداما كثيرا في البيانات المالية، لأن الاتجاه الحديث لدى المستثمرين لا ينصب فقط على دراسة الظواهر المالية والتنبؤ بالعوائد المتوقعة من الأسهم والسندات في أسواق المال، وإنما يهتمون أيضا بعنصر المخاطرة أو عدم التأكد، ومن أجل دراسة عدم التأكد ألحت الحاجة إلى نماذج خاصة تتعامل مع تقلب عبر السلسلة الزمنية أو ما يمكن أن نطلق عليه بتباين السلسلة، والنماذج التي تتعامل مع هذا النوع من التباين تنتمي إلى ما يمكن تسميته بأسرة نماذج *ARCH*.

الفصل الثالث:

الشبكات الرصية الامطناعية

مقدمة:

في العقود القليلة الأخيرة طوّرت العديد من نماذج التنبؤ اللاخطية، مثل أنظمة الذكاء الاصطناعي الذي يمكن أن تلائم البيانات وبشكل أفضل من النماذج الخطية التي غالباً ما يكون التنبؤ بها ضعيفاً، وتمتلك أنظمة الذكاء الاصطناعي تقنيات واسعة إذ توفر طرقاً بديلة لمعالجة المشاكل المعقدة، وهي قادرة على معالجة البيانات غير المتكاملة والتي تحتوي على ضوضاء، وكذلك حلّ المشاكل اللاخطية التنبؤية بسرعة عالية، وتتضمن أنظمة الذكاء الاصطناعي: الأنظمة الخبيرة، المنطق الغامض، الخوارزميات الجينية، الشبكات العصبية الاصطناعية وكذلك الأنظمة الهجينة التي تجمع بين واحد أو أكثر من هذه التقنيات⁽¹⁾.

تعد الشبكات العصبية الاصطناعية من أهم فروع الذكاء الاصطناعي، التي عرفت تطبيقاً واسعاً في مختلف المجالات العلمية، وتعكس تطوراً هاماً لطريقة تفكير الإنسان؛ وهي محاكاة للشبكة العصبية الحيوية الموجودة في دماغ الإنسان البشري، من خلال محاكاة البيانات للوصول إلى أفضل نموذج لغرض التحليل أو التنبؤ دون الحاجة إلى نموذج مقترح، حيث شهدت السنوات السابقة اهتماماً كبيراً من لدن العلماء والباحثين، بنماذج الشبكات العصبية الاصطناعية (Artificial Neural Network)،

وكذا استخدامها كبديل مناسب عن النماذج التقليدية؛ لقدرتها على التنبؤ الدقيق بحلّ المشكلات بسهولة ودقة مقارنة بالأساليب الإحصائية السابقة، من خلال تطبيقها - دون النظر إلى فرضيات معينة - بطبيعة المتغيرات وعلاقتها مع بعضها، إن عملية التدريب للشبكة يتم تدريجياً على بيانات مخزنة داخل الشبكة العصبية، ووفقاً لآلية التدريب من خلال خوارزمية التعلّم، ومن ثم فإن تطبيق أو استخدام أسلوب الشبكات العصبية يعتبر وسيلة مضمونة وأداة فعّالة، للوصول إلى أفضل تنبؤ بالقيم المستقبلية لظاهرة معينة⁽²⁾.

(1) أمية غانم عبد الجبار. (2013). استخدام الشبكات العصبية الاصطناعية بخوارزميات مختلفة في نمذجة درجات حرارة التربة على أعماق وأوقات مختلفة بدلالة بعض المعلومات المناخية. مجلة تكريت للعلوم الصرفة، 18(2)، 305-313. ص 305.

(2) م. د. بثينة عبد الجادر عبد العزيز & علي طارق عبد المجيد. (2019). استخدام النموذج الهجين SARIMA-ELMAN (ERNN) للتنبؤ بالمعدلات الشهرية لدرجات الحرارة العظمى لمدينة بغداد. مجلة الإدارة والاقتصاد، 270-284، (118)، ص 276.

ونظرا للأهمية البالغة لهذا النموذج، سنتناول من خلال هذا الفصل مفهوم الشبكات العصبية الاصطناعية وفلسفتها، وتقديم لمحة تاريخية عن تطور هذه الشبكات وكذلك عرض استخداماتها في العديد من المجالات وخصائصها، بالإضافة إلى مكوناتها ودوال التحفيز اللازمة لذلك الغرض. كما عرّجنا على البنية المعمارية للشبكة العصبية، وفقاً لعدد الطبقات وطبيعة انتشار البيانات، والحديث عن التدريب في الشبكات العصبية، من خلال خوارزمية الشبكة ذات الانتشار العكسي، وكذلك تم استخدام شبكات بيرسترون متعدد الطبقات في التنبؤ، وأخيراً التعرف على مزايا وعيوب استخدام الشبكات العصبية الاصطناعية.

3-1: مفهوم الشبكات العصبية الاصطناعية وفلسفتها :

تعد الشبكات العصبية الاصطناعية أحدَ حقول الذكاء الاصطناعي الذي شكّل تطورات ملحوظة في طريقة مَيْكَنَةِ التّفكير الإنساني. إنّ فكرة الشبكات العصبية تتمحور حول محاكاة المخ باستخدام الحاسب الآلي، ولعلّ الفضل في تطور هذا الحقل يعود بدرجة كبيرة إلى الدراسات العديدة التي تمت في حقل المعالجة العصبية، والذي يدرس النّشاط العصبي في مخ الإنسان. هذه الدراسات تعمل على محاولة محاكاة العقل البشري في طريقة حله للمسائل التي تواجهه وذلك من خلال اتباع عملية التّعليم الذاتية التي تحدث في العقل والتي يتم فيها الاستفادة من الخبرات التي مرت عليه في السابق في سبيل الوصول إلى نتائج أفضل في المستقبل⁽¹⁾.

يعود سبب تسميتها الشبكات العصبية الاصطناعية؛ كونها شبكة من وحدات الاتصالات الداخلية إذ أن هذه الوحدات مستوحاة من دراسة أنظمة الأعصاب الحيوية. إنّ فكرة عمل الشبكات العصبية الاصطناعية هو محاكاة البيانات للوصول إلى نموذج لهذه البيانات لغرض التحليل أو التصنيف أو التنبؤ أو أي معالجة أخرى دون الحاجة إلى نموذج مقترح لهذه البيانات، ولهذا فقد حازت الشبكات العصبية الاصطناعية اهتمام الكثير من الباحثين والعلماء؛ كونها تتميز بالمرونة العالية

(1) ساهد، عبد القادر، ومكيديش، محمد. (2014). دراسة مقارنة بين الانحدار المبهم باستخدام البرمجة بالأهداف والشبكات العصبية الاصطناعية للتنبؤ بأسعار البترول. *El-Bahith Review*, 233(1354), 1-27. ص 111.

بالمقارنة مع الأساليب الرياضية المستخدمة في عملية التعلم على نموذج البيانات و تخزين المعلومات وبثها في الشبكة العصبية الاصطناعية⁽¹⁾.

يوصف الشبكات العصبية الاصطناعية أحد مجالات الذكاء الاصطناعي، أو البحث في تصميم الآلات ذات القدرة المعرفية؛ تعمل على تمثيل عقل الإنسان الذي يعتبر كنظام اتخاذ القرار في الإنسان الذي يحتوي على ملايين من طيات الخلايا العصبية المتصلة بطريقة معقدة. ولذا يعد الدماغ أقوى وأسرع في معالجة المشكلات المعقدة المتعلقة بمشاكل الأداء البشري مقارنة مع معالجة الكمبيوتر⁽²⁾، وهذا عن طريق شبكة من المعطيات الرقمية التي تمثل الخلية العصبية متصلة بروابط موزونة، التي تمثل الروابط بين الخلايا والتي تتم معالجتها بواسطة نموذج رياضي محدد، فالمعطيات لوحدها لا تقوم بأي تأثير، أما إذا اتحدت هذه المعطيات مع الأوزان فإنها تؤدي إلى تحديد المهمة المطلوبة من الشبكة العصبية⁽³⁾.

3-2 : الشبكة العصبية البيولوجية :

لقد أستهتمت الشبكات العصبية الاصطناعية من العلوم البيولوجية ولا سيما العلوم العصبية، ورغم ذلك فإن تشابه الشبكات العصبية الاصطناعية مع نظيراتها البيولوجية يقتصر على بعض المفاهيم المستعارة من الشبكات البيولوجية، خاصة في بنيتها المعمارية كونها لا تزال بعيدة كل البعد عن عمل أبسط الشبكات البيولوجية وهذا بسبب التعقيد الهائل للشبكات البيولوجية.

تعرف الخلايا الموجودة في الدماغ البشري والجهاز العصبي بالخلايا العصبية، حيث تقوم بنقل المعلومات أو الإشارات بشكل أحادي الاتجاه من خلال الاتصالات بين الخلايا العصبية المعروفة كمحاور؛ يتم تلقي المعلومات من قبل الخلايا العصبية من خلال التشعبات الخاصة بها، حيث يتكون

(1) بختاوي فاطمة الزهراء، (2018 - 2019) تحليل فورييه وتقنية الشبكات العصبية الاصطناعية ونماذج ARIMA للتنبؤ باستهلاك الطاقة الكهربائية -دراسة حالة مؤسسة

سونلغاز - مقاطعة سعيدة- أطروحة دكتوراه علوم في العلوم الاقتصادية، تخصص طرق الكمية المطبقة في التسيير الجزائر. جامعة تلمسان. ص.21

(2) Haider, A., & Hanif, M. N. (2009). Inflation forecasting in Pakistan using artificial neural networks. *Pakistan economic and social review*, 123-138.p3.

(3) زكريا يحيى الجمال، & عمر صابر. (2012). مقارنة التنبؤ باستخدام شبكة الانحدار العصبية المعممة بأسلوب الشبكات العصبية وتحليل الانحدار. المجلة العراقية للعلوم الاحصائية، 12(21)، 234-245. ص.235.

دماغ الإنسان من حوالي 100 مليار خلية عصبية وأكثر من 10^{14} نقطة تشابك عصبية⁽¹⁾. تتواصل الخلايا العصبية مع بعضها البعض من خلال نقاط الاشتباك العصبي وهي فجوات أو تقاطعات بين الاتصالات، حيث يقوم الجانب المرسل من المشابك بإطلاق نواقل عصبية مقترنة بالمستقبلات العصبية على الجانب المستقبل من المشابك، يتم التعلم عادة عن طريق تعديل نقاط الاشتباك العصبي الموجودة، على الرغم من أن بعض وظائف التعلم والذاكرة يتم تنفيذها عن طريق إنشاء نقاط الاشتباك العصبي الجديدة، ففي الدماغ البشري يتم تنظيم الخلايا العصبية في مجموعات ولا يشارك سوى عدة آلاف أو مئات الآلاف في أي مهمة معينة. يعد محور العصبون هو مسار إخراج الخلايا العصبية التي تتفرع من خلال الضمانات المحورية والتي بدورها تتصل بالتشعبات أو مسارات الإدخال للخلايا العصبية من خلال تقاطع أو فجوة تعرف باسم المشبك، فمن خلالها يتم تنفيذ معظم التعلم إما عن طريق الإثارة أو إيقاف نشاط الخلايا العصبية المرتبطة بها، فرغم ذلك ليست كل الخلايا العصبية قابلة للتكيف. كما تحتوي المشابك العصبية على نواقل عصبية يتم إطلاقها وفقاً للإشارات الواردة، حيث تسمح المشابك أو تمنع نشاط الخلايا العصبية المرتبطة بها اعتماداً على الناقلات العصبية الصادرة. تقوم الخلية العصبية البيولوجية بجمع جميع الإشارات المنشطة وتطرح جميع الإشارات الغير المنشطة من جميع نقاط الاشتباك العصبي الخاصة بها، وبعد ذلك يقوم بإرسال إشارات فقط إلى المحاور الخاص به إذا كان الفرق أعلى من عتبة التنشيط.⁽²⁾


المعالجة في الدماغ البيولوجي متوازية للغاية وهي أيضاً متسامحة جداً مع الأخطاء، حيث تعد خاصية تحمل الخطأ هي نتيجة كون المسارات العصبية زائدة عن الحاجة وتنتشر المعلومات عبر نقاط الاشتباك العصبي في الدماغ. يسمح هذا التوزيع الواسع للمعلومات أيضاً للمسارات العصبية بالتعامل جيداً مع البيانات الصاخبة. الخلايا العصبية البيولوجية معقدة للغاية لدرجة أن أجهزة

(1) Bishop, C. M. (1994). *Neural networks and their applications. Review of scientific instruments*, 65(6), 1803-1832.p1804.

(2) Tan, C. N. W. (1997). *Artificial Neural Networks: A Financial Tool as Applied in the Australian Market (Doctoral dissertation, Bond University)*.p34.

الكمبيوتر العملاقة الحالية لا يمكنها حتى تشكيل خلية عصبية واحدة. لذلك قام الباحثون بتبسيط نماذج الخلايا العصبية في تصميم الشبكات العصبية الاصطناعية.

الشكل 1-3: عينة التركيب البيولوجي العصبي للخلايا العصبية ووصلاتها



Source : Haider, A., & Hanif, M. N. (2009). Inflation forecasting in Pakistan using artificial neural networks. *Pakistan economic and social review*, 123-138.p3.

3-3: الشبكة العصبية الاصطناعية :

تعتبر الشبكات العصبية الاصطناعية في الأساس نموذج محاكاة للجهاز العصبي البشري، الذي تكون عناصره الأساسية هي أيضاً عصبونات تستخدم لمعالجة المعلومات ونقل إشارة المعلومات هذه في الجهاز العصبي، حيث يتكون العصبون من نواة وزائدة المشجرة ومحاور، حيث تتألف من العقد (Nodes) والتي تعتبر أهم مكون لها، وقد صممت لتحاكي (الفهم) ومعالجة مدخلات الداخلة إلى الشبكة. حيث للعقدة الواحدة مدخلات للقياس منتفع بها، أو تعد مخرجات العقد الأخرى باعتبار أن كلا من المداخل تعامل بوصفها كتوصيلة مرتبطة بمدخل موزونة أخرى، حيث تمر متجهات الإدخال بين العقد عبر خطوط تسمى خطوط الربط أو الاتصال (Connections)، وكل عقدة تمثل ذاكرة محلية (Memory Local) كما يرافق كل خط اتصال وزن بعدد معين تضرب قيمته في قيم الإشارات الداخلة إلى جسم العقدة الاصطناعية ثم تطبق مع كل عقدة دالة تفعيل (Activation function) على دخل الشبكة التي تمثل مجموع إشارات الإدخال الموزونة ليتم تحديد إشارات الإخراج الناتج عنه وفقاً للصيغة التالية⁽¹⁾.

$$NET = \sum_k W_{ik} P_k, i = 1, 2, \dots, n$$

حيث تشير كل من k إلى عدد الاصناف و W إلى الأوزان وأخيراً P إلى العقد .

وتستند تلك المعالجة إلى التحليل المتوازي للمعلومات المعقدة إلى عناصر أساسية باستخدام قانون التدريب، وتشكل الهيئات الثلاثة من عقدة ووزن وقانون التدريب مع بعضها نموذجاً للشبكة العصبية الاصطناعية المناظرة في تكوينها للشبكة العصبية البيولوجية، وتتكون من ثلاثة أجزاء رئيسية⁽²⁾:

(1) طبقة الإدخال، (2) الطبقة الوسطى أو المخفية، و(3) طبقة الإخراج.

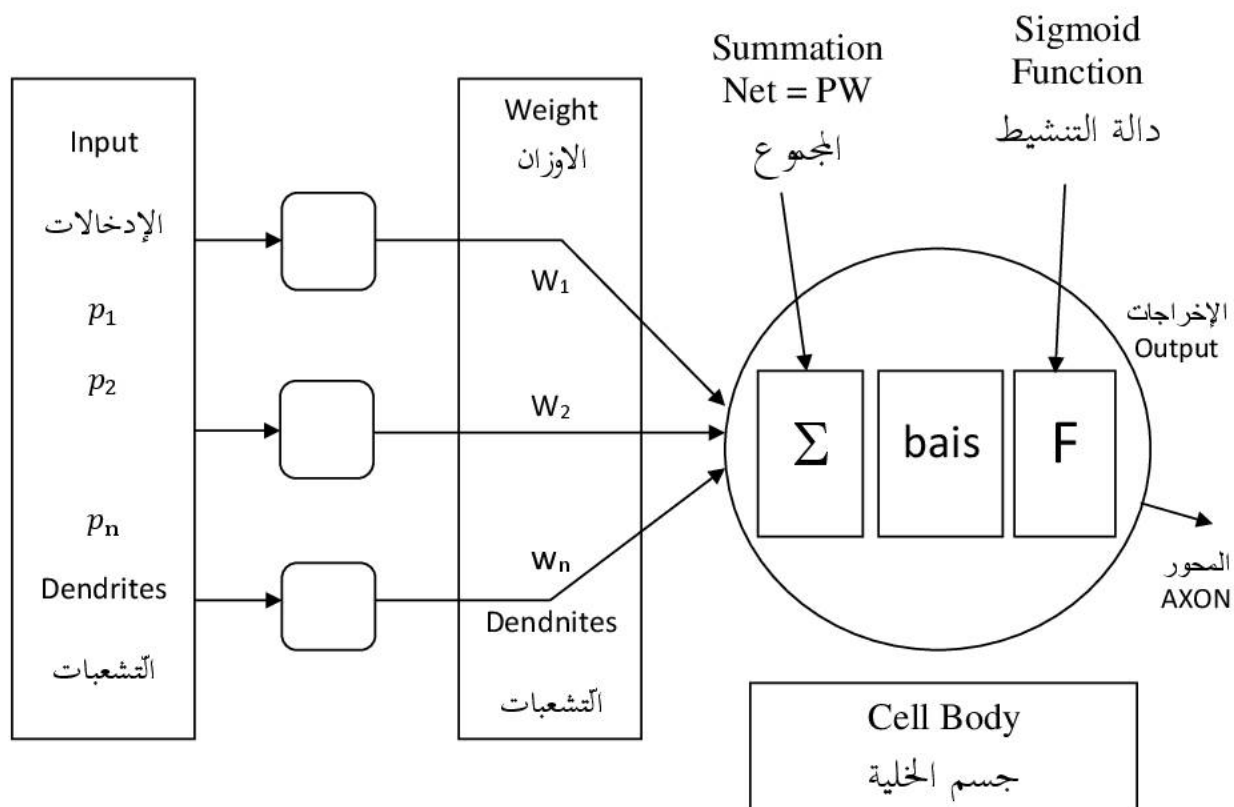
أولاً : تتكون طبقة الإدخال من مدخلات النظام. "طبقة الإدخال" هي ببساطة مُتَّجَةٌ للمدخلات.

(1) نياء حسين علي السبعواوي. (2006). تصنيف بيانات 'متعلقات الأرض' لمجلة الميدان لجمعية 'الموصل' باستخدام تقانات الشبكات العصبية الاصطناعية. *Journal of Education and science*, 13(14), ص 139.

(2) Chen, M., Challita, U., Saad, W., Yin, C., & Debbah, M. (2017). Machine learning for wireless networks with artificial intelligence: A tutorial on neural networks. *arXiv preprint arXiv:1710.02913*, 9,p10-9 .

ثانيًا : تمثل الطبقة المخفية جوهر الشبكة العصبية الاصطناعية، وتتكون من عدة وحدات تسمى الخلايا العصبية، حيث داخل الخلايا العصبية تحدث العمليات الحسابية الرئيسية لمعالجة المدخلات وتوفير المخرجات المناسبة. مثل الخلايا العصبية البيولوجية في الدماغ الحقيقي يتم تعريف قوة الاتصال بين اثنين من الخلايا العصبية على أنها قيمة الوزن، تستقبل الخلية العصبية في الطبقة المخفية وترسل خطأً من القيم من الطبقة السابقة والطبقة التالية على التوالي، إن القيم المستلمة والمرسلة تختلف من وإلى الخلية العصبية اعتمادًا على قيمة معامل الوزن التي يحمل القيمة من وإلى الخلية العصبية ونقصد بمعامل الوزن القيمة بضرب قيمة الأوزان بالقيمة القادمة من الخلايا العصبية السابقة قبل تمرير النتيجة إلى الخلية العصبية التالية، تتغير قيمة الوزن بتغيير المهمة المقصودة لأداء ويتم تحديد قيمتها من خلال التعلم والحفظ عند القيام بهذه المهمة.

الشكل 2-3: يبين مكونات الشبكات العصبية الاصطناعية وعلاقتها بالشبكة العصبية الحيوية



المصدر : طياء حسين علي السبعراوي. (2006). تصنيف بيانات استعمالات الأرض طحلة الميدان القديمة في مدينة الموصل باستخدام تقانات الشبكات العصبية الاصطناعية. (14)13، journal of Education and science، ص 140.

وعليه فإن التشابه بين الشبكات العصبية الاصطناعية (ANNs) والعقل البشري يكون من ناحيتين:

- بيئة الشبكات العصبية تكتسب المعرفة من خلال عملية التعلم.
- من أجل تخزين المعرفة، تستخدم الشبكات العصبية قوى وصل بين العصبونات تسمى الأوزان التشابكية .

3-4: تعريف الشبكات العصبية الاصطناعية :

بعد تطرقنا إلى الفكرة الأساسية التي استنبطت منها الشبكات العصبية الاصطناعية من خلال مقارنتها بالخلايا العصبية البيولوجية فإنه يمكن تعريف الشبكات العصبية الاصطناعية بأنها: عبارة عن نظام مصمم لمحاكاة الطريقة التي يؤدي بها العقل البشري مهمة معينة إذ يعد أسلوباً جديداً في تحليل البيانات وحساب التنبؤ لها والتي يرمز لها باختصار (ANN) (1).

بإنها عبارة عن نظام حاسوبي لمعالجة المعلومات مصممة لمحاكاة الطريقة التي يؤدي بها الدماغ البشري مهمة معينة حيث يتكون من عدد كبير جداً من وحدات المعالجة (Processing Elements) المترابطة في ما بينها ذات طبيعة ديناميكية وظيفتها هو التقسيم المتوازي لحساب الشبكة، وهذه الوحدات ما هي إلا عناصر حسابية تسمى عصبونات أو عقد (Nodes, Neurons) والتي لها خاصية عصبية، بحيث تقوم بتخزين المعرفة العملية والمعلومات التجريبية لتجعلها متاحة للمستخدم وذلك عن طريق ضبط الأوزان (2).

تعتبر الشبكات العصبية مجموعة مترابطة من عناصر أو وحدات أو عقد معالجة بسيطة، والتي تعتمد وظيفتها بشكل أساسي على الخلايا العصبية البيولوجية، يتم تخزين قدرة معالجة الشبكة في نقاط

(1) AL-Sharoot, M. H., & Saheb, D. A. (2014). Forecasting of electricity power consumption in AL-Qadisiya province by using time series models & Artificial neural networks models. *Journal of Al-Qadisiyah for computer science and mathematics*, 6(1), 9-26.p6

(2) Nadhim, e. a. (2013). Studying and analyzing of inflation level for standard numbers depending on time series (arima) compared with artificial neural network models (anm). *al-rafidain university college for sciences*, (31).p80.

قوة الاتصال أو الأوزان التي يتم الحصول عليها من خلال عملية التكييف مع مجموعة من أنماط التدريب أو التعلم منه⁽¹⁾.

الشبكات العصبية الاصطناعية هي برامج كمبيوتر مصممة لمحاكاة الطريقة التي يعالج بها الدماغ البشري للمعلومات، حيث يتم تعلم شبكات ANN (أو يتم تدريبها) من خلال الخبرة في نماذج التعلم المناسبة، وليس من مجموعة قواعد مبرمجة مسبقاً⁽²⁾.

الشبكات العصبية الاصطناعية هي نظام معالجة المعلومات الذي يكرر تقريباً سلوك الدماغ البشري من خلال محاكاة العمليات والاتصال بين الخلايا العصبية البيولوجية. كما تمثل الشبكات العصبية الاصطناعية وظائف معقدة وغير خطية مع العديد من المعلمات التي يتم ضبطها (معايرتها أو تدريبها) بطريقة تجعل ناتج ANN مشابهاً للمخرجات المقاسة على مجموعة بيانات معروفة⁽³⁾.

ويمكن تعريف الشبكة العصبية الاصطناعية على أنها نموذج رياضي أو نموذج حسابي يحاكي النموذج الحسابي مثل الشبكات العصبية البيولوجية. وهو يتألف من خلايا عصبية اصطناعية مترابطة ويعالج المعلومات باستخدام نهج الاتصال، وفي معظم الحالات تعتبر الشبكات العصبية الاصطناعية نظاماً تكييفياً يغير هيكله بناءً على معلومات خارجية أو داخلية تتدفق عبر الشبكة أثناء عملية التعلم. كما يمكن تعريف الشبكات العصبية الاصطناعية على أنها نموذج للخلايا العصبية البيولوجية، حيث تستقبل الخلايا العصبية الاصطناعية مدخلات (هي أرقام حقيقية) من الخلايا العصبية الأخرى، وتحسب مجموعاً مرجحاً لها وتطبق دالة تنشيط غير خطية على النتيجة، وأخيراً تعطي الإخراج المطلوب.

3-5 : مراحل ظهور وتطور الشبكات العصبونية الاصطناعية:

لقد تميز تطور الأنظمة العصبية الاصطناعية بتاريخ مثير للاهتمام، حيث يمكن القول بأن بداية تاريخ التفكير في الشبكات العصبية الاصطناعية قد بدأ في القرن العشرين عندما قام سيقمند فرويد

(1) Gurney, K. (1997). *An introduction to neural networks*. CRC press.p17

(2) Agatonovic-Kustrin, S., Glass, B. D., Wisch, M. H., & Alany, R. G. (2003). *Prediction of a stable microemulsion formulation for the oral delivery of a combination of anti-tubercular drugs using ANN methodology*. *Pharmaceutical research*, 20(11), 1760-1765.p1761.

(3) Palani, S., Liong, S. Y., & Tklich, P. (2008). *An ANN application for water quality forecasting*. *Marine pollution bulletin*, 56(9), 1586-1597.p1588.

(Freud Sigmund) بالتعرض الفلسفي للفكرة العامة لها، ويعتبر أول تطبيق عملي للشبكات البدائية في عام 1914 أين نفذ بيرتراند روسل (Russel Bertrand) جهازا هيدوليكيًا معتمدا على الفكرة العامة لهذه الشبكات، ويمكن اعتبار فترة الأربعينيات هي البداية الحقيقية لتطور هذه الشبكات حيث ساهم الكثير من العلماء والمهندسين في تطويرها، أما القفزة الحقيقية في التطوير فقد تجسدت خلال العقد الأخير من القرن العشرين لما أعلن البيت الأبيض الأمريكي أن الفترة 1990-2000 هي عقد المخ والشبكات العصبية والحساب العصبي نظرا للزيادة الكبيرة في عدد المهتمين بها⁽¹⁾.

تكمّن أصول الشبكات العصبية، أو الحوسبة العصبية (تسمى أحيانا الحوسبة العصبية أو التوصيلية)، في أربعينيات القرن العشرين مع مقالة ماكولوتش وبيتس. لقد أظهرنا أن شبكات الخلايا العصبية النموذجية قادرة على إجراء عمليات حسابية عالمية، وبعبارة أخرى يمكنهم من حيث المبدأ محاكاة أي آلة حوسبة للأغراض العامة.

وفيما يلي التسلسل الزمني لأهم الإنجازات في تطوير الشبكات العصبونية الاصطناعية⁽²⁾:

▪ **ماك كلوش وبيتس (Mcculloch and Pitts) (1943):** نمذجة الأنظمة الحيوية باستخدام شبكات من العمليات المنطقية البسيطة.

▪ **هب (Heeb) (1949):** اخترع خوارزمية تعلم مستوحاة من الناحية البيولوجية، حيث تكتسب الوصلات المستخدمة قوة تشابكية أعلى، ومن ناحية أخرى إذا لم يتم استخدام اتصال فإن قوة التشابك تميل إلى الصفر.

▪ **روزنبلات (Rosenblatt) (1958):** قام بتطوير أول نظام للشبكات العصبية باسم Perceptorn، حيث اعتبر أول نظام في الشبكات العصبية وكان قادرا على تصنيف النماذج الرياضية.

▪ **فترة الخمسينات:** أنواع أخرى من النماذج غير الخطية البسيطة، مثل نموذج Hammerstein و Wiener.

(1) محمد علي الشرقاوي، "الذكاء الاصطناعي والشبكات العصبية"، مطابع المكتب المصري الحديث، 1996. ص 261
(2) Larsen, J. (1999). Introduction to artificial neural networks. Technical University Of Denmark, p 6

- **ودرو وهو (Widrow and Ho) 1960:** قواعد التعلم للشبكات البسيطة، قام بتطوير نظام (Adaptive linear) والذي يعمل على تطبيقات تنفيذ الأجهزة ومعالجة الإشارات.
- **مينسكي وبابيرت (Minsky & Papert) 1969:** تحليل سلبي للإدراك البسيط.
- **Hop eld 1982:** التناظر بين المغناطيسية والذاكرة الترابطية (The Hop eld model).
- **هيتون وآخرون (Hinton et al) 1984:** التعلم بالأشراف على آلات Boltzmann العامة من خلال وحدات مخفية والتي تعمل على تغيير من مقدمات تحليل مينسكي وبابيرت بشكل كبير.
- **روميلهات وآخرون (Rumelhart et al) 1986:** عرفت هذه المرحلة باكتشاف طريقة خوارزمية " Backpropagation of Error " للخوارزمية الشبكات العصبية ذات التغذية الأمامية.
- **1987:** أول أجهزة كمبيوتر عصبية تجارية: لوحات Hecht-Nielsen ANZA PC الإضافية . The Science Application International Corp. DELTA PC add-on board
- **دراسة DARPA لعام 1988:** أظهرت دراسة DARPA برئاسة وودرو إمكانيات تطبيق الشبكات العصبية في العديد من مجالات التطبيق خاصة في مجال معالجة الإشارات، والتي كان لها تأثير كبير على البحث.

3-6 : تطبيقات الشبكات العصبية الاصطناعية :

عرفت الشبكات العصبية الاصطناعية تطبيقات كثيرة في مجالات الحياة، وتتوسع هذه التطبيقات كل يوم لتشمل مجالات جديدة فضلا عن تطوير التطبيقات السابقة، وهذا بالهدف للوصول إلى مزيد من الدقة، حيث أظهر استخدام هذه التقنية في هذه المجالات نتائج وحلول مرضية وذات كفاءة عالية⁽¹⁾ :

3-6-1 : التطبيقات الاقتصادية والمالية :

لقد استخدمت تقنية الشبكات العصبية الاصطناعية في بعض العمليات الاقتصادية وعمليات التحليل المالي ونذكر منها :

(1) حيدر حميد الكعبي، & علي درب الحياي، (2015). التنبؤ ببلنجة الغذائيه لمحصولي القمح والرز في العراق باستخدام طريقة لشبكات العصبية الاصطناعية ANN للمدة 2014-2022. مجلة المثنى للعلوم الزراعية، 4(1)، 1-21، ص. 6-7.

- التسويق.
- تقييم الائتمان.
- التنبؤ بالمبيعات والتنبؤ بالأسعار والتنبؤ بمعدلات التضخم .
- بناء نماذج العمليات والنماذج الإحصائية.
- إدارة المخاطر كالقروض المالية والرهن العقاري.

3-6-2: تطبيقات تحليل الصور والأنماط :

تتعدد هذه التطبيقات لتعطي العديد من المجالات المتعلقة بعمليات تحليل الصور، حيث يتم استخدام الصور الخام أو غير المعالجة كمدخل رئيسي ليتم التعرف على ما يراد معرفته من تحليل الصور، ومن أمثلة هذه التطبيقات نذكر :

- عمليات تصنيف الصور المشوهة أو الناقصة أو غير الواضحة كصور الأقمار الصناعية.
- عمليات تصنيف الصور.
- التعرف على الأهداف مثل التعرف على خط اليد .
- التفيتش الصناعي (تشخيص أعطال الآلات وتحليل أسبابها) .
- كثيرة من مشاكل التحكم الآلي استخدمت لحلها الشبكات العصبية الاصطناعية مثل :
- التسيير الذاتي للمركبات المتحركة.
- مسائل الاتزان (محاكاة القيادة) : يمكن وضع الطائرة في وضع الطيار الآلي بمجرد تعيين مسار للوجهة.

3-6-3: تطبيقات معالجة اللغات الحية :

عرفت استخدام هذه التقنية في مجال الكلام المنطوق والمقروء نجاحا، ومن أمثلة هذه التطبيقات

نذكر :

- تحويل النص المكتوب إلى كلام منطوق وكمثال على ذلك (Net Twalk).
- التعرف على الكلام المنطوق (الآلة الكاتبة الصوتية) .

3-6-4: تطبيقات معالجة الإشارة : *Signal processing*

وكمثال على ذلك عملية إزالة الضجيج من خطوط الهاتف وما يسمى بعمليات التنقية.

كما عرفت تطبيقات أخرى نذكر منها: (1)

3-6-5: التطبيقات في مجال الطبي:

تعد الشبكات العصبية الاصطناعية (ANN) حالياً منطقة بحث "ساخنة" في الطب ويعتقد أنها ستلقى تطبيقات واسعة النطاق على الأنظمة الطبية الحيوية في السنوات القليلة المقبلة، حيث في الوقت الحالي قد ارتكز البحث في الغالب على نمذجة أجزاء من جسم الإنسان والتعرف على الأمراض من عمليات المسح المختلفة (مثل مخططات القلب والأشعة المقطعية والمسح بالموجات فوق الصوتية وما إلى ذلك)، ولهذا تعد الشبكات العصبية مثالية في التعرف على الأمراض باستخدام عمليات المسح، فلا توجد حاجة لتوفير خوارزمية محددة حول كيفية تحديد المرض، لذا لا توجد حاجة إلى تفاصيل كيفية التعرف على المرض لأن الشبكات العصبية تتميز بخاصية التعلم .

3-6-6: الأحوال الجوية:

1. الطقس: تستخدم الشبكات العصبية للتنبؤ بأحوال الجو.
2. التنقيب في البيانات: اكتشاف أنماط (معرفة) ذات مغزى من كميات كبيرة من البيانات.
3. الأنظمة الخبيرة: تعتبر برنامج حاسوبي لصنع القرار يحاكي عملية تفكير خبير بشري.
4. المنطق الضبابي: نظرية التفكير التقريبي.
5. الحياة الاصطناعية: الحساب التطوري، ذكاء السرب.
6. جهاز المناعة الاصطناعي: برنامج كمبيوتر يعتمد على جهاز المناعة البيولوجي.

(1) Kohli, S., Miglani, S., & Rapariya, R. (2014). Basics of artificial neural network. International Journal of Computer Science and Mobile Computing, 3, 745-751.p 748-749.

3-7: مكونات الشبكة العصبية الاصطناعية :

تتألف البنية العامة أو الشكل العام للشبكات العصبية الاصطناعية من المكونات الأساسية الآتية أو بعض منها على الأقل حيث توجد بعض الشبكات لا تحتوي على كل هذه العناصر، وهي كالآتي⁽¹⁾:

3-7-1: طبقة المدخلات :

تعد المستوى الأول في الشبكة وهي مسؤولة عن تلقي المعلومات (البيانات) أو الإشارات من الخارج وتستقبل البيانات بواسطة وحدات المعالجة (العصبونات).
وحدات المعالجة في طبقة الإدخال لا يتم فيها أي معالجة حسابية بل تقوم بنقل البيانات المدخلة من هذه الطبقة عبر الوصلات البينية (الأوزان) إلى وحدات المعالجة في الطبقة الخفية وأي شبكة عصبية تحتوي على طبقة واحدة فقط من وحدات الإدخال ولكنها قد تحتوي على أكثر من طبقة من طبقات المعالجة.

3-7-2: طبقة المخرجات :

بدورها تتكون هذه الطبقة أيضاً من الخلايا العصبية، وبالتالي فهي مسؤولة عن إنتاج وتقديم مخرجات الشبكة النهائية، والتي تنتج عن المعالجة التي تقوم بها الخلايا العصبية في الطبقات السابقة. وقد تحتوي هذه الطبقة على وحدة معالجة أو أكثر وهذا تبعاً للبنية المعمارية للشبكة حيث تستقبل وحدات المعالجة في هذه الطبقة الإشارات القادمة إليها من طبقة الإدخال مباشرة أو من الطبقة الخفية، وبعد إجراء المعالجات اللازمة قد تُرسل إشارة بالمخرجات النهائية أو قد تقوم بإعادة هذه المخرجات كمدخلات مرة أخرى للشبكة وذلك عند تعثر المعالجة المطلوبة للبيانات، حيث تحتوي الشبكة العصبية عادة على طبقة مخرجات واحدة فقط.

(1) عامر قصي الدرويش (2017)، التنبؤ بالأمطار الشهرية في محطة حمص باستخدام أسلوب التحويل المويجي والشبكة العصبية الاصطناعية، رسالة ماجستير في الهندسة المدنية 'اختصاص الهندسة المائية والريّة، جامعة تشرين كلية الهندسة المدنية. ص18.

3-7-3 : الطبقة الخفية :

تسمى كذلك بالطبقة الوسيطة أو غير مرئية فهي تقع بين طبقة المدخلات وطبقة المخرجات، تتكون هذه الطبقات من الخلايا العصبية المسؤولة عن استخراج الأنماط المرتبطة بالعملية أو النظام الذي يتم تحليله وهذا من خلال استقبالها للإشارات القادمة إليها من طبقة المدخلات عبر الوصلات البينية فتقوم بمعالجتها ومن ثم إرسالها عبر الوصلات إلى طبقة المخرجات، حيث تؤدي هذه الطبقات معظم المعالجة الداخلية من الشبكة.

3-7-4 : الوصلات البينية (الأوزان) :

فهي عبارة عن وصلات اتصال بين الطبقات المختلفة تقوم بربط الطبقات مع بعضها البعض أو الوحدات داخل كل طبقة عبر الأوزان التي تكون مصاحبة أو مرفقة مع كل وصلة بينية ومهمة هذه الوصلات نقل الإشارات الموزونة بين وحدات المعالجة أو الطبقات.

3-7-5 : وحدات المعالجة (العصبونات) :

وحدات المعالجة أو العصبونات هي الوحدات المسؤولة عن عملية معالجة المعلومات في الشبكة العصبية وهي تشكل المكونات الأساسية التي تتألف منها كل طبقات الشبكة العصبية وتتصل هذه الوحدات بطرق مختلفة بواسطة الوصلات البينية لتعطي الشكل العام أو البنية المعمارية للشبكة العصبية الاصطناعية. وتتكون من العناصر الأساسية التالية :

1) معاملات الأوزان:

يعتبر الوزن العنصر الرئيس في الشبكة العصبية الاصطناعية في تمثيل الوسائط والروابط المختلفة التي يتم عبرها نقل البيانات من طبقة إلى أخرى، ويعبر عن درجة الأهمية النسبية للعنصر المدخل إلى عنصر المعالجة، وتعتبر هذه الأوزان بمثابة الوسيلة الأساسية لذاكرة الشبكة العصبية ويرمز للوزن بين عنصري معالجة (i) و (j) بالرمز، (W_{ij}) حيث تؤثر الأوزان على قيم المخرجات، ومن الممكن تعديل الأوزان من خلال خاصية التعلم في الشبكة والتي تعرف بدالة التجميع.

(2) دالة الجمع :

تتم من خلالها أول معالجة تقوم بها وحدة المعالجة وهي حساب مجموع المدخلات الموزونة، حيث تقوم هذه الدالة بحساب مجموع متوسط الأوزان لكل المدخلات وذلك بضرب قيمة كل مدخلة في وزنها، ومن ثم إيجاد المجموع لكل حواصل الضرب .

وتأخذ دالة التجميع وفق الصيغة الرياضية التالية⁽¹⁾:

$$Z_j = \sum_{i=1}^n X_i W_{ij}$$

حيث :

Z_j : هي ناتج عملية الجمع لكل وحدة معالجة j .

X_i : تشير إلى القيمة المدخلة القادمة من الوحدة (i) والداخلية إلى الوحدة (j) .

W_{ij} : تشير إلى الوزن الذي يربط وحدة المعالجة (j) بالوحدة (i) الموجودة في الطبقة السابقة.

وأحيانا تكتب المعادلة كما يلي⁽²⁾ :

$$Z_j = b_j + \sum_{i=1}^n X_i W_{ij}$$

حيث :

b_j تمثل انحياز وهو يعتبر أحد مكونات الدخل وعمله مشابه لعمل الأوزان ودخله $X_0=1$

فوحدة التحيز غير مرتبطة بأي طبقة سابقة، أي أنها لا تمثل "نشاط" حقيقي وإضافة وحدة انحياز إلى وحدات الدخل تغير من شكل تابع التنشيط أو دالة التحويل فقط .

(1) Derbal, A. محاولة التنبؤ بمؤشرات الأسواق المالية العربية باستعمال النماذج القياسية دراسة حالة: مؤشر سوق دبي أمالي (Doctoral dissertation). ص92.

(2) بوعوروي. (2019). مساهمة الشبكات العصبونية الاصطناعية في التنبؤ بحجم المبيعات لدعم صنع القرارات الإدارية في المؤسسات الاقتصادية: دراسة لبعض المؤسسات الجزائرية (Doctoral dissertation). ص102.

3) دالة التفعيل (التنشيط) :

أن العملية الثانية في وحدة المعالجة بعد عمل دالة الجمع هي تحويل ناتج الجمع إلى أحد القيم التي يفترض أن تكون ضمن نواتج الشبكة المرغوب بها وهذا باستخدام دالة من عددي إلى عددي تسمى "دالة التنشيط أو دالة العتبة أو دالة التفعيل"، وإخراج قيمة نتيجة تسمى "تنشيط الوحدة"⁽¹⁾. كل خلية عصبية لها مستوى استثارة، يتم حساب هذا المستوى عن طريق دالة التجميع وهذا ما يسمى بالمحاكاة الداخلية، تتم هذه الخطوة بالاعتماد على نتائج الدالة التجميعية والتي تمثل المنشط الداخلي، وقد يطلق عليها دالة التحفيز الخارجية ومن أهم وظائفها هي تحويل ناتج الجمع إلى أحد القيم المرغوبة وأن تكون ضمن نواتج الشبكة حيث تقوم الدالة بتحويل ناتج عملية الجمع الموزون في الخطوة الأولى إلى قيمة محصورة بين مديين، ويتم ذلك بمقارنة نتيجة الجمع مع قيمة العتبة ويرمز لها بالرمز θ من أجل تحديد الناتج ويطبق على المجموع عادة قبل المقارنة تابع تنشيط معين وتتوقف مخرجات الشبكة بصورة أساسية على هذا التوزيع وبناء على هذه التوابع أو الدوال تعطي الشبكة مخرجات محصورة ضمن المجال (0,1) أو المجال (-1, +1).

ومن أهم توابع التحويل أو توابع التنشيط⁽²⁾:


- دالة الإشارة (Sign Function) : حيث يكون فيها صورة المخرجات بين [-1,1]؛ أي تقوم هذه الدالة بتقريب قيم الإخراج إما إلى 1 في حالة إذا ما كانت قيمة المعامل موجبة (+1) وإلى (-1) في حالة السالب، كما أنها تستخدم في التصنيف والتعرف على الأنماط .
- دالة الخطوة (Step Function) : وهي الدالة التي تكون مخرجاتها بين [0,1] .
- الدالة الخطية (Linear Function) : وهي الدالة التي تكون فيها صورة المخرجات مثل صورة المدخلات وتعطي تصنيفات متعددة وغير محدودة.

(1) Karlik, B., & Olgac, A. V. (2011). Performance analysis of various activation functions in generalized MLP architectures of neural networks. *International Journal of Artificial Intelligence and Expert Systems*, 1(4), 111-122.p112.

(2) بن نور فريد، نايت مرزوق محمد العربي، استخدام نماذج الذكاء الاصطناعي للتنبؤ باحتياجات الصرف الأجنبي في الجزائر - نموذج الشبكات العصبية الاصطناعية ANN - مجلة اقتصاديات شمال إفريقيا، المجلد 15 العدد 20 السنة : 2019 ص 67-82 ص 74.

- دالة السيغمويد (Sigmoid Function): تأخذ هذه الدالة قيم المدخلات المحصورة بين $-\infty$ و ∞ وتجعل المخرجات محصورة بين $[0, 1]$ وتسمى بدالة التنشيط اللوجستي الثنائي أو تحويل المخرجات إلى قيم بين $[-1, 1]$ وتسمى بدالة التنشيط اللوجستي ثنائي القطبية, وتعتبر هذه الدالة من أكثر الدوال استخداماً في الشبكات العصبية الاصطناعية⁽¹⁾.

الشكل 3-3: يبين أشهر دوال التنشيط



Source :Qasim, O. S., & Mohammed, I. R. (2013). An Analytical Mathematical Study of Artificial Neural Network Algorithms in the Suitability of a Model for Medical Diagnosis. AL-Rafidain Journal of Computer Sciences and Mathematics, 10(1), 183-194.p187.

3-7-6: دالة المخرجات:

بعد أن تقوم دالة الجمع بعملية الجمع الموزون للمدخلات ومن ثم دالة التحويل تقوم بتحويل ناتج الجمع إلى قيمة محصورة في مدى معين، فقد تكون المخرجات في أغلب الأحيان مساويةً لناتج دالة التحويل. ولكن هناك بعض الشبكات تقوم وحدة المعالجة فيها بتعديل نتيجة دالة التحويل ويتم ذلك خلال تنافس وحدات المعالجة المجاورة مع بعضها البعض ويتم التنافس عادة في وحدات المعالجة التي يكون لها تنشيط أكبر، هذه المنافسة تحدد وحدة المعالجة التي ستكون نشطة أو التي ستقوم

(1) Simon, H. (2009). Neural networks and learning machines. Upper Saddle River: Pearson Education, 3.p14

بالإخراج. وكذلك تساعد المنافسة في تحديد الوحدات التي سوف تشارك في عملية التعلم والتدريب، ويمكن تلخيص عمل وحدة المعالجة في الشبكة العصبية في الخطوات التالية :

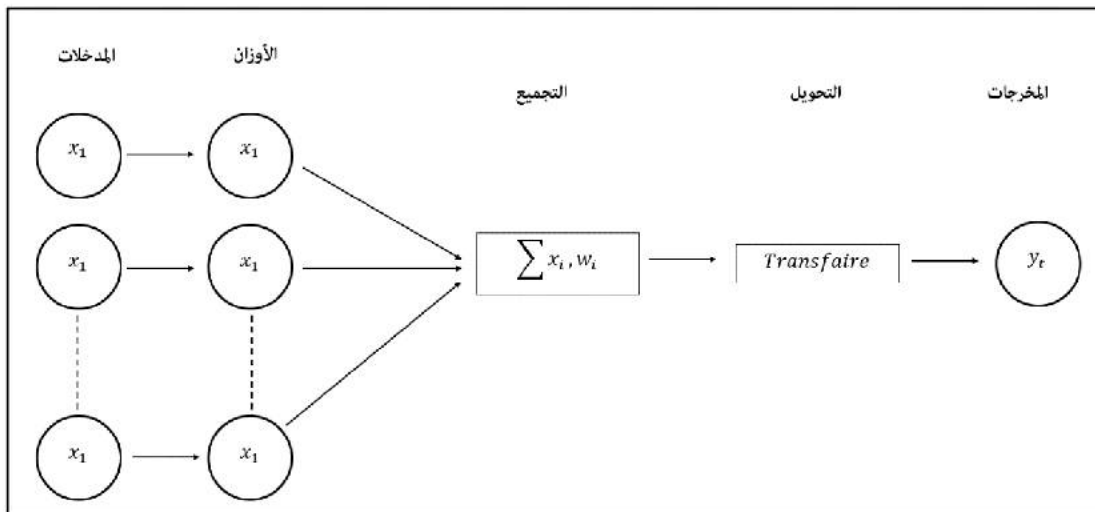
- 1- استقبال الإشارات أو المدخلات من العالم الخارجي.
- 2- تعديل الإشارة الداخلة إلى الوحدة عن طريق الأوزان حيث يضرب كل إشارة داخله بالوزن الموجود في خط ربط الوحدة.
- 3- جمع أوزان الداخل القادمة من الوحدات الأخرى باستخدام قاعدة أو دالة الجمع.
- 4- تطبيق تابع تنشيط معين علي مجموع إشارات الدخل الموزونة حتى يتم تحديد إشارة الخرج الناتجة من هذه الوحدة.
- 5- الخرج الناتج عن هذه الوحدة يمكن أن يربط إلى عدة وحدات معالجة أخرى أو يمكن أن يكون هو الناتج النهائي للشبكة.

3-8: نموذج رياضي لخلية عصبية :

الشبكة العصبية الاصطناعية (ANN) هي نموذج رياضي يحاول محاكاة بنية ووظائف الشبكات العصبية البيولوجية، اللبنة الأساسية لكل شبكة عصبية اصطناعية هي الخلايا العصبية الاصطناعية، أي يمثل نموذج رياضي بسيط (دالة) يحتوي على ثلاث مجموعات بسيطة من القواعد: الضرب والجمع والتفعيل. عند مدخل الخلايا العصبية الاصطناعية، يتم ترجيح المدخلات مما يعني أن كل قيمة مدخلات يتم ضربها بالوزن الفردي، في القسم الأوسط من الخلايا العصبية الاصطناعية، توجد دالة مجموع تلخص جميع المدخلات المرجحة والتحفيز، وعند خروج الخلايا العصبية الاصطناعية، يمر مجموع المدخلات المرجحة سابقاً والتحفيز بدالة تنشيط التي تُسمى أيضاً دالة التحويل⁽¹⁾.

(1) Krenker, A., Bester, J., & Kos, A. (2011). Introduction to the artificial neural networks. In Artificial neural networks-methodological advances and biomedical applications. IntechOpen.p3.

الشكل 4-3 : يبين أشهر دوال التنشيط



Source : SUJANA PRAJITHKUMAR, D., VERMA, S., & MAHAJAN, B. Application of ANN model for the prediction of Water Quality Index. International Journal of Engineering Research and General Science, 3(1).p655.

من خلال الشكل نلاحظ أن العصبون يتكون من :

1- إشارات المدخلات : $X_1, X_2, \dots, \dots, X_k$

-الأوزان : $W_1, W_2, \dots, \dots, W_{kj}$

2- عنصر المعالجة (دالة التنشيط) والذي ينقسم إلى قسمين :

أ- الجامع الذي يقوم بجمع الإشارات في المدخل الموزون ويعطى بالصيغة التالية :

$$Total\ input = \sum_{i=1}^{i=n} W_{ij} X_i$$

ب- تابع التفعيل : حيث هذا التابع يجد من مخرج العصبون لهذا سميا بتابع التخميد.

3- المخرجات : X_k .

وتكتب الصيغة الرياضية للعصبون كآلاتي:

حيث المدخلات في العقدة عبارة عن مجموع محتمل من المخرجات من العقد المتصلة بها، يتم إعطاء دالة الإدخال بواسطة المعادلة:

$$Net_i = \sum W_{ij} X_j + \mu_i$$

حيث :

Net_i تمثل صافي المدخلات X_i (الموزونة بالأوزان W_{ij}) التي تؤثر على الوحدة i ، حيث W_{ij} تعبر أيضا عن أوزان تربط j بالخلية i .

X_j هو الناتج من الوحدة j و i تدل عن عتبة الخلية العصبية i ، حيث مصطلح العتبة يعد إدخال أساسي في العقدة وهذا في حالة غياب أي مدخلات أخرى تأخذ كل وحدة دخلها الصافي وتطبق دالة تفعيل عليها، حيث يوجد العديد من دوال التفعيل التي تحدد ما هي قيمة المخرجات التي يمكن استنتاجها من صافي المدخلات. حيث تم استخدام عدد من الدوال غير الخطية في الأدبيات دوال تنشيط أو تفعيل ومن بين دوال التنشيط الأكثر استخداما في بناء الشبكات العصبية لدينا (*hyperbolic tangent* , *Sigmoid function*) والمعادلة 1 و 2 توضح الصيغة الرياضية الخاصة بكل دالة (1):

$$f(X) = \frac{1}{1 + e^{-X}}$$

$$f(X) = \frac{e^X - e^{-X}}{e^X + e^{-X}}$$

$\sum W_{ij} X_j + \mu_i$ تعبر عن تابع عملية الجمع، حيث μ_i تمثل الانحياز أو عتبة الخلية العصبية.

3-9: البنية المعيارية للشبكة العصبية :

تحتوي الشبكات العصبية الاصطناعية على العديد من البنى القائمة على الطريقة التي يتم بها ربط الخلايا العصبية وتوزيعها في الشبكة، إذ تتميز ببنيتها التي تمثل نمط الاتصال بين العقد وطريقتها في تحديد أوزان الاتصال ووظيفة التنشيط، فنموذج الشبكات العصبية الاصطناعية يتكون من عدد من

(1) Sharifi, F., Haddad, O. B., & Naderi, M. (2005). Reservoir optimal operation using DP-ANN. Evolutionary Computation, 496-281.p333.

العقد التي يتم تنظيمها وفقاً لترتيب معين، ووفقاً لهذا يمكن تصنيف الشبكات العصبية الاصطناعية إلى صنفين رئيسيين⁽¹⁾:

أولاً من حيث عدد الطبقات، و**ثانياً** وفق اتجاه تدفق المعلومات ومعالجتها.

3-9-1 : تصنيف الشبكات العصبية وفقاً لعدد الطبقات :

يمكن تصنيف الشبكات بحسب عدد مستوياتها (طبقاتها) إلى صنفين رئيسيين⁽²⁾ :

(1) شبكات وحيدة الطبقة:

تعد من أبسط الشبكات التي تمتلك طبقة إدخال وطبقة إخراج دون امتلاكها لطبقة خفية، فطبقة الإدخال تقوم باستقبال الإشارات من العالم الخارجي، وطبقة الإخراج هي التي تعطي لنا استجابة الشبكة وتوضع الترابطات بينها، وسبب تسميتها بهذا الاسم كونها تمتلك طبقة واحدة من ترابطات الأوزان.

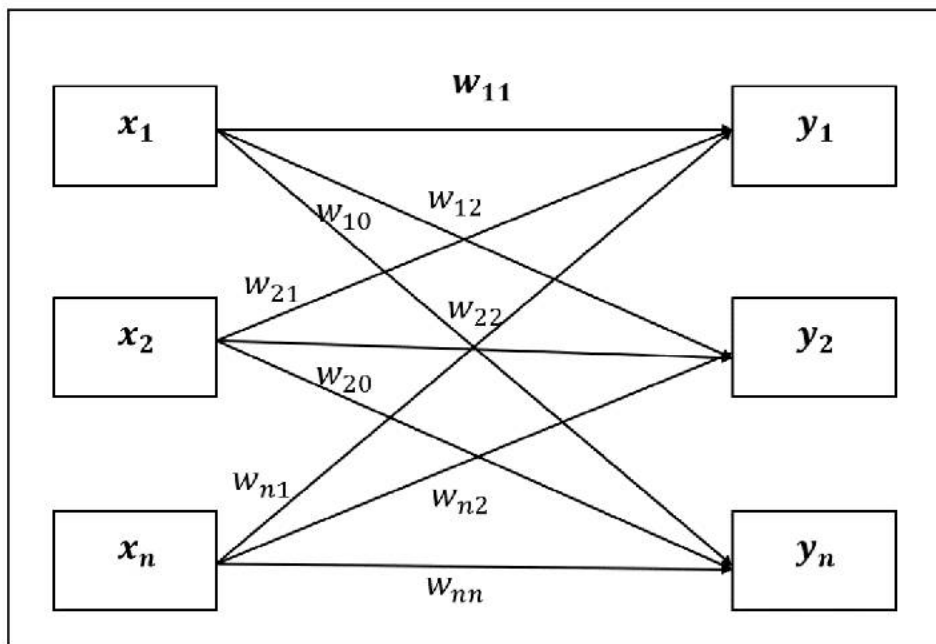
(2) شبكات متعددة الطبقات :

يمتلك هذا النوع من الشبكات متعددة الطبقات على الأقل طبقتين؛ طبقة إدخال، والتي تقوم باستقبال المدخلات، وطبقة المخرجات، وبين الطبقتين توجد طبقة مخفية واحدة أو أكثر تعمل على زيادة قدرة الشبكة على معالجة البيانات، ومن عيوبها كونها بطيئة في عملية المعالجة؛ حيث تستغرق عملية التدريب وقتاً أطول ولكن ميزتها هي إيجاد الحلول المثلى لأية مشكلة معقدة ومن تم تحسين الأداء.

(1) ASCE Task Committee on Application of Artificial Neural Networks in Hydrology. (2000). Artificial neural networks in hydrology. I: Preliminary concepts. Journal of Hydrologic Engineering, 5(2), 115-123.p115.

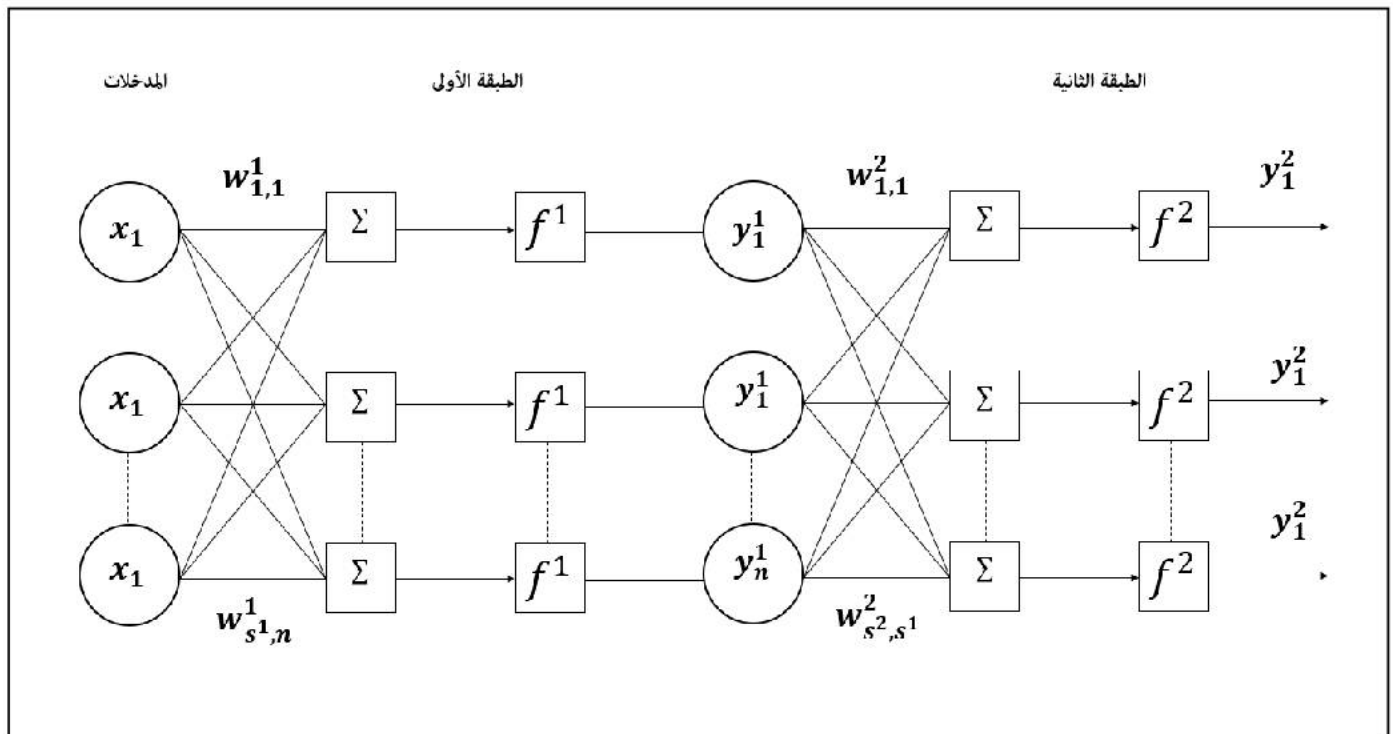
(2). د.ظافر رمضان مطر البدراني، رهاد عماد صليوا" تقييم تنبؤ السلسلة الزمنية لمعدلات درجات الحرارة باستخدام الشبكات العصبية" المجلة العراقية للعلوم الاحصائية (26) 2014 ص ص (19-1) ص 8.

الشكل 3-5 : يبين معمارية الشبكة العصبية وحيدة الطبقة



المصدر : دعاء عبد الكريم صاحب، محمد حبيب الشاروط، التنبؤ باستهلاك الطاقة الكهربائية في محافظة القادسية باستخدام نماذج السلاسل الزمنية ونماذج الشبكات العصبية الاصطناعية، مجلة القادسية لعلوم الحاسوب والرياضيات، المجلد (2)، العدد (1)، السنة 2014، ص 14.

الشكل 3-6 : يبين معمارية الشبكة العصبية متعددة الطبقات:



المصدر : دعاء عبد الكريم صاحب، محمد حبيب الشاروط، التنبؤ باستهلاك الطاقة الكهربائية في محافظة القادسية باستخدام نماذج السلاسل الزمنية ونماذج الشبكات العصبية الاصطناعية، مجلة القادسية لعلوم الحاسوب والرياضيات، المجلد (2)، العدد (1)، السنة 2014، ص 14.

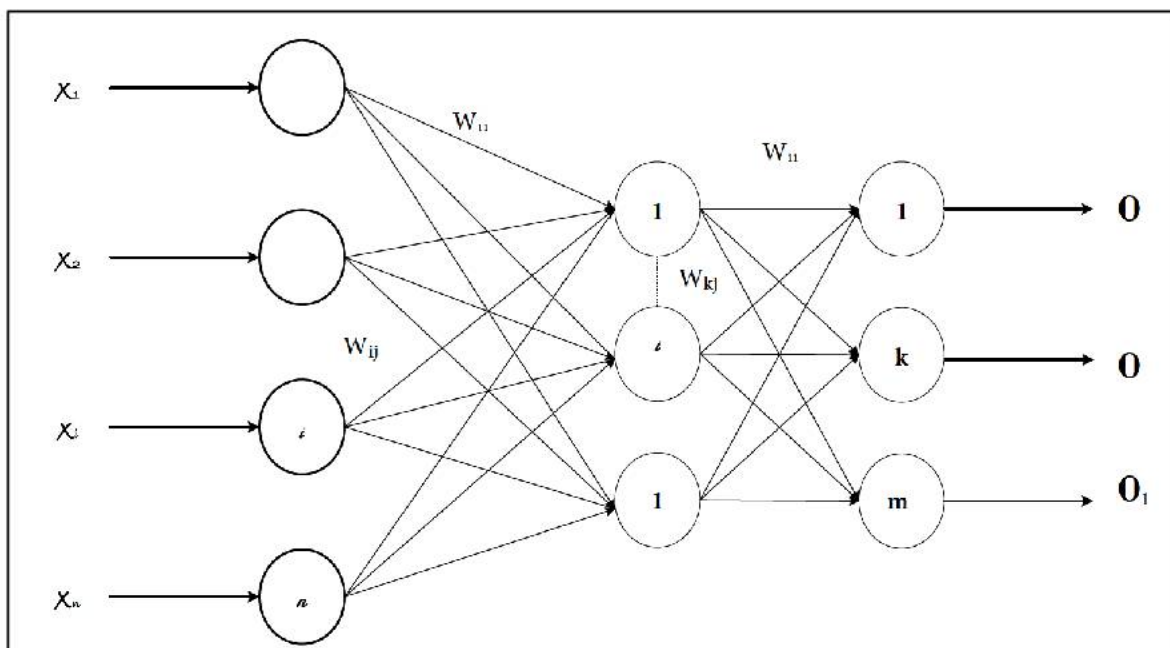
3-9-2: تصنيف الشبكات العصبية وفقاً لاتجاه تدفق المعلومات ومعالجتها:

1) الشبكات ذات التغذية الأمامية:

تسمى الشبكة العصبية الاصطناعية التي تحتوي على هيكل تغذية أمامي بالشبكة العصبية الاصطناعية ذات التغذية الأمامية. حيث يتضمن بشكل أساسي شرطاً واحداً فقط، يجب أن تتدفق المعلومات شكل تسلسلي بدا من طبقة المدخلات وانتهاء بطبقة المخرجات في اتجاه واحد فقط وبدون أي رجوع خلفية. كما لا توجد قيود على عدد الطبقات، أي يخلو تركيبها من وجود حلقة مغلقة من الترابطات بين الوحدات المكونة لها⁽¹⁾.

بشكل عام، هذا النوع من الشبكات قد يتكون من طبقتين على الأقل طبقة مدخلات وطبقة مخرجات فقط بدون طبقات خفية ويطلق عليها شبكات التغذية الأمامية أحادية الطبقة، كما قد تحتوي على الأقل على طبقة خفية Hidden Layer بين طبقة المدخلات وطبقة المخرجات ويطلق عليها اسم شبكات التغذية الأمامية متعددة الطبقات⁽²⁾.

الشكل 3-7 : يبين الشبكات العصبية الاصطناعية ذات التغذية الأمامية



Source : Amir Jalalkamali* and Navid Jalalkamali(2011),Groundwater modeling using hybrid of artificial neural network with genetic algorithm ,African Journal of Agricultural Research Vol.6(26), pp.5775-5784, p5777.


(1) Gendary, A. I. (2019). ANN and DNN-based Models for DDoS Detection via Network Traffic Forecasting (Doctoral dissertation, Middle East University).p15.

(2) Haykin, S. S. (2009). Neural networks and learning machines/Simon Haykin.p 21-22

(2) الشبكات ذات التغذية العكسية :

تسمى الشبكة العصبية الاصطناعية التي تحتوي على هيكل تغذية عكسية بالشبكة العصبية الاصطناعية ذات التغذية العكسية. حيث أنها تشبه الشبكات العصبية ذات التغذية الأمامية إلى أنها لا تشترط تدفق المعلومات في اتجاه واحد فقط، بل السماح بالرجوع إلى الطبقة السابقة أيضا. يولد المخطط حالات داخلية داخل الشبكات تسمح لهم بإظهار سلوكيات زمنية ديناميكية مما يمكن لشبكة ANN المتكررة استخدام وحدات الذاكرة الداخلية الخاصة بها لمعالجة أي سلسلة من المدخلات⁽¹⁾.

الشكل 3-8 : يبين الشبكات العصبية الاصطناعية ذات التغذية العكسية



Source : Amir Jalalkamali* and Navid Jalalkamali(2011),Groundwater modeling using hybridof artificial neural network with genetic algoritm ,African Journal of Agricultural Research Vol.6(26),pp.5775-5784,p5777.

3-10 : خوارزميات التعلم في الشبكات العصبية الاصطناعية :

تحاكي الشبكات العصبية الاصطناعية الدماغ البشري في التعلم، من حيث التدريب وتخزين البيانات، وهذا من خلال التجارب التي يمر بها، ولذا تلعب خوارزمية التدريب دورًا مهمًا في أي

(1) Welch, R. L., Ruffing, S. M., & Venayagamoorthy, G. K. (2009, June). Comparison of feedforward and feedback neural network architectures for short term wind speed prediction. In 2009 International Joint Conference on Neural Networks (pp. 3335-3340). IEEE,p3336

شبكة عصبية، ومنه اعتبرت العملية التي تعدل أوزان وتحييزات الخلايا العصبية، حيث يتم تحسين الأداء بمرور الوقت من خلال التحديث المتكرر للأوزان في الشبكة، والتي بدورها تسمح للشبكات بربط بعض أنماط بيانات الإدخال بقيم مخرجات معينة⁽¹⁾.

تعتبر القدرة على التعلّم سمة أساسية من سمات الذكاء الاصطناعي، ورغم صعوبة صياغة تعريف دقيق للتعلّم، يمكن النظر إلى عملية التعلّم في سياق الشبكات العصبية الاصطناعية، على أنها مشكلة تحديث بُنية الشبكة وأوزان الاتصال، وحتى تتمكن الشبكة من أداء مهمة محددة بكفاءة، يجب أن تتعلم عادة أوزان الاتصال من أنماط التدريب المتاحة.

إن قدرة الشبكات العصبية الاصطناعية على التعلّم تلقائياً من الأمثلة تجعلها أكثر استخداماً بدلاً من إتباع مجموعة من القواعد المحددة من قبل الخبراء البشريين، يبدو أن الشبكات العصبية الاصطناعية تتعلم القواعد الأساسية (مثل علاقات المدخلات والمخرجات) من مجموعة معينة من الأمثلة التمثيلية. مما يجعلها إحدى المزايا الرئيسة للشبكات العصبية على الأنظمة الخبيرة التقليدية.

ومن أجل فهم أو تصميم عملية التعلّم، يجب أن يكون لديك أولاً نموذجاً للبيئة التي تعمل فيها الشبكة العصبية، أي يجب أن تعرف ما هي المعلومات المتاحة للشبكة وثانياً يجب أن تفهم كيفية تحديث أوزان الشبكة، أي قواعد التعلّم التي تحكم عملية التحديث حيث تشير خوارزمية التعلّم إلى إجراء يتم فيه استخدام قواعد التعلّم لضبط الأوزان⁽²⁾.

يوجد العديد من الأنواع المختلفة لشبكات العصبية الاصطناعية، وبعضها أكثر شهرة من البعض الآخر، فعند استخدام الشبكات العصبية من أجل تحليل بيانات السلسلة الزمنية، فمن المهم التمييز بين نماذج الشبكات العصبية الاصطناعية (ترتيب الشبكة) وكذا خوارزمياتها (الحسابات التي

(1) Fasel, B. (2003). An introduction to bio-inspired artificial neural network architectures. *Acta neurologica belgica*, 103(1), 6-12.p8.

(2) Jain, A. K., Mao, J., & Mohiuddin, K. M. (1996). Artificial neural networks: A tutorial. *Computer*, 29(3), 31-44.p34-35.

تنتج لنا في النهاية مخرجات الشبكة)، وبمجرد هيكلية الشبكة لتطبيق معين، تصبح هذه الشبكة جاهزة للتدريب⁽¹⁾.

وبناءً على استراتيجية التعلم، يمكن تصنيف طرق التعلم في الشبكات العصبية إلى ثلاث فئات رئيسية وهي كما يلي⁽²⁾:

3-10-1: التعلم المراقب (بواسطة معلم):

هذا النوع من التعلم يتطلب حضور المراقب أثناء عملية التعلم، حيث يتم تدريب الشبكة من خلال أسلوب تدريب معين على بيانات الإدخال والشكل المستهدف والذي يتضمن نمط الإدخال المرتبط بالهدف المقابل أو النمط المطلوب، حيث سيشكل نمط التدريب هذا مجموعة من الأمثلة المستخدمة لتدريب الشبكة من أجل تعلم السلوك المحدد ووجود المخرجات المرغوبة لكل مدخل في نمط التدريب، مما يجعل هذا النوع من التعلم تحت الإشراف.

فمن خلال عملية التعلم تتم مقارنة قيم المخرج الفعلي للشبكة العصبية بالقيمة المستهدفة ويتم إجراء تصحيح وزن الشبكة عبر خوارزمية التعلم بطريقة تقلل دالة الخطأ بين القيمتين. هذه هي مشكلة هذا النوع، حيث تبحث خوارزمية التعلم عن الأوزان المثلى التي يمكن أن تمثل الحل لمشكلة التقريب، ومن أمثلة التعلم الخاضع للإشراف قاعدة دلتا وقاعدة بيرسبترون.

3-10-2: التعلم غير المراقب (بدون معلم):

في هذا النوع من التعلم لا يوجد هدف أو هدف متاح للشبكة، بل يوجد فقط نمط الإدخال، أي لا يوجد مراقب لتعلم الشبكة؛ فهو تكيف الشبكة للاستجابة للمدخلات واختيارها للهيكليّة من المدخلات فقط، ولهذا يسمى هذا النوع من التعلم أيضاً بطريقة التعليم الذاتي (Self-Supervised Learning) لعدم استخدامها مراقب خارجي⁽³⁾، ومن بين طرق التعلم الغير المراقب نجد:

(1) Agatonovic-Kustrin, S., & Beresford, R. (2000). Basic concepts of artificial neural network (ANN) modeling and its application in pharmaceutical research. *Journal of pharmaceutical and biomedical analysis*, 22(5), 717-727.p721

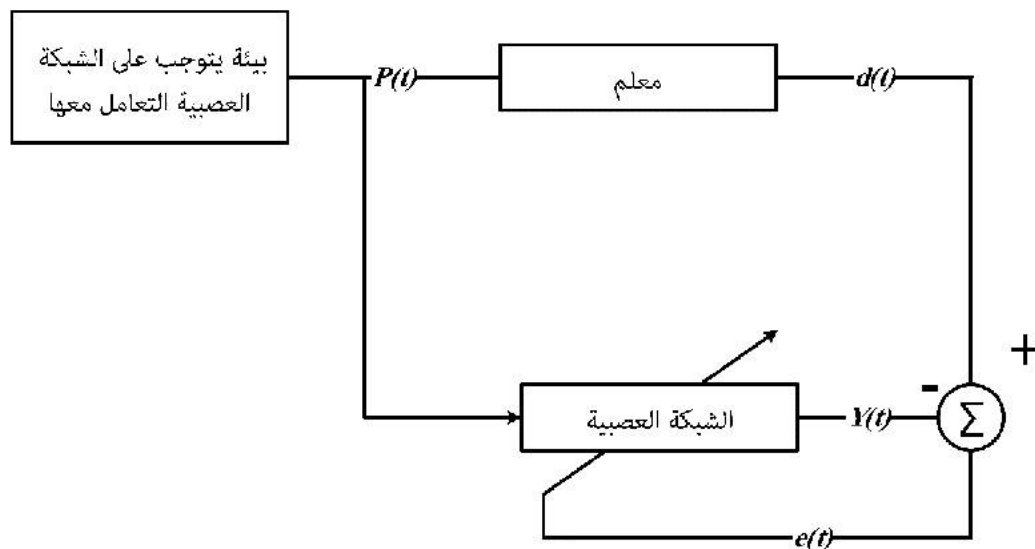
(2) Kumar, K., & Thakur, G. S. M. (2012). Advanced applications of neural networks and artificial intelligence: A review. *International journal of information technology and computer science*, 4(6), 57.p59

(3) رهاد عماد صليوا، ظافر رمضان مطر. (2019). مقارنة أداء التنبؤ بين بعض الشبكات العصبية الاصطناعية ومنهجية (بوكس -جنكيز) مع التطبيق،المجلة العراقية للعلوم الإحصائية (28)صص (51-76). ص 61.


▪ قاعدة التعلم الهيبباني.

▪ قاعدة التعلم التنافسي.

الشكل 9-3 : يبين آلية التعلم المراقب



الشكل 10-3 : يبين آلية التعلم غير المراقب



المصدر : عامر قصي الدرويش (2017)، التنبؤ بالامطار الشهرية في محطة حمص باستخدام أسلوب التحويل المويجي والشبكة العصبية الاصطناعية، رسالة ماجستير في الهندسة المدنية اختصاص الهندسة المائية والري، جامعة تشرين كلية الهندسة المدنية. ص 31-32.

3-10-3: التعلم بإعادة التدعيم :

يعتمد هذا النوع من التعلم على الخلط بين طريقة التعلم المراقب وغير المراقب، أي يعد تعلم وسطياً، حيث لا تكشف الشبكة العصبية عن القيم الحقيقية للمخرجات كما هي الحال في التعلم الغير الخاضع للإشراف ولكن يشار إلى الشبكة بصحة نتائجها أو خطئها كما في طريقة التعلم الخاضع للإشراف⁽¹⁾.

3-11: خوارزميات التعليم المستخدمة لتدريب الشبكات العصبية :

يجري تعليم الشبكات العصبية بواسطة خوارزميات متخصصة تسمى خوارزميات التعلم *Algorithms Learning*، تتولى تعديل أوزان الشبكة لتحسين أدائها وتقليل الخطأ فيها استناداً إلى مقياس معلوم للوصول إلى النتيجة المطلوبة، حيث يجري تعديل هذه الأوزان جزئياً في كل دورة، وتؤخذ إشارة الخطأ دليلاً ومؤشراً على مدى القرب أو البعد عن القيم الصحيحة.

وتمثل تلك الأوزان المعلومات الأولية التي تتعلم بها الشبكة، لهذا لا بد من تحديث هذه الأوزان خلال مرحلة التدريب، ومن أجل هذا التحديث نستخدم خوارزميات مختلفة حسب نوع الشبكة ومن بين هذه الخوارزميات⁽²⁾، تعد خوارزمية الانتشار الخلفي (BPNN) من أكثر الطرق استخداماً في عملية التعلم تحت الإشراف، أي الشبكات العصبية ذات التغذية الأمامية ومتعددة الطبقات وكاملة الارتباط، ومن خلال هذا الإجراء يمكن للشبكة أن تتعلم تعيين مجموعة من المدخلات لمجموعة من المخرجات، عن طريق تقليل الخطأ، حيث تعمل خوارزمية الانتشار العكسي البحث عن الحد الأدنى من دالة الخطأ في مساحة الوزن باستخدام طريقة التدرج الانحداري، حيث يعتبر الجمع بين الأوزان التي تقلل من دالة الخطأ حلاً لمشكلة التعلم⁽³⁾، ويتم تنفيذ هذه الخوارزمية من خلال ثلاثة مراحل رئيسية هي⁽⁴⁾:

(1) العباسي، عبد الحميد (2013). "التنقيب في البيانات Data Mining تطبيقات باستخدام SPSS MODEL R"، جامعة القاهرة، مصر، ص.5.
 (2) قصي حبيب الحسيني، مقدمة في الشبكات العصبية الاصطناعية "جامعة الامام جعفر الصادق، بغداد، 2011م" ص.10
 (3) Ak, R. (2014). *Modélisation à base de réseaux de neurones dédiés à la prédiction sous incertitudes appliqué aux systèmes énergétiques (Doctoral dissertation, Supélec)*, p25.
 (4) مروان جمعة درويش. (2019). فعالية التنبؤ بمؤشر بورصة فلسطين باستخدام نموذج الشبكات العصبية الاصطناعية: مقارنة بنموذج الانحدار الذاتي. مجلة جامعة القدس المفتوحة للبحوث الإدارية والاقتصادية، 3(10)، ص.79.

▪ **المرحلة الأولى : الانتشار الأمامي Feed forward Back Propagation :**

لا يحصل فيها أي تعديل للأوزان المشبكية وتبدأ هذه المرحلة بعرض الشكل المدخل للشبكة، حيث تخصص آل عنصر معالجة من طبقة عناصر الإدخال لأحد مكونات الشعاع الذي يمثل الدخل، وتسبب قيم مكونات متجهة الدخل استثارة لوحدة طبقة الإدخال ويعقب ذلك انتشار أمامي لتلك الاستثارة عبر بقية طبقات الشبكة.

▪ **المرحلة الثانية : الانتشار العكسي Back Propagation :**

وهي مرحلة ضبط أوزان الشبكة . حيث تعد خوارزمية الانتشار العكسي القياسية بمثابة خوارزمية الانحدار التدريجي gradient descent algorithm والتي تسمح لأوزان الشبكة أن تتحرك على الجانب السلبي من تابع الأداء .

▪ **مرحلة الثالثة : توليف أوزان الشبكة:**

إن دور الانتشار العكسي يعود إلى الطريقة التي يتم بها حساب الميل لطبقات الشبكة المتعددة اللاحقة، حيث يتم في أحد مراحل التعليم إعادة انتشار الإشارة من الخرج إلى الدخل بشكل عكسي ويتم خلالها ضبط أوزان الشبكة، ويمكن تمثيل الخوارزمية لتكرار واحد كما يلي :

$$X_{k+1} = X_k - \alpha k * gk$$

حيث :

X_k تشير إلى شعاع الأوزان والإنحيازات الحالية.

αk تدل على معدل التعلم و gk إلى الميل الحالي.

ونظراً لأن الانحدار التدرجي يحاول تقليل مجموع الخطأ التربيعي بين قيم مخرجات الشبكة والقيم المستهدفة المحددة عن طريق حساب الانحدار التدرجي لدالة الخطأ، يجب على كل خطوة من خطوات التكرار أن تكون دالة الخطأ قيد الاستخدام مستمر وقابل للتفاضل⁽¹⁾، وتوجد هناك طريقتان لحساب الانحدار التدرجي وهما كالآتي :

▪ **أولاً : النظام التزايد Incremental mode :**

يتم وفق هذه الطريقة حساب الميل ومن تم تعديل الأوزان بعد كل دخل يعطى للشبكة.

(1) op .cit. Ak, R. (2014). P25

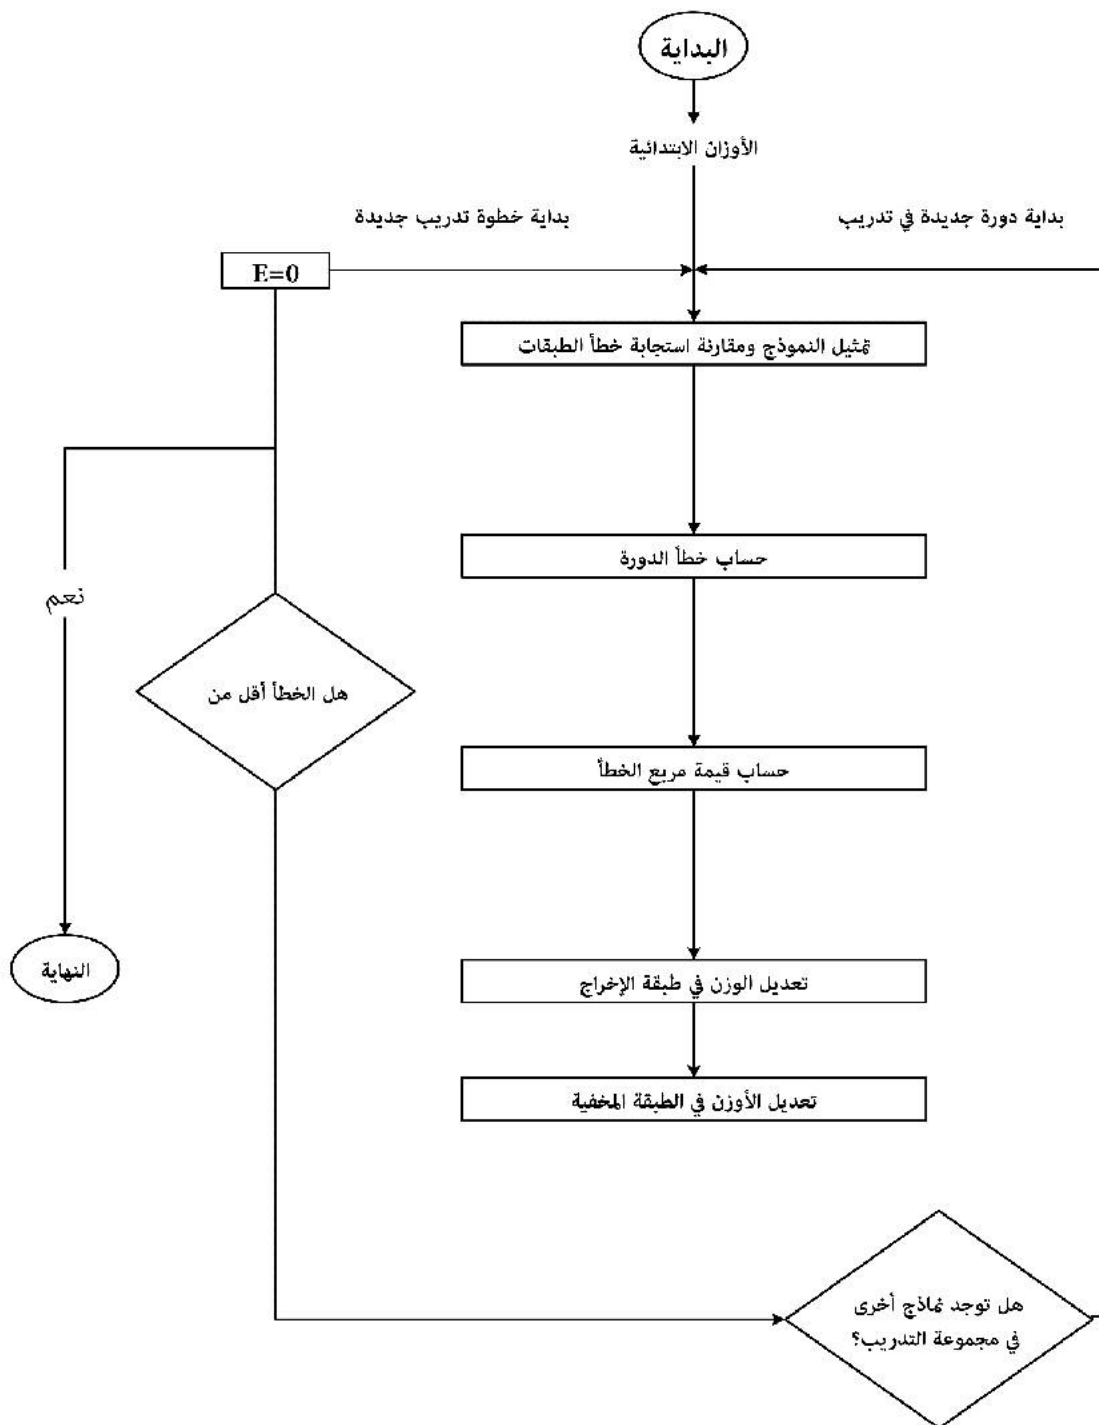
▪ ثانياً: نظام الدفعة الواحدة Batch mode :

وفق هذا النمط تزود الشبكة بكل أشعة الدخل قبل القيام بعملية تحديث الأوزان، وبالتالي يمكن أن نقول: أن الأوزان والانحيازات في هذه الطريقة تعدل بعد تزويد الشبكة بكامل مجموعة التدريب، حيث أن الميول المحسوبة في كل مثال تدريبي تضاف لبعضها البعض لتحديد التغيرات في الأوزان والانحيازات.

○ قاعدة دلتا المعممة العامة (للتعليم) :

إن قاعدة التعليم تعتبر معقدة بعض الشيء إذا ما قورنت بطريقة التعليم البسيطة للشبكة، حيث تعمل على تعليم وتدريب الشبكة الاصطناعية من خلال إجراء الحسابات اللازمة في دالة المدخلات للحصول على قيم المخرجات، ثم تقوم بحساب الخطأ بين هذه المدخلات والمخرجات المعينة المطلوبة، ثم يتم بعد ذلك العمل على تقليل قيم الخطأ من خلال نقله إلى طبقة المدخلات وتعديل الأوزان عندها، وإعادة حساب قيم المخرجات مرة أخرى، ثم إعادة حساب الخطأ بين المخرجات الجديدة والمخرجات المطلوبة، ونقوم بإعادة هذه العملية مرات عدة إلى أن يقل أو يتلاشى الخطأ وتصبح المخرجات المحسوبة مكافئة للمخرجات المطلوبة، وبذلك تتعلم الشبكة، حيث يعد عدد مرات التكرار مقياساً للتعليم.

الشكل 11-3 : خوارزمية التدريب شبكة الانتشار الخلفي



المصدر: عائلة يونس محمد المراد " مقارنة بين الانحدار الكلاسيكي والشبكات العصبية الاصطناعية في التنبؤ بمستويات نتائج بحوث كلية التربية الرياضية " المجلة العراقية للعلوم الإحصائية (21) 2012، ص ص [286-303]، ص 294.

3-12 : إجراءات تصميم الشبكات العصبية الاصطناعية :

لقد أشار بعض الباحثين أن استخدام الشبكات العصبية لا يحتاج إلى المعرفة الكاملة لما يجري بداخلها من أمور فنية وهذا راجع للبرامج الحاسوبية التي تعطي كل ما يحتاج من قدرة على تصميم وتدريب واختبار وتطبيق الشبكة العصبية، ولأجل نجاح تصميم وبناء الشبكة العصبية الاصطناعية هناك بعض الإجراءات التي يجب إتباعها والتي تشمل ما يلي⁽¹⁾:

الإجراء الأول: تقرير ما هو الشيء الذي يراد أن تقوم الشبكة العصبية بالتعرف عليه.

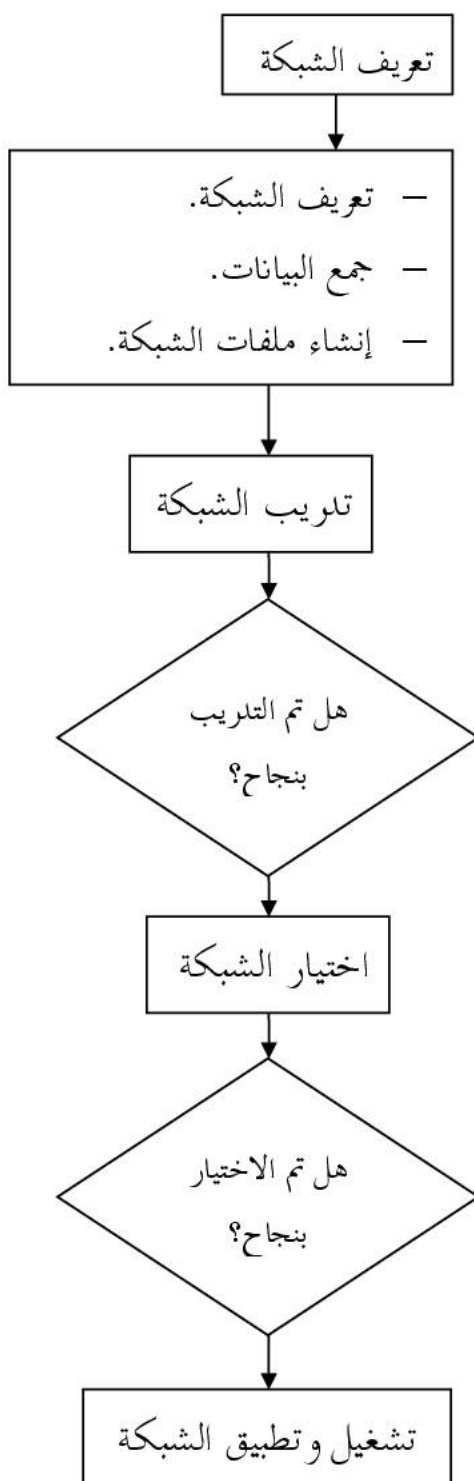
الإجراء الثاني: تحديد المعلومات التي يجب على الشبكة استخدامها والاعتماد عليها في إيجاد المطلوب منها، وهذه المعلومات يجب أن تحتوي عادة على ما هو متوافر ومحدد للمخرج المرغوب حيث أن الشبكات تتعلم عن طريق ربط المدخلات بالمخرجات .

الإجراء الثالث: يتضمن تجميع معلومات كافية (حالات أو أمثلة) يكون المخرج المرغوب معروف مقدما، وكلما تم جمع عدد أكبر من الحقائق كلما أمكن تدريب الشبكة بشكل أفضل أي تحديد العدد المناسب من المدخلات والمخرجات لكي تستخدم في الشبكة .

الإجراء الرابع: تحديد بعض الأمور الفنية المتصلة بعدد الطبقات الخفية المناسبة، نوع دالة التحويل ومداهها وكذا معدل التعلم، وأغلب البرامج هي التي تقوم بالاختيار بشكل عملي ومناسب. الخطوات المتبعة في تصميم الشبكات العصبية الاصطناعية موضحة كما يلي في الشكل (12-3)

(1) احمد حلمي جمعة. استخدام الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في البيانات المالية : دراسة تطبيقية. المؤتمر العلمي السنوي الحادي عشر. دكاء الأعمال واقتصاد المعرفة. جامعة الزيتونة الأردنية، كلية الاقتصاد والعلوم الإدارية. 23-32-نيسان (أبريل 2012). عمان-الأردن.ص 205.

الشكل 12-3 : الخطوات المتبعة في تصميم الشبكات العصبية الاصطناعية



المصدر: ساهد عبد القادر، استخدام البرمجة بالأهداف في تحليل الانحدار المبهم للتنبؤ بأسعار البترول، أطروحة دكتوراه في العلوم الاقتصادية، تخصص إدارة العمليات الإنتاجية، جامعة ابو بكر بلقايد- تلمسان- الجزائر، 2012-2013.

3-13 : التنبؤ باستخدام الشبكات العصبية الاصطناعية :

يعد التنبؤ بالسلاسل الزمنية أحد مجالات البحث المهمة التي اجتذبت الكثير من الاهتمام من طرف الباحثين في العديد من المجالات العملية بما في ذلك لتطوير نماذج تنبؤ تتميز بالفعالية من أجل التحسين المستمر لدقة التنبؤ، وتعد الشبكات العصبية الاصطناعية من الأساليب الحديثة التي عرفت استخداما واسعا في عملية التنبؤ كونها لا تحتاج إلى شروط صارمة ودقيقة لغرض التنبؤ كما أنه يمكن تغيير سلوك البيانات غير الخطية⁽¹⁾.

ويمكن تلخيص عمل شبكة الانتشار العكسي للخطأ في التنبؤ بالخطوات الآتية⁽²⁾:

الخطوة الأولى : اختيار المتغيرات : في هذه الخطوة يتم اختيار المشاهدات التي تمثل المشكلة المراد التنبؤ بقيمتها بصورة جيدة.

الخطوة الثانية: معالجة البيانات: يتم في هذه الخطوة إجراء بعض العمليات على البيانات المستخدمة لتحديد الاتجاه العام، التركيز على العلاقات بين المشاهدات، إيجاد توزيع البيانات .

الخطوة الثالثة : تقسيم البيانات إلى مجاميع :

- 1- مجموعة التدريب : مجموعة تعلم وتحديد نموذج للبيانات.
- 2- مجموعة الاختبار: والتي يمكن عن طريقها تقرير مهارة الشبكة الافتراضية وإمكانية استخدامها بصورة عامة.

3- مجموعة الشرعية : وهي مجموعة لإجراء اختبار نهائي لأداء الشبكة.

الخطوة الرابعة : نموذج الشبكة العصبية: عند تحديد نموذج الشبكة العصبية يجب اختبار الآتي:

- 1- عدد العقد العصبية للإدخال والذي يساوي عدد المتغيرات المستقلة.
- 2- عدد الطبقات المخفية والذي يعتمد على قيمة الخطأ المستخدم في الشبكة.
- 3- عدد العقد العصبية المخفية والذي يحدد عن طريق التجربة.

(1) بختاوي فاطمة الزهراء، مرجع سابق، ص 35.

(2) حذيفة حازم طه، عمار أحمد عثمان "استخدام طريقة المتوسطات المتحركة لتحسين عمل شبكة المدرك في التنبؤ بالحالة الجوية لمدينة الموصل" المجلة العراقية للعلوم الإحصائية(26) 2014 ص ص / 161-137 / ص 146.

4- عصبون الإخراج والذي عادة يساوي واحد.

الخطوة الخامسة: دالة التحويل : هي تلك الصيغة الرياضية المتبعة لتحديد المخرجات التي تمنع المخرجات عادة من الوصول إلى قيمة عالية جدا وعادة تستخدم هذه الصيغة إحدى الدوال الآتية :

1- دالة الخطية.

2- دالة الإشارة .

3- دالة Sigmoid .

الخطوة السادسة : معيار التقييم: إن معيار المستخدم هذه الخطوة تكون الغاية منه تقييم الخطأ في الشبكة وهو مجموع مربعات الأخطاء (MSE).

الخطوة السابعة: تدريب الشبكة العصبية وتضم هذه الخطوة:

- **تعليم النموذج:** إيجاد مجموعة الأوزان بين العقد العصبية والتي تجعل الخطأ أقل ما يمكن.

- **الخوارزمية:** تستخدم خوارزمية تدريب الانحدار لتقليل الميل.

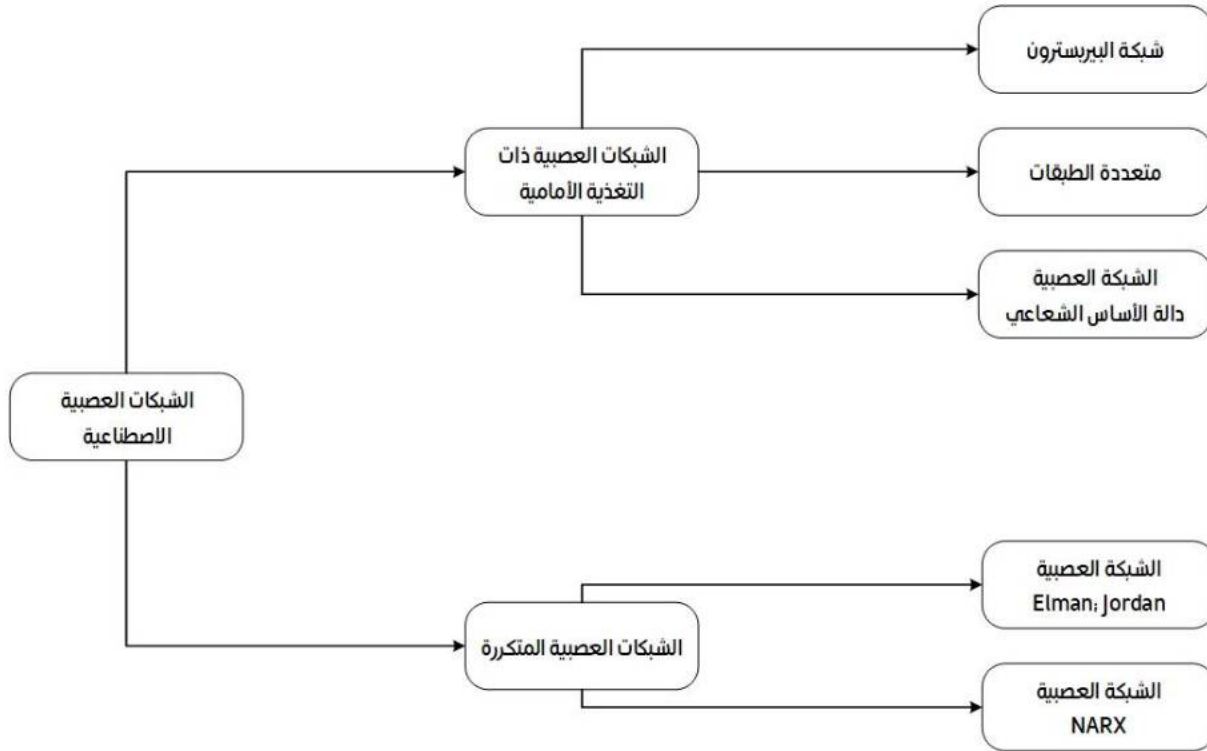
الخطوة الثامنة: التنفيذ: تعتبر هذه الخطوة من أهم الخطوات حيث تختبر الشبكة من حيث قدرة التكيف مع حالة التغير في الدورة وإمكانية إعادة التدريب والوصول إلى أقل مربع خطأ ممكن عند تغير البيانات.

2-13 : نماذج الذكاء الاصطناعي :

تعتبر طرق الذكاء الاصطناعي طرق حسابية تم تصميمها خصيصا للتعامل مع المشكلات التي لا تستطيع الطرق القياسية حلها بفعالية، حيث تعتبر أنظمة ذكية بسبب قدرتهم على التكيف مع الأنظمة الديناميكية المعقدة.

الفئات الرئيسية للنماذج الذكاء الاصطناعي هي الشبكات العصبية الاصطناعية والأنظمة الضبابية وآلات المتجه الداعم.

ويمكن تصنيف الشبكات العصبية الاصطناعية إلى صنفين وهما الشبكات العصبية ذات التغذية الأمامية والشبكات العصبية المتكررة، كما هو مبين في الشكل الموالي:
الشكل 3-13 : تصنيف الشبكات العصبية الاصطناعية الأكثر استخداما



Source : Taş, B. (2018). *Electricity price forecasting using hybrid time series models* (Master's thesis, Middle East Technical University).p15.

3-14: بعض النماذج المستخدمة في التنبؤ :

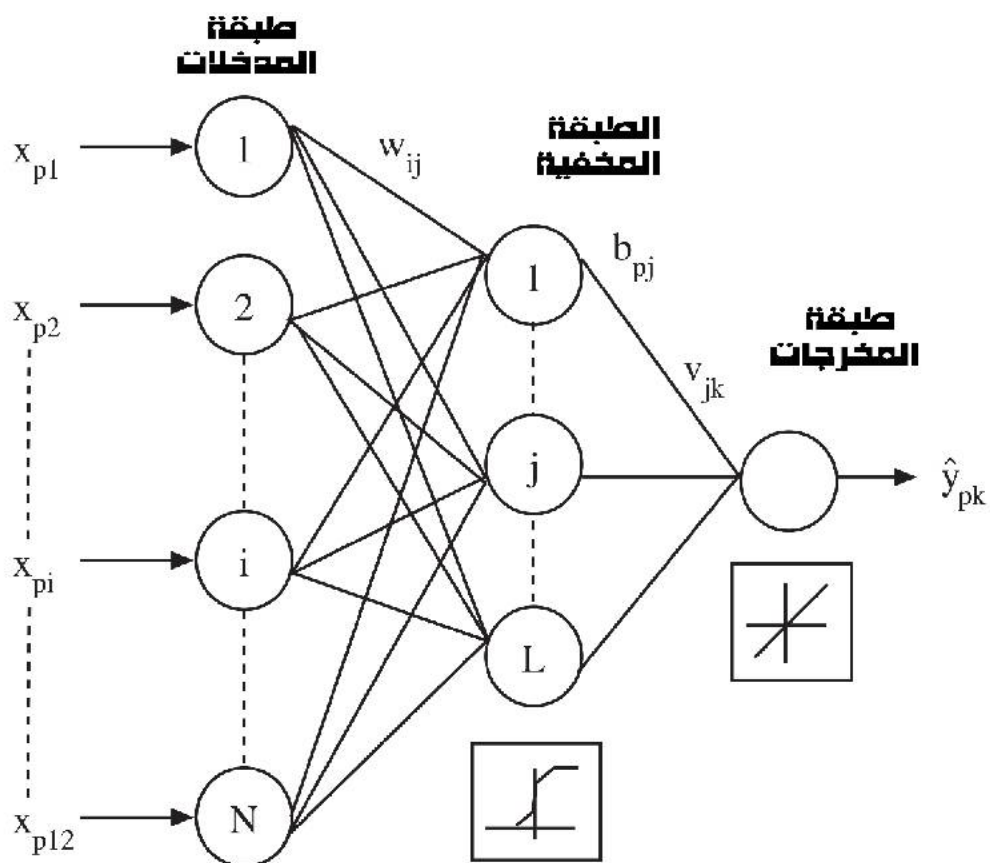
❖ شبكات بيرسترون متعددة الطبقات (MLPNN) :

تعد من أكثر الشبكات العصبية استخداما في التنبؤ بالسلاسل الزمنية حيث تقوم فكرتها على استخدام القيم السابقة كمدخلات ويتم جمع الاوزان في الطبقة الخفية بالنسبة للمدخلات ويتم استخدام دالة التحويل الغير خطية (السيغمويد)، وطبقة المخرجات تستقبل مخرجات الطبقة الخفية وتطبق عليها دالة التحويل الخطية حيث يتم التنبؤ بالقيم المستقبلية للسلسلة⁽¹⁾.

(1) عتروس سهيلة، استخدام منهجية بوكس جنكنز والشبكات العصبية الاصطناعية للتنبؤ باستهلاك الطاقة الكهربائية بمؤسسة سونلغاز -دراسة حالة : ولاية بسكرة- رسالة لنيل شهادة دكتوراه علوم في علوم التسيير، تخصص الاساليب الكمية في التسيير،كلية العلوم الاقتصادية والتجارية وعلوم التسيير،جامعة محمد خيضر بسكرة،الجزائر، 2017-2018،ص 170-180.

- يتصف الشكل القياسي لمعمارية شبكة (MLP) الأكثر استخداما في التنبؤ كالآتي (1):
- شبكة ذو بنية معمارية كاملة الترابطات .
- تحيزات وترابطات مختصرة مباشرة من المدخلات إلى وحدات المخرجات.
- طبقة خفية واحدة مع دالة تحفيز لوجستية وذلك من أجل تحسين عدم الخطية في الوحدات الخفية.
- تستخدم طبقة المخرجات مع وحداتها دالة خطية من أجل وزن مدي المخرجات وغالبا ما يكون المدى محصور بين المجال [0، 1].

الشكل 3-14 : يبين معمارية شبكات اليرسبترون متعدد الطبقات (MLPNN)



Source : Moreno, J. J. M. (2011). Artificial neural networks applied to forecasting time series. *Psicothema*, 23(2), 322-329.p326.

(1) Sahera Hussein Zain Al-Thalabi, & Kholoud Musa Omra(2016) . Determine the best model to predict the consumption of electric energy in the southern region. *journal of Economics And Administrative Sciences*, 22(90).p 17.

النموذج العام لشبكة (MLPN) الذي يستخدم في التنبؤ يعطي بالصيغة التالية :

$$\hat{y}_t = \theta_0 + \sum_{j=1}^n \theta_j f_j \left(\sum_{i=1}^m \theta_{ij} X(k-1) \right) + \theta_{j0}$$

حيث :

m و n : تمثلان على التوالي عدد وحدات الطبقة الخفية وعدد وحدات المدخلات .

θ_j : تمثل الأوزان بين الطبقة الخفية وطبقة المخرجات .

θ_{ij} : تشير إلى الأوزان بين المدخلات والطبقة الخفية.

: تمثل دالة التحويل سيغمويد في الوحدات الخفية.

3-15: مميزات وحدود استخدام الشبكات العصبية الاصطناعية :

في هذا العصر التكنولوجي كل شيء له مزايا وبعض العيوب وبعبارة أخرى هناك مزايا وحدود لكل نظام مما يجعل تقنية الشبكات العصبية قوية وضعيفة في بعض النقاط⁽¹⁾:

مزايا الشبكات العصبية الاصطناعية :

1. التعلم التكيفي: القدرة على تعلم كيفية القيام بالمهام بناءً على البيانات المقدمة للتدريب أو الخبرة الأولية.
2. التنظيم الذاتي: يمكن لشبكة ANN إنشاء منظمتها الخاصة أو تمثيل المعلومات التي تتلقاها أثناء وقت التعلم.
3. التعرف على الأنماط: تعتبر تقنية قوية لتسخير المعلومات في البيانات وتعميمها، كما تتعلم الشبكات العصبية التعرف على الأنماط الموجودة في مجموعة البيانات.
4. تقوم الشبكات العصبية بتعليم نفسها الأنماط الموجودة في البيانات من خلال التعلم بدلاً من البرمجة .

(1) Op.cit. Kohli, S., Miglani, S., & Rapariya, R. (2014).p 749.

5. الشبكات العصبية مرنة في بيئة متغيرة. رغم أن الشبكات العصبية قد تستغرق بعض الوقت لتتعلم تغييرا جذريا مفاجئا، إلا أنها ممتازة في التكيف مع المعلومات المتغيرة باستمرار.

6. يمكن للشبكات العصبية بناء نماذج وهذا عندما تفشل الأساليب التقليدية، كون أن الشبكات العصبية يمكنها التعامل مع تفاعلات معقدة للغاية، فيمكنها بسهولة نمذجة البيانات التي يصعب للغاية نمذجتها باستخدام الأساليب التقليدية مثل الإحصائيات الاستدلالية أو منطق البرمجة.

7. يعد أداء الشبكات العصبية جيد على الأقل مثل النمذجة الإحصائية الكلاسيكية وأفضل في معظم المشاكل، كما أنها تبني نماذج أكثر انعكاسًا لهيكل البيانات في وقت أقل وكذا بشكل ملحوظ.

❖ حدود الشبكات العصبية الاصطناعية :

1- الشبكات العصبية الاصطناعية ليست بأداة لحل المشكلات ذات الأغراض العامة للحياة اليومية.

2- لا تتوفر منهجية منظمة متاحة في الشبكات العصبية الاصطناعية.

3- لا يوجد نموذج موحد واحد لتطوير الشبكات العصبية الاصطناعية.

4- قد تكون جودة إخراج الشبكات العصبية الاصطناعية غير متوقعة.

5- لا تصف العديد من أنظمة الشبكات العصبية الاصطناعية طريقة كيفية حل المشكلات.

6- طبيعة الصندوق الأسود (boite noire) حيث تقوم الشبكة بنفسها اكتشاف العلاقة بين

المتغيرات ولا تظهر كيفية استخراجها أو العناصر التي تم استخدامها من أجل تفسير تلك المتغيرات ولهذا يبقى من الصعب على مستعملها أن يكتشف تلك العلاقات كونها تبقى داخلية .

7- عبء حسابي أكبر.

8- الانطباع أكثر من المناسب.

9- الطبيعة التجريبية لتطوير النموذج.

خلاصة :

إن عملية التنبؤ بالقيم المستقبلية تعتبر من الأهداف الرئيسة للعلوم الإحصائية، حيث يكتسي التنبؤ أهمية كبيرة في عملية التخطيط واتخاذ القرارات في جميع المجالات وخاصة المجال الاقتصادي الذي يعرف تغيرات كثيرة في بياناته، ولذا عن طريق التنبؤ نستطيع التعرف على الظروف والحالات المحيطة بالمشكلة وهذا قبل اتخاذ القرار.

إذ أولى الباحثون اهتماما بالغا بتطوير الأساليب المختلفة لغرض التنبؤ ويعد التنبؤ باستخدام الشبكات العصبية الاصطناعية من أحدث أساليب التنبؤ التي لازالت البحوث والدراسات مستمرة من أجل التعرف على أفضلية هذه الأساليب، حيث تطبيقها في عملية التنبؤ لا يتطلب افتراضات عن طبيعة السلسلة كونها خطية أو غير خطية أو مستقرة أي تطبيقها في عملية التنبؤ لا يأخذ بعين الاعتبار فرضيات معينة بطبيعة المتغيرات وعلاقتها مع بعضها البعض، فهي تعمل على تمثيل أو محاكاة عقل الإنسان من خلال شبكة من المعطيات الرقمية والتي يتم معالجتها بواسطة مجموعة من الحسابات أو نماذج الرياضية التي تعتمد أسلوب المعالجة المتوازية للبيانات.

الفصل الرابع:

الشبكات العصبية ذات دالة الأساس
التعاملي والنماذج الهجينة

1-4 : الشبكة العصبية ذات دالة الأساس الشعاعي : Radial Basis Function Network**تمهيد:**

تعتبر دوال الأساس الشعاعي للشبكات العصبية ببساطة نوع من الدوال، من حيث المبدأ يمكن استخدامها في أي نوع من النماذج الخطية أو غير الخطية وأي نوع من الشبكات سواء كانت وحيدة الطبقة أو متعددة الطبقات، ولقد تم تقديم دوال الأساس الشعاعي كنوع من الشبكة العصبية الاصطناعية لأول مرة من طرف Powell لحل مشكلة الاستيفاء في المساحات المتعددة الأبعاد، التي تتطلب العديد من المراكز مثل: نقاط البيانات، وبعد ذلك قام كل من Broomhead و Lowe في 1988 بتطوير شبكة دالة الأساس الشعاعي (RBFNN) من خلال إزالة التقييد (الصارم أو الدقيق)، واستخدموا مراكز أقل من عينات البيانات، مما يسمح لشبكة العصبية ذات الأساس الشعاعي (RBFNN) لتطبيقها في العديد من العمليات التي يكون فيها عدد العينات مرتفعاً جداً .

عرفت شبكات (RBFNN) نجاحاً كبيراً وهذا من خلال تطبيقها في العديد من المجالات المتنوعة مثل دالة تقريب، التنبؤ بالسلاسل الزمنية، مراقبة النظام، التعرف على الأنماط⁽¹⁾ . تتميز شبكة دالة الأساس الشعاعي بخصائص هجينة مقارنة مع الشبكات الأخرى، بالإضافة إلى ذلك قدرتها على التكيف والتعديل، والتقريب الوظيفي، التصنيف، سرعة التعلم، القدرة التجريبية⁽²⁾، كما تتميز الشبكة العصبية ذات الأساس الشعاعي (RBFNN) بهيكل بسيط والتقارب الأسرع، وكذلك معلمات أقل وأكثر كفاءة حسابية الخ⁽³⁾ .

1-1-4 : دوال الأساس :

قبل تطرقنا إلى أنواع دوال الأساس الشعاعي الأكثر استخداماً، سوف نقوم باعطاء مفهوم للدوال الشعاعية والغرض من وراء استخدامها في الشبكات العصبية.

-
- (1) Novakovic, J. D., & Veljovic, A. (2017). Solving medical classification problems with RBF neural network and filter methods. *International Journal of Reasoning-based Intelligent Systems*, 9(2), 80-89.p8
- (2) Kagoda, P. A., Ndiritu, J., Ntuli, C., & Mwaka, B. (2010). Application of radial basis function neural networks to short-term streamflow forecasting. *Physics and Chemistry of the Earth, Parts A/B/C*, 35(13-14), 571-581.p572
- (3) Yang, L., & Li, B. (2016). The combination forecasting model of auto sales based on seasonal index and RBF neural network. *International Journal of Database Theory and Application*, 9(1), 67-76.p71

تعد دوال الأساس الشعاعي نوعاً خاصاً من الدوال؛ وتتمثل ميزتها الخاصة في أن استجابتها تتناقص أو تتزايد بوتيرة واحدة مع المسافة من النقطة المركزية، حيث يعد المركز ومقياس المسافة والشكل المحدد لدالة الشعاعي معاملات للنموذج، وكلها ثابتة إذا كانت خطية⁽¹⁾.

4-1-2: أنواع دوال الأساس الشعاعي الأكثر استخداماً:

كما نعلم أن كل وحدة مخفية تنفذ دالة الأساس الشعاعي، حيث هذه الدوال أو التي يشار إليها باسم دوال النواة، تعتبر دوال موجبة تماماً ومتناظرة شعاعياً. ومن بين دوال الأساس الشعاعي الأكثر شيوعاً نذكر⁽²⁾:

Gaussian Functions:

$$\begin{aligned} \phi(x) &= \exp\left(-\frac{x^2}{2\sigma^2}\right) && \text{width parameter } \sigma > 0 \\ &= \exp\left(-\frac{x^2}{2\sigma^2}\right) && \text{width parameter } \sigma > 0 \end{aligned}$$

Multi-Quadric Functions:

$$\phi(x) = \sqrt{x^2 + \sigma^2} \quad \text{parameter } \sigma > 0$$

Generalized Multi-Quadric Functions⁽³⁾:

$$\phi(r) = \sqrt{x^2 + \sigma^2}^\beta \quad \text{parameter } \sigma > 0, 1 > \beta > 0$$

Inverse Multi-Quadric Functions:

$$\phi(x) = \sqrt{x^2 + \sigma^2}^{-\frac{1}{2}} \quad \text{parameter } \sigma > 0$$

Generalized Inverse Multi-Quadric Functions :

$$\phi(x) = \sqrt{x^2 + \sigma^2}^{-\alpha} \quad \text{parameter } \sigma > 0, \alpha > 0$$

Thin Plate Spline Function:

$$\phi(r) = r^2 \ln(r)$$

Cubic Function:

$$\phi(x) = x^3$$

Linear Function:

$$\phi(x) = x$$

(1) Orr, M. J. (1996). Introduction to radial basis function networks.p9.

(2) Harpham, C., & Dawson, C. W. (2006). The effect of different basis functions on a radial basis function network for time series prediction: A comparative study. Neurocomputing, 69(16-18), 2161-2170.p2162-2163.

(3) Engelbrecht, A. P. (2007). Computational intelligence: an introduction. John Wiley & Sons.p 75-76.

4-1-3: الشبكة العصبية دالة الأساس الشعاعي :

(1) مقارنة نظرية بين كل من نماذج $MLPNN$ و $RBFNN$:

تعتبر الشبكة العصبية دالة الأساس الشعاعي والتي يرمز لها باختصار ($RBFNN$) كبديل أو حالة خاصة لنموذج الشبكات العصبية متعددة الطبقات بيرسبترون التي لا تزال تعرف استخداما واسعا⁽¹⁾، ورغم هذا فتعد الشبكة العصبية دالة الأساس الشعاعي كمنافس لها، حيث أكدت العديد من الدراسات مثل دراسة⁽²⁾. التي هدفت إلى المقارنة بين النماذج الرئيسة للشبكات العصبية الاصطناعية ANN التي أثبتت فائدتها في التنبؤ بالسلاسل الزمنية، وهو نموذج $Perceptron$ متعدد الطبقات $MLPNN$ ودالة الأساس الشعاعي $RBFNN$ وشبكة الانحدار العصبي المعمم $GRNN$ والشبكة العصبية المتكررة RNN . أظهرت النتائج أن نموذج $RBFNN$ يعطي الأداء الأفضل مقارنة مع النماذج الأخرى ولهذا تعتبر الشبكة العصبية RBF كأداة بديلة تستخدم للتعلم في الشبكات العصبية، والجدول (4-1) يبيّن ميزات النموذجين .

الجدول 4-1: ميزات الشبكة العصبية $RBF&MLPNN$

نوع الشبكة	ميزات الشبكة
بيرسبترون (Perceptron)	<ul style="list-style-type: none"> - تتكون من طبقة مخفية واحدة على الأقل أو أكثر - يعتمد بناءها على دالة السيبي - يتم تطبيقها كدالة في الشبكات العصبية لزيد من 90 % - مشهور في أبحاث الشبكة - تقدم تغذية متعدد الطبقات إلى الأمام - التوصيلات الموزونة بين الطبقات - خوارزمية التعلم الأكثر استخداما هي : Backpropagation
دالة الأساس الشعاعي (radial basis function)	<ul style="list-style-type: none"> - لديها طبقة مخفية واحدة فقط - بناء على دالة Gaussian - يتطلب خلايا عصبية مخفية - تطبيقات في التنبؤ والتحكم ودالة تقرب

(1) Oludolapo, O. A., Jimoh, A. A., & Kholopane, P. A. (2012). Comparing performance of MLP and RBF neural network models for predicting South Africa's energy consumption. *Journal of Energy in Southern Africa*, 23(3), 40-46.p39.

(2) Moreno, J. J. M. (2011). Artificial neural networks applied to forecasting time series. *Psicothema*, 23(2), 322-329.

<ul style="list-style-type: none"> - تغذية متعددة الطبقات للأمام - لا توجد اتصالات مرجحة بين طبقة الإدخال والطبقة المخفية - لديها عملية تدريب أسرع بكثير وبنية أبسط مقارنة بالشبكة العصبية متعددة الطبقات (Perceptron) (1) 	
---	--

Source : Niaki, A. (2017). Forecasting Automobile Demand Via Artificial Neural Networks & Neuro-Fuzzy Systems. West Virginia University.p37.

(2) تعريف الشبكة العصبية دالة الأساس الشعاعي :

تعد الشبكة العصبية دالة الأساس الشعاعي نوعاً من الشبكة العصبية ذات التغذية الأمامية (FFNN) (2)، والتي تعتمد على نظرية تقريب الدالة، أو التعلم باستخدام تقنية التدريب الخاضع للإشراف (المعلم) أو الغير الخاضع للإشراف (بدون معلم) (3)، تحتوي الشبكات العصبية لدالة الأساس الشعاعي على ثلاث طبقات: **طبقة إدخال، وطبقة مخفية واحدة؛** حيث بالضرورة تكون دالة التنشيط في الطبقة الخفية دالة أساس شعاعي، كما تقوم كل عقدة في الطبقة المخفية بتقييم دالة أساس شعاعي على المدخلات الواردة وأخيراً **طبقة الإخراج** والتي يكون فيها الإخراج عبارة عن مجموع مرجح من طبقة المخفية ويكون الناتج الإخراج خطي.

(3) هيكل الشبكة العصبية دالة الأساس الشعاعي :

تتكون بنية *RBFNN* من طبقة الإدخال التي تتلقى إشارات الإدخال التي تقوم بنشرها من خلال شبكة الاتصال، يكون التحويل من مساحة الإدخال إلى مساحة الوحدة المخفية غير خطي بينما يكون التحويل من مساحة الوحدة المخفية إلى مساحة الإخراج خطياً.

وباختصار فإن عملية التعيين بين طبقة الإدخال والطبقة المخفية يمكن اعتبارها بمثابة تحويل غير خطي، بينما يمكن اعتبار عملية التعيين بين الطبقة المخفية وطبقة المخرجات على أنها تحويل

(1) Kayri, M. (2015). An intelligent approach to educational data: performance comparison of the multilayer perceptron and the radial basis function artificial neural networks. *Educational Sciences: Theory & Practice*, 15(5).p1249.

(2) Heddami, S. (2016). Simultaneous modelling and forecasting of hourly dissolved oxygen concentration (DO) using radial basis function neural network (RBFNN) based approach: a case study from the Klamath River, Oregon, USA. *Modeling Earth Systems and Environment*, 2(3), 135.p5

(3) Ladhani, I., Houichi, L., Djemili, L., Heddami, S., & Belouz, K. (2012). Modeling daily reference evapotranspiration (ET₀) in the north of Algeria using generalized regression neural networks (GRNN) and radial basis function neural networks (RBFNN): a comparative study. *Meteorology and Atmospheric Physics*, 118(3-4), 163-178.p169

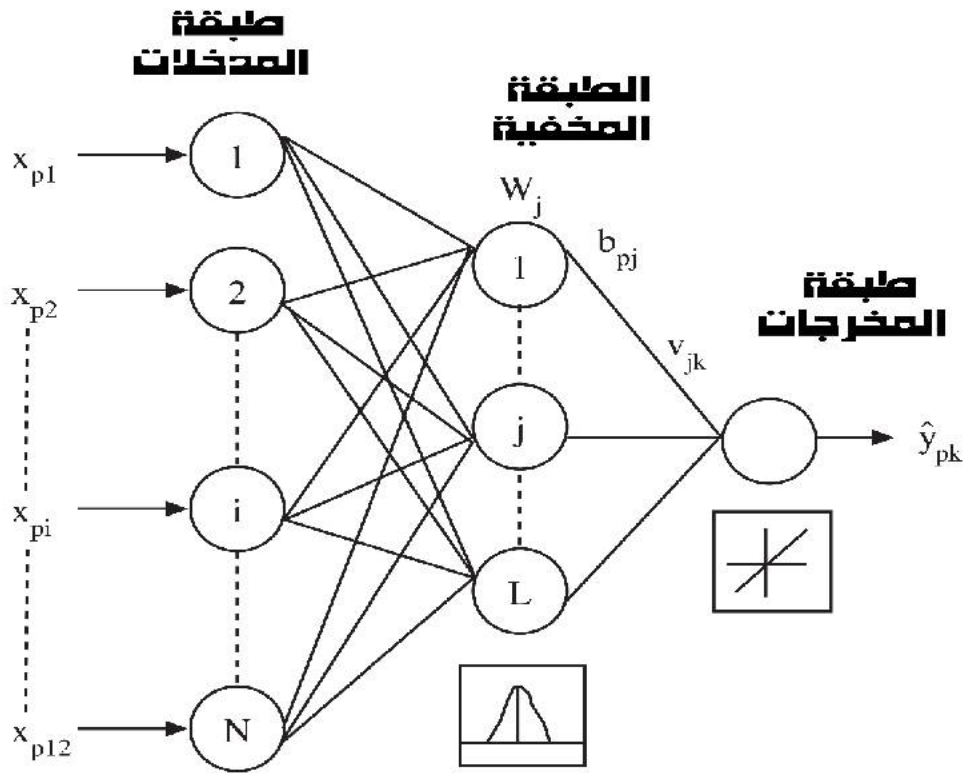
خطي⁽¹⁾، وهكذا ينتج $RBNN$ مجموعة خطية من دوال الأساس غير الخطي حيث يتطابق أبعاد المدخلات مع أبعاد كل مركز شعاعي. تعرف كل وحدة أو عقدة مخفية باسم المركز الشعاعي ويمثل كل مركز واحداً أو بعضاً من أنماط الإدخال، تستخدم الوحدات المخفية في شبكات $RBNN$ دالة $Gaussian$ أو دالة نواة أساسية أخرى، حيث تعمل كل وحدة مخفية كمعالج مضبوط محلياً يحسب النتيجة للمطابقة بين متجه الإدخال ومراكز الاتصال الخاصة به⁽²⁾.

تستخدم الأوزان التي تربط الوحدات الأساسية بالمخرجات من أجل أخذ مجموعات خطية من الوحدات المخفية لإنتاج التصنيف النهائي أو الإخراج، كما يجب أن يكون الناتج مساوياً للإخراج المطلوب بشكل مثالي ويتم استخدام الفرق بين الناتج الذي تم الحصول عليه والمخرج المطلوب لتعديل أو تدريب معلمات الشبكة، بحيث يتم تقليل الخطأ. تتكون معلمات الشبكة من أوزان الطبقة المخفية إلى المخرجات والمعلمات المرتبطة بوظائف الطبقة المخفية التي تمثلها كل عقدة طبقة مخفية. على غرار جميع أنواع الشبكات العصبية الأخرى، ترتبط شبكات $RBNN$ بمجموعة من المعلمات التي تحتاج إلى التعديل من أجل تعليم الشبكة العصبية التعيين الصحيح بين المدخلات والمخرجات، أي أن مجموعة معلمات الشبكة العصبية تعتمد بشكل مباشر على بنية الشبكة العصبية.

(1) Havaluddin, H., & Tahyudin, I. (2015). Time series prediction using radial basis function neural network.p766.

(2)Zheng, F., & Zhong, S. (2011). Time series forecasting using a hybrid RBF neural network and AR model based on binomial smoothing. World Academy of Science, Engineering and Technology, 75, 1471-1475.p1465

الشكل 1-4: يبين هيكل الشبكة العصبية دالة الأساس الشعاعي (RBFNN)

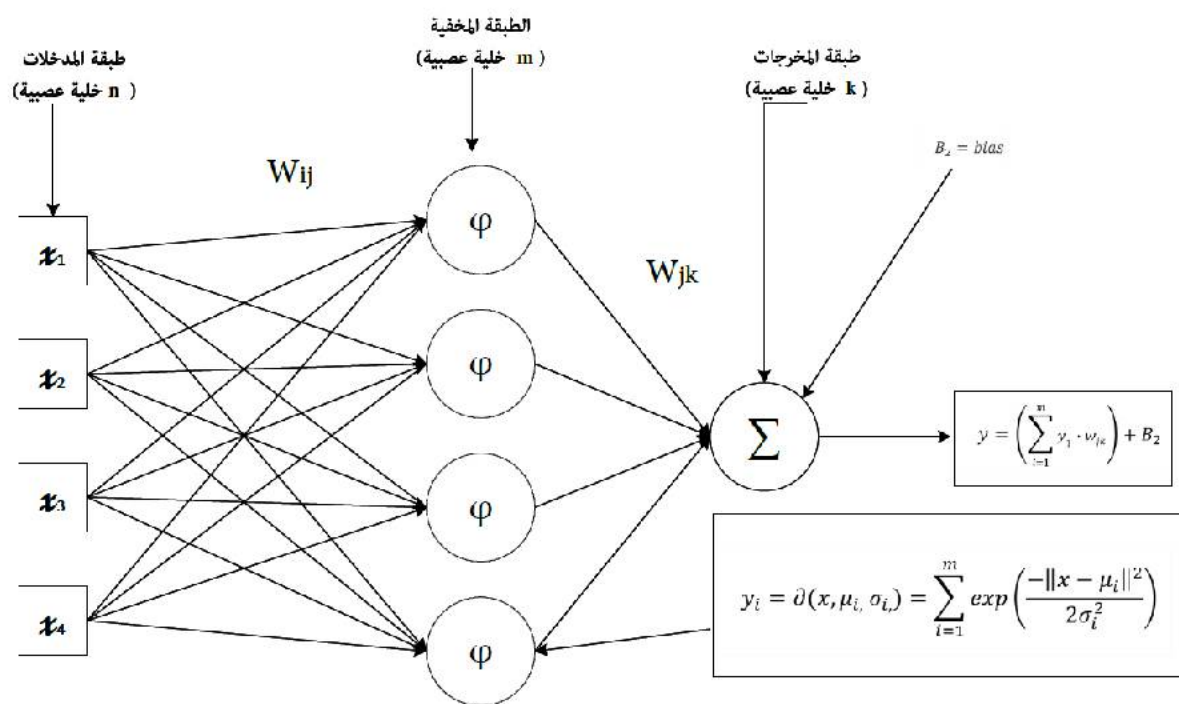


Source : Moreno, J. J. M. (2011). Artificial neural networks applied to forecasting time series. Psicothema, 23(2), 322-329.p326.

4) العملية الرياضية للشبكة العصبية دالة الأساس الشعاعي :

الشكل رقم (2-4) يوضح العملية الرياضية للبنية الأساسية لشبكة العصبية دالة الأساس الشعاعي من خلال تدفق البيانات، بدءاً من طبقة الإدخال مروراً عبر الطبقة المخفية ووصولاً إلى طبقة الإخراج، حيث تتميز طبقة الإدخال والإخراج بدوال التنشيط الخطي، أما الخلايا العصبية في الطبقة الخفية لها دالة تنشيط غير خطية، والشكل التالي يبين هذه العملية .

الشكل 2-4: العملية الرياضية للشبكة العصبية ذات دالة الأساس الشعاعي (RBFNN)



Source : Heddam, S. (2016). Simultaneous modelling and forecasting of hourly dissolved oxygen concentration (DO) using radial basis function neural network (RBFNN) based approach: a case study from the Klamath River, Oregon, USA. Modeling Earth Systems and Environment, 2(3), 1-18.p5.

من خلال الشكل اعلاه نلاحظ أن شبكة هي شبكة ذات تغذية امامية ولها ثلاثة طبقات : طبقة الادخال والطبقة المخفية وطبقة الإخراج، كما انها تستخدم دالة التنشيط الخطي للخلايا العصبية الناتجة ودالة Gaussian غير الخطية للخلايا العصبية المخفية. والسبب وراء اختيار دالة Gaussian لتكون غالبا هي دالة الأساس الشعاعي كونها تستطيع أن تحدث تقاربا في أي دالة ثابتة وهذا بدون الاعتماد على نموذج النظام⁽¹⁾.

(1) جمال صلاح الدين سيد مجيد، & إسراء زهير مجيد قبع. (2013). تخمين الجهد البرمجي باستخدام نموذج الـ COCOMO التقليدي والشبكات العصبية. مجلة الراقدن لعلوم الحاسوب والرياضيات، 10(1)، 351-364. ص 357-358

من الوجهة الرياضية يمكن تقديم بنية الشبكة العصبية دالة الأساس الشعاعي (RBFN) على النحو التالي(1):

$$\phi_i(x) = \|x - \mu_i\| \quad i = 1, 2, \dots, N$$

حيث :

$\phi(x)$: هو ناتج الخلايا العصبية المخفية j_{th} .

$\| \cdot \|$: تشير إلى المسافة الإقليدية .

x : هي متجه ادخال البعد p .

μ_i : هي مركز (متجه) للخلية العصبية المخفية i_{th} .

ϕ : هي دالة التنشيط .

دالة التنشيط Gaussian يمكن كتابتها على النحو التالي :

$$\phi_i(x) = \exp\left(-\frac{\|x - \mu_i\|^2}{2\sigma_i^2}\right) \quad i = 1, 2, N,$$

حيث :

σ_i : هو عرض أو انتشار الخلايا العصبية المخفية .

يتم حساب ناتج نموذج RBFNN على النحو التالي :

$$\hat{y}_t = \sum_{j=1}^N w_{ij} \phi_j(x) + B_2$$

حيث :

w_{ij} : تمثل الوصلات الموزونة بين الخلايا العصبية دالة الأساس الشعاعي والخلايا العصبية الناتجة .

N : هي عدد الخلايا في الطبقة المخفية .

B_2 : هو المصطلح الثابت ويمثل التحيز .

(1) Op.cit.Heddam, S. (2016). P 5.

أما بالنسبة لناتج الشبكة فهو عبارة عن تجميع خطي لدوال الأساسية المحسوبة بواسطة عقد الطبقة المخفية.

(5) عملية التعلم في الشبكة العصبية دالة الأساس الشعاعي :

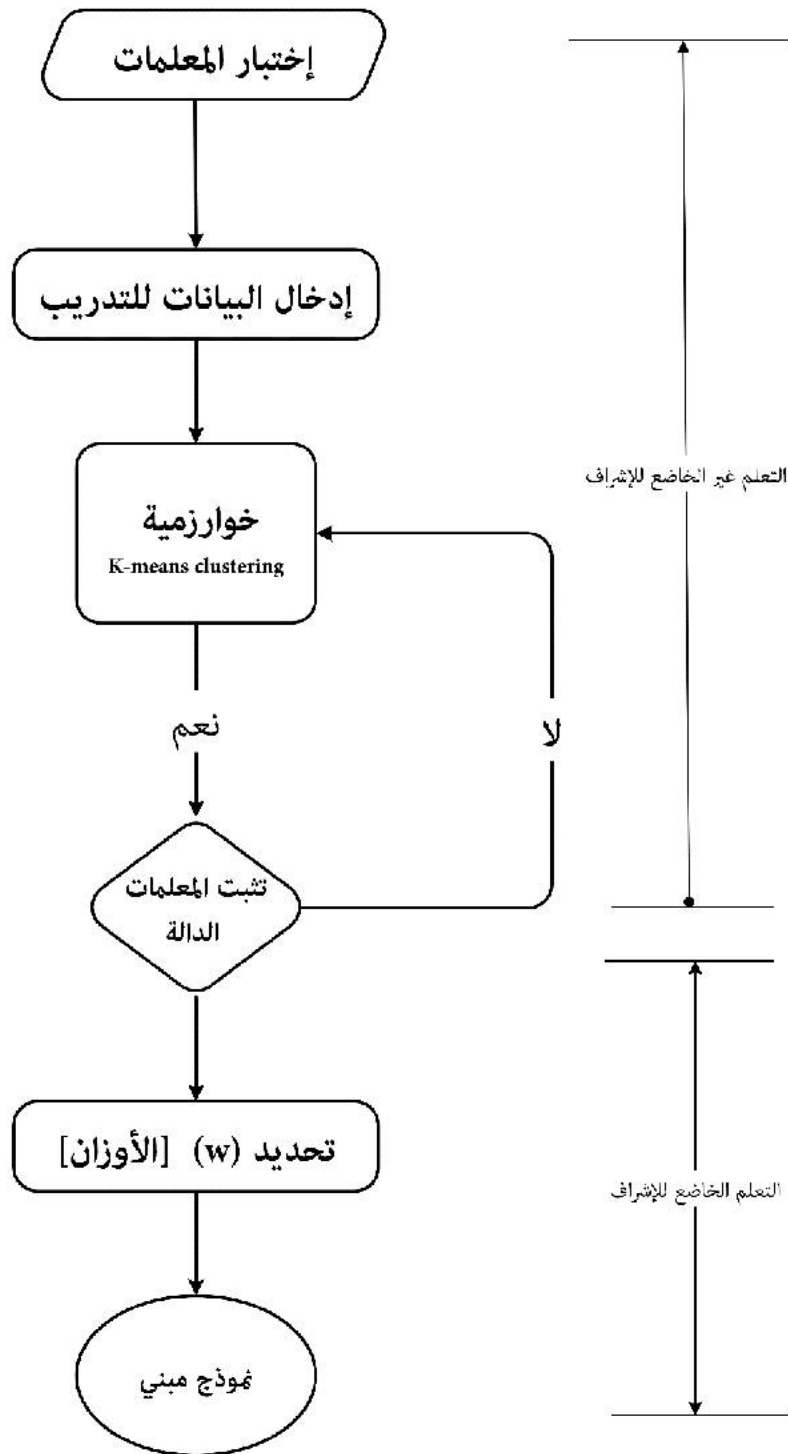
تنقسم عملية التعلم في الشبكة العصبية دالة الأساس الشعاعي *RBFFNN* إلى مرحلتين⁽¹⁾ :

في المرحلة الأولى يتم استخدام عملية التعلم غير الخاضعة للإشراف بين طبقة الإدخال والطبقة المخفية، ويتم استخدام في هذه المرحلة مثل خوارزمية *K-means clustering*، وخوارزمية المربعات الصغرى المتعامدة (*OLS*)، وما إلى ذلك لحلّ مركز وتباين دالة غاوس.

في المرحلة الثانية يتم استخدام عملية التعلم الخاضعة للإشراف بين الطبقة المخفية وطبقة الإخراج، ويعتمد فيها على نسبة الخطأ، ومن أجل ذلك تستخدم في هذه المرحلة مثل خوارزمية النزول التدريجي، وخوارزمية المربع الأقل من أجل ضبط الوزن بين الطبقة المخفية وطبقة الإخراج. والشكل التالي يبيّن مخطط عام لخوارزمية بناء النموذج باستخدام الشبكة العصبية دالة الأساس الشعاعي *RBFFNN*.

(1)Wongsathan, R., & Jaroenwiriya, W. (2016). A hybrid ARIMA and RBF neural network model for tourist quantity forecasting: a case study for Chiangmai province. *Asia-Pacific Journal of Science and Technology*, 21(1), 37-54.p 41.

الشكل 3-4: يبين عملية التعلم في الشبكة العصبية ذات دالة الأساس الشعاعي (RBFNN)



Source : Chang, F. J., & Chen, Y. C. (2003). Estuary water-stage forecasting by using radial basis function neural network. Journal of Hydrology, 270(1-2), 158-166.p 160.

نلاحظ من خلال هذا الشكل أن عملية التدريب تتم عبر مرحلتين: ففي المرحلة الأولى يتم استخدام قيم الإدخال فقط لتحديد المراكز وعرض دوال الأساس الشعاعي. وتعرف بمرحلة التعلم غير خاضع للإشراف .

فبمجرد تثبيت معاملات الدالة، يمكن استخدام التدريب الخاضع للإشراف (أي مع المعلومات المستهدفة) لتحديد أوزان الطبقة الإخراج .

(6) طرق اختيار المعلمات لشبكة *RBFFNN* العصبية :

تتكون الشبكة العصبية دالة الأساس الشعاعي من ثلاث معلمات مهمة في نموذج الشبكة العصبية *RBFFNN* وهي :

- مراكز *RBFFNN* (الخلايا العصبية المخفية) .
- العرض (*Width*) والمعروفة أيضًا باسم نصف القطر (الانحرافات المعيارية الخاصة بكل منها).
- أوزان طبقة الإخراج .

المرحلة الأولى: التعلم الغير الخاضع للإشراف :

يتم استخدام هذا التعلم بين طبقة الادخال والطبقة المخفية، حيث تعد قيم هذه المعلمات غير معروفة بشكل عام ويمكن الحصول عليها أثناء عملية التعلّم للشبكة، إلا أن المشكل الرئيس هو كيفية اختيار مجموعة مناسبة من مراكز *RBFFNN*، ومن أجل التغلب على هذه المشكلة تتطلب بعض الاستراتيجيات لاختبار المجموعة الصحيحة، حيث توجد استراتيجيات مختلفة لتدريب نماذج *RBFFNN*، وتعد خوارزمية *K-means clustering* من بين الخوارزميات الأكثر استخداما في عملية التعلم غير الخاضعة للإشراف بين طبقة الإدخال والطبقة المخفية ويرجع ذلك لبساطتها وقدرتها على تحقيق نتائج جيدة (1) .

(1) Pislaru, C., & Shebani, A. (2014). Identification of nonlinear systems using radial basis function neural network. *International Journal of Computer, Information, Systems and Control Engineering*, 8(9), 1528-1533.p1529.

ومن أجل تطبيق خوارزمية K-means clustering يجب اتباع الخطوات التالية (1) :

1. اختيار عدد K من المراكز وتعيين نقاط البيانات بشكل عشوائي لمجموعات فرعية .
 2. وضع كل هدف في أقرب مجموعة.
 3. إعادة حساب مركز المجموعات التي تتلقى البيانات الجديدة والمجموعات التي تفقد البيانات.
 4. إعادة تكرار الخطوات من (1) إلى (3) حتى تكون المراكز متماثلة أو متقاربة مع بعضها البعض.
- والطريقة الأكثر استخداما لتحديد المجال هي قياس المسافة الإقليدية، حيث أقصر مسافة بين المتجه X والمتجه C هي المسافة الإقليدية والتي يتم التعبير عنها على النحو التالي :

$$E_{dist} = \sqrt{\sum_{i=1}^n X_i - C_j}$$

حيث :

n : هي بعد المتجه.

E_{dist} : هي المسافة الإقليدية.

المرحلة الثانية: التعلم الخاضع للإشراف:

يتم استخدام عملية التعلم هذه بين الطبقة المخفية وطبقة الإخراج، حيث تهدف خوارزمية التدريب إلى تقليل نسبة الخطأ، ومن أجل ذلك تستخدم في هذه المرحلة مثل خوارزمية النزول التدريجي، وخوارزمية المربع الأقل من أجل ضبط الوزن بين الطبقة المخفية وطبقة الإخراج.

النزول التدريجي:

كون أن الشبكة العصبية *RBFFNN* تشبه إلى حد كبير الشبكة العصبية *MLP*، يمكن أيضا تطبيق نفس فكرة التدريب التعلم للشبكة العصبية *RBFFNN*. لكن الاختلاف الوحيد هو أن شبكات

(1) Abadi, A. M., Wustqa, D. U., & Nurhayadi, N. (2019). Diagnosis of brain cancer using radial basis function neural network with singular value decomposition Method. *International Journal of Machine Learning and Computing*, 9(4), 527-532.p528.

RBFFNN لا تقوم بتحدد فقط أوزانها، ولكن أيضاً وحداتها عن طريق تعيين مراكز ومجالات مخصصة. ولهذا يمكن تحديد الهدف الرئيس لعملية التدريب على أنه تحديد جميع المعلمات المطلوبة لتقليل خطأ التدريب الكلي. يمكن التعبير عن القاعدة العامة للتعلم الخاضع للإشراف لشبكات *RBFFNN* على النحو التالي:

للاشتقاق خوارزمية التعلم الخاضع للإشراف لشبكة RBF مع أي دالة أساس شعاعي، نقوم بكتابة دالة الخطأ كالآتي (1):

$$E = \sum_p \sum_k \left(t_k^p - y_k(X^p) \right)^2 = \sum_p \sum_k \left(t_k^p - \sum_{j=0}^M w_{kj} \phi_j(X^p, \mu_j, \sigma_j) \right)^2$$

ويمكن تحديث الأوزان بشكل متكرر باستخدام:

$$\Delta w_{jk} = -n_w \frac{\partial E}{\partial w_{jk}}$$

$$\Delta \mu_{ij} = -n_\mu \frac{\partial E}{\partial \mu_{ij}}$$

$$\Delta \sigma_j = -n_\sigma \frac{\partial E}{\partial \sigma_j}$$

(7) خوارزمية الشبكة العصبية دالة الأساس الشعاعي :

تعتبر عملية التدريب الشبكة العصبية RBF عملية تكرارية أو دورية، حيث كل دورة تتألف من الخطوات التالية (2):

الخطوة الأولى: تكوين أوزان الشبكة W بقيم عشوائية صغيرة.

الخطوة الثانية: تحديد قيمة الثابت σ وهذه القيمة تكون محصورة بين المجال $[0, 1]$ ، وحساب قيم الإخراج باتجاه أمامي لكل وحدة z من الطبقة المخفية وذلك من خلال المعادلة التالية :

(1) Bullinaria, J. A. (2015). *Radial basis function networks: Introduction. Neural Computation: Lecture, 13.p 17*

(2) مها عبد الإله محمد البدراني (2008). استخدام شبكة دالة القاعدة الشعاعية *RBFFN* في تشخيص أمراض الأطفال. المجلة العراقية للعلوم الإحصائية (13) 2008. من ص/ (195-179) / ص ص 184-185.

$$O_j(x) = \exp \left[-\frac{\|x_i - w_j\|^2}{2\sigma^2} \right]$$

حيث :

x_i هي متجه الإدخال.

w_j هو ناقل الوزن المرتبط بالوحدة j (على سبيل المثال مركزها دالة Gaussian) .

σ^2 تمثل عامل التطبيع.

ملاحظة: تقع مخرجات الطبقة المخفية بين المجال 0 و 1، حيث أنه كلما اقترب الإدخال من

مركز دالة Gaussia زادت استجابة العقد، لأن العقد تنتج مخرجات متطابقة للمدخلات متساوية المسافة من مركز Gaussian، ويطلق عليه أساس الشعاعي .

الخطوة الثالثة :

يتم حساب مستوى التنشيط (O_j) من طبقة الإخراج بواسطة :

$$O_j = \sum W_{ji} o_i$$

حيث :

W_{ji} تمثل الوزن من الطبقة المخفية i إلى طبقة الإخراج j .⁽¹⁾

الخطوة الرابعة :

تغيير الأوزان وهذا في حالة عدم تحقيق الإخراج المطلوب ويكون ذلك من خلال المعادلة التالية :

$$\Delta W_{ij} = X_i * E_j * C$$

حيث أن :

X_i تمثل ادخال الخلية

C تمثل نسبة التعلم في الشبكة .

E_j هو مقدار الخطئ وسيحسب وفق العلاقة التالية :

(1) Tiwari, A., Dubey, A. D., & Patel, D. (2015). Comparative study of short term load forecasting using multilayer feed forward neural network with back propagation learning and radial basis functional neural network. SAMRIDDHI J. Phys. Sci. Eng. Technol, 7, 14-27.p18-19

$$E_j = T_j - O_j$$

حيث :

T_j الإخراج المطلوب للخلية .

O_j الإخراج الحقيقي للخلية .

حيث يتم الاحتفاظ بقيم الأوزان الجديدة للمرحلة التالية من عملية المعالجة في طبقة الإخراج.

الخطوة الخامسة :

في حالة عدم الوصول إلى الحل المطلوب نقوم بتكرار خطوات الخوارزمية من الخطوة الثالثة حتى نصل إلى الحل المطلوب .

4-2: النماذج الهجينة :

إنّ عوامل صياغة نموذج التنبؤ ليست بالمهمة السهلة أثناء استخدام البيانات التاريخية للتنبؤ بالبيانات المستقبلية .

تعد نماذج المتوسط المتحرك المتكامل الإنحدار التلقائي (ARIMA) واحدة من أهم نماذج السلاسل الزمنية الخطية المستخدمة على نطاق واسع، وعلى الرغم من أنها مرنة جدا من حيث تمثيل العديد من أنواع المختلفة للسلاسل الزمنية، وكذلك تتميز أيضا بالتنبؤ الدقيق على الفترة الزمنية قصيرة المدى، إلا أن قيودها الرئيسة هي الشكل الخطي المفترض مسبقا للنموذج كونها تفترض أن القيم المستقبلية للسلسلة زمنية لها علاقة خطية مع القيم الحالية والماضية وكذلك مع التشويش الأبيض، ولذلك قد لا تكون التقديرات التقريبية بواسطة نماذج ARIMA كافية لمشاكل العالم الحقيقية غير الخطية المعقدة⁽¹⁾.

تعتبر الشبكات العصبية الاصطناعية نماذج غير خطية مرنة تتميز بقدرتها على معالجة البيانات دون الحاجة إلى صياغة مسبقة أو معرفة طبيعة العلاقة بين المتغيرات، أي تتناسب مع كل أنواع

(1) Khashei, M., & Bijari, M. (2012). Which methodology is better for combining linear and nonlinear models for time series forecasting?.p266.

البيانات، ومع ذلك فإن الإفراط في التعلم بسبب عملية التعلم هو العيب الرئيس للشبكات العصبية الاصطناعية⁽¹⁾.

ومع الحاجة المستمرة إلى تنبؤات أكثر دقة بالظواهر المختلفة، اقترحت كل من النتائج النظرية والتجريبية أن الجمع بين النماذج المختلفة يمكن أن يكون كذلك طريقة فعّالة لتحسين الأداء التنبؤي، حيث يأتي الدافع لدمج النماذج كون أن نموذجا واحدا قد لا يكون كافيا لتحديد جميع خصائص السلاسل الزمنية، على سبيل المثال قد تعرض سلسلة زمنية كلا من الأنماط الخطية وغير الخطية خلال نفس الفترة الزمنية، ففي مثل هذه الحالات لا يستطيع النموذج الخطي والنموذج الغير الخطي إلى نمذجة كلا المركبتين في وقت واحد.

ومؤخرا قد ثبت أن التقنيات الهجينة التي تعمل على تحليل السلاسل الزمنية إلى مكوناتها الخطية وغير الخطية ناحجة؛ لأنها تعطي أداءً أفضل مقارنة مع النماذج الفردية⁽²⁾.

4-2-1: تعريف النموذج الهجين:

هو النموذج الذي يقوم بالجمع أو الدمج بين نموذج خطي وآخر غير خطي، بغرض تحسين التنبؤات المستقبلية.

4-2-2: الهدف من عملية التهجين:

إنّ الهدف من الطرق الهجينة هو الجمع بين خصائص النمذجة الخطية للطرق الإحصائية مع قدرات النمذجة غير الخطية لطرق التعلم الآلي، حيث تظهر الحاجة إلى مثل هذه النماذج في الحالات التي يكون فيها شكل مجموعة البيانات غير معروف، أو تكون مجموعة البيانات عرضة للتغيرات الهيكلية. كما تعد النماذج الهجينة مناسبة أيضا لمجموعات البيانات التي لم يتم تعريفها بوضوح على أنها خطية أو غير خطية، ولكنها تحتوي بدلا من ذلك على أنماط خطية وغير خطية⁽³⁾.

(1)Wongsathan, R., & Jaroenwiriayapap, W. (2016). A hybrid ARIMA and RBF neural network model for tourist quantity forecasting: a case study for Chiangmai province. *Asia-Pacific Journal of Science and Technology*, 21(1), 37-54.p38.

(2)Taskaya-Temizel, T., & Casey, M. C. (2005). A comparative study of autoregressive neural network hybrids. *Neural Networks*, 18(5-6), 781-789.p 781.

(3) Malila, T. (2019). *Time-series sales forecasting for an Enterprise Resource Planning system*

4-2-3: النماذج الهجينة *Hybrid Models* :

سوف نتطرق في هذه الدراسة إلى النماذج الهجينة التالية :

1- نموذج Zhang الهجين (Zhang's Hybrid ARIMA – ANN).

2- نموذج *Generalized Hybrid ARIMA – ANN* الهجين المعمم

(1) نموذج Zhang الهجين : *Zhang Hybrid ARIMA-ANN(2003)*

يتم بناء النموذج الهجين بافتراض أن السلسلة الزمنية (y_t) تتكون من مركبة خطية (L_t) ومركبة

غير خطية (N_t) في الزمن t ، كما هو موضح في المعادلة الآتية⁽¹⁾ :

$$y_t = L_t + N_t$$

حيث :

y_t : تمثل السلسلة الزمنية.

L_t : تمثل المركب الخطي في السلسلة الزمنية.

N_t : تمثل المركب غير الخطي في السلسلة الزمنية.

ومن أجل بناء النموذج الهجين *ARIMA – ANN* توجد خطوتين يجب اتباعها وهي كالآتي :

1. نموذج *ARIMA* :

الذي تم استخدامه للتنبؤ بـ y_t والحصول على القيم المقدرة والبواقي، حيث تشير \hat{L}_t إلى نتائج

التنبؤ (القيم المقدرة) أما e_t هو المتبقي بين نموذج *ARIMA* والسلسلة، ويتم الحصول على البواقي e_t عند الزمن t من خلال العلاقة الآتية :

$$e_t = y_t - \hat{L}_t$$

2. بناء نموذج الشبكات العصبية الاصطناعية لنمذجة البواقي :

من خلال نمذجة القيم المتبقية باستخدام الشبكات العصبية الاصطناعية، يمكن اكتشاف

العلاقات غير الخطية. مع n من عقد الإدخال، سيكون نموذج ANN للبواقي كما يلي:

$$e_t = f(e_{t-1}, \dots, e_{t-n}) + \varepsilon_t$$

(1) Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159-175.p165

حيث :

f : تشير إلى الدالة غير الخطية.

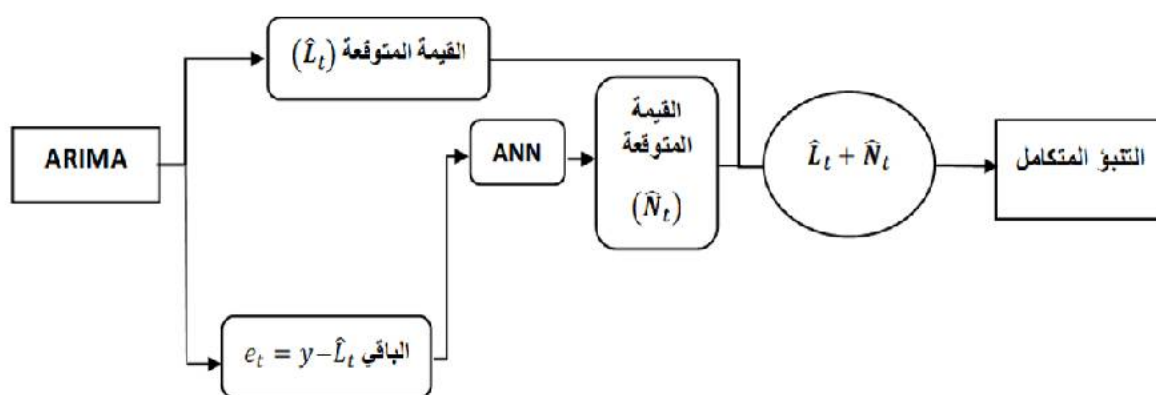
e_t : هو الخطأ العشوائي.

وأخيرا يتم الحصول على القيمة المتنبأ بها من نموذج الهجين \hat{y}_t وذلك من خلال الجمع بين

التنبؤات ويكون على النحو التالي :

$$\hat{y}_t = \hat{L}_t + \hat{N}_t$$

الشكل 4-4: يوضح خطوات التنبؤ لنموذج (Zhang) الهجين



Source : Dutsarak, A., & Liangrokapart, J. (2018). A study of the hybrid model performance for time series forecasting. *Kasem Bundit Engineering Journal*, 8, 151-163.p 155

(2) نموذج $ARIMA - ANN$ الهجين المعمم (Khashei & Bijary 2011):

قام كل من Khashei و Bijary بتعديل نموذج Zhang الذي يفترض أن تكون العلاقة بين المركبات الخطية وغير الخطية تجميعية مما قد يقلل هذا الافتراض من دقة التنبؤ لنموذج Zhang إذا كانت العلاقة لا تفي بهذا الافتراض، حيث تم اقتراح نموذج هجين جديد يحدد السلاسل الزمنية كدالة لمركباتها الخطية وغير الخطية.

وتكون صياغة هذا العلاقة على النحو التالي(1)

$$y_t = f(L_t, N_t)$$

حيث :

(1) Pannakkong, W., Huynh, V. N., & Sriboonchitta, S. (2019). A novel hybrid autoregressive integrated moving average and artificial neural network model for cassava export forecasting. *International Journal of Computational Intelligence Systems*, 12(2), 1047-1061.p1051.

تشير y_t إلى مشاهدات السلاسل الزمنية في الزمن t .

أما N_t تشير إلى المركبة الخطية وتشير N_t إلى المركبة الغير الخطية.

يتضمن هذا النموذج الهجين ثلاث خطوات وهي كالآتي :

- استخراج المركب الخطي (L_t) من السلاسل الزمنية باستخدام نموذج $ARIMA$.
- تحديد المركبات غير الخطية كدالة للقيم المتأخرة للبواقي e_t والقيم المتأخرة للسلسلة الزمنية y_t .
- تطبيق نموذج ANN لتحديد الدالة التي تمثل العلاقة بين السلاسل الزمنية والمركبات الخطية وغير الخطية.

ويتم يتم وصف تفاصيل هذه الخطوات الثلاث كالتالي (1):

- **الخطوة الأولى:** الهدف الرئيس هو النمذجة الخطية، لذلك يتم استخدام نموذج الانحدار الذاتي والمتوسطات المتحركة المتكاملة ($ARIMA$) من أجل نمذجة المركبة الخطية، سوف تحتوي القيم المتبقية من المرحلة الأولى على العلاقة غير الخطية التي لا يستطيع النموذج الخطي صياغتها، وكذلك على العلاقة الخطية. وبالتالي L_t تكون على النحو التالي :

$$L_t = \left[\sum_{i=1}^p \phi_i y_{t-i} - \sum_{j=1}^q \theta_j \varepsilon_{t-j} \right] + e_t = \hat{L}_t + e_t$$

حيث :

\hat{L}_t هي القيمة المقدرة، و e_t هي البواقي عند الزمن t من النموذج الخطي.

- **الخطوة الثانية:** الهدف الرئيس هو النمذجة غير الخطية، لذا يتم استخدام الشبكات العصبية والتي تستخدم نتائج المرحلة الأولى والمتضمنة القيم المقدرة والبواقي، ومن أجل وضع نموذج متزامن للعلاقات غير الخطية والخطية المحتملة التي قد تبقى في بقايا النمذجة الخطية التي لم يستطيع النموذج الخطي نمذجتها وكذلك العلاقات غير الخطية والخطية في البيانات الأصلية.

(1) Khashei, M., & Bijari, M. (2011). A new hybrid methodology for nonlinear time series forecasting. *Modelling and Simulation in Engineering*, 2011.p 3

ويكون بناء هذا النموذج على النحو التالي :

$$N_t^1 = f^1(e_{t-1}, \dots, e_{t-n})$$

$$N_t^2 = f^2(y_{t-1}, \dots, y_{t-m})$$

حيث :

f^1, f^2 هي الدوال الغير الخطية التي تحددتها الشبكة العصبية.

m و n أعداد صحيحة تمثل الحد الأقصى لعدد الفترات السابقة المدرجة في النموذج.

ويتم حساب بواقى نموذج $ARIMA$ في الزمن t أي (e_t) كما يلي :

$$e_t = y_t - \hat{L}_t$$

حيث :

تشير \hat{L}_t نتيجة نموذج $ARIMA$ و y_t إلى السلاسل الزمنية في الزمن t .

-**الخطوة الثالثة:** يتم تمثيل السلاسل الزمنية بدالة المركبتين الخطية والغير الخطية على الصيغة

التالية :

$$y_t = (\hat{L}_t, N_t^1, N_t^2)$$

$$y_t = f(\hat{L}_t, e_{t-1}, \dots, e_{t-n}, y_{t-1}, \dots, y_{t-m})$$

حيث :

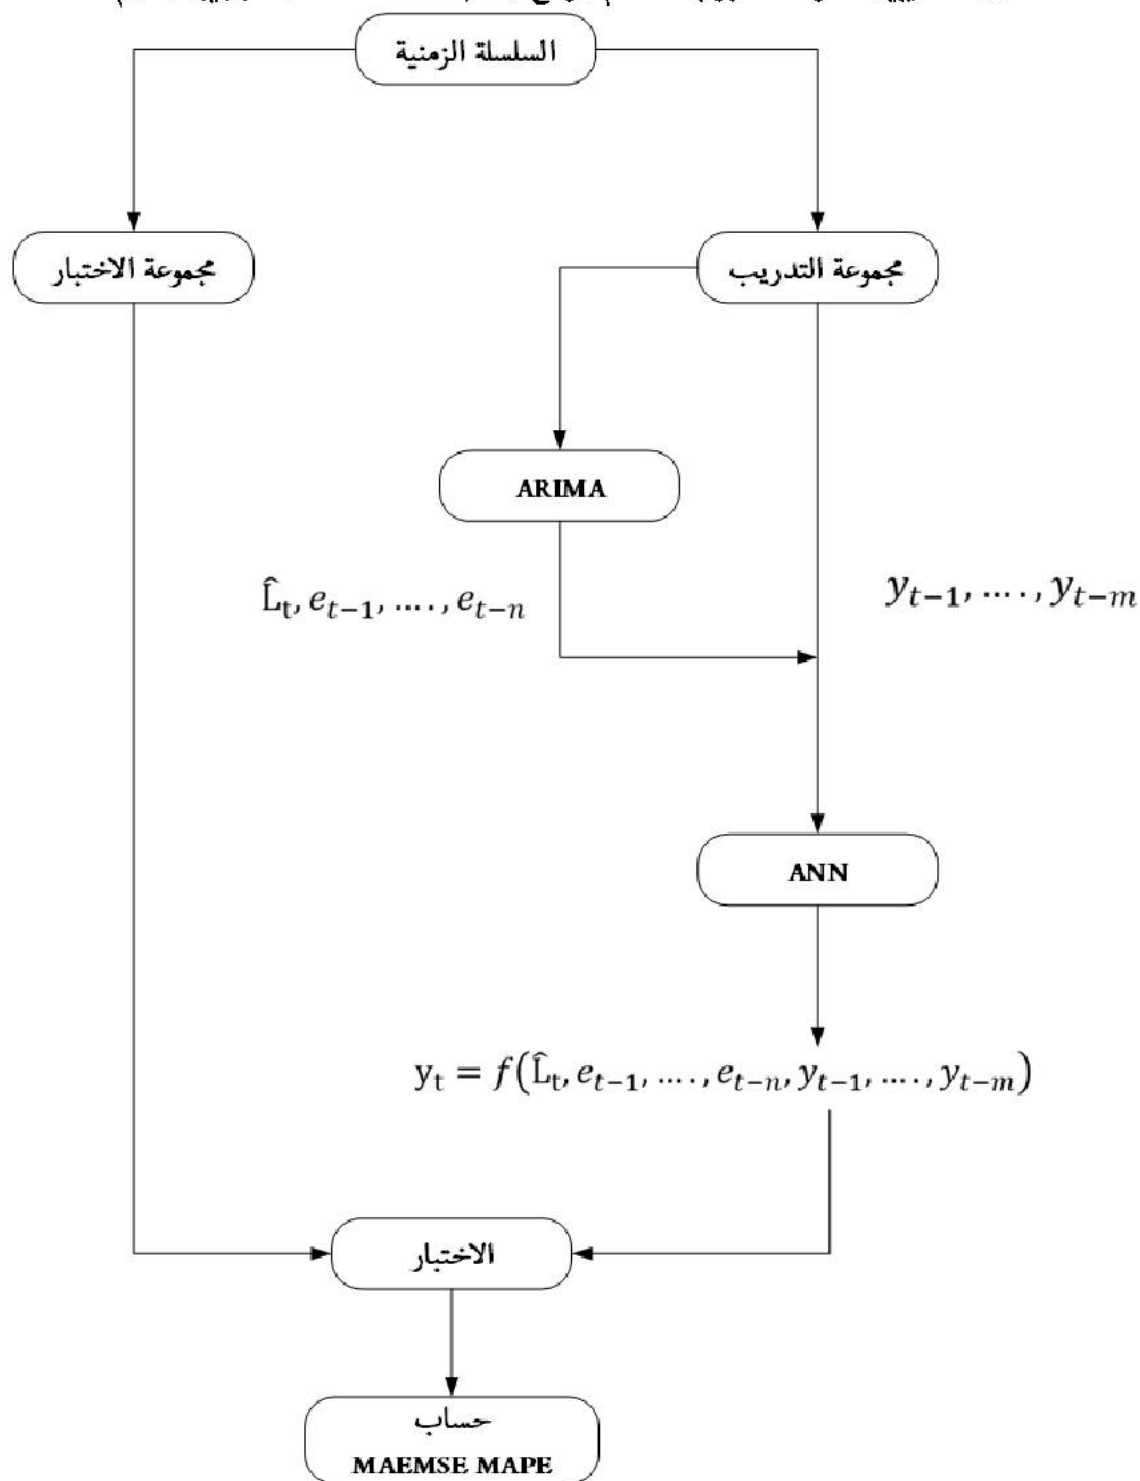
f هي الدالة غير الخطية التي يحددها نموذج ANN .

m و n تمثل أعدادا صحيحة يتم تحديدها في عملية التصميم للشبكة العصبية النهائية كما يمكن

تغييرها من 1 إلى 12.

والشكل التالي يبيّن خطوات التنبؤ باستخدام نموذج Khashei & Bijary الهجين المعمم :

الشكل 4-5: يبين خطوات التنبؤ باستخدام نموذج (Khashei & Bijari) الهجين المعمم



المصدر : بديع احمد محمد حمدان(2015) " التنبؤ بأسعار صرف الدولار مقابل الشيكول باستخدام نموذج ARIMA-ANN الهجين "رسالة ماجستير في الاحصاء، كلية الاقتصاد والعلوم الادارية -جامعة الازهر-غزة.

خلاصة :

تعد الشبكات العصبية الاصطناعية من بين التقنيات المعروفة القادرة على حلّ المشاكل الغير الخطية مثل التنبؤ، لقدرتها على التكيف بسهولة مع البيئة بسبب عملية التعلم في مرحلة التدريب. تعد الشبكة العصبية للوظيفة الشعاعية (RBFNN) نوع من أنواع بين الشبكات العصبية الاصطناعية الأكثر استخداما، فتم تطويرها (RBFNN) بناء على دوال الأساس الشعاعي وتقريب المعلمات .

تعتبر نوع من الشبكات العصبية ذات التغذية الأمامية، حيث توضح العبارة "التغذية إلى الأمام" أن بنية RBFNN تم تطويرها بناءً على ترتيب الخلايا العصبية في طبقات حسب بنية الطبقات. تطبق الشبكة العصبية دالة الأساس الشعاعي تقنية تدريب الغير الخاضعة للإشراف والخاضعة للإشراف، كما تتميز مقارنة بالشبكات العصبية الاخرى مثل الشبكة العصبية متعددة الطبقات بعملية (Perceptron) تدريب أسرع بكثير وبنية أبسط.

وميزة أخرى هي أن الشبكة العصبية Radial Basis Function قادرة على تتبع نمط الإخراج مع اختبار البيانات التي تتجاوز مجال بيانات التدريب.

تتكون الشبكة العصبية دالة الأساس الشعاعي من طبقة الإدخال والطبقة المخفية وطبقة الإخراج، فيتم تغذية معلمات الإدخال في الشبكة من خلال طبقة الإدخال بينما يتم إنتاج معلمات الإخراج بواسطة طبقات الإخراج، فالتبقات المخفية التي تتكون من دوال أساس شعاعي تقوم بتقييم معلمات الإدخال باستخدام دوال غير خطية.

هناك العديد من أنواع هذه الدوال غير الخطية مثل الدوال الغاوسية ودوال الرباعية المتعددة والدوال الأسية والدوال المكعبية ...

تعد نماذج ARIMA من الطرق الاحصائية التي استخدمت في العديد من المجالات لبناء نماذج التنبؤ بالسلاسل الزمنية، وعلى الرغم من أنه يمكن الاعتماد عليها للحصول على نموذج تنبئي دقيق، إلا أنها لا يمكنها معالجة العلاقات غير الخطية.

ومن أجل بناء نموذج تنبئي أكثر دقة من نماذج ARIMA بالنسبة إلى السلاسل الزمنية غير الخطية، تعتبر الشبكات العصبية الاصطناعية من بين الأساليب الحديثة التي تحديد العلاقات غير الخطية المعقدة بين مجموعات بيانات المدخلات والمخرجات دون الحاجة إلى معلومات عن طبيعة الظواهر ودون وضع افتراضات أساسية فيما يتعلق بالخطية ورغم هذا لا يمكن لنموذج الشبكة العصبية وحده معالجة الأنماط الخطية وغير الخطية بالتساوي.

وبشكل عام غالباً ما تكون السلاسل الزمنية في تطبيقات العالم الحقيقي خصائص خطية أو غير خطية ففي هذه الحالة، قد لا تكون قدرة نماذج التنبؤ الفردية كافية لالتقاط العلاقة بين السلاسل الزمنية التاريخية والمستقبلية.

ولهذا فالجمع بين طرق التنبؤ يؤدي إلى تحسين دقة التنبؤ.

اقترح Zhang في (2003) منهجية هجينة باستخدام نموذج ARIMA ليمثل المركبات الخطية ونموذج ANN ليمثل المركبات غير الخطية. حيث يمكن لنموذج الهجين ARIMA-ANN تحسين أداء التنبؤ مقارنة بالنماذج الفردية.

الفصل الخامس:
الجانب الحقيقي

5-1 : البيانات وبعض الإحصائيات الوصفية :

تستند مجموعة البيانات المستخدمة في هذه الدراسة إلى أسعار الذهب العالمية وهي عبارة عن بيانات شهرية لأسعار الذهب العالمية للفترة الممتدة من 01-01-2000 إلى 31-12-2020 (بالدولار الأمريكي لكل أوقية)، وتتكون من 252 مشاهدة لسعر الذهب الشهري، حيث تم الحصول على هذه البيانات من موقع البنك الدولي⁽¹⁾.

5-1-1 : دراسة الإحصائية الوصفية لبيانات السلسلة الزمنية :

سنقوم بدراسة الخواص الإحصائية لبيانات الشهرية لسلسلة المستخدمة في هذه الدراسة من أجل إعطاء فكرة عامة عن هذه البيانات.

التائج المتحصل عليها مبينة في الجدول 1-5، أدناه.

الجدول 1-5: الإحصاءات الوصفية لبيانات الشهرية لأسعار الذهب العالمية

التفرطح	الالتواء	الانحراف المعياري	الوسط الحسابي	الوسيط	اصغر قيمة	أعلى قيمة	الإحصاءات
1.730502	-0.062195	488.3098	974.4244	1125.905	260.4800	1968.630	أسعار الذهب

المصدر: Eviews 11

نلاحظ من خلال الجدول (1-5) أن أعلى قيمة لأسعار الذهب العالمية كانت 1968.630 أوقية/\$ شهريا وأصغر قيمة كانت 260.480 أوقية/\$ شهريا ، الوسط الحسابي لسلسلة الزمنية سجل قيمة 974.4244، أما الوسيط والانحراف المعياري فقد سجل كل منهما 1125.905، 488.3098 على التوالي، كما يبيّن الجدول أن مقياس التفرطح والالتواء بلغ كل منهما 1.730502، - 0.062195 على التوالي، كما نلاحظ أن مقياس التفرطح أقل من 3 مما يدل على أن منحنى البيانات مفرطح.

تمثل هذه السلسلة الزمنية أسعار الذهب، لقد تم تحويل البيانات الأصلية باستخدام اللوغاريتم الطبيعي من أجل تقليل القيم المتطرفة، حيث تتمثل إحدى مزايا هذا التحويل في تثبيت تباين

(1) Data Catalog (worldbank.org).

السلاسل الزمنية، مما لا يسمح بفقدان المعلومات المهمة من البيانات، ومن هذا فإن السلسلة التي سيتم استخدامها في التحليل في هذه الدراسة هي: **اللوغاريتم الطبيعي لأسعار الذهب (LGP)**. بعد إدخال اللوغاريتم الطبيعي على السلسلة الزمنية لأسعار الذهب، سنقوم بإظهار الخواص الإحصائية لبيانات الشهرية لسلسلة المستخدمة الجديدة، والجدول (2-5) يبيّن النتائج التي تم التوصل إليها:

الجدول 2-5: الإحصاءات الوصفية لبيانات الشهرية للوغاريتم الطبيعي لأسعار الذهب العالمية

التفرطح	الالتواء	الانحراف المعياري	الوسط الحسابي	الوسيط	أصغر قيمة	أعلى قيمة	الإحصاءات
1.533582	0.009477	0.641147	6.509170	6.500381	5.562526	7.479943	أسعار الذهب

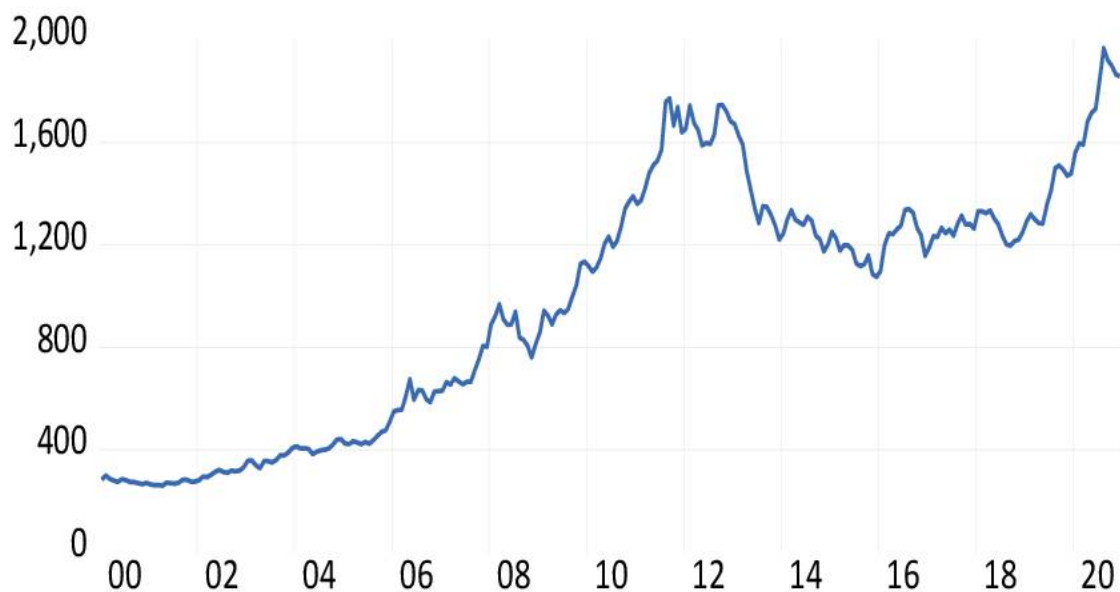
المصدر: Eviews 11

يتبين من خلال الجدول أعلاه أن أعلى قيمة اللوغاريتم الطبيعي لأسعار الذهب (LGP) كانت 7.479943 أوقية/\$ شهريا وأصغر قيمة كانت 5.562526 أوقية/\$ شهريا، الوسط الحسابي لسلسلة الزمنية سجل قيمة 6.509170، أما الوسيط والانحراف المعياري فقد سجل كل منهما 6.500381، 0.641147 على التوالي، كما يبيّن الجدول أن مقياس التفرطح والالتواء بلغ كل منهما 1.533582، -0.009477 على التوالي، كما نلاحظ أن مقياس التفرطح أقل من 3 مما يدل على أن منحنى البيانات مُفرطح.

5-1-2: التمثيل البياني للسلسلة الزمنية الأصلية لأسعار الذهب الشهرية والسلسلة الزمنية


لأسعار الذهب الشهرية بعد إدخال اللوغاريتم الطبيعي:

الشكل 5-1: التمثيل البياني للسلسلة الزمنية الأصلية لأسعار الذهب الشهرية
GP



المصدر: Eviews 11

الشكل 5-2: السلسلة الزمنية لأسعار الذهب الشهرية بعد إدخال اللوغاريتم الطبيعي
LGP



المصدر: Eviews 11

نلاحظ من خلال التمثيل البياني للسلسلة الزمنية- أعلاه- التي سوف نتطرق إلى تحليلها أنها سلسلة زمنية غير مستقرة، حيث تختلف هذه السلسلة بشكل عشوائي عبر الزمن مع نمط اتجاه متزايد. **3-1-5: التنبؤ بأسعار الذهب الشهرية باستخدام منهجية Box-Jenkins لتحديد نماذج ARIMA** قبل التطرق إلى تطبيق هذه المنهجية سوف نقوم بتقسيم السلسلة الزمنية لأسعار الذهب الشهرية التي تم إدخال اللوغاريتم الطبيعي عليها، إلى مرحلة التدريب إذ خصص لها 70% و 30% لأجل الاختبار.

❖ مرحلة التدريب:

1-3-1-5: دراسة استقرارية السلسلة الزمنية

من خلال الشكل 2-5، نستنتج وجود اتجاه عام نحو الزيادة في البيانات، مما يعني وجود مركبة الاتجاه العام بالسلاسل الزمنية لأسعار الذهب مما يجعلها غير مستقرة، ولكن الحكم على عدم استقرارية السلسلة من الملاحظة للتمثيل البياني غير كافية، وللمزيد من التأكد في استقرارية السلسلة الزمنية سنستخدم اختبار ديكي- فولر المطور وكذلك اختبار فيليبس بيرون.

2-3-1-5: اختبار ديكي- فولر المطور لفحص استقرارية السلسلة الزمنية :

كما ذكرنا سابقاً أن اختبار ديكي- فولر المطور يعتمد عليه في دراسة استقرارية السلاسل الزمنية بهدف الكشف عن وجود جذر الوحدوي، حيث ينص هذا الاختبار على تقدير ثلاثة نماذج وهي (مع ثابت فقط، مع ثابت واتجاه، بدون ثابت واتجاه).

الجدول 3-5: اختبار ديكي- فولر المطور لفحص استقرارية السلسلة الزمنية

المتغير	النماذج	القيمة المحسوبة	القيمة الإحتمالية	القرار
أسعار الذهب العالمية	وجود ثابت فقط	-0.8674	0.7966	السلسلة غير مستقرة
	ثابت واتجاه	-0.8830	0.9546	
	بدون ثابت واتجاه	2.8369	0.9989	

المصدر: Eviews 11

ومن خلال الجدول رقم 3-5 نلاحظ أن القيم الاحتمالية لديكي- فولر أكبر من 0.05، ومنه قبول الفرضية العدمية بعدم استقرارية السلسلة الزمنية بأسعار الذهب العالمية وهي من نوع DS.

5-3-1-3 : اختبار فيليبس بيرون لفحص استقرارية السلسلة الزمنية :

الجدول 4-5: اختبار فيليبس بيرون لفحص استقرارية السلسلة الزمنية

المتغير	النماذج	القيمة المحسوبة	القيمة الإحتمالية	القرار
أسعار الذهب العالمية	وجود ثابت فقط	-0.8650	0.7973	السلسلة غير مستقرة
	ثابت واتجاه	-1.1542	0.9157	
	بدون ثابت واتجاه	2.5923	0.9978	

المصدر: Eviews 11

من خلال الجدول أعلاه لاختبار فيليبس بيرون لفحص استقرارية السلسلة الزمنية كانت نفس النتائج المتحصل عليها في اختبار ديكي-فولر، أي القيمة الاحتمالية أكبر من 0.05 ومنه سوف يتم قبول الفرضية العدمية بعدم استقرارية السلسلة الزمنية بأسعار الذهب الشهرية.

5-3-1-4 : نتائج اختبار استقرارية السلسلة الزمنية ذات الفروق الأولى باستخدام اختبار ديكي-فولر المطور :

من أجل استقرارية السلسلة الزمنية سوف نقوم بالفروق الأولى وهذا بالاعتماد على اختبار ديكي-فولر، النتائج المتحصل عليها مبينة في الجدول (5-5) بعد إجراء الفروقات .

الجدول 5-5: اختبار استقرارية السلسلة الزمنية ذات الفروق الأولى باستخدام اختبار ديكي-فولر

المتغير	النماذج	القيمة المحسوبة	القيمة الإحتمالية	القرار
أسعار الذهب العالمية	وجود ثابت فقط	-11.9692	0.0000 ***	السلسلة مستقرة
	ثابت واتجاه	-11.9517	0.0000 ***	
	بدون ثابت واتجاه	-11.5288	0.0000 ***	

المصدر: Eviews 11

ملاحظة: (*) معنوية عند 10%، (**) معنوية عند 5%، (***) معنوية عند 1% .

بعد أخذ الفروق الأولى للسلسلة بيّنت النتائج أن اختبار *ADF* معنوية أي أن القيم الاحتمالية لديكي-فولر أصغر من القيم الحرجة لتوزيع *MacKinnon*، وهذا ما أكدته نسبة الاحتمال $prob = 0.0000$ ، أي نرفض فرضية وجود جذر وحدوي ومنه أصبحت السلسلة مستقرة.

5-3-1-5 : اختبار استقرارية السلسلة الزمنية ذات الفروق الأولى باستخدام اختبار فيليبس بيرون :

الجدول 5-6: نتائج اختبار استقرارية السلسلة الزمنية ذات الفروق الأولى باستخدام اختبار فيليبس بيرون

المتغير	النماذج	القيمة المحسوبة	القيمة الاحتمالية	القرار
أسعار الذهب العالمية	بوجود ثابت فقط	-11.9796	0.0000 ***	السلسلة مستقرة
	ثابت واتجاه	-11.9592	0.0000 ***	
	بدون ثابت واتجاه	-11.6993	0.0000 ***	

المصدر: Eviews 11

ملاحظة: (*) معنوية عند 10٪، (**) معنوية عند 5٪، (***) معنوية عند 1٪.

بعد إجراء الفروق الأولى لسلسلة أسعار الذهب العالمية باستخدام اختبار فيليبس بيرون، اتضح من خلال النتائج أن القيم الاحتمالية لهذا الاختبار أصغر من القيم الحرجة لتوزيع MacKinnon كما هو موضح في الجدول أعلاه ومنه نرفض فرضية وجود جذر وحدوي، أي أصبحت سلسلة أسعار الذهب العالمية مستقرة.

وبعد إجراء الفروق الأولى لسلسلة أسعار الذهب العالمية فإن تقدير السلسلة يعتمد على نموذج $ARIMA(p, 1, q)$ ، حيث يشير 1 إلى الفروق الأولى، أما p و q فهما عدد فجوات الانحدار الذاتي، والمتوسطات المتحركة على التوالي.

5-3-1-6 : مرحلة تحديد النموذج :

من أجل التعرف على أي نموذج وفقاً لمنهجية بوكس-جنكينز يعني تحديد الرتب p, q للنماذج AR, MA على التوالي، ومن أجل إيجاد قيم p, q سوف نلجأ إلى رسم دالتي الارتباط الذاتي والارتباط الذاتي الجزئي، كما هو موضح في الشكل 3-5.

الشكل 3-5: دالتي الارتباط الذاتي والارتباط الذاتي الجزئي

Correlogram of D(LGP)

Date: 07/28/21 Time: 23:12 Sample: 2000M01 2014M08 Included observations: 175						
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.094	0.094	1.5722	0.210
		2	-0.071	-0.080	2.4634	0.292
		3	0.067	0.083	3.2625	0.353
		4	0.090	0.070	4.7168	0.318
		5	-0.022	-0.027	4.8025	0.440
		6	0.014	0.027	4.8394	0.565
		7	0.033	0.014	5.0416	0.655
		8	-0.063	-0.070	5.7783	0.672
		9	-0.057	-0.039	6.3768	0.702
		10	-0.009	-0.017	6.3914	0.781
		11	0.191	0.199	13.284	0.275
		12	-0.022	-0.049	13.373	0.343
		13	-0.045	-0.005	13.753	0.392
		14	0.016	-0.008	13.802	0.465
		15	0.040	0.014	14.118	0.517
		16	0.047	0.063	14.554	0.557
		17	0.025	0.006	14.677	0.619
		18	0.012	-0.001	14.705	0.682
		19	-0.098	-0.088	16.617	0.616
		20	0.059	0.088	17.323	0.632

المصدر: مخرجات برنامج **EvIEWS. 11**

بعد التفحص الأولي لدالة الارتباط الذاتي ACF ودالة الارتباط الذاتي الجزئي $PACF$ ، تم ترشيح عدة نماذج أولية والتي تعد مناسبة لتمثيل السلسلة الزمنية، ومن أجل المقارنة بين هذه النماذج تم الاعتماد على معيار AIC ومعيار SC ، فالنموذج الأفضل هو الذي لديه أقل قيمة لهذين المعيارين، فمن خلال المقارنة تبين أن النموذج الأفضل المرشح من نماذج بوكس جنكترز هو $ARIMA(11,1,0)$ ، كون قيم المعيارين التي استخدمت للمفاضلة بين النماذج المختلفة بيّنت أقل ما يمكن بين جميع القيم المعيارين للنماذج الأخرى.

5-1-3-6 : مرحلة التقدير :

بعد التحقق من ملائمة النموذج تأتي مرحلة التقدير، والجدول 5-7 يبيّن نتائج تقدير النموذج

المرشح.

الجدول 5-7: نتائج تقدير النموذج ARIMA(11,1,0)

Dependent Variable: D(LGP)				
Method: ARMA Maximum Likelihood (OPG - BHHH)				
Date: 07/23/21 Time: 00:06				
Sample: 2000M02 2014M08				
Included observations: 175				
Convergence achieved after 6 iterations				
Coefficient covariance computed using outer product of gradients				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.008294	0.003619	2.291588	0.0231
AR(11)	0.193954	0.078372	2.474785	0.0143
SIGMASQ	0.001451	0.000134	10.84325	0.0000
R-squared	0.039413	Mean dependent var	0.008664	
Adjusted R-squared	0.028244	S.D. dependent var	0.038980	
S.E. of regression	0.038425	Akaike info criterion	-3.660806	
Sum squared resid	0.253956	Schwarz criterion	-3.606553	
Log likelihood	323.3205	Hannan-Quinn criter.	-3.638799	
F-statistic	3.528610	Durbin-Watson stat	1.776155	
Prob(F-statistic)	0.031488			
Inverted AR Roots	.86	.72+.47i	.72-.47i	.36+.78i
	.36-.78i	-.12+.85i	-.12-.85i	-.56-.65i
	-.56+.65i	-.83+.24i	-.83-.24i	

المصدر : مخرجات برنامج Eviews. 11

ومنه يمكن كتابة معادلة النموذج المقدر وفقا للجدول (5-7) كالآتي :

$$ARIMA(11,1,0): D(LGP)_t = 0.008294 + 0.193954D(LGP)_{t-11}$$

كما أن التحقيق في نتائج هذه التقديرات تُظهر أن جميع المعاملات معنوية.

5-1-3-7 : مرحلة اختبار دقة ملائمة النموذج المقدر :

بعد الإنتهاء من مرحلتَي التعرف والتقدير، تأتي مرحلة التّشخيص والتي يتم فيها التحقق من

النموذج المستخدم، وذلك بإخضاعه لعدد من الاختيارات، كما يلي :

1-5-3-7-1 : اختبار عشوائية سلسلة البواقي للنموذج المقدر :

من أجل اختبار عشوائية سلسلة البواقي للنموذج المقدر قمنا باستخدام دوال الارتباط الذاتي والجزئي للبواقي، فمن خلال الشكل 4-5 نلاحظ بأن جميع معاملات الارتباط الذاتي والجزئي تقع داخل حدي فترة الثقة ومنه نستنتج أن سلسلة البواقي عشوائية.

الشكل 4-5: دوال الارتباط الذاتي والجزئي للبواقي لنموذج المقدر

Correlogram of Residuals

Date: 07/23/21 Time: 00:08 Sample: 2000M01 2014M08 Included observations: 175 Q-statistic probabilities adjusted for 1 ARMA term						
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.107	0.107	2.0554	
		2	-0.055	-0.068	2.6031	0.107
		3	0.083	0.098	3.8321	0.147
		4	0.081	0.058	5.0256	0.170
		5	-0.036	-0.041	5.2594	0.262
		6	0.014	0.026	5.2961	0.381
		7	0.015	-0.007	5.3354	0.502
		8	-0.065	-0.064	6.1279	0.525
		9	-0.060	-0.043	6.7972	0.559
		10	-0.035	-0.039	7.0330	0.634
		11	-0.012	0.001	7.0601	0.720
		12	-0.033	-0.020	7.2702	0.777
		13	-0.032	-0.020	7.4685	0.825
		14	0.005	0.013	7.4730	0.876
		15	0.012	0.012	7.5001	0.914
		16	0.061	0.068	8.2242	0.914
		17	0.048	0.032	8.6800	0.926
		18	0.012	0.001	8.7073	0.949
		19	-0.076	-0.090	9.8668	0.936
		20	0.079	0.082	11.110	0.920


المصدر : مخرجات برنامج Eviews.11

1-5-3-7-2 : التوزيع الطبيعي لسلسلة بواقي عملية التقدير:

أما فيما يخص تأكيد ملائمة النموذج المقدر، تم تطبيق اختبار *Jarque – Bera* والشكل (5-5)

يبين النتائج المتوصل إليها:

الشكل 5-5: اختبار Jarque-Bera لسلسلة بواقي عملية التقدير



المصدر: مخرجات برنامج *Eviews. 11*

نلاحظ من خلال الجدول أعلاه أن احتمالية *Jarque - Bera* أكبر من 0.05 ومنه يتم قبول فرضية التوزيع الطبيعي للأخطاء العشوائية.

5-1-3-7-3 : اختبار ثبات التباين لبواقي النموذج المقدر :

الجدول 5-8: نتائج اختبار تجانس التباين لبواقي النموذج المقدر

Heteroskedasticity Test: ARCH				
F-statistic	4.892675	Prob. F(1,172)	0.0283	
Obs*R-squared	4.812667	Prob. Chi-Square(1)	0.0283	
Test Equation:				
Dependent Variable: RESID^2				
Method: Least Squares				
Date: 07/23/21 Time: 00:11				
Sample (adjusted): 2000M03 2014M08				
Included observations: 174 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.001206	0.000212	5.700505	0.0000
RESID^2(-1)	0.166395	0.075226	2.211939	0.0283
R-squared	0.027659	Mean dependent var		0.001448
Adjusted R-squared	0.022006	S.D. dependent var		0.002413
S.E. of regression	0.002386	Akaike info criterion		-9.226905
Sum squared resid	0.000979	Schwarz criterion		-9.190594
Log likelihood	804.7408	Hannan-Quinn criter.		-9.212175
F-statistic	4.892675	Durbin-Watson stat		2.042839
Prob(F-statistic)	0.028288			

المصدر: مخرجات برنامج *Eviews. 11*

فيما يتعلق بهذا الاختبار، فإن الفرضية الصفرية هي أنه لا يوجد أثر ARCH ، والفرضية البديلة هي أن هناك أثر لعدم ثبات التباين في بواقي النموذج المقدر (يوجد أثر ARCH)، من خلال نتائج الجدول 5-8، نلاحظ أن القيمة الاحتمالية (0.0283) أصغر من 0.05، إذن نرفض الفرضية العدمية ونقبل الفرضية البديلة القائلة أن هناك أثر لعدم ثبات التباين في بواقي النموذج المقدر.

5-1-3-8 : المفاضلة بين نماذج ARCH و GARCH :

بعد إثبات وجود أثر ARCH في البواقي، سوف نقوم بالمقارنة بين عدة نماذج من عائلة GARCH ومن أجل تحديد نموذج GARCH المناسب، استخدمنا معيار AIC ومعيار SC للمفاضلة بين النماذج المقترحة، فبعد اقتراح عدة نماذج تبين أن النموذج $GARCH(1,1)$ هو الأفضل كونه أعطى أقل قيمة للمعيارين AIC و SC.

5-1-3-9 : تقدير النموذج $GARCH(1,1) - ARIMA(11,1,0)$:

الجدول 5-9: نتائج اختبار معنوية معاملات النموذج $GARCH(1,1) - ARIMA(11,1,0)$

Dependent Variable: D(LGP)				
Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)				
Date: 07/23/21 Time: 00:13				
Sample (adjusted): 2001M01 2014M08				
Included observations: 164 after adjustments				
Convergence achieved after 18 iterations				
Coefficient covariance computed using outer product of gradients				
Presample variance: backcast (parameter = 0.7)				
GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*GARCH(-1)				
Variable	Coefficient	Std. Error	z-Statistic	Prob.
C	0.009763	0.003848	2.537141	0.0112
AR(11)	0.187589	0.080354	2.334523	0.0196
Variance Equation				
C	0.000254	0.000207	1.227560	0.2196
RESID(-1)^2	0.159213	0.101067	1.575326	0.1152
GARCH(-1)	0.671304	0.217219	3.090449	0.0020
R-squared	0.039168	Mean dependent var	0.009528	
Adjusted R-squared	0.033237	S.D. dependent var	0.039456	
S.E. of regression	0.038795	Akaike info criterion	-3.682216	
Sum squared resid	0.243814	Schwarz criterion	-3.587708	
Log likelihood	306.9417	Hannan-Quinn criter.	-3.643849	
Durbin-Watson stat	1.769558			
Inverted AR Roots				
	.86	.72+.46i	.72-.46i	.36+.78i
	.36-.78i	-.12+.85i	-.12-.85i	-.56-.65i
	-.56+.65i	-.82+.24i	-.82-.24i	

المصدر: مخرجات برنامج *Eviews. 11*

من خلال نتائج الجدول نلاحظ أن جميع معاملات المقدرة للنموذج تختلف جوهرياً عن الصفر، كما نلاحظ أن قيمة معيار AIC ومعيار SC بلغت (-3.682، -3.5877) على التوالي، كما نلاحظ أن قيمة DW بلغت 1.769 وهذا يشير إلى عدم وجود ارتباط ذاتي بين بواقي النموذج النهائي ومنه يكون النموذج المقدر هو الأكثر ملائمة وتوافقاً مع المعايير بين جميع النماذج السابقة.

وبناءً على الجدول (9-5) يمكن كتابة معادلة النموذج النهائي التباين الشرطي ومعادلة الانحدار الذاتي والمتوسطات المتحركة المستخدمة للتنبؤ بأسعار الذهب العالمية المستقبلية على النحو التالي:

$$ARIMA(11,1,0): D(LGP)_t = 0.008294 + 0.193954D(LGP)_{t-11}$$

$$GARCH(1,1): \sigma_t^2 = 0.000254 + 0.159\varepsilon_{t-1}^2 + 0.671\sigma_{t-1}^2$$

5-8-5: فحص النموذج المقدر الجديد:

الجدول 5-10: نتائج اختبار تجانس التباين لبواقي النموذج المقدر ARIMA(11,1,0)-GARCH (1,1)

Heteroskedasticity Test: ARCH				
F-statistic	0.053109	Prob. F(1,161)	0.8180	
Obs*R-squared	0.053751	Prob. Chi-Square(1)	0.8167	
Test Equation:				
Dependent Variable: WGT_RESID^2				
Method: Least Squares				
Date: 07/23/21 Time: 00:14				
Sample (adjusted): 2001M02 2014M08				
Included observations: 163 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	1.011291	0.147580	6.852489	0.0000
WGT_RESID^2(-1)	-0.018145	0.078736	-0.230455	0.8180
R-squared	0.000330	Mean dependent var	0.993092	
Adjusted R-squared	-0.005879	S.D. dependent var	1.587094	
S.E. of regression	1.591753	Akaike info criterion	3.779742	
Sum squared resid	407.9219	Schwarz criterion	3.817703	
Log likelihood	-306.0490	Hannan-Quinn criter.	3.795154	
F-statistic	0.053109	Durbin-Watson stat	1.991557	
Prob(F-statistic)	0.818031			

المصدر: مخرجات برنامج Eviews. 11

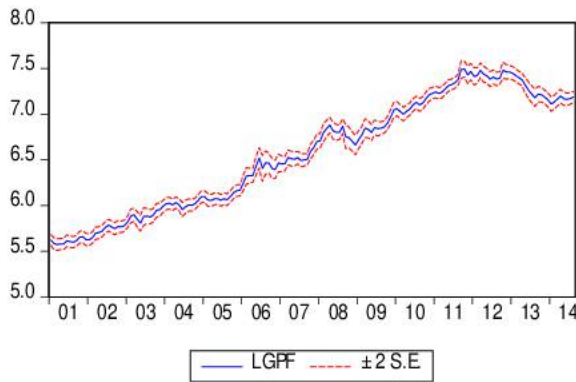
نلاحظ من خلال الجدول أعلاه أن القيمة الاحتمالية تساوي (0.8180) أكبر من 0.05، إذن نقبل الفرضية العدمية ونرفض الفرضية البديلة القائلة أن هناك أثر لعدم ثبات التباين في بواقي النموذج المقدر.

5-9 : التنبؤ باستخدام نموذج $ARIMA(11, 1, 0) - GARCH(1, 1)$


التنبؤ هو المرحلة الأخيرة من مراحل تحليل السلسلة الزمنية باستخدام منهجية بوكس-جنكينز.

فبعد تقدير النموذج $ARIMA(11,1,0) - GARCH(1,1)$ وفحصه والتأكد من صلاحيته، يمكن استخدامه للتنبؤ بالقيم المستقبلية لأسعار الذهب الشهرية.

الشكل (5-6) يوضح القيم التنبؤية بالتباين الشرطي وكذلك رسم بياني للتنبؤ بالتباين الشرطي باستخدام نموذج $GARCH(1, 1)$ ، وكذلك يبين تقييم جودة التنبؤ باستخدام النموذج المقدر. الشكل 5-6: يوضح القيم التنبؤية بالتباين الشرطي وكذلك رسم بياني للتنبؤ بالتباين الشرطي باستخدام نموذج $GARCH(1, 1)$ ، وكذلك يبين تقييم جودة التنبؤ باستخدام النموذج المقدر لمرحلة التدريب.



Forecast: LGPF	
Actual: LGP	
Forecast sample: 2000M01 2014M08	
Adjusted sample: 2001M01 2014M08	
Included observations: 164	
Root Mean Squared Error	0.038557
Mean Absolute Error	0.029832
Mean Abs. Percent Error	0.452032
Theil Inequality Coefficient	0.002920
Bias Proportion	0.000023
Variance Proportion	0.006210
Covariance Proportion	0.993768
Theil U2 Coefficient	0.945053
Symmetric MAPE	0.451976

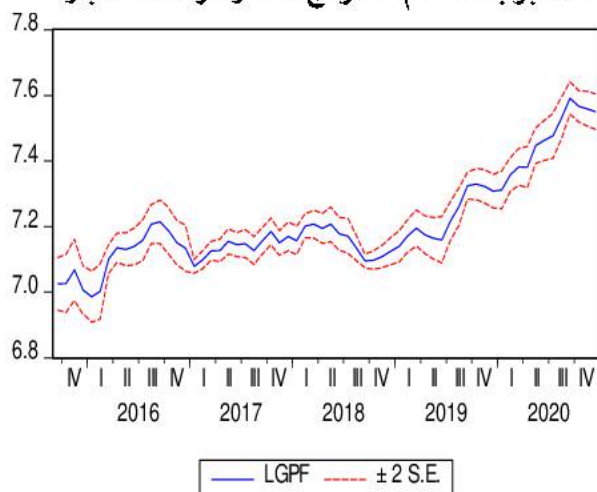


المصدر: مخرجات برنامج Eviews 11

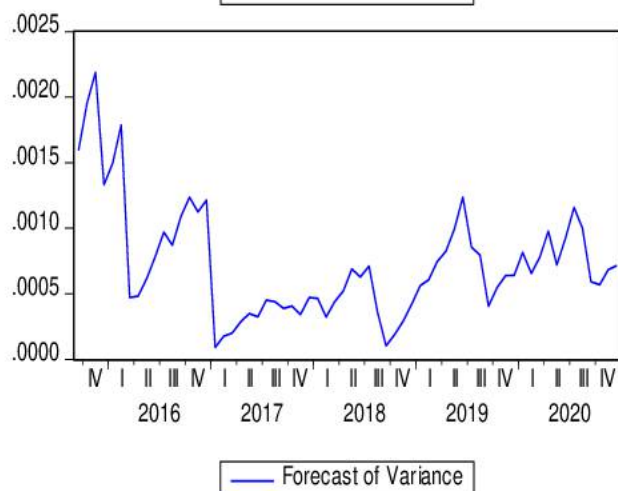
نلاحظ من خلال الشكل (5-6) أن النموذج المقدر محصور بين حدّي الثقة بانحراف معياري ± 2 ومنه نستنتج أن النموذج معنوي على طول السلسلة. ومن ناحية أخرى فإن الفجوة بين السعر الفعلي والسعر المتنبأ به يمثلها الجذر التربيعي للخطأ المتوسط = 0.038557 صغيرة جداً. ومنه فإن القدرة التنبؤية لنموذج دقيقة.

بعد التوصل إلى النموذج الأمثل $ARIMA(11,1,0) - GARCH(1,1)$ ، تم أخذ 30% من البيانات المتبقية من الفترة الممتدة من 2014 إلى غاية 2020، والتي تعتبر كمرحلة اختبار، حيث تم التوصل إلى النتائج التالية والموضحة في الشكل (5-7) أدناه:

الشكل 5-7: يوضح القيم التنبؤية بالتباين الشرطي وكذلك رسم بياني للتنبؤ بالتباين الشرطي باستخدام نموذج $GARCH(1,1)$ ، وكذلك يبين تقييم جودة التنبؤ باستخدام النموذج المقدر لمرحلة الاختبار.



Forecast: LGPF	
Actual: LGP	
Forecast sample: 2014M09 2020M12	
Adjusted sample: 2015M09 2020M12	
Included observations: 64	
Root Mean Squared Error	0.031331
Mean Absolute Error	0.024802
Mean Abs. Percent Error	0.344076
Theil Inequality Coefficient	0.002172
Bias Proportion	0.001141
Variance Proportion	0.006769
Covariance Proportion	0.992090
Theil U2 Coefficient	0.988183
Symmetric MAPE	0.344080



المصدر: مخرجات برنامج Eviews 11

نلاحظ من خلال الشكل (5-7) أن النموذج المقدر محصور بين حدّي الثقة بانحراف معياري ± 2 ومنه نستنتج أن النموذج معنوي على طول السلسلة. ومن ناحية أخرى فإن الفجوة بين

السعر الفعلي والسعر المتنبأ به يمثلها الجذر التربيعي للخطأ المتوسط = 0.031331 صغيرة جداً. ومنه فإن القدرة التنبئية لنموذج دقيقة؛ لأن الجذر التربيعي لمتوسط الخطأ في مرحلة التدريب أقل من مرحلة الاختبار.

5-2: التنبؤ باستخدام الشبكات العصبية الاصطناعية :

تكمن مشكلة نماذج السلاسل الزمنية في أنها تفترض وجود علاقة خطية بين القيم الحالية والمستقبلية، ولتغلب على هذه المشكلة توفر الشبكات العصبية إمكانية التنبؤ بالسلسلة الزمنية غير الخطية فتعتبر الشبكات العصبية الاصطناعية من الأساليب الحديثة التي تعمل على محاكاة الطريقة التي يؤدي بها الدماغ البشري مهمة معينة، وذلك عن طريق معالجة ضخمة موزعة على التوازي. ومنه فالشبكات العصبية الاصطناعية تتشابه مع الدماغ البشري في أنها تكتسب المعرفة بالتدريب، وتخزن هذه المعرفة باستخدام قوى وصل داخل العصبونات تسمى الأوزان التشابكية. ولذا لاقت اهتماماً واسعاً في مجالات متعددة منها التنبؤ بأسعار العملات، والتنبؤ بالمبيعات وغيرها، كما تساعد في عملية التخطيط من أجل اتخاذ القرارات المستقبلية. ويرجع الاهتمام في استخدام الشبكات العصبية الاصطناعية بشكل واسع؛ كونها لا تحتاج إلى شروط صارمة ودقيقة لغرض التنبؤ.

وبناءً على ما سبق ذكره تم الاعتماد في هذه الدراسة على الشبكة العصبية متعددة الطبقات بيرسبترون (*MLPNN*) والشبكة العصبية دالة الأساس الشعاعي (*RBFNN*) والنماذج الهجينة التي تم التطرق إليها في الجانب النظري للتنبؤ بأسعار الذهب العالمية.

5-2-1: التنبؤ باستخدام الشبكات العصبية :

سنقوم بتحليل البيانات الشهرية لسلسلة الزمنية محل الدراسة باستخدام نوعين من الشبكات العصبية ذات التغذية الأمامية : الشبكة العصبية متعددة الطبقات بيرسبترون (*MLPNN*) والشبكة العصبية دالة الأساس الشعاعي *RBFNN* .

حيث سيتم في التحليل الاعتماد على نفس طريقة تقسيم البيانات إلى مجموعتين:

- مجموعة تدريب .
- مجموعة اختبار .

5-2-1-1: التنبؤ باستخدام الشبكة العصبية متعددة الطبقات بيرسبترون (*MLPNN*):

كما سبق الذكر فتعد الشبكة العصبية متعددة الطبقات بيرسبترون (*MLPNN*) من بين النماذج الشبكات العصبية الأكثر استخداما في التنبؤ بالسلاسل الزمنية، ووفقا لهذه الميزة تم الاعتماد عليها للتنبؤ بأسعار الذهب التي تم إدخال عليها اللوغاريتم الطبيعي (*LGP*) خلال فترة الدراسة (1 جانفي 2000 إلى 31 ديسمبر 2020)، ولبناء الشبكة العصبية *MLP* نتبع الخطوات التالية:

❖ مرحلة تقسيم البيانات:

تعتبر هذه المرحلة أول خطوة يقوم بها برنامج الشبكات العصبية، تم تقسيم البيانات المدخلة إلى جزأين بالاعتماد على برنامج *SPSS - 25*، حيث تتم عملية توزيع المشاهدات بشكل عشوائي، والجدول التالي يوضح عدد مشاهدات كل مجموعة ونسبتها:

الجدول 5-11: نتائج تقسيم البيانات

المجموعة	نسبة المشاهدات	عدد المشاهدات
مجموعة التدريب	72.3%	180
مجموعة الاختبار	27.7%	69
مجموع المشاهدات	100%	249

المصدر: مخرجات برنامج (*SPSS-25*)

يتضح من خلال الجدول أعلاه أن إجمالي المشاهدات يبلغ 249، حيث خصص منها (180) مشاهدة، ونسبة (72.3%) كمجموعة تدريب، و (69) مشاهدة ونسبة (27.7%) كمجموعة اختبار.

- تحديد المعيارية:


أولا قمنا بتحويل البيانات الأصلية إلى بيانات معيارية باستخدام الدرجة المعيارية التالية:

المدخلات أي (1,2...,12) $x_{scaled} = \frac{x-x_{min}}{x_{max}-x_{min}}$ لتحديد معمارية الشبكة العصبية المثلى، فقد تم تجريب عدد من

حيث يتم تغيير عدد العقد في الطبقة المخفية في كل مرة، كما يتم استخدام دالة التنشيط المناسبة لذلك في نفس الوقت، من أجل الحصول على الأوزان المثلى التي تعطي أقل مجموع مربعات الأخطاء. تم عرض مجموعة من الأشكال الممكنة للشبكة العصبية، ومن خلال التجربة تبين أن النموذج الأنسب الذي يعطي أقل قيمة لمجموع مربعات الأخطاء (SSE) هو MLP(3,1,1) والممثل في الشكل أدناه:

الشكل 5-8: نموذج الشبكة العصبية لبيانات أسعار الذهب التي تم إدخال عليها اللوغاريتم الطبيعي (LGP)

— Synaptic Weight > 0
— Synaptic Weight < 0



Hidden layer activation function: Hyperbolic tangent

Output layer activation function: Identity

المصدر : مخرجات برنامج (SPSS – 25)

ومن خلال هذا الشكل نلاحظ أن أحسن معمارية للشبكة العصبية تتكون من ثلاثة طبقات وهي طبقة المدخلات وطبقة المخفية وطبقة المخرجات وتوزع فيها العصبونات كالآتي :

طبقة المدخلات : إشملت على ثلاثة وحدات معالجة والمتمثلة في رقم الإبطاء ثلاثة $(y_{t-1}, y_{t-2}, y_{t-3})$ حيث تم تحديده بالاعتماد على دالة الخطأ ممثلة في مجموع مربع الأخطاء .

طبقة المخفية : تحتوي على وحدة معالجة واحدة .

طبقة المخرجات : تحتوي على وحدة معالجة واحدة .

ترتبط هذه الطبقات فيما بينها بوصلات تحمل الأوزان .

كما تم استخدام دالة التنشيط *Hyperbolic tangent* الغير الخطية في الطبقة المخفية حيث تأخذ القيم $[-1, +1]$ ودالة التنشيط *Identity* الخطية في طبقة المخرجات والتي تأخذ القيم من $(-\infty, +\infty)$.

❖ ملخص النموذج :

الجدول 5-12: يبين مجموع مربعات الأخطاء ونسبة الخطأ البالغة في مرحلة التدريب ومرحلة الاختبار.


خطأ نسبي (Relative Error)	مجموع مربعات الأخطاء (SSE)	
0.155	0.348	التدريب
0.005	0.004	الاختبار

المصدر : مخرجات برنامج (SPSS – 25)

وبناء على النتائج التي تم التوصل إليها سوف نعرض النتائج النهائية لعملية التدريب والاختبار

لشبكة (MLPNN) من خلال الشكل الموالي :

الشكل 9-5: القيم الأصلية مع القيم المتنبأ بها




المصدر: مخرجات برنامج (SPSS – 25)

يبين الشكل أعلاه سحابة النقاط لقيم التنبؤية على المحور (y) والقيم الأصلية على المحور (x) لعينات التدريب والاختبار. حيث من الناحية المثالية يجب على القيم أن تقع على طول خط 45 درجة من نقطة الأصل .

وبالنظر إلى المخطط البياني نلاحظ أن القيم الفعلية للسلسلة الأصلية تحاكي القيم التنبؤية (مخرجات الشبكة) بنسبة كبيرة لأسعار الذهب العالمية لكل من مرحلتي التدريب والاختبار، أي أن القيم المقدرة لمعلمة المخرجات أقرب إلى القيم الفعلية وبالتالي تكون الأخطاء صغيرة والعكس صحيح، يعني هناك علاقة إيجابية قوية بين مجموعتي القيم. ومنه التنبؤ الذي أجرته الشبكة العصبية (MLPNN) يشير إلى الأداء الجيد وكذا جودة نموذج الشبكة العصبية الذي تم إختياره، مما يمكن الاعتماد عليه للتنبؤ بأسعار الذهب.

الشكل 10-5: المخطط البياني للبواقي والقيم المتنبأ بها



المصدر: مخرجات برنامج (SPSS – 25)

الشكل أعلاه يبيّن المخطط البياني للبواقي مع القيم المقدرة حيث يعرض هذا المخطط سحابة نقاط البواقي (القيمة الفعلية مطروح منها القيمة المتنبأ بها) على المحور x وقيمة التنبؤ على المحور y .

فمن خلال هذا الشكل نلاحظ أن انتشار البواقي مع القيم المقدرة تأخذ الشكل العشوائي على جانبي الخط الذي يمثل الصفر (الخط الذي يفصل بين البواقي الموجبة والسالبة).

5-2-1-2: التنبؤ باستخدام الشبكة العصبية دالة الأساس الشعاعي (RBFNN):

ومن أجل تطبيق الشبكة العصبية دالة الأساس الشعاعي للتنبؤ بأسعار الذهب التي تم إدخال اللوغاريتم (LGP) عليها، سنقوم باتباع الخطوات التالية:

مرحلة تقسيم البيانات:

بالاعتماد على برنامج SPSS-25 تم تقسيم المدخلات إلى جزأين، حيث تمت عملية توزيع

المشاهدات بشكل عشوائي، والجدول 13-5 يوضح عدد مشاهدات كل مجموعة ونسبتها:

الجدول 13-5: نتائج تقسيم البيانات

عدد المشاهدات	نسبة المشاهدات	المجموعة
164	65.9%	مجموعة التدريب
85	34.1 %	مجموعة الاختبار
249	100%	مجموع المشاهدات

المصدر: مخرجات برنامج (SPSS-25)

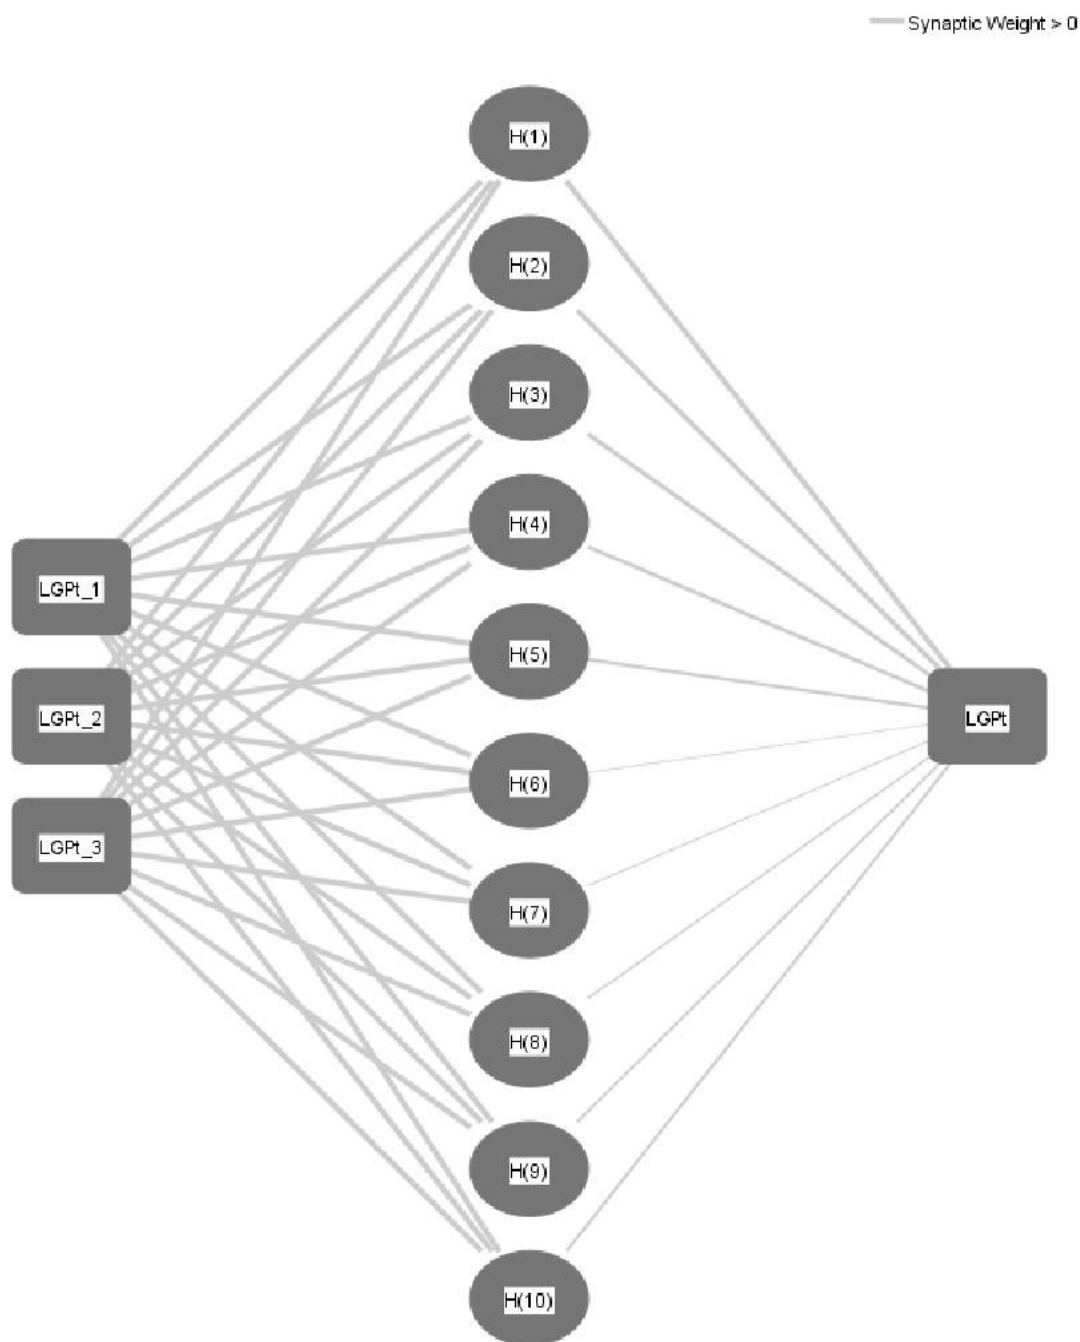
نلاحظ خلال الجدول أعلاه أن مجموعة التدريب خصص لها (164) مشاهدة وبنسبة (65.9%)، ومجموعة الاختبار تضمنت (85) مشاهدة وبنسبة (34.1%) أي إجمالي المشاهدات مكونة لعينة الدراسة هو 249 مشاهدة.

تحديد المعمارية:

تم عرض مجموعة من الأشكال الممكنة للشبكة العصبية من أجل تحديد معمارية الشبكة، ومن أجل المفاضلة بين هذه الأشكال فتم الاعتماد على معيار مجموع مربعات الأخطاء (SSE) لاختيار الأفضل.

ومن خلال التجربة تبين أن النموذج الأنسب الذي يعطي أقل قيمة لمجموع مربعات الأخطاء (SSE) هو $RBFFNN(3,10,1)$ والممثل في الشكل (11-5).

الشكل 5-11: نموذج الشبكة العصبية لبيانات أسعار الذهب التي تم إدخال عليها اللوغاريتم الطبيعي (LGP)



Hidden layer activation function: Softmax

Output layer activation function: Identity

المصدر : مخرجات برنامج (SPSS-25)

نلاحظ من خلال هذا الشكل أن أحسن معمارية للشبكة العصبية تتكون من ثلاثة طبقات: وهي طبقة المدخلات وطبقة المخفية وطبقة المخرجات وتتوزع فيها العصبونات كالآتي:

- طبقة المدخلات: اشتملت على ثلاثة وحدات معالجة والمتمثلة في رقم الإبطاء ثلاثة $(y_{t-1}, y_{t-2}, y_{t-3})$ ، حيث تم تحديده بالاعتماد على دالة الخطأ ممثلة في مجموع الأخطاء.
- طبقة المخفية: تحتوي على عشرة وحدات معالجة.
- طبقة المخرجات: تحتوي على وحدة معالجة واحدة.

كما تم استخدام دالة التنشيط الغير الخطية *Normalized radial basis fonction* في الطبقة المخفية. ودالة التنشيط *Identity* الخطية في طبقة المخرجات.

❖ ملخص النموذج :


الجدول 5-14: يبين مجموع مربعات الأخطاء ونسبة الخطأ البالغة في مرحلة التدريب ومرحلة الاختبار.

خطء نسبي (Relative Error)	مجموع مربعات الأخطاء (SSE)	
0.054	0.060	التدريب
0.015	0.007	الاختبار

المصدر : مخرجات برنامج (SPSS-25)

وبناء على النتائج التي تم التوصل إليها سوف نعرض النتائج النهائية لعملية التدريب والاختبار لشبكة (*RBFNN*) من خلال الشكل الموالي :

الشكل 5-12: القيم الأصلية مع القيم المتنبأ بها




المصدر : مخرجات برنامج (SPSS-25)

يوضح الشكل أعلاه سحابة النقاط لقيم التنبؤية على المحور (y) والقيم الأصلية على المحور (x) لعينات التدريب والاختبار. حيث من الناحية المثالية يجب على القيم أن تقع على طول خط 45 درجة من نقطة الأصل .

وبالنظر إلى المخطط البياني نلاحظ أن القيم الفعلية للسلسلة الأصلية تحاكي القيم التنبؤية (مخرجات الشبكة) بنسبة كبيرة لأسعار الذهب العالمية لكل من مرحلتَي التدريب والاختبار؛ مما يعني الانتشار الأصغر لنقاط النتيجة، أي أن القيم المقدرة لمعلمة المخرجات أقرب إلى القيم الفعلية وبالتالي تكون الأخطاء صغيرة والعكس صحيح. ومنه التنبؤ الذي أجرته الشبكة العصبية ($RBFNN$) يشير إلى الأداء الجيد وكذا جودة نموذج الشبكة العصبية الذي تم اختياره، مما يمكن الاعتماد عليه للتنبؤ بأسعار الذهب.

الشكل 5-13: المخطط البياني للبواقي والقيم المتنبأ بها



المصدر : مخرجات برنامج (SPSS-25)

يوضح الشكل أعلاه الرسم البياني للبواقي مع القيم المقدرة حيث يعرض هذا الشكل سحابة نقاط البواقي (القيمة الفعلية مطروح منها القيمة المتنبأ بها) على المحور y وقيمة التنبؤ على المحور x .

فمن خلال هذا الشكل نلاحظ أن جميع النقاط متناظرة وعمودية بالنسبة للصفر إلى حد كبير عكس الشبكة العصبية متعددة الطبقات بيرسبترون، وهذا مما يزيد من دقة النموذج المختار للشبكة العصبية دالة الأساس الشعاعي للتنبؤ .

5-2-2: المفاضلة بين نموذج ($ARIMA - GARCH$) ونموذج الشبكة العصبية (MLP) ونموذج الشبكة العصبية (RBF):

بداية قمنا بتحليل البيانات باستخدام نماذج $ARIMA$ الخطية المعروفة بمنهجية $Box - Jenkins$ وتم اختيار النموذج $(1,1)(11,1,0) - GARCH - ARIMA$ من بين عدة نماذج وإضافة إلى ذلك نموذج الشبكة العصبية $(3,1,1) - MLP$ ونموذج الشبكة العصبية $(3,10,1) - RBFNN$ الغير الخطية، ومن أجل معرفة النماذج التي لديها الأفضلية من حيث دقة التنبؤ بالقيم المستقبلية لأسعار الذهب العالمية، تم الاعتماد على مقياس دقة التنبؤ $RMSE$ في كل من مرحلة التدريب والاختيار، والنتائج المتوصل إليها مدونة في الجدول التالي:

الجدول 5-15: المفاضلة بين نموذج ($ARIMA - GARCH$) ونماذج الشبكات العصبية ($MLPNN, RBF$)

مرحلة الاختيار	مرحلة التدريب	النماذج
0.031331	0.038557	$ARIMA - GARCH$
0.0473	0.04396	$MLPNN$
0.0252	0.0192	$RBFNN$

المصدر: مخرجات SPSS-25

يتبين من خلال الجدول أعلاه، عند إجراء المفاضلة بين النموذج الخطي $(1,1)(11,1,0) - GARCH - ARIMA$ وبين النماذج الغير الخطية $RBFNN$ و MLP ، إن النموذج الأفضل من حيث مرحلة التدريب والاختبار وفقا لمقياس دقة التنبؤ ($RMSE$) هو نموذج الشبكة العصبية دالة الأساس الشعاعي ($RBFNN$) وهو أكثر دقة من نموذج ($MLPNN$) ونموذج $ARIMA - GARCH$ مما يثبت صحة الفرضية، كما أن نموذج $ARIMA - GARCH$ أفضل من نموذج ($MLPNN$) وهذا وفقا لمقياس دقة التنبؤ في كل من مرحلة التدريب والاختبار.

3-2-5: التنبؤ باستخدام النماذج الهجينة:

سوف نقوم في هذا القسم بتنفيذ مفهوم الجمع بين التنبؤين اللذان تحصلا على أقل قيمة لمعيار دقة التنبؤ، وهما نموذج $ARIMA - GARCH$ ونموذج $(RBFNN)$ حيث سنقوم باستخدام الطرق الهجينة التي تم التطرق إليها في الجانب النظري للتنبؤ بأسعار الذهب العالمية.

ووفقا لنموذج (Zhang, 2003) الهجين، يفترض أن تتكون أي سلسلة زمنية من أنماط خطية وغير خطية. حيث يمكن التعامل مع الأنماط الخطية بطريقة خطية مثل نماذج $ARIMA$ ، بينما يمكن نمذجة الأنماط غير الخطية بطريقة غير خطية مثل ANN .

ووفقا لنموذج (Kashei&Bijary, 2011) الهجين المعمم، فهو لا يفترض توفر افتراضات مسبقة، حيث هذا النموذج ينظر لسلسلة الزمنية على أنها دالة في مركبتين: الأول خطي والثاني غير خطي.

سيتم في التحليل كذلك الاعتماد على نفس طريقة تقسيم البيانات إلى مجموعتين: مجموعة تدريب ومجموعة اختبار ونفس السلسلة الزمنية التي تم ادخال عليها اللوغاريتم الطبيعي.

1-3-2-5: التنبؤ باستخدام نموذج Zhang الهجين:

بالاعتماد على برنامج SPSS- 25 تم تقسيم المدخلات إلى جزأين، حيث تم عملية توزيع المشاهدات كان بشكل عشوائي، والجدول (5-16) يوضح عدد مشاهدات كل مجموعة ونسبتها:

الجدول 5-16: نتائج تقسيم البيانات

عدد المشاهدات	نسبة المشاهدات	المجموعة
164	68.9%	مجموعة التدريب
74	31.1%	مجموعة الاختبار
238	100%	مجموع المشاهدات

❖ المصدر: مخرجات برنامج (SPSS-25)

نلاحظ خلال الجدول أعلاه أن مجموعة التدريب خصص لها (164) مشاهدة وبنسبة (68.9%) ومجموعة الاختبار تضمنت (74) مشاهدة وبنسبة (31.1%)، أي إجمالي المشاهدات مكونة لعينة الدراسة هو 238 مشاهدة.

بناء النموذج الهجين :

في هذا النموذج يتم استخدام البواقي المستخرجة من نموذج $ARIMA - GARCH$ لبناء الشبكة العصبية $RBNN$ وهذا وفقا للخطوات التالية :

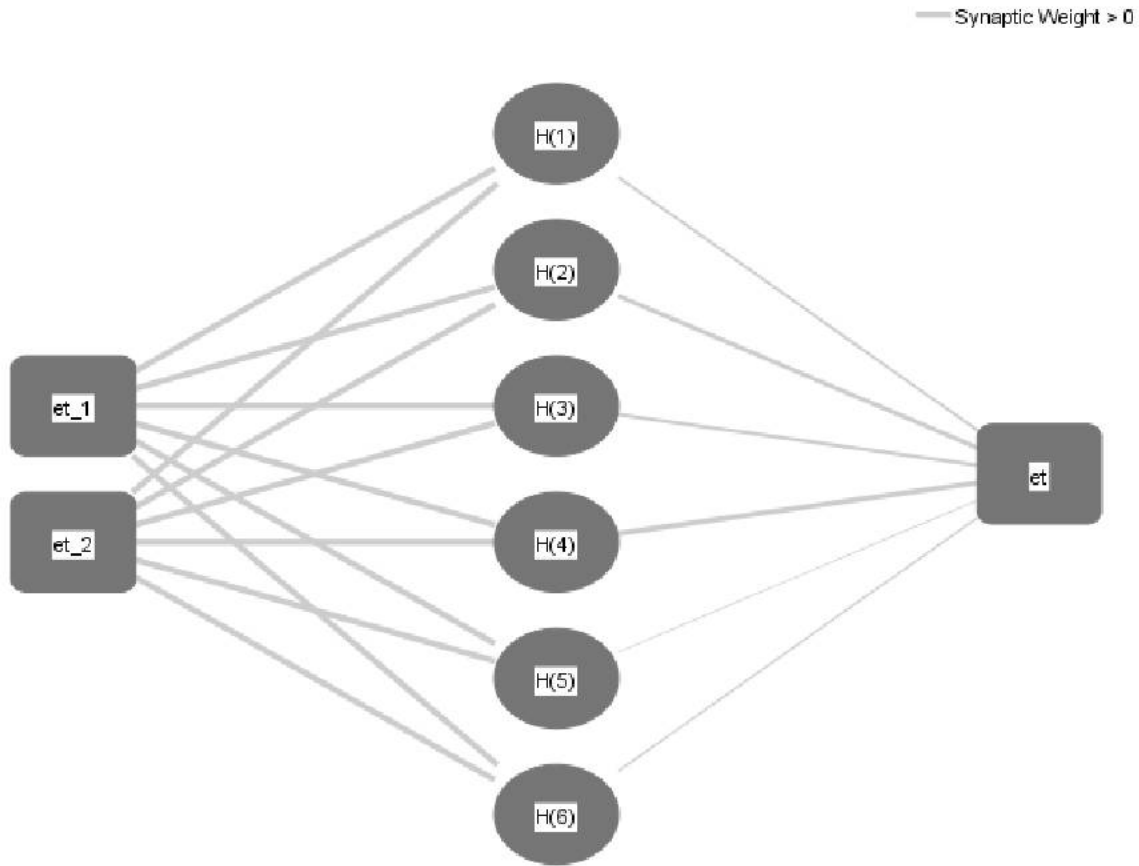
الخطوة الأولى من النمذجة الهجينة هي الحصول على القيم المتنبأ بها من نموذج $ARIMA - GARCH(11,1,0)(1,1)$ والتي يرمز لها (\hat{L}_t) الذي تم اختياره ليمثل السلسلة الزمنية محل الدراسة. أما الخطوة الثانية فهي نمذجة البواقي باستخدام نموذج الشبكة العصبية دالة الأساس الشعاعي ($RBNN$) والذي يعتمد على تباطؤين لسلسلة البواقي من نموذج $ARIMA - GARCH$ والذي هو موضح في الشكل (14-5).

وبعد تقدير الأنماط الغير الخطية الموجودة في سلسلة البواقي (\hat{N}_t) .

تأتي الخطوة الاخيرة من نموذج (Zhang) الهجين وهي الجمع بين تنبؤات من نموذج $ARIMA - GARCH(11,1,0)(1,1)$ مع التنبؤات من نموذج الشبكات العصبية $RBNN(2,6,1)$ للحصول على القيم المتنبأ بها \hat{y}_t والتي تكتب على النحو التالي :

$$\hat{y}_t = \hat{L}_t + \hat{N}_t$$

الشكل 14-5: معمارية الشبكة العصبية (RBF)



Hidden layer activation function: Softmax

Output layer activation function: Identity

المصدر : مخرجات برنامج (SPSS-25)

يعرض الشكل أعلاه أحسن معمارية للشبكة العصبية (RBFNN) لسلسلة البواقى التي تتكون من ثلاثة طبقات وهي طبقة المدخلات وطبقة المخفية وطبقة المخرجات وتتوزع فيها العصبونات كالآتي :

- طبقة المدخلات : اشتملت على وحدتي معالجة والمتمثلة في رقم الإبطاء اثنان، حيث تم تحديدها بالاعتماد على دالة الخطأ ممثلة في مجموع مربع الأخطاء .
- طبقة المخفية : تحتوي على ستة وحدات معالجة .
- طبقة المخرجات : تحتوي على وحدة معالجة واحدة .

كما تم استخدام دالة التنشيط الغير الخطية *Normalized radial basis fonction* في الطبقة المخفية. ودالة التنشيط *Identity* الخطية في طبقة المخرجات.

ملخص النموذج :

الجدول (5-17) يبين مجموع مربعات الأخطاء ونسبة الخطأ البالغة في مرحلة التدريب ومرحلة الاختبار لنموذج الهجين .

الجدول 5-17: يبين مجموع مربعات الأخطاء ونسبة الخطأ البالغة في مرحلة التدريب ومرحلة الاختبار لنموذج الهجين .

خطء نسبي (Relative Error)	مجموع مربعات الأخطاء (SSE)	
0.890	2.461	التدريب
1.089	2.268	الاختبار

المصدر: مخرجات برنامج (SPSS-25)

5-2-3-2: التنبؤ باستخدام نموذج (Khashet&Bijary, 2011) الهجين المعمم :

بالاعتماد على برنامج SPSS-25 تم تقسيم المدخلات إلى جزأين، حيث تم عملية توزيع المشاهدات كان بشكل عشوائي، والجدول (5-18) يوضح عدد مشاهدات كل مجموعة ونسبتها :

الجدول 5-18: نتائج تقسيم البيانات

عدد المشاهدات	نسبة المشاهدات	المجموعة
161	67.6%	مجموعة التدريب
77	32.4 %	مجموعة الاختبار
238	100%	مجموع المشاهدات

المصدر: مخرجات برنامج (SPSS-25)

نلاحظ من خلال الجدول أعلاه أن مجموعة التدريب خصص لها (161) مشاهدة وبنسبة (61.6%) ومجموعة الاختبار تضمنت (77) مشاهدة وبنسبة (32.4%) أي إجمالي المشاهدات مكونة لعينة الدراسة هو 238 مشاهدة.

▪ بناء النموذج الهجين :

يتم بناء هذا النموذج وفقا للخطوات التالية :

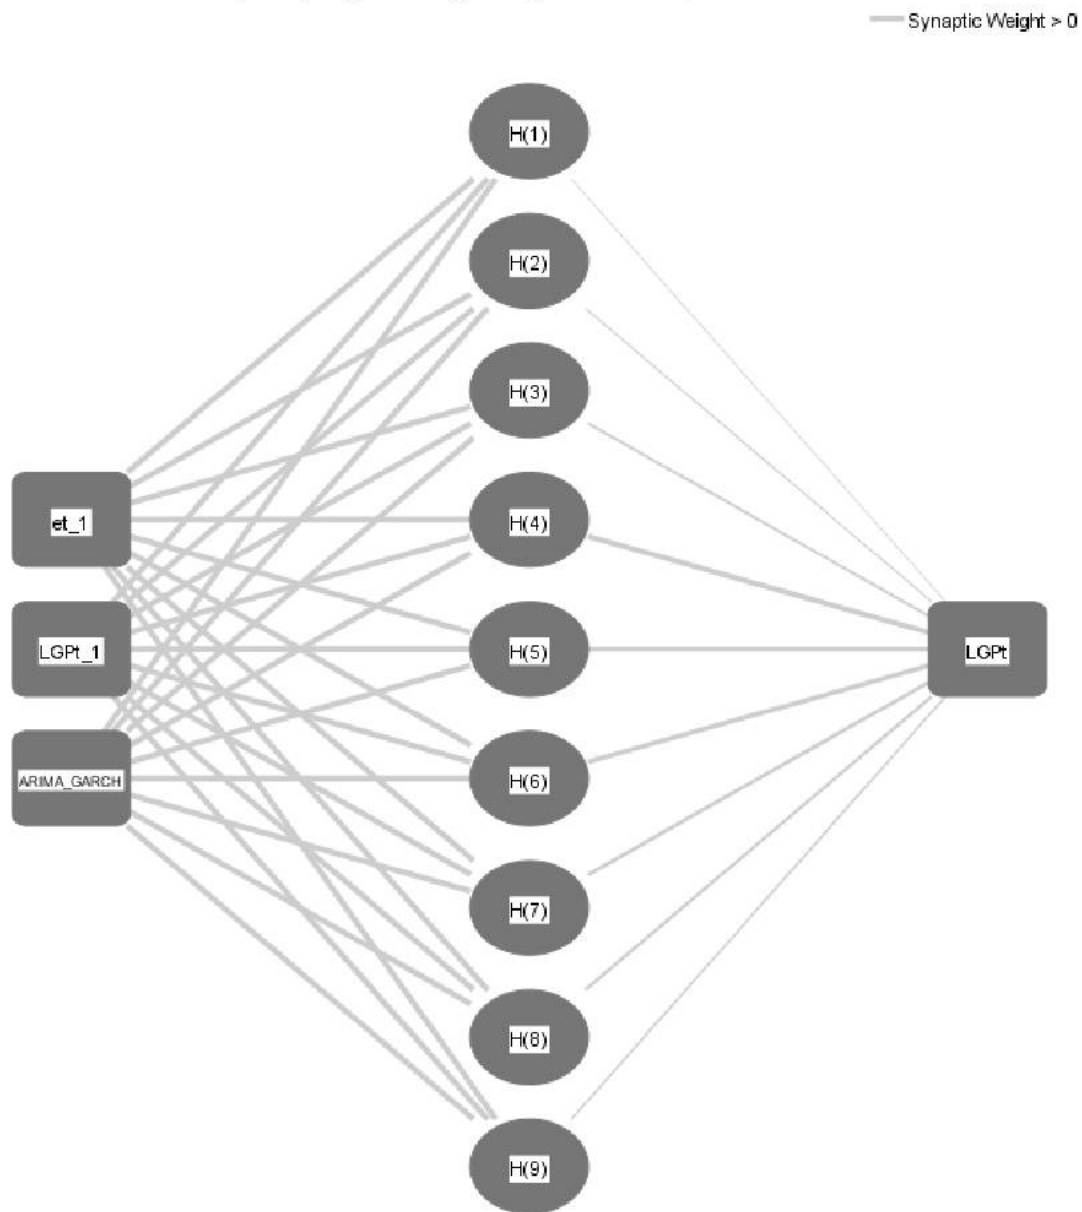
الخطوة الاولى يتم فيها يتم استخدام نموذج نموذج $ARIMA - GARCH(11,1,0)(1,1)$ لنمذجة المركبة الخطية من أجل تحديد القيم المقدرة (\hat{L}_t) والبواقي السابقة (e_{t-1}) من نموذج $ARIMA - GARCH$.

أما الخطوة الثانية فهي استخدام نموذج الشبكة العصبية دالة الأساس الشعاعي ($RBFFNN$) للنمذجة الغير خطية، حيث تستخدم المشاهدات السابقة (LGP_{t-1}) والقيم المقدرة (\hat{L}_t) والبواقي السابقة (e_{t-1}) من نموذج $ARIMA - GARCH$ والذي هو موضح في الشكل 5-15. تأتي الخطوة الأخيرة من نموذج الهجين المعمم ويأخذ نموذج الجمع الشكل التالي:

$$y_t = f(\hat{L}_t, e_{t-1}, \dots, e_{t-n}, y_{t-1}, \dots, y_{t-m})$$

$$ARIMA - GARCH(11,1,0)(1,1)(3,9,1)$$

الشكل 5-15: معمارية الشبكة العصبية (RBF)



Hidden layer activation function: Softmax

Output layer activation function: Identity

المصدر : مخرجات برنامج (SPSS-25)

يوضح الشكل أعلاه أحسن معمارية للشبكة العصبية (RBFNN) التي تتكون من ثلاثة طبقات

وهي طبقة المدخلات وطبقة المخفية وطبقة المخرجات وتوزع فيها العصبونات كالآتي :

طبقة المدخلات : اشتملت على ثلاثة وحدات معالجة والمتمثلة في المشاهدات السابقة (LGP_{t-1}) والقيم المقدرة (\hat{L}_t) والبواقي السابقة (e_{t-1}) من نموذج $ARIMA - GARCH$ حيث تم تحديدها بالاعتماد على دالة الخطأ ممثلة في مجموع مربع الأخطاء .

طبقة المخفية: تحتوي على تسعة وحدات معالجة .

طبقة المخرجات : تحتوي على وحدة معالجة واحدة .

كما تم استخدام دالة التنشيط الغير الخطية *Normalized radial basis function* في الطبقة المخفية. ودالة التنشيط *Identity* الخطية في طبقة المخرجات.

❖ ملخص النموذج :

الجدول 5-19: يبين مجموع مربعات الأخطاء ونسبة الخطأ البالغة في مرحلة التدريب ومرحلة الاختبار لنموذج الهجين .

خطء نسبي (Relative Error)	مجموع مربعات الأخطاء (SSE)	
0.025	0.170	التدريب
0.021	0.061	الاختبار

المصدر: مخرجات برنامج (SPSS-25)

5-2-3-3 : المفاضلة بين النماذج الهجينة :

من أجل المفاضلة بين نموذج Zhang الهجين ونموذج (Khashei&bijary, 2011) الهجين المعمم، تم الاعتماد على مقياس دقة التنبؤ $RMSE$ في كل من مرحلة التدريب والاختبار، من أجل معرفة النموذج الهجين الذي لديه الافضلية من حيث دقة التنبؤ بالقيم المستقبلية لاسعار الذهب العالمية والنتائج المتوصل اليها موضحة في الجدول التالي :

الجدول 5-20: المفاضلة بين نموذج Zhang الهجين ونموذج (Khashei&bijary, 2011) الهجين المعمم

$RMSE$ مرحلة الاختبار	$RMSE$ مرحلة التدريب	النماذج الهجينة
0.028767	0.037351	نموذج Zhang الهجين
0.028146	0.03249	نموذج (Kashei&bijary, 2011) الهجين المعمم

المصدر: مخرجات برنامج (SPSS-25)

يتضح من خلال الجدول أعلاه، أن نموذج (Khashei&bijary,2011) الهجين المعمم هو الأفضل من حيث مرحلة التدريب والاختبار وفقاً لمقياس دقة التنبؤ (RMSE) مقارنة مع نموذج Zhang الهجين.

3-5: المفاضلة بين النماذج الخمسة :

وأخيراً تم الوصول إلى المرحلة الأخيرة وهي المفاضلة بين النماذج التي اختيرت من بين أفضل نماذج: (1,1) ARIMA – GARCH(11,1,0) و MLP(3,1,1) و RBFNN(3,10,1) والنموذج الهجين لـ Zhang, 2003 والنموذج الهجين لـ Khashei & Bijari, 2011، حيث تضمن إنجاز تحليل هذه المقارنة لدقة أداء كل من مرحلة التدريب ومرحلة الاختبار لهذه النماذج باستخدام معيار جذر متوسط مربعات الأخطاء (RMSE)، حيث كلما كانت قيم الخطأ أصغر، كان الأداء أفضل والقيم المتوقعة أقرب إلى القيم الفعلية. والجدول أدناه يبيّن قيم معيار المفاضلة بين النماذج الخمسة :

الجدول 5-21: قيم معيار المفاضلة بين النماذج الخمسة

RMSE مرحلة الاختبار	RMSE مرحلة التدريب	النماذج
0.031331	0.038557	ARIMA – GARCH(11,1,0)(1,1)
0.0473	0.04396	MLP(3,1,1)
0.0252	0.0192	RBFNN(3,10,1)
0.028767	0.037351	نموذج Zhang ARIMA – GARCH(11,1,0)(1,1) RBFNN(3,10,1)
0.028146	0.03249	نموذج Khashei and Bijari

المصدر: مخرجات برنامج (SPSS-25)

نلاحظ من خلال نتائج هذا الجدول أن جميع النتائج متقاربة حيث :
يعمل نموذج الشبكة العصبية RBFNN(1,10,1) في كل من مرحلة التدريب ومرحلة الاختبار بشكل أفضل مقارنة مع نموذج MLP وفقاً للمعيار دقة الأداء.
يعتبر نموذج الشبكة العصبية RBFNN(1,10,1) أفضل من النماذج الهجينة في كلا المرحلتين.

يتميز نموذج نموذج الشبكة العصبية $RBNN(1,10,1)$ بأداء أفضل من نموذج $ARIMA - GARCH$ في كل من مرحلة التدريب والاختبار باستخدام هذا المعيار.

يعد نموذج $Khashei and Bijari$ الهجين أفضل من نموذج $Zhang$ الهجين ونموذج MLP ونموذج $ARIMA - GARCH$ حسب معيار دقة التنبؤ.

نموذج $Zhang$ أفضل من نموذج $MLPNN$ ونموذج $ARIMA - GARCH$ في كل من مرحلة التدريب ومرحلة الاختبار حسب معيار دقة التنبؤ.

يعتبر نموذج $ARIMA - GARCH$ أفضل من نموذج $MLPNN$ في كلا المرحلتين وفقاً للمعيار دقة الأداء.


وأخيراً، يمكن الاستنتاج من المناقشة أعلاه أن نتائج الشبكة العصبية ($RBNN$) كانت أكثر دقة مع أقل قيمة لمعيار $RMSE$ وأن نموذج الشبكة العصبية ($RBNN$) يعد تقنية التنبؤ الأكثر كفاءة لسعر الذهب الشهري من النماذج المستعملة في هذه الدراسة.

4-5 : مقارنة بين القيم الفعلية مأخوذة باللوغاريتم والقيم المتنبأ بها باستخدام النماذج السابقة :

من أجل توضيح مدى تقارب القيم الفعلية لسعر الذهب الشهري مع القيم المتنبأ بها باستخدام كل نوع من النماذج المستخدمة .

قمنا بتمثيل بياني لسلسلة الأصلية لسعر الذهب الشهري ومقارنتها بالسلاسل المتنبأ بها باستخدام النماذج الخمسة فتحصلنا على الشكل التالي :

الشكل 5-16: تمثيل بياني لسعر الذهب الشهري الفعلي مأخوذة باللوغاريتم والقيم المتنبأ بها باستخدام النماذج السابقة



المصدر : مخرجات برنامج (SPSS-25)

نلاحظ من خلال الشكل أعلاه وجود تقارب كبير بين السلسلة الأصلية والسلسلة المستخرجة عن طريق الشبكة العصبية ذات دالة الأساس الشعاعي (RBFNN) مقارنة بالنماذج الأخرى المستخدمة مما يعكس دقة ونجاعة وأداء هذه الشبكة في التنبؤ بأسعار الذهب العالمية .

خلاصة :

من خلال هذا الفصل التطبيقي تطرقنا إلى التنبؤ بأسعار الذهب الشهرية بالاعتماد على خمسة نماذج مقترحة من أجل المفاضلة بينها، حيث تم استخدام منهجية *Box - Jenkins* والمعروفة بنماذج *ARIMA* بمراحلها الأربعة المتبعة لتحليل السلاسل الزمنية من خلال دراسة استقرارية السلسلة، وتأتي مرحلة تحديد النموذج الذي تمثل في نموذج *ARIMA(11,1,0)* ليتم بعد ذلك مرحلة تقدير النموذج وتليها مرحلة التشخيص والتي يتم فيها التحقق من النموذج المستخدم، وذلك بإخضاعه لعدد من الاختيارات، فعند إجراء اختبار ثبات التباين لبواقي النموذج المقدر، تبين أن هناك أثراً لعدم ثبات التباين في بواقي النموذج المقدر، وبعد إثبات وجود أثر *ARCH* في البواقي تم إجراء المفاضلة بين عدة نماذج من عائلة *GARCH* فتبين أن النموذج *GARCH(1,1)* هو الأفضل كونه أعطى أقل قيمة للمعيارين *AIC* و *SC*. وآخر مرحلة وفق هذه المنهجية هي مرحلة التنبؤ بالنموذج الذي تم اختياره *ARIMA(11,1,0) - GARCH(1,1)* للتنبؤ بالقيم المستقبلية لأسعار الذهب الشهرية.

بعد ذلك انتقلنا إلى التنبؤ بنوعين من الشبكات العصبية الاصطناعية ذات التغذية الأمامية، ألا وهما الشبكة العصبية *MLP* حيث تبين أن النموذج الأنسب الذي يعطي أقل قيمة لمجموع مربعات الأخطاء (*SSE*) هو *MLP(3,1,1)*، أما النوع الثاني فيتمثل في الشبكة العصبية *RBFNN* والنموذج الأنسب الخاص بهذا النوع هو *RBFNN(3,10,1)*، الذي أعطى أقل قيمة لمجموع مربعات الأخطاء (*SSE*).

بعد المفاضلة بين النماذج الثلاثة بالاعتماد على مقياس دقة التنبؤ *RMSE* في كل من مرحلة التدريب والاختيار اتضح أن الشبكة العصبية *RBFNN* هي الأفضل مقارنة مع باقي النماذج الأخرى، كما تبين أن نموذج *ARIMA - GARCH* أفضل من نموذج *MLPNN*.

ثم بعدها انتقلنا إلى التنبؤ بأسعار الذهب باستخدام طريقتين من النماذج الهجينة، فالنموذج الأول تمثل في نموذج *Zhang 2003* والنموذج الثاني هو نموذج *Khashei and Bijari 2011* الهجين المعمم والذي جمع بين نموذج *ARIMA - GARCH* ونموذج *RBFNN*، ومن أجل

المفاضلة بينهما تم الاعتماد على مقياس دقة التنبؤ $RMSE$ في كل من مرحلة التدريب والاختيار، تبين أن نموذج *Khashei and Bijari* المهجين المعمم هو الأفضل والأكثر دقة مقارنة من نموذج *Zhang 2003*.

أخيراً، ومن أجل اختيار النموذج الذي بإمكانه تقديم تنبؤ دقيق لأسعار الذهب العالمية تم التوصل إلى أنّ الشبكة العصبية دالة الأساس الشعاعي $RBFFNN$ تفوقت على النماذج الأخرى وهذا من خلال إعطائها أصغر قيمة لجذر متوسط مربعات الأخطاء ($RMSE$).

الخاتمة العامة

يعد الذهب أحد أهم السلع في العالم، حيث يعتبر السلعة الوحيدة التي تحتفظ بقيمتها خلال جميع فترات الأزمات سواء كانت اقتصادية، أو المالية أو السياسية.

فاعتبر الذهب كأحد أفضل مؤشرات أداء السوق، لها قيمة نقدية وتطلبها البنوك المركزية لتكون جزءاً من احتياطياتها الدولية والتي تحقق العديد من الأغراض، كما لها استخدامات صناعية ويمكن تحويلها إلى مجوهرات.

ففي التمويل الحديث يتم استخدامه كأداة تحوط ضد التضخم وملاذ آمن أثناء الأزمات (استثمار)، ولهذا يلعب سعر الذهب دوراً مهماً في الأنظمة الاقتصادية والنقدية، فهو مؤثر مشترك للعديد من العوامل، حيث يتسم بالعشوائية وعدم اليقين واللاخطية، كما أن تذبذبه شديد للغاية، لذا أصبحت كيفية التنبؤ الدقيق لسعر الذهب موضوعاً ساخناً يثير قلق جميع البلدان، وهدفاً مهماً للعديد من الاقتصاديين، فليس للتحقيق مكاسب مالية فحسب وإنما أيضاً لتشكيل سياسات مالية واستثمارية لكل من الخواص والحكومة. فيساعد التنبؤ الدقيق لأسعار الذهب على التنبؤ بظروف الاتجاهات في المستقبل.

وعليه تم تطوير وتنفيذ عدة طرق للتنبؤ بسعر الذهب؛ فيمكن تصنيف طرق التنبؤ إلى ثلاث طرق رئيسية:

النموذج الرياضي التقليدي مثل نماذج (ARIMA)،

الذكاء الاصطناعي مثل الشبكات العصبية الاصطناعية (ANN)،

النماذج الهجينة.

ومن خلال كل هذا ظهرت الحاجة إلى استخدام أساليب كمية تعطي نتائج قريبة من الواقع، ومنه تمحورت إشكالية الأطروحة حول ما مدى فعالية الشبكة العصبية ذات دوال الأساس الشعاعي في التنبؤ بأسعار الذهب العالمية.

فالجانب التطبيقي للأطروحة قد قمنا بتطبيق منهجية *Box-Jenkins* بالاستعانة ببرنامج

Eviews11، والشبكة العصبية دالة الأساس الشعاعي (RBFNN) والنماذج الهجينة

بالاستعانة ببرنامج SPSS 25 على السلسلة الزمنية لأسعار الذهب العالمية، وهذا للفترة الزمنية الممتدة من 01 جانفي 2000 إلى 31 ديسمبر 2019 (بالدولار الأمريكي لكل أوقية)، ومن أجل معرفة مدى جودة وكفاءة النموذج الأمثل تم الاعتماد على معيار جذر متوسط مربعات الأخطاء (RMSE) وذلك من أجل إثبات فرضيات البحث.

وفي مايلي يتم عرض أهم النتائج والاستنتاجات التي تم التوصل إليها:

الاستنتاجات:

من أجل الإجابة عن إشكالية الدراسة وفرضياتها نضع النتائج والاستنتاجات التالية:

تم تطبيق منهجية *Box – Jenkins* المعروفة بنماذج *ARIMA* على السلسلة الشهرية لأسعار الذهب العالمية للفترة الممتدة من 01-01-2000 إلى 31-12-2020 (بالدولار الأمريكي لكل أوقية) وتتكون من 252 مشاهدة لسعر الذهب الشهري، فقد تم تحويل البيانات الأصلية باستخدام اللوغاريتم الطبيعي من أجل تقليل القيم المتطرفة، كما تم دراسة استقرارية السلسلة الزمنية باستخدام اختبار ديكي-فولر المطور واختبار فيليبس بيرون لفحص استقرارية السلسلة الزمنية، فتبين من خلال النتائج أن السلسلة غير مستقرة، تم أخذ الفروقات من الدرجة الأولى وبينت النتائج أن السلسلة مستقرة وهي من الدرجة الأولى، تم ترشيح العديد من نماذج *ARIMA* وبالاعتماد على معيار *AIC* ومعيار *SC* تبين أن نموذج *ARIMA(11,1,0)*. ففي مرحلة الفحص تبين أثر لعدم ثبات التباين في بواقي النموذج المقدر؛ الأمر الذي استدعى إلى الاعتماد على نماذج *ARCH* من أجل تمثيل أخطاء نموذج *ARIMA(11,1,0)*. فبعد اقتراح عدة نماذج تبين أن النموذج *GARCH(1,1)* هو الأفضل كونه أعطى أقل قيمة للمعيارين *AIC* و *SC*.

فبعد تقدير النموذج *ARIMA(11,1,0) – GARCH(1,1)* وفحصه والتأكد من صلاحيته يمكن استخدامه للتنبؤ بالقيم المستقبلية لأسعار الذهب الشهرية.

وقد تم تطبيق نوعين من الشبكات العصبية الاصطناعية ذات التغذية الأمامية على السلسلة الشهرية لأسعار الذهب العالمية، التي تم إدخال اللوغاريتم عليها.

- الشبكة العصبية الأولى هي الشبكة العصبية متعددة الطبقات بيرسبترون ($MLPNN$)، حيث بينت النتائج أن الشبكة العصبية الأمثل التي يمكن استخدامها في التنبؤ بأسعار الذهب تتكون من ثلاثة طبقات مدخلات، وطبقة مخفية، وطبقة مخرجات.

- الشبكة العصبية الثانية وهي الشبكة العصبية دالة الأساس الشعاعي ($RBFFNN$)، حيث بينت النتائج الشبكة العصبية الأمثل التي يمكن الاعتماد عليها في التنبؤ بأسعار الذهب العالمية، تتكون من ثلاثة طبقات مدخلات، وعشرة طبقات مخفية، وطبقة واحدة للمخرجات.

بعد المقارنة بين النماذج الثلاثة وبالاعتماد على مقياس دقة التنبؤ $RMSE$ تبين أن نموذج الشبكة العصبية دالة الأساس الشعاعي ($RBFFNN$) أعطى نتائج أفضل مقارنة من نموذج ($MLPNN$)، ونموذج $ARIMA(11,1,0) - GARCH(1,1)$. كما أن نموذج $ARIMA - GARCH$ أفضل من نموذج ($MLPNN$) وهذا وفقا لمقياس دقة التنبؤ $RMSE$. عند تطبيق النماذج الهجينة لكل من نموذج $Zhang$ الهجين ونموذج ($Kashei\&Bijary, 2011$) الهجين المعمم. تبين أن النموذج الأول يتكون من طبقتين كمدخلات، وستة طبقات مخفية، وطبقة مخرجات، أما النموذج الثاني يتكون من ثلاثة طبقات كمدخلات، وتسع طبقات مخفية، وطبقة واحدة كمخرجات.

ولأجل المفاضلة بين نموذج $Zhang$ الهجين ونموذج ($Kashei\&bijary, 2011$) الهجين المعمم بالاعتماد على مقياس دقة التنبؤ $RMSE$ تبين أن النموذج ($Kashei\&bijary, 2011$) الهجين المعمم هو الأفضل وفقا لمقياس دقة التنبؤ ($RMSE$). أخيرا وبعد المفاضلة بين النماذج الخمسة باستخدام معيار جذر متوسط مربعات الأخطاء ($RMSE$) تبين أن نموذج الشبكة العصبية دالة الأساس الشعاعي ($RBFFNN$) هو الأفضل مقارنة مع النماذج الأخرى.

نتائج اختبار الفرضيات :

الفرضية الأولى: الشبكة العصبية ذات دالة الأساس الشعاعي تعطي تنبؤات دقيقة إذا كانت السلسلة الزمنية غير خطية.

نلاحظ من خلال تطبيق الشبكة العصبية ذات دالة الأساس الشعاعي (*RBFNN*) على البيانات الشهرية لأسعار الذهب العالمية (بالدولار الأمريكي لكل أوقية) للفترة الزمنية الممتدة من 01 جانفي 2000 إلى غاية 31 ديسمبر 2020، إن هذه الأداة تعطي تنبؤات دقيقة إذا كانت السلسلة الزمنية غير خطية وهذا ما أكدته نتائج قيم معيار دقة التنبؤ *RMSE*، مما يدل على صحة الفرضية الأولى.

الفرضية الثانية: تعطي الشبكة العصبية ذات دالة الأساس الشعاعي تنبؤات دقيقة مقارنة مع نموذج (*ARIMA*) والشبكة العصبية متعددة الطبقات *Perceptron*.

بعد تطبيق كل من منهجية *Box – Jenkins* ونموذج الشبكة العصبية متعددة الطبقات *Perceptron (MLPNN)* على البيانات الشهرية لأسعار الذهب العالمية (بالدولار الأمريكي لكل أوقية) لنفس الفترة موضوع الدراسة، وبالاعتماد على معيار دقة التنبؤ *RMSE* بينت النتائج أن الشبكة العصبية ذات دالة الأساس الشعاعي (*RBFNN*) أعطت نتائج أفضل وقدرة عالية في التنبؤ وذلك لامتلاكها أقل قيمة للمعيار *RMSE* مقارنة بنموذج (*MLPNN*) ونموذج (*ARIMA*)، مما يثبت صحة الفرضية الثانية.

الفرضية الثالثة: النموذج الهجين بين *ARIMA-RBFNN* يعطي تنبؤات دقيقة.

بعد تطبيق نموذج *Zhang* الهجين (2003) ونموذج *Khashei & bijary* الهجين المعمم (2011) على البيانات الشهرية لأسعار الذهب العالمية (بالدولار الأمريكي لكل أوقية) لنفس الفترة، توصلنا إلى أن هذه النماذج تعطي تنبؤات دقيقة، مما يثبت صحة الفرضية الثالثة.

توصيات :

من خلال هذه الدراسة ووفقا للنتائج التي تم التوصل إليها نوصي بما يلي :
من أجل التوصل إلى أفضل النماذج التي يمكن من خلالها نمذجة والتنبؤ بالظواهر الاقتصادية يجب استخدام المقارنة بين النماذج المعلمية والغير معلمية والمفاضلة بينهما.
استخدام نماذج أخرى من الشبكات العصبية ذات التغذية المتكررة للتنبؤ بأسعار الذهب ومقارنتها مع الشبكة العصبية ذات دالة الأساس الشعاعي .
كما نوصي باستخدام نماذج هجينة أخرى قد تعطي نتائج أكثر دقة.

الأفاق المستقبلية :

محاولة التنبؤ بسلسلة أسعار الذهب الأسبوعية واليومية باستخدام الشبكة العصبية ذات دالة الأساس الشعاعي .
العمل على تطبيق النماذج الهجينة التي تجمع بين الشبكات العصبية ذات دالة الأساس الشعاعي والخوارزميات الجينية للتنبؤ بأسعار الذهب العالمية.
توسيع نطاق استخدام الشبكة العصبية ذات دالة الأساس الشعاعي في مجالات اقتصادية أخرى.
محاولة التنبؤ بأسعار الذهب العالمية باستخدام الشبكة العصبية ذاكرة طويلة-قصيرة المدى (LSTM).

كما سنقوم بمحاولة تطبيق شبكة (GMDH) Group method of data handling للتنبؤ بأسعار الذهب العالمية.

قائمة المصادر والمراجع

أولا المراجع باللغة العربية

1. بثينة عبد الجادر عبد العزيز & علي طارق عبد المجيد. (2019). استخدام الانموذج الهجين (ERNN) SARIMA-ELMAN للتنبؤ بالمعدلات الشهرية لدرجات الحرارة العظمى لمدينة بغداد. مجلة الادارة والاقتصاد. (118), 270-284.
2. أحمد حلمي جمعة. استخدام الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في البيانات المالية : دراسة تطبيقية. المؤتمر العلمي السنوي الحادي عشر، ذكاء الأعمال واقتصاد المعرفة. جامعة الزيتونة الأردنية، كلية الاقتصاد والعلوم الإدارية. 23-32-نيسان (ابريل 2012). عمان- الأردن.
3. ألفت فتحي سالم أبو عابدة (2015)، استخدام الطرق الإحصائية في التنبؤ بأسعار الذهب العالمية، رسالة ماجستير، كلية الاقتصاد والعلوم الادارية، جامعة الازهر، غزة.
4. أمية غانم عبد الجبار. (2013). استخدام الشبكات العصبية الاصطناعية بخوارزميات مختلفة في نمذجة درجات حرارة التربة على اعماق واطاق مختلفة بدلالة بعض المعلومات المناخية. مجلة تكريت للعلوم الصرفة، 18(2)، 305-313.
5. إيمان محمد المشهداني، & جاسم محمد كاظم. (2016). استعمال نماذج بوكس وجنكنز للتنبؤ باعداد المرضى المصابين بمرض التهاب الكبد الفيروسي في العراق.
6. بختاوي فاطمة الزهراء، (2018 - 2019)، تحليل فورييه وتقنية الشبكات العصبية الاصطناعية ونماذج ARIMA للتنبؤ باستهلاك الطاقة الكهربائية -دراسة حالة مؤسسة سونلغاز - مقاطعة سعيدة-أطروحة دكتوراه علوم في العلوم الاقتصادية، تخصص الطرق الكمية المطبقة في التسيير. الجزائر. جامعة تلمسان.
7. بن نور فريد ، نايت مرزوق محمد العربي ، استخدام نماذج الذكاء الاصطناعي للتنبؤ باحتياجات الصرف الأجنبي في الجزائر -نموذج الشبكات العصبية الاصطناعية- ANN مجلة اقتصاديات شمال إفريقيا، المجلد 15 \ العدد 20 السنة : 2019 ص 67-82 .
8. بوعروري. (2019). مساهمة الشبكات العصبونية الاصطناعية في التنبؤ بحجم المبيعات لدعم صنع القرارات الإدارية في المؤسسات الاقتصادية: دراسة لبعض المؤسسات الجزائرية. (Doctoral dissertation) ص 102.
9. تاهمي نادية. دور أساليب التنبؤ في التخطيط المستقبلي للتوزيع ودعم تنافسية المؤسسة الإنتاجية الجزائرية- دراسة حالة عينة من المؤسسات الإنتاجية، (Doctoral dissertation) جامعة محمد بو ضياف المسيلة، معهد العلوم التجارية. (ص 59).
10. جبريل محمد صديق. (2017). استخدام أساليب تحليل السلاسل الزمنية للتنبؤ بالمصابين بمرض الملاريا: دراسة حالة مستشفى ودمدني التعليمي، السودان 2010-2015. (Doctoral dissertation, University of Gezira).
11. جمال صلاح الدين سيد مجيد، & إسراء زهير مجيد قبع. (2013). تخمين الجهد البرمجي باستخدام نموذج ال COCOMO التقليدي والشبكات العصبية. مجلة الرافدين لعلوم الحاسوب والرياضيات، 10(1)، 351-364.
12. حذيفة حازم طه ، عمار احمد عثمان "استخدام طريقة المتوسطات المتحركة لتحسين عمل شبكة المدرك في التنبؤ بالحالة الجوية لمدينة الموصل"المجلة العراقية للعلوم الإحصائية(26) 2014 ص ص [137-161]
13. حيدر حميد الكعبي، & علي درب الحياي. (2015). التنبؤ بالفجوة الغذائية لمحصولي القمح والرز في العراق باستخدام طريقة الشبكات العصبية الاصطناعية ANN للمدة 2014-2022. مجلة المثنى للعلوم الزراعية، 4(1)، 1-21.
14. خليدة دلهوم ، "أساليب التنبؤ بالمبيعات دراسة حالة "، مذكرة مقدمة لنيل شهادة الماجستير في العلوم التجارية ،جامعة الحاج لخضر - باتنة- كلية العلوم الاقتصادية وعلوم التسيير، 2008- 2009.

15. ربيعة محمد، وسام حسيني (2019)، دراسة سلوك سلسلة الزمنية لمؤشر الأسعار العالمية للغذاء باستخدام نماذج GARCH، مجلة الدراسات الاقتصادية المعاصرة، المجلد 40 / العدد: 2 (2019) ، ص 57-70.
16. رهاد عماد صليوا، ظافر رمضان مطر. (2019) . مقارنة أداء التنبؤ بين بعض الشبكات العصبية الاصطناعية ومنهجية) بوكس-جنكنز (مع التطبيق ،المجلة العراقية للعلوم الإحصائية (28، ص ص) 51-76.
17. زكريا يحيى الجمال، & عمر صابر. (2012). مقارنة التنبؤ باستخدام شبكة الانحدار العصبية المعممة بأسلوب الشبكات العصبية وتحليل الانحدار. المجلة العراقية للعلوم الإحصائية، 12(21)، 234-245.
18. ساهد عبد القادر، استخدام البرمجة بالأهداف في تحليل الانحدار المبهم للتنبؤ بأسعار البترول، أطروحة دكتوراه في العلوم الاقتصادية، تخصص إدارة العمليات والإنتاج، جامعة تلمسان، الجزائر، (2012-2013).
19. ساهد عبد القادر، قهوي حسن ، التنبؤ بأسعار البترول باستخدام النموذج الهجين ARIMA - GARCH للمدة (2000 - 2020)، مجلة نور الدراسات الاقتصادية، 2020، مجلد 06، العدد 10.
20. ساهد، عبد القادر، & مكيدش، محمد. (2014). دراسة مقارنة بين الانحدار المبهم باستخدام البرمجة بالأهداف والشبكات العصبية الاصطناعية للتنبؤ بأسعار البترول. El-Bahith Review, 233(1354), 1-27.
21. سعدية عبد الكريم طعمه. (2012). استخدام تحليل السلاسل الزمنية للتنبؤ بأعداد المصابين بالأورام الخبيثة في محافظة الانبار. مجلة جامعة الانبار للعلوم الاقتصادية والادارية، 4(8)، 371-393.
22. شادي اسماعيل التلباني، طارق عبد العزيز الدوب، دراسة أثر الصدمات الايجابية والسلبية على تقلبات عوائد بورصة الكويت وسوق دبي المالي باستخدام نماذج عائلة GARCH ، المجلة العاملة لاقتصاد والاعمال، 9(3) (2020)، 638-650.
23. شيخي محمد، "طرق الإقتصاد القياسي، محاضرات وتطبيقات، دار ومكتبة حامد للنشر والتوزيع، عمان، الطبعة الأولى، 2012 .
24. ظافر رمضان مطر البدراني ، رهاد عماد صليوا" تقييم تنبؤ السلسلة الزمنية لمعدلات درجات الحرارة باستخدام الشبكات العصبية" المجلة العراقية للعلوم الإحصائية، (2014)، 19-26.
25. عامر قصي الدروي—ش (2017) ، التنبؤ بالامطار الشهرية في محطة حمص باستخدام أسلوب التحويل المويجي والشبكة العصبية الاصطناعية، رسالة ماجستير في الهندسة المدنية اختصاص الهندسة المائية والري، جامعة تشرين كلية الهندسة المدنية.
26. العباسي، عبد الحميد (2013). "التنقيب في البيانات Data Mining تطبيقات باستخدام SPSS MODEL R"، جامعة القاهرة، مصر.
27. عبد المنعم احمد عبد الوهاب، طارق محمد الرشيد، أمنة محمد عمر "قياس أثر مؤشر سوق الخرطوم للأوراق المالية على أرباح المصارف السودانية باستخدام منهجية نماذج GARCH خلال الفترة 2013-2017" ،مجلة الدراسات العليا -جامعة النيلين (مج14)، (ع 56 - 2)، 15/ 07/ 2019 .
28. عتروس سهيلة ،استخدام منهجية بوكس جنكنز والشبكات العصبية الاصطناعية للتنبؤ باستهلاك الطاقة الكهربائية بمؤسسة سونلغاز -دراسة حالة : ولاية بسكرة- رسالة لنيل شهادة دكتوراه علوم في علوم التسيير ، تخصص الاساليب الكمية في التسيير، كلية العلوم الاقتصادية والتجارية وعلوم التسيير، جامعة محمد خيضر بسكرة، الجزائر، 2017-2018.
29. عثمان نقار- منذر العواد، منهجية Box-Jenkins في تحليل السلاسل الزمنية والتنبؤ دراسة تطبيقية على أعداد تلاميذ الصف الأول من التعليمية الأساسي في سورية، مجلة جامعة دمشق للعلوم الاقتصادية والقانونية - المجلد 27-العدد الثالث- 2011 .

30. الغنم, حمد بن عبد الله, (2003) " تحليل السلسلة الزمنية لمؤشر أسعار الأسهم في المملكة العربية السعودية باستخدام منهجية بوكس وجنكينز", كلية العلوم الادارية, جامعة الملك سعود, المملكة العربية السعودية.
31. فاتح لقوقي, محمد شيخي, استخدام نماذج ARCH لنمذجة تقلبات أسعار الأسهم في سوق المال السعودي - دراسة حالة شركة اتحاد
32. قصي حبيب الحسيني, مقدمة في الشبكات العصبية الاصطناعية "جامعة الامام جعفر الصادق , بغداد, 2011م". ص 10
33. لمياء حسين علي السبعواوي. (2006). تصنيف بيانات استعمالات الأرض لمحلة الميدان القديمة في مدينة الموصل باستخدام تقانات الشبكات العصبية الاصطناعية, JOURNAL OF EDUCATION AND SCIENCE, 13(14).
34. م.م. زيان إحسان كريم حمدي. (2013). استخدام نماذج Box- Jenkins لمتنبؤ بالمبيعات (دراسة تطبيقية في معمل سمنت كركوك). مجلة جامعة كركوك للعلوم الإدارية والاقتصادية المجلد (3) العدد (2013).
35. اوات سردار وادي, سامية خالد حسن (2012). التنبؤ بأسعار الذهب وذلك باستخدام سلاسل ماركوف وطريقة الامكان الأعظم. (MLE) كلية الادارة والاقتصاد -قسم الاحصاء- جامعة صلاح الدين. مجلة دنانير / العدد 43.
36. محمد علي الشرقاوي, " الذكاء الاصطناعي والشبكات العصبية ", مطابع المكتب المصري الحديث, 1996 .
37. المدرس المساعد عمار شهاب أحمد. (2017). استخدام نماذج السلاسل الزمنية للتنبؤ بكمية صادرات العراق النفطية لعامي 2016-2017. (52). Journal of Baghdad College of Economic sciences University.
38. مروان جمعة درويش. (2019). فعالية التنبؤ بمؤشر بورصة فلسطين باستخدام نموذج الشبكات العصبية الاصطناعية: مقارنة بنموذج الانحدار الذاتي. مجلة جامعة القدس المفتوحة للبحوث الإدارية والاقتصادية, 3(10).
39. مها عبد الإله محمد البدراني (2008). استخدام شبكة دالة القاعدة الشعاعية RBFN في تشخيص أمراض الأطفال. المجلة العراقية للعلوم الإحصائية (13) (2008), [179-195].
40. مولود حشان: نماذج وأساليب التنبؤ قصير المدى , ديوان المطبوعات الجامعية , الجزائر , ص 27.
41. ميكيديش محمد, ساهد عبد القادر, دراسة قياسية لأسعار البترول باستخدام نماذج GARCH. مجلة الاقتصاد المعاصر, العدد 03 افريل 2008, ص ص 171-189.
42. هاله فاضل حسين, & حسيبة كامل مثنى. (2013). التنبؤ المناخي بإنتاج محصول الحنطة للفترة من (1986-2010) باستخدام نماذج السلاسل الزمنية الخطية. Al-Nahrain Journal of Science, 16(3), 48-61.
43. هتهات, & سعيد. (2006). دراسة إقتصادية وقياسية لظاهرة التضخم في الجزائر, (Doctoral dissertation), روقلة, جامعة قاصدي مرباح. كلية الحقوق والعلوم الاقتصادية.
44. ورد عبد العزيز كوجك (2018). التنبؤ بعوائد المحافظ الاستثمارية باستخدام نموذج الانحدار الذاتي المشروط بعدم ثبات التباين/ARCH/ (دراسة تطبيقية على سوق عملن المالي), رسالة ماجستير في التمويل والمصاريف.
45. ياسر محمود محمد الحاج. (2017). استخدام الطرق الإحصائية في التنبؤ بكميات الأسماك المنتجة في قطاع غزة (Doctoral dissertation)..
46. عدالة عجالة, (2010), استخدامات العمليات العشوائية ونماذج الشبكات العصبية في التنبؤ الاقتصادي, ودورها في دراسة الآفاق المستقبلية للواقع التقني والتسويقي للمؤسسة الصناعية بالجزائر (Doctoral dissertation, Université Mohamed Ben Ahmed d'Oran 2).
47. Altaher, A. M., & Alaswed, H. A. (2018). مقارنة بعض اختبارات جذر الوحدة في الكشف عن استقرار السلاسل الزمنية باستخدام المحاكاة, (JOPAS) Sebha University Journal of pure & Applied sciences, 17(2).

48. أ. دربال، محاولة التنبؤ بمؤشرات الأسواق المالية العربية باستعمال النماذج القياسية دراسة حالة: مؤشر سوق دبي المالي. (Doctoral dissertation).
49. خولة حضري، (2015)، استخدام السلاسل الزمنية من خلال منهجية بوكس جينكينز في اتخاذ القرار الإنتاجي دراسة حالة مطاحن الرياض سطيف وحدة تقرت-في الفترة، (Doctoral dissertation, (2008-2013) Université Mohamed Khider-(Biskra ..

ثانيا: المراجع باللغة الأجنبية

50. Abadi, A. M., Wustqa, D. U., & Nurhayadi, N. (2019). *Diagnosis of brain cancer using radial basis function neural network with singular value decomposition Method. International Journal of Machine Learning and Computing*, 9(4), 527-532.p528.
51. Adhikari, R., & Agrawal, R. K. (2013). *An introductory study on time series modeling and forecasting. arXiv preprint arXiv:1302.6613.p20.*
52. Agatonovic-Kustrin, S., & Beresford, R. (2000). *Basic concepts of artificial neural network (ANN) modeling and its application in pharmaceutical research. Journal of pharmaceutical and biomedical analysis*, 22(5), 717-727.p721
53. Agatonovic-Kustrin, S., Glass, B. D., Wisch, M. H., & Alany, R. G. (2003). *Prediction of a stable microemulsion formulation for the oral delivery of a combination of antitubercular drugs using ANN methodology. Pharmaceutical research*, 20(11), 1760-1765.p1761.
54. Ahmed, F., Kashif, M., & Feroz, F. (2017). *Dynamic relationship between gold prices, oil prices, exchange rate and stock returns: Empirical evidence from Pakistan. NUML International Journal of Business & Management*, 12(1), 109-126.p 111.
55. AIDOO, E. (2011). *Forecast performance between sarima and setar models: An application to ghana inflation rate.p7.*
56. Ak, R. (2014). *Modélisation à base de réseaux de neurones dédiés à la prédiction sous incertitudes appliqué aux systèmes énergétiques (Doctoral dissertation, Supélec).p25.*
57. Al-Ameer, M., Hammad, W., Ismail, A., & Hamdan, A. (2018). *The relationship of gold price with the stock market: The case of Frankfurt Stock Exchange. International Journal of Energy Economics and Policy*, 8(5), 357-371.p 358.
58. Ali, A., Ch, M. I., Qamar, S., Akhtar, N., Mahmood, T., Hyder, M., & Jamshed, M. T. (2016). *Forecasting of daily gold price by using Box-Jenkins methodology. International Journal of Asian Social Science*, 6(11), 614-624.

59. Alsharif, M. H., Younes, M. K., & Kim, J. (2019). *Time series ARIMA model for prediction of daily and monthly average global solar radiation: The case study of Seoul, South Korea. Symmetry, 11(2), 240.p5.*
60. AL-Sharoot, M. H., & Saheb, D. A. (2014). *Forecasting of electricity power consumption in AL-Qadisiya province by using time series models & Artificial neural networks models. Journal of Al-Qadisiyah for computer science and mathematics, 6(1), 9-26.p2.*
61. AL-Sharoot, M. H., & Saheb, D. A. (2014). *Forecasting of electricity power consumption in AL-Qadisiya province by using time series models & Artificial neural networks models. Journal of Al-Qadisiyah for computer science and mathematics, 6(1), 9-26.p6*
62. Amponsah, S. K., Otoo, D., & Todoko, C. A. K. (2015). *Time series analysis of water consumption in the Hohoe municipality of the Volta region, Ghana. International Journal of Applied Mathematics Research, 4(2), 393.p21.*
63. Amponsah, S. K., Otoo, D., & Todoko, C. A. K. (2015). *Time series analysis of water consumption in the Hohoe municipality of the Volta region, Ghana. International Journal of Applied Mathematics Research, 4(2), 393.P395.*
64. ASCE Task Committee on Application of Artificial Neural Networks in Hydrology. (2000). *Artificial neural networks in hydrology. I: Preliminary concepts. Journal of Hydrologic Engineering, 5(2), 115-123.p115.*
65. Baber, P., Baber, R., & Thomas, G. (2013). *Factors affecting Gold prices: a case study of India. Proc. Evolving Management Paradigms in Manufacturing and Service Sectors.p6.*
66. Bakar, N. A., & Rosbi, S. (2017). *Autoregressive integrated moving average (ARIMA) model for forecasting cryptocurrency exchange rate in high volatility environment: A new insight of bitcoin transaction. International Journal of Advanced Engineering Research and Science, 4(11), 237311.p132.*
67. Beckmann, J., Czudaj, R., & Pilbeam, K. (2015). *Causality and volatility patterns between gold prices and exchange rates. The North American Journal of Economics and Finance, 34, 292-300.p 1.*
68. bin Khamis, A., & Yee, P. H. (2018). *A Hybrid Model of Artificial Neural Network and Genetic Algorithm in Forecasting Gold Price. European Journal of Engineering and Technology Research, 3(6), 10-14*
69. bin Sukri, M. K. A. (2015). *The relationship between selected macroeconomic factors and gold price in malaysia.*
70. Bishop, C. M. (1994). *Neural networks and their applications. Review of scientific instruments, 65(6), 1803-1832.p1804.*
71. Boudrioua, M. S. (2019). *Modeling and forecasting the Algiers Stock Exchange returns using the Box-Jenkins methodology.p7.*
72. Bourbonnais, R. (2015) ,*Op-cit,p246*

73. Bourbonnais, R. (2015). *Économétrie-9e édition: Cours et exercices corrigés*. Dunod.p245
74. Bullinaria, J. A. (2015). *Radial basis function networks: Introduction*. *Neural Computation: Lecture*, 13.p 17
75. Chafik Arbach et al (2011), *Les testes de causalité & cointégration dans l'analyse des séries temporelles*, *Tishreen University Journal for Research and Scientific Studies -Economic and Legal Sciences Series Vol. (33) No. (5) 2011.p82*.
76. Chen, M., Challita, U., Saad, W., Yin, C., & Debbah, M. (2017). *Machine learning for wireless networks with artificial intelligence: A tutorial on neural networks*. *arXiv preprint arXiv:1710.02913*, 9.p9-10 .
77. Dierinck, B., Frömmel, M., Schrauwen, B., & Hermans, M. (2012). *Determinants of the gold price*. *Unievrsiteit Gent.p17*.
78. Ehsan, Z. A. (2020). *A Vector Error Correction model analysis of gold prices-how will COVID-19 impact the price of gold?*. Available at SSRN 3644893.p1.
79. Engelbrecht, A. P. (2007). *Computational intelligence: an introduction*. John Wiley & Sons.p 75-76.
80. Eryiğit, M. (2017). *Short-term and long-term relationships between gold prices and precious metal (palladium, silver and platinum) and energy (crude oil and gasoline) prices*. *Economic research-Ekonomska istraživanja*, 30(1), 499-510.
81. Farhat, S., & Ghalayini, L. (2020). *Modeling and Forecasting Gold Prices.p17*.
82. Fasel, B. (2003). *An introduction to bio-inspired artificial neural network architectures*. *Acta neurologica belgica*, 103(1), 6-12.p8.
83. Fatima Abdul Hamid Jawad Al Bermami. (2019). *Using Time Series for Predict the Standard Numbers for Residential Rent in Iraq for the Years 2018-2021*. Al-Rafidain University College For Sciences,
84. Gendary, A. I. (2019). *ANN and DNN-based Models for DDoS Detection via Network Traffic Forecasting (Doctoral dissertation, Middle East University).p15*.
85. Gokmenoglu, K. K., & Fazlollahi, N. (2015). *The interactions among gold, oil, and stock market: Evidence from S&P500*. *Procedia Economics and Finance*, 25, 478-488
86. Gomes, P., & Castro, R. (2012). *Wind speed and wind power forecasting using statistical models: autoregressive moving average (ARMA) and artificial neural networks (ANN)*. *International Journal of Sustainable Energy Development*, 1(1/2).p43.
87. Guha, B., & Bandyopadhyay, G. (2016). *Gold price forecasting using ARIMA model*. *Journal of Advanced Management Science*, 4(2).

88. Guha, B., & Bandyopadhyay, G. (2016). Gold price forecasting using ARIMA model. *Journal of Advanced Management Science*, 4(2).p 118
89. Gurney, K. (1997). *An introduction to neural networks*. CRC press.p17
90. Gutiérrez, M., Franco, G., & Campuzano, C. (2013). Gold prices: Analyzing its cyclical behavior. *Lecturas de Economía*, (79), 113-142.
91. Gutiérrez, M., Franco, G., & Campuzano, C. (2013). Gold prices: Analyzing its cyclical behavior. *Lecturas de Economía*, (79), 113-142.p 115.
92. Haider, A., & Hanif, M. N. (2009). Inflation forecasting in Pakistan using artificial neural networks. *Pakistan economic and social review*, 123-138.p3.
93. Harpham, C., & Dawson, C. W. (2006). The effect of different basis functions on a radial basis function network for time series prediction: A comparative study. *Neurocomputing*, 69(16-18), 2161-2170.p2162-2163.
94. Hashem, F. (2020), *Op-cit*,p 101.
95. Hashem, F. (2020). Analysis of time series to predict the numbers of pupils in the first grade of primary school using of the Box Jenkins ((applied study in the governorate of Basra)). *Economic Sciences*, 15(59).p 100.
96. Havaluddin, H., & Tahyudin, I. (2015). Time series prediction using radial basis function neural network.p766.
97. Haykin, S. S. (2009). *Neural networks and learning machines/Simon Haykin*.p 21-22
98. Heddham, S. (2016). Simultaneous modelling and forecasting of hourly dissolved oxygen concentration (DO) using radial basis function neural network (RBFNN) based approach: a case study from the Klamath River, Oregon, USA. *Modeling Earth Systems and Environment*, 2(3), 135.p5
99. Hira, F. I., Maruf, M. F., & Hossain, A. (2018). Stock market prediction using time series analysis (Doctoral dissertation, BRAC University).p9
100. Ho, T. T., Phan, D., Nguyen, V. N., & Sipko, J. (2017). Application of ARIMA model to forecast gold price in Vietnam. *11th International Days of Statistics and Economics*.
101. Hosseinipoor, S. (2016). *Forecasting Natural Gas Prices in the United States Using Artificial Neural Networks*.p27
102. Irshad, H., Bhatti, G. A., Qayyum, A., & Hussain, H. (2014). Long run Relationship among Oil, Gold and Stock Prices in Pakistan. *Journal of Commerce* (22206043), 6(4).p10.
103. Isa, M. A. M., Latif, R. A., Nasrul, F., Zaharum, Z., & Ariff, m. k. relational study between macroeconomic variables and gold price: latest malaysian evidence
104. Ismail, Z., Yahya, A., & Shabri, A. (2009). Forecasting gold prices using multiple linear regression method. *American Journal of Applied Sciences*, 6(8), 1509.

105. Jain, A. K., Mao, J., & Mohiuddin, K. M. (1996). Artificial neural networks: A tutorial. *Computer*, 29(3), 31-44.p34-35.
106. Jawad, B. K. (2019). The effect of VIX index volatility on the S & P 500 index and gold prices. *THE IRAQI MAGAZINJE FOR MANAGERIAL SCIENCES*, 15(60).p 36.
107. Juma'at, N., & Sazeli, Z. A. (2021). Comparison between Causal Model and Time Series Model to Forecast Gold Prices. *Multidisciplinary Applied Research and Innovation*, 2(1), 156-163.
108. Kagoda, P. A., Ndiritu, J., Ntuli, C., & Mwaka, B. (2010). Application of radial basis function neural networks to short-term streamflow forecasting. *Physics and Chemistry of the Earth, Parts A/B/C*, 35(13-14), 571-581.p572
109. Karlik, B., & Olgac, A. V. (2011). Performance analysis of various activation functions in generalized MLPNN architectures of neural networks. *International Journal of Artificial Intelligence and Expert Systems*, 1(4), 111-122.p112.
110. Kayri, M. (2015). An intelligent approach to educational data: performance comparison of the multilayer perceptron and the radial basis function artificial neural networks. *Educational Sciences: Theory & Practice*, 15(5).p1249.
111. Khan, M. M. A. (2013). Forecasting of gold prices (Box Jenkins approach). *International Journal of Emerging Technology and Advanced Engineering*, 3(3), 662-670.
112. Khashei, M., & Bijari, M. (2010). Gold price forecasting using hybrid artificial neural networks with fuzzy regression model. *Advances in Industrial Engineering*, 44(1).
113. Khashei, M., & Bijari, M. (2011). A new hybrid methodology for nonlinear time series forecasting. *Modelling and Simulation in Engineering*, 2011.p 3
114. Khashei, M., & Bijari, M. (2012). Which methodology is better for combining linear and nonlinear models for time series forecasting?.p266.
115. Kocak, H., & Un, T. (2014). Forecasting the gold returns with artificial neural network and time series. *International Business Research*, 7(11), 139-152.
116. Kohli, S., Miglani, S., & Rapariya, R. (2014). Basics of artificial neural network. *International Journal of Computer Science and Mobile Computing*, 3, 745-751.p 748-749.
117. Krenker, A., Bester, J., & Kos, A. (2011). Introduction to the artificial neural networks. In *Artificial neural networks-methodological advances and biomedical applications*. IntechOpen.p3.
118. Krishna, K. M., Reddy, N. K., & Sharma, M. R. Forecasting of Daily Prices of Gold in India using ARIMA and FFNN Models.

119. Kristjanpoller, W., & Minutolo, M. C. (2015). *Gold price volatility: A forecasting approach using the Artificial Neural Network–GARCH model. Expert systems with applications*, 42(20), 7245-7251.
120. Kumar, K., & Thakur, G. S. M. (2012). *Advanced applications of neural networks and artificial intelligence: A review. International journal of information technology and computer science*, 4(6), 57.p59
121. Ladlani, I., Houichi, L., Djemili, L., Heddam, S., & Belouz, K. (2012). *Modeling daily reference evapotranspiration (ET₀) in the north of Algeria using generalized regression neural networks (GRNN) and radial basis function neural networks (RBFNN): a comparative study. Meteorology and Atmospheric Physics*, 118(3-4), 163-178.p169
122. Larsen, J. (1999). *Introduction to artificial neural networks. Technical University Of Denmark*,.p 6
123. Madhushan, R. M. K., Rathnayaka, R. M. A. C., Sandaruwan, T. M. D. M., Maduranga, A. D., & Gunarathne, A. V. C. H. *RELATIONSHIP BETWEEN GOLD PRICE AND DETERMINANTS OF GOLD PRICE IN SRI LANKA*.p 5.
124. Mahat, N., Yusuf, A. M., & Raseli, S. S. (2019). *Forecasting Malaysia gold's price by using neural networks. Jurnal Intelek*, 14(2), 126-134.
125. Malila, T. (2019). *Time-series sales forecasting for an Enterprise Resource Planning system*
126. Matroushi, S. M. (2011). *Hybrid computational intelligence systems based on statistical and neural networks methods for time series forecasting: the case of gold price (Doctoral dissertation, Lincoln University)*.p 12-13-14.
127. MBAYE, A. (2019). *ARMA model for short-term forecasting of solar potential: application to a horizontal surface of Dakar site. OAJ Materials and Devices*, 4(1).p 3.!
128. Mbaye, A., Ndiaye, M., Ndione, D., Diaw, M., Traoré, V., Ndiaye, A., ... & Ndiaye, P. (2019). *ARMA model for short-term forecasting of solar potential ARMA model for short-term forecasting of solar potential: application to a horizontal surface on Dakar site A. Mbaye et al, ARMA model for short-term forecasting of solar potential*.p3.
129. Mishra, P. K., Das, J. R., & Mishra, S. K. (2010). *Gold price volatility and stock market returns in India. American Journal of Scientific Research*, 9(9), 47-55.
130. MOHAMED, S. N. H. B. (2011). *SHORT-TERM FORECAST OF GOLD PRICE USING GENERALIZED AUTOREGRESSIVE CONDITIONAL HETEROSCEDASTIC (Doctoral dissertation, University Technology Malaysia*

131. Mombeini, H., & Yazdani-Chamzini, A. (2015). Modeling gold price via artificial neural network. *Journal of Economics, business and Management*, 3(7), 699-703.p699.
132. Mombeini, H., & Yazdani-Chamzini, A. (2015). Modeling gold price via artificial neural network. *Journal of Economics, business and Management*, 3(7), 699-703
133. Moradi, H., Joka, I., & Forouzantabar, A. (2015). Modelling and forecasting gold price using GMDH neural network. *Indian Journal of Fundamental and Applied Life Sciences*, 5(1), 30-41
134. Moreno, J. J. M. (2011). Artificial neural networks applied to forecasting time series. *Psicothema*, 23(2), 322-329.
135. Nadhim, E. A. (2013). Studying And Analyzing Of Inflation Level For Standard Numbers Depending On Time Series (ARIMA) Compared With Artificial Neural Network Models (ANNM). *Al-Rafidain University College For Sciences*, (31).p80.
136. Naz, F., & Ahmad, Z. (2016). Forecasting of Indian Gold Prices Using Box Jenkins Methodology. *Journal of Indian Studies*, 2(1), 75-83.
137. Ngmerty, R. K. (2019). *Effects of Macroeconomic Variables on Gold Prices in Ghana (Doctoral dissertation, University of Ghana)*.p 7.
138. Nihad Sharif Khalaf and Heba Hani Abdullah. (2012)Modeling the time series of the mean of monthly temperature in Samraa City. *Tikrit Journal of Administration and Economics Sciences*, 8(25).p144.
139. Nor, M. E., Safuan, H. M., Shab, N. F. M., Asrul, M., Abdullah, A., Mohamad, N. A. I., & Lee, M. H. (2017, May). *Neural network versus classical time series forecasting models. In AIP Conference Proceedings (Vol. 1842, No. 1, p. 030027). AIP Publishing LLC.*
140. Novakovic, J. Đ., & Veljovic, A. (2017). Solving medical classification problems with RBF neural network and filter methods. *International Journal of Reasoning-based Intelligent Systems*, 9(2), 80-89.p8
141. NS. Dr. Ali Nasser Hussein. (2017). Use the Time Series for the period (2006-20016) to predict Rainfall in Iraqresearcher. *Economic Sciences*, 12(47).p104.
142. NUR ATIKAH KHALID AND NURFADHLINA ABDUL HALIM.(2019). GOLD PRICE FORECASTING USING BOX-JENKINS METHOD. *Universiti Malaysia Terengganu Journal of Undergraduate Research . Volume 1 Number 3, Julai 2019: 15-27.*
143. Nyoni, T. (2018). *Box-Jenkins ARIMA approach to predicting net FDI inflows in Zimbabwe*.p6.
144. Oludolapo, O. A., Jimoh, A. A., & Kholopane, P. A. (2012). Comparing performance of MLPNN and RBF neural network models for predicting South

- Africa's energy consumption. *Journal of Energy in Southern Africa*, 23(3), 40-46.p39.
145. Omag, A. (2012). *An observation of the relationship between gold prices and selected financial variables in Turkey. Muhasebe ve finansman dergisi*, (55).
146. Orr, M. J. (1996). *Introduction to radial basis function networks*.p9.
147. Palani, S., Liong, S. Y., & Tkalich, P. (2008). *An ANN application for water quality forecasting. Marine pollution bulletin*, 56(9), 1586-1597.p1588.
148. Pannakkong, W., Huynh, V. N., & Sriboonchitta, S. (2019). *A novel hybrid autoregressive integrated moving average and artificial neural network model for cassava export forecasting. International Journal of Computational Intelligence Systems*, 12(2), 1047-1061
149. Pannakkong, W., Huynh, V. N., & Sriboonchitta, S. (2019). *A novel hybrid autoregressive integrated moving average and artificial neural network model for cassava export forecasting. International Journal of Computational Intelligence Systems*, 12(2), 1047-1061.p1051.
150. Paretkar, P. S. (2008). *Short-Term Forecasting of Power Flows over Major Pacific Northwestern Interties: Using Box and Jenkins ARIMA Methodology (Doctoral dissertation, Virginia Tech)*.p27.
151. Pazvakawambwa, G. T. (2017). *A time-series forecasting model for Windhoek Rainfall, Namibia*.P2.
152. Pislaru, C., & Shebani, A. (2014). *Identification of nonlinear systems using radial basis function neural network. International Journal of Computer, Information, Systems and Control Engineering*, 8(9), 1528-1533.p1529.
153. Pitigalaarachchi, P. A. A. C., Jayasundara, D. D. M., & Chandrasekara, N. V. (2016). *Modeling and forecasting Sri Lankan gold prices. International Journal of Sciences: Basic and Applied Research*, 27(3), 247-260.p 247.
154. Sahed, A., Mekidiche, M., & Kahoui, H. (2020). *Fuzzy Auto-Regressive Integrated Moving Average (FARIMA) Model for Forecasting the Gold Prices. Journal of Smart Economic Growth*, 5(1), 1-13.
155. Sahera Hussein Zain Al-Thalabi/, & Kholoud Musa Omran. (2016). *Determine the best model to predict the consumption of electric energy in the southern region. journal of Economics And Administrative Sciences*, 22(90).p 17.
156. Salisu, A. A., Vo, X. V., & Lawal, A. (2021). *Hedging oil price risk with gold during COVID-19 pandemic. Resources Policy*, 70, 101897.
157. Setlhare, L. (2002). *Empirical foundations of monetary policy in Botswana*.p125.
158. Sharifi, F., Haddad, O. B., & Naderi, M. (2005). *Reservoir optimal operation using DP-ANN. Evolutionary Computation*, 496-281.p333.
159. Simáková, J. (2011). *Analysis of the relationship between oil and gold prices. Journal of finance*, 51(1), 651-662.p654-655.

160. Simon, H. (2009). *Neural networks and learning machines*. Upper Saddle River: Pearson Education, 3.p14
161. Sinton, J. (2014, April). *An empirical investigation of the causal relationship between gold price, exchange rate changes and jakarta composite index*. World Business and Social Science Research Conference, Hotel Crowne Plaza Republique, Paris, France.,p 2.
162. Sivalingam, K. C., Mahendran, S., & Natarajan, S. (2016). *Forecasting gold prices based on extreme learning machine*. *International Journal of Computers Communications & Control*, 11(3), 372-380.
163. Sjaastad, L. A. (2008). *The price of gold and the exchange rates: Once again*. *Resources Policy*, 33(2), 118-124.
164. Srinivasan, P. (2014). *Gold Price, Stock Price and Exchange rate Nexus: The Case of India*. *Romanian Economic Journal*, 17(52).p 79.
165. Sujit, K. S., & Kumar, B. R. (2011). *Study on dynamic relationship among gold price, oil price, exchange rate and stock market returns*. *International journal of applied business and economic research*, 9(2), 145-165.p 165.
166. Suleiman, S., Usman, U., & Adamu, U. (2015). *Modeling and forecasting the crude oil price in Nigeria*. *Nov. Journals*, 2(1), 1-13.p3.
167. Sutthikul, W. (2021). *The Interrelation between Prices of Gold and Crude Oil*. *UBRU International Journal*, 1(1), 22-28.p22.
168. Taheri Tizro, A., Ghashghaie, M., Georgiou, P., & Voudouris, K. (2014). *Time series analysis of water quality parameters*. *Journal of Applied Research in Water and Wastewater*, 1(1), 40-50.p43.
169. Taherifard, E. (2019). *Load and Demand Forecasting in Iraqi Kurdistan using Time series modelling*.p8
170. Tan, C. N. W. (1997). *Artificial Neural Networks: A Financial Tool as Applied in the Australian Market (Doctoral dissertation, Bond University)*.p34.
171. Taskaya-Temizel, T., & Casey, M. C. (2005). *A comparative study of autoregressive neural network hybrids*. *Neural Networks*, 18(5-6), 781-789.p 781.
172. TH, M. (2008). *Using ARIMA model to forecasting with production of electrics in Australia*. *AL-Anbar University journal of Economic and Administration Sciences*, 1(2).p2.
173. Tiwari, A., Dubey, A. D., & Patel, D. (2015). *Comparative study of short term load forecasting using multilayer feed forward neural network with back propagation learning and radial basis functional neural network*. *SAMRIDDHI J. Phys. Sci. Eng. Technol*, 7, 14-27.p18-19
174. Todoko, C. A. K. (2013). *Time series analysis of water consumption in the hohoe municipality of the volta region of ghana (Doctoral dissertation)*.p29.

175. Toraman, C., Basarir, Ç., & Bayramoglu, M. F. (2011). Determination of factors affecting the price of gold: A study of MGARCH model. *Business and Economics Research Journal*, 2(4), 37-50.p 38.
176. Toraman, C., Basarir, Ç., & Bayramoglu, M. F. (2011). Determination of factors affecting the price of gold: A study of MGARCH model. *Business and Economics Research Journal*, 2(4), 37-50.
177. Tripathy, N. (2017). Forecasting Gold Price with Auto Regressive Integrated Moving Average Model. *International Journal of Economics and Financial Issues*, 7(4).p 324.
178. Tripathy, N. (2017). Forecasting Gold Price with Auto Regressive Integrated Moving Average Model. *International Journal of Economics and Financial Issues*, 7(4).
179. Trivedi, P., & Behera, S. R. (2012). The Macroeconomic Determinants Gold Prices in India: An ARDL Approach. *Journal of International Economics* (0976-0792), 3(2).
180. Tuama, S. A. (2012). Using Analysis of Time Series to Forecast numbers of The Patients Malignant Tumors in Anbar Provinc with. *AL-Anbar University journal of Economic and Administration Sciences*, 4(8).p380.
181. Tuama, S. A. (2012). Using Analysis of Time Series to Forecast numbers of The Patients Malignant Tumors in Anbar Provinc with. *AL-Anbar University journal of Economic and Administration Sciences*, 4(8).p381.
182. Tufail, S., & Batoool, S. (2013). An analysis of the relationship between inflation and gold prices: evidence from Pakistan. *The Lahore journal of economics*, 18(2), 1.
183. Uche-Ikonne Okezie, O., Offorha Bright, C., & Ukomah Henry, I. (2020). Forecasting monthly prices of gold using artificial neural network. *Journal of Statistical and Econometric Methods*, 9(3), 19-28.p22.
184. Uche-Ikonne Okezie, O., Offorha Bright, C., & Ukomah Henry, I. (2020). Forecasting monthly prices of gold using artificial neural network. *Journal of Statistical and Econometric Methods*, 9(3), 19-28.
185. Uche-Ikonne Okezie, O., Offorha Bright, C., & Ukomah Henry, I. (2020). Forecasting monthly prices of gold using artificial neural network. *Journal of Statistical and Econometric Methods*, 9(3), 19-28.p 20.
186. Walid Bashishi, Salim Majkh, & Hamza Baali. Using models Box-Jenkins ARIMA forecasting of The exchange rate of the dollar against the Algerian dinar.p114.
187. Wang, Z. (2007). Study the relationship between real exchange rate and interest rate differential–United States and Sweden.p7
188. Welch, R. L., Ruffing, S. M., & Venayagamoorthy, G. K. (2009, June). Comparison of feedforward and feedback neural network architectures for

- short term wind speed prediction. In 2009 International Joint Conference on Neural Networks (pp. 3335-3340). IEEE.p3336*
- 189.** Wongsathan, R., & Jaroenwiryapap, W. (2016). A hybrid ARIMA and RBF neural network model for tourist quantity forecasting: a case study for Chiangmai province. *Asia-Pacific Journal of Science and Technology*, 21(1), 37-54.p 41.
- 190.** Wongsathan, R., & Jaroenwiryapap, W. (2016). A hybrid ARIMA and RBF neural network model for tourist quantity forecasting: a case study for Chiangmai province. *Asia-Pacific Journal of Science and Technology*, 21(1), 37-54.p38.
- 191.** Yang, L., & Li, B. (2016). The combination forecasting model of auto sales based on seasonal index and RBF neural network. *International Journal of Database Theory and Application*, 9(1), 67-76.p71
- 192.** Yang, X. (2018). The Prediction of Gold Price Using ARIMA Model. *Advances in Social Science, Education and Humanities Research*, 196(2), 273-276.p276.
- 193.** Yang, X. (2018). The Prediction of Gold Price Using ARIMA Model. *Advances in Social Science, Education and Humanities Research*, 196(2), 273-276.
- 194.** Yang, X. (2019, January). The Prediction of Gold Price Using ARIMA Model. In *2nd International Conference on Social Science, Public Health and Education (SSPHE 2018) (pp. 273-276). Atlantis Press.*
- 195.** Yasseen, F. J. (2011). Economic forecasting in wheat acreage in Iraq by using ARIMA model for period (2007-2015). *Anbar Journal of Agricultural Sciences*, 9(2).p6 .
- 196.** Yazdani-Chamzini, A., Yakhchali, S. H., Volungevičienė, D., & Zavadskas, E. K. (2012). Forecasting gold price changes by using adaptive network fuzzy inference system. *Journal of Business Economics and Management*, 13(5), 994-1010.
- 197.** Yaziz, S. R., Azizan, N. A., Ahmad, M. H., Zakaria, R., Agrawal, M., & Boland, J. (2015, February). Preliminary analysis on hybrid Box-Jenkins-GARCH modeling in forecasting gold price. In *AIP Conference Proceedings (Vol. 1643, No. 1, pp. 289-297). American Institute of Physics.*
- 198.** Yaziz, S. R., Azizan, N. A., Zakaria, R., & Ahmad, M. H. (2013, December). The performance of hybrid ARIMA-GARCH modeling in forecasting gold price. In *20th International Congress on Modelling and Simulation, Adelaide (pp. 1-6).*
- 199.** Yousef, I., & Shehadeh, E. (2020). The impact of the COVID-19 on gold price volatility. *Int J Econ Bus Adm*, 8(4), 353-64..

200. Yuan, C., Liu, S., & Fang, Z. (2016). Comparison of China's primary energy consumption forecasting by using ARIMA (the autoregressive integrated moving average) model and GM (1, 1) model. *Energy*, 100, 384-390.
201. Yussof, F. N. M., Ahmad, M. H., & Osman, H. (2016). Modelling and Forecasting Malaysian Gold Price Using Hybrid ANN-GARCH. In *International Mathematical Forum* (Vol. 11, No. 6, pp. 287-294).
202. Zain, S. H. (2018). Using the ARIMA method in forecasting money Supply in the Iraqi economy. *Gulf Economist*, 34(35).
203. Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159-175.
204. Zheng, F., & Zhong, S. (2011). Time series forecasting using a hybrid RBF neural network and AR model based on binomial smoothing. *World Academy of Science, Engineering and Technology*, 75, 1471-1475.

قائمة المختصرات

Dickey-Fuller(DF)	اختبار ديكبي فولر
The augmented Dickey -Fuller(ADF)	اختبار ديكبي فولر المطور
Akaike Informati Criteria(AIC)	معيار اكاكي للمعلومات
Phillips and perron(PP)	اختبار فليبس وبيرون
Kwiatkoski-Phillips Schmidt-Shin(KPSS)	اختبار
Schwarz Information Criterion(SIC)	معيار شوارتز
Hannan-Criterion(H,Q)	معيار حنان- كوين
Box & Jenkins(B-J)	بوكس - جنكينز
Auto Regressive Model(AR)	نموذج الانحدار الذاتي
Moving Average Model(MA)	نموذج المتوسط المتحرك
Moving Average Auto Regressive Model(ARMA)	نموذج الانحدار الذاتي والمتوسط المتحرك
Auto Regressive Integrated Moving Average Model(ARIMA)	نموذج الانحدار الذاتي والمتوسطات المتحركة المتكاملة
Autoregressive Conditional Heteroskedasticity Model (ARCH)	نماذج الانحدار الذاتي المشروط بعدم تجانس تباينات الاخطاء
Generalized Autoregressive Conditional Heteroskedasticity Model (GARCH)	نماذج تعميم الانحدار الذاتي المشروط بعدم تجانس تباينات الاخطاء
Artificial Neural Networks	الشبكات العصبية الاصطناعية
Multilayer Perceptron Neural Network(MLPNN)	الشبكة العصبية متعددة الطبقات بيرسبترون
Radial Basis Fonction Neural Network(RBFNN)	الشبكة العصبية دالة الاساس الشعاعي
Zhang Hybrid(ARIMA-ANN)	نموذج Zhang الهجين ARIMA-ANN
Generalized Hybrid(ARIMA-ANN)	نموذج ARIMA-ANN الهجين المعمم

الملخص:

تهدف هذه الدراسة إلى التنبؤ بأسعار الذهب العالمية باستخدام نموذج الشبكة العصبية دالة الأساس الشعاعي (*RBFFNN*) باستعمال البيانات الشهرية للفترة الزمنية الممتدة من 2000 إلى 2020، ومقارنتها بالنموذج الإحصائي التقليدي (*ARIMA_GARCH*) ونموذج *MLPNN* ونوعين من النماذج الهجينة: نموذج (*ARIMA-RBFNN*) (Zhang, 2003) والنموذج الهجين المعمم *ARIMA-MLPNN* (Khashei & Bijary, 2011). من أجل تقييم أداء النماذج تم استخدام جذر متوسط مربع الأخطاء (*RMSE*). تظهر النتائج أن نموذج *RBFFNN* يتفوق على كل من نموذج *ARIMA_GARCH* ونموذج *MLPNN* والنموذجين الهجينين.

الكلمات المفتاحية: التنبؤ، أسعار الذهب، *RBFFNN*.

Abstract :

This study aims to forecast the gold prices using Radial Basic Function Neural Network (RBFFNN) model, using monthly data for the time period from 2000 to 2020. Besides this, Autoregressive Integrated Moving Average (ARIMA GARCH), Multi-Layer Perception (MLPNN), and two types of hybrid models namely: Hybrid ARIMA-RBFNN (Zhang, 2003) and Generalized Hybrid ARIMA-RBFNN (Khashei and Bijary, 2011) are implemented. The performance of the models is measured using Root Mean Squared Error (RMSE). Results obtained using RBFFNN, ARIMA-GARCH, MLPNN, and the two hybrid models are compared with each other. The results show that the RBFFNN outperforms ARIMA-GARCH, MLPNN, and the two hybrid models.

Key words: Forecasting, Gold Prices, RBFFNN.

Résumé:

Cette étude avait pour objectif d'évaluer la qualité d'un modèle de prévision des cours mondiaux de l'or. Utilisant Le réseaux à fonction de base radiales (RBFFNN), le modèle proposé a été testé à partir des données mensuelles pour la période 2000-2020 ; et les résultats obtenus furent comparés avec ceux du modèle ARIMA_GARCH, du modèle MLPNN, et des modèles hybrides ARIMA-RBFNN de Zhang (2003) et de Khashei & Bijary (2011). Pour évaluer les performances des modèles, racine de l'erreur quadratique moyenne (RMSE) a été utilisée. Les résultats ont montré que le modèle RBFFNN offre des prévisions plus précises que les autres modèles.

Mots clés : prévisions, Prix de l'or, RBFFNN.