

الفصل الاول

1-1 تمهيد:

يعتبر التنبؤ أحد أهم أدوات اتخاذ القرار وأهم عنصر في عملية التخطيط للمستقبل فمن أجل إتخاذ القرار السليم لأبد من دراسة كل البدائل المتاحة وتحليل متغيرات الماضي والحاضر لتحديد ما هو الأفضل وما هي الآثار التي سوف تنتج من هذا القرار، لذلك نجد أن التنبؤ يعتمد على بيانات الماضي والحاضر من أجل معرفة المستقبل.

وتأتي الحاجة الملحة للتنبؤ من عدم معرفتنا للمستقبل ومن ثم إرتفاع درجة المخاطرة في القرارات المتعلقة بالمستقبل، ولتقليل هذه المخاطرة فإننا نعلم على تحليل سير الظاهرة في الماضي لتحديد ملامح المستقبل ومعرفة درجة التشابه بين الماضي والمستقبل وهذه المعرفة تؤدي إلى رفع درجة الثقة في القرار المتخذ.

ويكثر استخدام أدوات التنبؤ في بيانات السلاسل الزمنية وذلك لأن معظم هذه البيانات تم تجميعها لظواهر خلال فترات زمنية في الماضي.

هناك العديد من الطرق التي تستخدم في بناء نماذج التنبؤ وتعد أساليب تحليل السلاسل الزمنية المختلفة من أكثر هذه الطرق استخداماً وهناك طرق أخرى حديثة في التنبؤ كالشبكات العصبية الاصطناعية والبرمجة الجينية وطرق تعدين البيانات وغيرها.

في هذا البحث سوف يتم تناول التنبؤ في السلاسل الزمنية باستخدام أسلوبين من أساليب التنبؤ أسلوب تقليدي يتمثل في نماذج بوكس جنكنز Box-Jenkins وأسلوب حديث يتمثل في نماذج الشبكات العصبية الاصطناعية (Artificial Neural Networks (ANN ويتم التطبيق على السلاسل الزمنية لفيضان مياه نهر النيل.

2-1 مشكلة البحث:

إن عملية التنبؤ في السلاسل الزمنية تتأثر بشكل مباشر باختيار النموذج المناسب لبيانات السلسلة الزمنية حيث تؤثر هذه الخطوة تأثيراً مباشراً في دقة التنبؤات المتحصل عليها.

وتعتبر بيانات السلاسل الزمنية في القطاعات المختلفة في معظمها بيانات غير خطية وتعاني

أحياناً من العشوائية والاضطراب إلا أن معظم طرق التنبؤ المستخدمة في تحليل هذه البيانات قد

لا تراعي هذه الجوانب مما قد ينعكس سلباً على دقة النتائج المتحصل عليها من هذه الطرق.

ولكي نحصل على نماذج تتنبؤ لبيانات السلاسل الزمنية يكون لها المقدرة على تصوير الواقع ودقة عالية في التنبؤات المستقبلية يجب أن تأخذ هذه النماذج كل الاعتبارات المتعلقة بالبيانات من خطية وعدم خطية ونوعية البيانات والتأثيرات المختلفة وغيرها من العوامل الأخرى المتعلقة بالبيانات . فعليه يمكن تمثيل مشكلة البحث في التساؤلات الآتية إلى أي مدى يمكن لنماذج بوكس جنكنز التعامل مع واقعية بيانات السلاسل الزمنية من حيث الخطية وعدم الخطية؟ وما هي المزايا والإخفاقات في النماذج المبنية بهذه الأساليب ؟ وهل يمكن أن تكون نماذج الشبكات العصبية هي البديل الأكفأ لنماذج بوكس جنكنز من خلال دقة التنبؤات؟ وكيف يمكن تقييم أداء الأسلوبين؟ وهل يمكن الإكمال بين الأسلوبين في تحليل بيانات سلسلة زمنية واحدة من أجل الوصول إلى أعلى درجة من الكفاءة التنبؤية؟ وهل يمكن وضع معايير من خلالها نتمكن من اختيار نموذج معين متلائم وطبيعية البيانات؟.

3-1 أهمية البحث:

يتناول البحث دراسة مياه الفيضان والتنبؤات المستقبلية بكمية مياه الفيضان والتي تعتبر عامل رئيسي للحد من المخاطر المترتبة عند حدوث الفيضان كما يمكن المزارعين الاستفادة القصوي من مياه الفيضان دون إي خسارة بالإضافة الي ذلك تكمن أهمية البحث في تناول الأساليب المختلفة للسلاسل الزمنية مثال لذلك أسلوب بوكس جنكنز Box – Jenkins وأسلوب الشبكات العصبية الاصطناعية (ANN) .

4-1 اهداف البحث:

- 1- معرفة مدى كفاءة نماذج بوكس جنكنز Box – Jenkins ونماذج الشبكات العصبية (Artificial Neural Networks) ANN للتنبؤ في السلاسل الزمنية لفيضان مياه النيل.
- 2- المفاضلة بين نماذج الشبكات العصبية ANN ونماذج بوكس جنكنز Box – Jenkins في التعامل مع واقعية بيانات السلاسل الزمنية من حيث الخطية وعدم الخطية.
- 3- التنبؤ بمستقبل فيضان مياه النيل ، الذي يعد واحد من الدعامات الرئيسية للاقتصاد السوداني من خلال بناء نماذج سلاسل زمنية لبيانات القطاع الاقتصادي باستخدام أسلوب بوكس – جنكنز والشبكات العصبية.
- 4- محاولة تحديث أساليب التنبؤ المستخدمة في المحطة لمناسيب النيل بإضافة نماذج الشبكات العصبية الاصطناعية.

5-1 فرضيات البحث:

- 1- تزيد الدقة التنبؤية لنماذج الشبكات العصبية على نماذج بوكس -جنكنز في التنبؤات طويلة المدى.
- 2- يمكن استخدام نماذج بوكس جنكنز ونماذج الشبكات العصبية معاً من أجل زيادة دقة التنبؤ في بيانات السلاسل الزمنية.
- 3- تعتبر نماذج الشبكات العصبية أكفاً وأكثر دقة من نماذج بوكس جنكنز في التعامل مع بيانات السلاسل الزمنية غير الخطية..

6-1 حدود البحث:

الحدود المكانية مياه نهر النيل والحدود الزمنية في الفترة 1940 وحتى 2009.

7-1 منهجية البحث والادوات المستعملة:

هذا البحث مزيج بين المنهج الوصفي التحليلي في الجانب النظري، ومنهج دراسة الحالة في الجانب التطبيقي. ولذلك فقد تم تقسيم البحث الي جانبين هما الجانب النظري والذي تم فيه التطرق بشكل مبسط الي الأسس النظرية الخاصة بنماذج السلاسل الزمنية من حيث الشكل العام ومراحل بناء النموذج وطرق التقدير والتنبؤ. أما الجانب التطبيقي فقد تم فيه إجراء دراسة تطبيقية (دراسة حالة) علي بيانات واقعية عن كميه مياه فيضان نهر النيل للوصول الي نموذج رياضي للتنبؤ بكمية المياه لفترات لاحقه. وتضمن الجزء الأخير علي أهم الاستنتاجات والتوصيات والملاحق والمصادر، أما الأدوات المستخدمة فهي البرنامج الإحصائي spss والـ Minitab و Excel و STATISTICA .

8-1 الدراسات السابقة:

1- Albert Kuany Jok بحث لنيل درجة الماجستير في الإحصاء التطبيقي من جامعة السودان للعلوم و التكنولوجيا في العام 2006م عن الأمطار في ولاية القضارف. و قد هدف البحث إلى إيجاد نموذج مناسب لتقدير كمية الأمطار الشهرية في ولاية القضارف وقد توصل الباحث الي:

- إن النموذج المناسب لتقدير كمية الأمطار الشهرية في ولاية القضارف هو النموذج الموسمي المضاعف $ARIMA(5,1,0) \times (6,11,1)$.

2- منتصر أحمد عثمان بحث لنيل درجة الماجستير في الإحصاء التطبيقي من جامعة السودان للعلوم و التكنولوجيا في عام 2009م بعنوان: (إستخدام تحليل السلاسل الزمنية للتنبؤ بكمية الأمطار في ولاية كسلا) وقد توصل الباحث الي:

- أن كميات الأمطار السنوية في ولاية كسلا خلال الفترة 1960-2007م تمثل سلسلة خطية ساكنة

- النموذج المناسب للأستخدام في التنبؤ بكميات الأمطار في ولاية كسلا هو نموذج $ARMA(1,1)$

- يمكن إستخدام النموذج الذي تم تقديره في التنبؤ بكميات الأمطار في ولاية كسلا لأنه النموذج الأنسب وأن الأخطاء الناتجة من تطبيقه تتبع التوزيع الطبيعي ومستقلة.

3- رشا شمس الدين محبوب بحث لنيل درجة الماجستير في الإحصاء التطبيقي من جامعة السودان للعلوم و التكنولوجيا في عام 2009م بعنوان: (تطبيق نماذج بوكس جنكنز للتنبؤ بتكلفة الحالات المحولة بالتأمين الصحي) وقد توصل الباحث الي :

- أن بيانات تكلفة الحالات المحولة من الولايات بالتأمين الصحي يمكن تحليلها بواسطة السلاسل الزمنية بأستخدام نماذج بوكس وجنكنز

- وأن بيانات تكلفة الحالات المحولة من الولايات بالتأمين الصحي غير ساكنة حيث تحوى إتجاه عام واصبحت ساكنة بعد أخذ الفرق الأول.

وهدفت الدراسة الي :

- إبراز العلاقة ما بين الأساليب المستخدمة للتنبؤ في السلاسل الزمنية ودقة التنبؤات المتحصل عليها ، ومدى تأثير التغيرات التي تطرأ على السلاسل الزمنية ودرجة العشوائية واللاخطية في البيانات على أداء هذه الأساليب.

- أفضل نموذج لتمثيل بيانات تكلفة الحالات المحولة من الولايات بالتأمين الصحي هو (1.1.3) ARIMA يمكن استخدام النموذج الذي تم تقديره في التنبؤ بتكلفة الحالات المحولة من الولايات بالتأمين الصحي).

4- عماد يعقوب رسالة لنيل درجة الدكتوراه مقدمة إلى كلية العلوم جامعة السودان للعلوم والتكنولوجيا في عام 2009م تناولت هذه الدراسة استخدام نماذج بوكس جنكيز ونماذج الشبكات العصبية للتنبؤ في السلاسل الزمنية الاقتصادية وتم التطبيق على بيانات القطاع الزراعي ممثلة في السلاسل الزمنية السنوية لمحاصيل الذرة والفل السوداني والقمح للفترة الزمنية من (1965-2000).

5- انتصار أبوتلة بشير ادريس محمد بحث لنيل درجة الماجستير في الإحصاء التطبيقي من جامعة السودان للعلوم و التكنولوجيا في عام 2010م بعنوان: (استخدام السلاسل الزمنية لبناء حوادث الحركة لولاية الخرطوم) وقد توصل الباحث الي:

- استخدام تحليل السلاسل الزمنية مناسب في دراسة حوادث المرور البسيطة والجسيمة و الموت.

- النموذج الإحصائي لسلسلة الحوادث البسيطة هو نموذج الإنحدار الذاتي من الدرجة الأولى $AR(1)$

- النموذج الإحصائي لسلسلة الحوادث الجسيمة نموذج الأوساط المتحركة من الدرجة الثانية $MA1 (1,2)$ or $ARIMA (0,1,2)$.

- النموذج الإحصائي لسلسلة حوادث الموت هو نموذج الأوساط المتحركة من الدرجة الأولى $MA1 (1,1)$ or $ARIMA (0,1,1)$

- يمكن استخدام النماذج التي توصل إليها البحث لمعرفة اتجاهات السلسلة لإستخدامها من قبل الجهات التخطيطية لتحليل ودراسة الظاهرة.

5- ورقة منشورة في مجلة العلوم والتقانة الصادرة من جامعة السودان للعلوم والتكنولوجيا والمقدمة من قبل بسام يونس إبراهيم تناولت الورقة تطبيق النموذج الموسمي المضاعف $ARIMA(0.1.1) \times$

12 (0.1.1) على المعدلات الشهرية لمتوسطات الحرارة في ولاية الخرطوم للفترة من (1991-2001) ومن خلال تقدير معاملات الارتباط الذاتي والجزئي قد توصل الباحث الي:
- أن السلسلة غير ساكنة كما أنها تتضمن عنصر الموسمية حيث أتضح أن السلسلة تعيد نفسها كل 12 شهر، وتم التحقق من كفاءة النموذج وذلك بإعطائه تنبؤات قريبة إلى الواقع اعتماد حساب الإحصائية Q (إبراهيم، بسام ، يونس ، 2005)

1-9 هيكلية البحث :

يضم البحث خمسة فصول ، الفصل الأول يضم المقدمة و المشكلة و الاهداف و الفروض و الأهمية و حدود البحث والمنهجية و بعض الدراسات و البحوث السابقة، ويضم الفصل الثاني الإطار النظري للسلاسل الزمنية و مراحل تحليلها و كما خصص الفصل الثالث للإطار النظري للشبكات العصبية و مراحل تحليلها ، ويضم الفصل الرابع الجانب العملي (التطبيقي)، و خصص الفصل الخامس لأهم الإستنتاجات والتوصيات.

الفصل الثاني

2-1 تمهيد:

السلسلة الزمنية هي عبارة عن مجموعة من القياسات المأخوذة عن متغير مرتبة وفقاً لزمان حدوثها وتعتبر السلاسل الزمنية الخاصة بالمؤثرات الاقتصادية مثل الدخل القومي البطالة، الإنتاج الصناعي وغيرها من السلاسل الزمنية المهمة وكذلك الحال بالنسبة للمبيعات السنوية للشركات التجارية والصناعية خلال فترة زمنية معينة هي عبارة عن سلاسل زمنية مهمة كذلك. وذلك لا يعني أن السلاسل الزمنية مقتصرة على المجالات الاقتصادية والتجارية بل تمتد أيضاً لمجالات أخرى مثل قياس كمية الأمطار في منطقة معينة، عدد الطلبة في مؤسسة تعليمية ما، حجم السكان في منطقة ما.

2-2 أنواع السلاسل الزمنية:

وتكون السلسلة الزمنية على نوعين متصل Continuous ومنفصلة Discrete بحسب الزمن. ويمكن أن تكون مستقرة Stationary إذا كانت الخصائص الإحصائية لا تتأثر بالزمن أو غير مستقرة Non stationary إذا كانت الخصائص الإحصائية تتأثر بالزمن، ونموذج السلسلة الزمنية هو الدالة التي تربط قيم السلسلة الزمنية بالقيم السابقة لها وأخطائها.

2-3 مكونات السلسلة الزمنية:

تتكون السلسلة الزمنية عادة من أربعة عناصر والتي يطلق عليها عادة بمكونات أو مركبات السلسلة الزمنية وهي:

1- الاتجاه العام Secular Trend

2- التغيرات الدورية Cyclical Variations

3- التغيرات الموسمية Seasonal Variations

4- التغيرات العرضية أو الغير منتظمة Irregular Variations

2-3-1 الاتجاه العام:

وهو العنصر الذي يقصد به الحركة المنتظمة للسلسلة عبر فترة زمنية طويلة نسبياً. ويعتبر في العادة أهم عناصر السلسلة الزمنية وغالباً ما يعتبر كعنصر وحيد في بناء التوقعات ويقال أن الاتجاه العام للسلسلة الزمنية موجباً إذا كان الاتجاه نحو التزايد بمرور الزمن كما هو الحال مع عدد السكان في أغلب دول العالم. ويقال أن الاتجاه العام للسلسلة سالباً إذا اتجهت القيم نحو التناقص بمرور الزمن كما هو الحال لنسبة الأميين إلى مجموع السكان في العديد من دول العالم.

2-3-2 التغيرات الدورية:

وهي التغيرات التي تطرأ على قيم السلسلة الزمنية بصورة منتظمة أو غير منتظمة ويزيد أمدتها على السنة والتغيرات الدورية تقيس فترة أو دورة التغير للمعطيات وبصورة عامة يتضمن هذا العنصر عدة مراحل هي:

مرحلة الإرتفاع الأولي، ومرحلة التراجع، ثم مرحلة الإلتعاش المحدود (الركود) وأخيراً مرحلة الإرتفاع النهائي وهذه المراحل الأربعة تمثل دورة كاملة. ومن الأمثلة على ذلك الدورات الإقتصادية التي تمر بها بعض الدول حيث يمر الإقتصاد فيها بمرحلة النمو السريع تعقبها مرحلة من التراجع الإقتصادي ثم مرحلة ركود ثم إستعادة النشاط الإقتصادي ذات النمو.

2-3-3 التغيرات الموسمية:

وهي التغيرات التي تحدث بصيغة دورية في فترات زمنية لا يزيد طولها عن السنة، فقد تكون أسبوعية أو شهرية أو فصلية، أي أنها التغيرات المتشابهة التي تظهر في الأسابيع أو الشهور أو الفصول المتناظرة خلال الفترات الزمنية المختلفة. ومن الأمثلة على ذلك مبيعات الملابس في فترة الأعياد، استهلاك الكهرباء، مبيعات بطاقات التهاني في المناسبات والأعياد.

2-3-4 التغيرات العرضية

وتشير إلى ما تبقى من التغيرات التي لم تدخل في العناصر السابق ذكرها وترجع التغيرات العرضية إلى عوامل لا يمكن التحكم فيها أو تلك التي تقع بصورة غير متوقعة مثل الزلازل والحروب والأحداث السياسية وغيرها. لذا يعتبر هذا العنصر عشوائي وقد تسمى هذه التغيرات بالتغيرات العشوائية، إلا أن تأثيرها يكون مؤقتاً يزول بزوال الأسباب المؤدية إليه.

أخيراً إن التعرف على هذه المركبات وتقديرها أحد أهداف دراسة السلاسل الزمنية، وذلك لأن معرفة الاتجاه العام مثلاً يساعدنا في التخطيط طويل الأجل، والتنبؤ بما قد يحدث في المستقبل، أما معرفة التغيرات الموسمية أو الدورية فإنه يفيدنا في التخطيط قصير الأجل.

وحتى نتمكن من تطبيق تحليل السلاسل الزمنية كان لابد من التطرق إلى المفاهيم التالية:

_ يقال إن السلسلة الزمنية المشاهدة $\{z_1, z_2, \dots, z_{n-1}, z_n\}$ مستقرة Stationary إذا حققت الشروط التالية:

$$1- E(z_t) = \text{constant} = \mu, \quad \forall t$$

$$2- \text{cov}(z_t, z_s) = \begin{cases} \text{constant} = \gamma_0, & \forall t, \forall s, t = s \\ f(|s - t|), & \forall t, \forall s, t \neq s \end{cases}$$

_ التشويش الأبيض White Noise $\{a_t\}$ هو عبارة عن متتابعة من المشاهدات العشوائية غير المرتبطة (وأحياناً نفترض إنها متتابعة من المتغيرات العشوائية التي تكون مستقلة ولها توزيعات متطابقة Independent, Identically Distributed (IID)) بمتوسط صفري وتباين ثابت σ^2 و غالباً ما يكون لها الخصائص الآتية:

$$1- E(a_t) = 0, \quad \forall t$$

$$2- \text{cov}(a_t, a_s) = \begin{cases} \sigma^2, & \forall t, \forall s, t = s \\ 0, & \forall t, \forall s, t \neq s \end{cases}$$

$$3- a_t \sim N(0, \sigma^2)$$

$$4- E(a_t, a_s) = 0, \quad \forall t, \forall s, t \neq s$$

$$5- E(z_s, a_t) = 0, \quad \forall t, \forall s, t \neq s$$

- دالة التغاير الذاتي Auto covariance Function وتعرف كالتالي:

$$\gamma_{t,s} = \text{cov}(z_t, z_s), \dots \forall t, \forall s$$

$$= E[(Z_t - \mu) - (z_s - \mu)], \forall t, \forall s \dots \dots \dots (1-2)$$

وإذا عرفنا الإزاحة k على إنها الفترة الزمنية التي تفصل بين Z_t وبين Z_{t-k} أو Z_{t+k} فإن دالة التغاير الذاتي تعطى بالعلاقة:

$$\gamma_k = \text{cov}(z_t, z_{t-k}), \dots k = 0, \pm 1, \pm 2, \dots$$

$$= E[(Z_t - \mu) - (Z_{t-k} - \mu)], k = 0, \pm 1, \pm 2, \dots \dots \dots (2-2)$$

- دالة الارتباط الذاتي Autocorrelation Function (ACF)

وتعرف كالتالي:

$$\rho_k = \lambda_k \div \lambda_0, k = 0 \pm 1, \pm 2, \dots \dots \dots (3-2)$$

ولها الخواص التالية:

1. $\rho_0 = 1$
2. $\rho_{-k} = \rho_k$
3. $0 \leq |\rho_k| \leq 1$

- دالة التغاير الذاتي للتشويش الأبيض هي:

$$\lambda_k = \text{cov}(a_t, a_{t-k}) \{ \sigma^2, k=0 \} \dots \dots \dots (4-2)$$

And

$$\rho_k = \lambda_k \div \lambda_0 \{ \sigma^2, k=0 \} \dots \dots \dots (5-2)$$

ـ دالة الارتباط الذاتي الجزئي Partial Autocorrelation Function (PACF)

وتعطي مقدار الارتباط بين Z_t و Z_{t-k} بعد إزالة تأثير الارتباط الناتج من المتغيرات $Z_{t-1}, Z_{t-2}, \dots, Z_{t-k+1}$ الواقعة بينهما ويرمز لها عند الإزاحة k بالرمز ϕ_{kk} وأحد طرق حسابها تقوم على حساب معامل الانحدار الذاتي ϕ_{kk} :

$$z = \phi_{k1} z_{t-1} + \phi_{k2} z_{t-2} + \dots + \phi_{kk} z_{t-k} + a_t \dots \dots \dots (6-2)$$

$$z_k = \phi_1 z_{t-1} + a_t$$

حساب ϕ_{11} :

بضرب طرفي العلاقة بـ Z_{t-1} وأخذ التوقع نجد

$$E(Z_{t-1}Z_t) = \phi_{11}E(Z_{t-1}Z_{t-1}) + E(Z_{t-1}a_t)$$

أي

$$\lambda_1 = \phi_{11}\lambda_0 \dots \dots \dots (7-2)$$

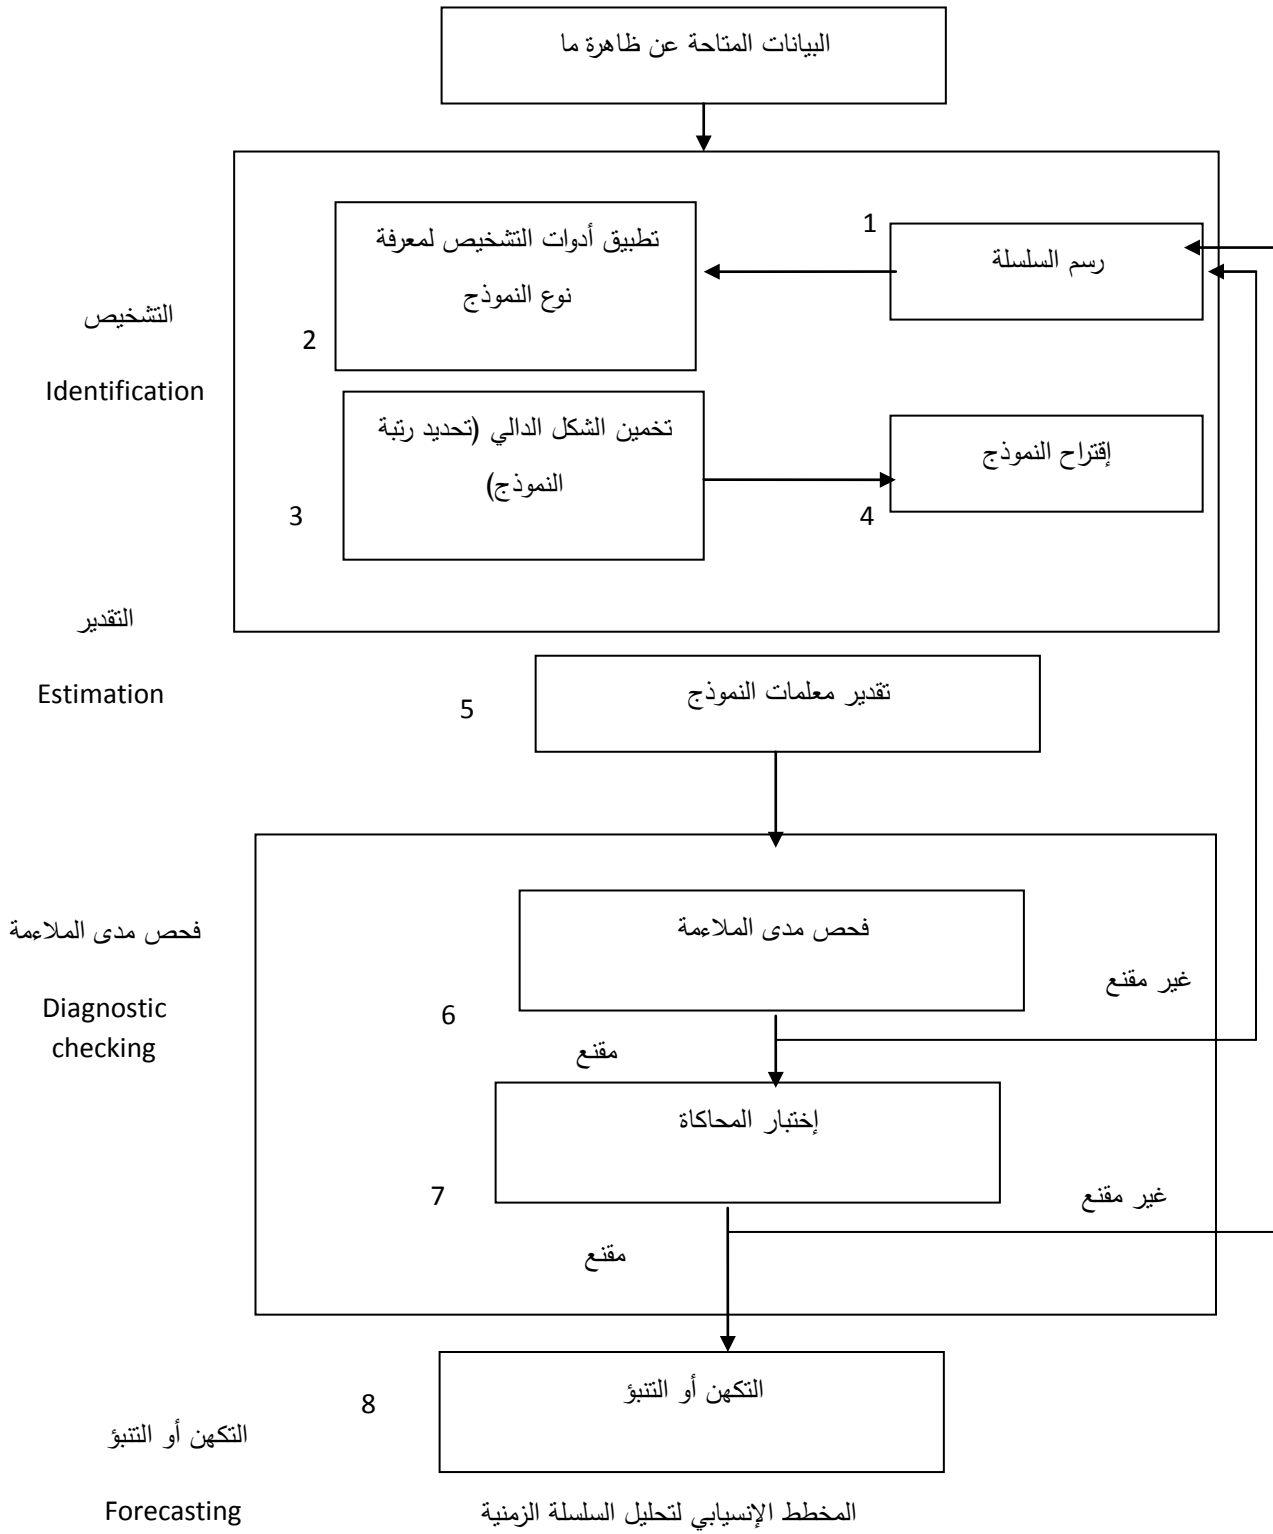
بالقسمة على γ_0 نجد

$$\phi_{11} = \rho_1 \dots \dots \dots (8-2)$$

4-2 تحليل السلاسل الزمنية : Time Series analysis

يتكون تحليل السلاسل الزمنية من مراحل متسلسلة تبدأ بمرحلة التشخيص Identification للنموذج والتي تعد المرحلة الأهم. وتليها مرحلة تقدير Estimation معلمات النموذج ، ومن ثم مرحلة فحص مدى الملاءمة Diagnostics Checking للنموذج. وتأتي المرحلة الأخيرة وهي مرحلة التنبؤ Forecasting. ومن الجدير بالذكر أن هناك إتجاهين لتحليل السلاسل الزمنية الأول هو إتجاه الزمن Time Domain والذي يعتمد على دوال الارتباط الذاتي ودوال الارتباط الذاتي الجزئي الثاني هو إتجاه التكرار Frequency Domain والذي يعتمد على تحليل الطيفي Spectrum Analysis وهنا سيكون تطبيقنا في هذا البحث على الإتجاه الأول. شكل 1-2 هو مخطط يوضح المراحل المختلفة لتحليل السلسلة الزمنية.

شكل (1-2): مراحل تحليل السلسلة الزمنية:



2-5 مراحل تحليل السلاسل الزمنية:

هنالك أربع مراحل يمر بها تحليل السلسلة الزمنية و هي التشخيص ثم التقدير ثم الفحص ثم التنبؤ كما هو موضح بالمخطط الإنسيابي في شكل (2-1).

2-5-1 تشخيص النموذج : Model Identification :

تعد مرحلة التشخيص المرحلة الأولى لتحليل السلاسل الزمنية. وتشمل معرفة نوع النموذج وتحديد الرتبة للنموذج المحدد من خلال المعايير التي تستخدم للمقارنة بين النماذج لتحديد النموذج الأفضل .

مرحلة التشخيص تتضمن الخطوات الآتية:

2-5-1-1 رسم بيانات السلسلة:

ويعد رسم البيانات الخطوة الأولى في تحليل أية سلسلة زمنية ومن خلال الرسم تكون لدينا فكرة جيدة عن إحتواء السلسلة على موسمية أو إتجاه عام أو قيم شاذة أو عدم الإستقرارية الذي يقود إلى التحويلات الممكنة على البيانات، لذلك فإن رسم السلسلة يبين حاجتها إلى التحويل المناسب لتستقر في متوسطها أو تبايناتها إذا لم تكن مستقرة قبل أي تحليل.

2-5-1-2 حساب وفحص PACF,ACF:

للعينة المسحوبة من السلسلة الأصلية لتحديد درجة الفروق (في حالة عدم الاستقرارية)، فإذا كانت ACF للعينة تنحدر ببطء شديد ، PACF للعينة تقطع بعد الإزاحة الأولى (أو بالعكس) فإن هذا يستوجب أخذ الفرق الأول $(1-B)Z_t$. وللتخلص من عدم الإستقرارية نحتاج إلى أخذ أعلى رتبة من الفروق $(1-B)^d Z_t$ حيث $d > 0$ (وغالباً ما تكون $d=0,1,2$). وإن النتائج المترتبة على إستخدام الفروق غير الضروري تكون أقل خطورة من النتائج المترتبة على التقليل من أهمية الفروق.

نحسب ونفحص PACF, ACF للعينة لتشخيص النموذج، وتوجد ثنائية ما بين نماذج ARMA(1,0) أو AR(1) ونماذج ARMA(0,1) أو MA(1) وفقاً للدالتين. وتزداد المشكلة تعقيداً في حالة النماذج

المختلطة $ARMA(p,q)$ ، لأن الاعتماد على ACF ، $PACF$ لتشخيص النموذج وتحديد رتبته لا يكون فاعلاً ، كون الدوال أعلاه في هذه الحالة تسلك سلوكاً متشابهاً هو سلوك التناقص التدريجي. جدول يوضح (1-2) خواص النماذج حسب الارتباط الذاتي و الارتباط الذاتي الجزئي:

جدول (1-2) خواص النماذج حسب الارتباط الذاتي و الارتباط الذاتي الجزئي:

الرقم	النموذج	ACF	PACF
1	AR(p)	يقترّب من الصفر تدريجياً	يساوي الصفر بعد الإزاحة p
2	MA(q)	يساوي الصفر بعد الإزاحة q	يقترّب من الصفر تدريجياً
3	ARMA(p,q)	يقترّب من الصفر تدريجياً	يقترّب من الصفر تدريجياً
4	AR(1)	يقترّب من الصفر تدريجياً	يساوي الصفر بعد الإزاحة 1
5	MA(1)	يساوي الصفر بعد الإزاحة 1	يقترّب من الصفر تدريجياً
6	AR(2)	يقترّب من الصفر تدريجياً	يساوي الصفر بعد الإزاحة 2
7	MA(2)	يساوي صفر بعد الإزاحة 2	يقترّب من الصفر تدريجياً

2-5-1-3 معايير اختبار الرتبة :

و هنالك معايير تستخدم للمقارنة بين النماذج لتحديد رتبة النموذج من هذه المعايير:

أ- معيار أكايكي للمعلومات **Akaike's Information Criterion** :

و يرمز له اختصاراً بـ AIC و يحسب من الصيغة الآتية :

$$AIC = n \ln SSR + 2K \dots \dots \dots (9-2)$$

حيث:

SSR : مجموع مربعات البواقي

n : حجم العينة

$$k = p + d + q$$

و النموذج الأفضل بين النماذج المقارنة هو الذي له أقل قيمة لـ AIC .

ب- معيار شوارتز Schwartz Bayesian Criterion :

و يرمز له إختصاراً بـ SBC و يحسب من الصيغة الآتية:

$$SBC = n \ln(SSR) + K \ln_{(n)} \dots\dots\dots(10 - 2)$$

حيث:

SSR : مجموع مربعات البواقي

n : حجم العينة

و

$$k = p + d + q$$

و النموذج الأفضل بين النماذج المقارنة هو الذي له أقل قيمة لـ SBC

2-5-2 تقدير النموذج: The Model Estimation

بعد تحديد شكل النموذج لابد من تقدير معلمات النموذج و σ^2 ، \hat{b}_1 ، \hat{b}_0 وذلك بإستخدام البيانات التاريخية المتوفرة لدينا. هنالك طرق كثيرة لتقدير المعلمات علي سبيل المثال طريقة العزوم وطريقة المربعات الصغري.

2-5-3 فحص واختبار دقة النموذج : Model Diagnostics Checking

بعد التعرف على نموذج مبدئي وتقدير معلمات هذا النموذج نجري بعض التشخيصات على البواقي أو الأخطاء المقدرة لنرى مدى مطابقة النموذج للسلسلة المشاهدة ، ويفترض أن البواقي هي مقدرات التشويش الأبيض a_t والتي نفترض إنها موزعة طبيعياً بمتوسط صفري وتباين σ^2 . البواقي تعطى بالعلاقة

$$e_t = z_t - \hat{z}_t = \hat{a}_t, \quad t = 1, 2, \dots, n$$

يقوم الفحص والاختبارات على فحص البواقي هل هي تشويش أبيض أم لا ، فإذا كانت تشويش أبيض نعتبر النموذج المطبق مقبولاً أما إذا لم تكن كذلك فيجب علينا إعادة النظر وإقتراح نموذج آخر . ويمكن إستخدام الإحصائية الآتية لمعرفة ما إذا كان النموذج المقدر ملائم للبيانات أم لا ، و الإحصائية هي:

$$Q = (n - d)(n - d + 2) \sum r^2(a_t) \div (n - d - k) \dots \dots \dots (11 - 2)$$

وتسمى الإحصائية Q بإحصائية Ljung-box و هي تتوزع توزيع مربع كاي بدرجة حرية $(m - p - q)$ حيث:

$$m = \frac{n}{4}$$

فإذا كانت قيمة Q أقل من قيمة $\chi^2_{m,\alpha}$ حيث α هي مستوى المعنوية فإن هذا يعني كفاءة و ملائمة النموذج المقدر للبيانات .

2-5-4 التنبؤ : Forecasting

تعتبر مرحلة التنبؤ من أهم مراحل تحليل نماذج السلاسل الزمنية ، و هي الهدف الأساسي لعملية تقدير النموذج ، إذ بعد أن يتم التعرف على النموذج في المرحلة الأولى و هي مرحلة التشخيص و من ثم تقدير معلمات النموذج في المرحلة الثانية و التحقق و فحص النموذج في المرحلة الثالثة ، تأتي المرحلة الرابعة و هي المرحلة الأهم و هي مرحلة التنبؤ حيث يتم معرفة سلوك الظاهرة المدروسة في المستقبل، و يتم عرض التنبؤ باستخدام طريقة مربع الخطأ الأدنى.

و عند التنبؤ بنماذج السلاسل الزمنية فإن قيمة الخطأ a_t عند الزمن الذي يتم التنبؤ بقيمة الظاهرة عنده تعطى لها القيمة صفر

2-6 السكون (الإستقرارية): Stationary

من شروط تحليل السلسلة الزمنية أن تكون مستقرة في المتوسط أي أن متوسطها ثابت و لا يختلف باختلاف الزمن . و أيضا يجب أن يكون تباين السلسلة الزمنية ثابت و لا يختلف باختلاف الزمن. و عدم تحقق أي من الشرطين السابقين يؤدي إلى عدم إمكانية تحليل السلسلة الزمنية و لذلك يجب معالجته أولاً.

2-6-1 معالجة عدم الاستقرار في المتوسط :

تتم معالجة عدم الإستقرار في المتوسط بإيجاد تحويل مناسب للسلسلة غير المستقرة لتحويلها إلى سلسلة مستقرة فإذا كان لدينا النموذج الآتي:

$$z_t = a_0 + a_1 +$$

نجد إن المتوسط هو

$$E(z_t) = \alpha_0 + \alpha_1 t$$

وهو غير ثابت بالنسبة للزمن، أي أن شرط الإستقرار الأول غير متحقق في هذه الحالة.

نوجد التحويل ∇z_t كالتالي:

$$\nabla z_t = z_t - z_{t-1}$$

الآن نجد متوسط السلسلة الجديدة w_t

$$E(w_t) = \alpha_1 = \text{const} \dots \forall t$$

أي أن تطبيق التحويل $\nabla = (1 - B)$ على السلسلة غير المستقرة (أي أخذ الفرق الأول للسلسلة) حولها إلى سلسلة مستقرة.

و كمثال آخر إذا كان لدينا النموذج الآتي:

$$z_t = a_0 + a_1 t$$

بإيجاد المتوسط

$$E(z_t) = \alpha_0 + \alpha_1 t + \alpha_2 t^2$$

وهو يعتمد على الزمن، أي أن النموذج غير مستقر. بأخذ التحويل $\nabla^2 z_t$ (أخذ الفرق الثاني) نجد

$$\rho_1 = \phi_1 + \phi_2 \rho_1 + \dots + \phi_p \rho_{p-1}$$

$$(1 - 2B + B^2)z_t = (1 - 2B + B^2)(\alpha_0 + \alpha_1 t + \alpha_2 t^2 + a_t)$$

$$= 2\alpha_1 + E(a_t + a_{t-1} + a_{t-2})$$

وهكذا

$$w_t = \nabla^2 z_t = 2\alpha_1$$

$$E(w_t) = 2\alpha_1 = \text{const} \dots \forall t$$

أي أن تطبيق التحويل ∇^2 (أي أخذ الفرق الثاني) على السلسلة غير المستقرة حولها إلى مستقرة.

بشكل عام إذا كان النموذج غير المستقر على الشكل

$$z_t = \alpha_0 + \alpha_1 t + \dots + \alpha_s t^s + a_t, a_t \sim N(0, \delta^2), \alpha_0, \alpha_1, \dots, \alpha_s \in (-\infty, \infty)$$

فإن التحويل $\nabla^d z_t$ يحوله إلى نموذج مستقر، أي أن $w_t = \nabla^d z_t$ هو نموذج مستقر.

2-6-2 معالجة عدم الاستقرار في التباين:

تتم معالجة عدم الاستقرار في التباين بإيجاد تحويل مناسب للسلسلة غير المستقرة لتحويلها إلى سلسلة مستقرة فإذا كان لدينا النموذج الآتي:

$$z_t = z_{t-1} + a_t, \quad a_t \sim N(0, \sigma^2) \dots \dots \dots (16 - 2)$$

نجد من التعويض المتكرر

$$z_t = a_1 + a_2 + \dots + a_t$$

وبأخذ التوقع والتباين

$$E(z_t) = 0 = \text{constant} \quad \forall t$$

$$V(z_t) = t\sigma^2$$

ونلاحظ إن التباين يعتمد على الزمن t .

$$w_t = \nabla z_t = z_t - z_{t-1} = a_t \quad \dots \dots \dots (17 - 2) \quad \text{بأخذ الفرق الأول}$$

وبأخذ التوقع والتباين

$$E(w_t) = 0 = \text{constant} \quad \forall t$$

$$V(w_t) = \sigma^2 = \text{constant} \quad \forall t$$

إذن الفرق الأول حول السلسلة غير المستقرة في التباين إلى سلسلة مستقرة.

بشكل عام إذا كان التباين دالة في متوسط متغير على الشكل

$$V(z_t) = cf(\mu_t)$$

حيث $c > 0$ ثابت و $f(u_t)$ دالة معروفة تعطى قيمة غير سالبة و μ_t متوسط يتغير مع الزمن و بالتالي فإن التباين يعتمد على الزمن وهنا نحاول إيجاد تحويل $T(z_t)$ أي إيجاد دالة $T(u_t)$ لإستقرار التباين.

التحويل

$$y = T(z) = \frac{z_1^\lambda - 1}{\lambda} \dots \dots \dots (18 - 2)$$

يعطي سلسلة مستقرة في التباين حيث $\lambda \in (-\infty, \infty)$ هو معلمة التحويل. الجدول التالي يعطي القيم الأكثر استخداماً للمعلمة λ مع التحويلات المقابلة لها:

جدول (2-2): القيم الأكثر استخداماً للمعلمة λ مع التحويلات المقابلة لها:

λ	-0.1	-0.5	0.0	0.5	1.0
y_t	$\frac{1}{z_t}$	$\frac{1}{\sqrt{z_t}}$	$\ln z_t$	$\sqrt{z_t}$	z_t

7-2 نماذج تحليل السلاسل الزمنية Time Series analysis models

تضم نماذج تحليل السلاسل الزمنية بصورة عامة ثلاثة نماذج أساسية تسمى نماذج بوكس جنكز ونستعرض في هذا الجزء هذه النماذج:

7-2-1 نماذج بوكس - جنكيز Box-Jenkins Model

في هذه النماذج هنالك متغير تابع y_t أو x_t وهو يمثل قيمة السلسلة في الأزمنة الماضية .
إفترضات هذه النماذج:-

$$\epsilon(a_t)=0$$

$$\text{var}(a_t)=\epsilon(a_t^2)=S_a^2$$

$$\epsilon(a_t, a_{t-s})=0$$

أي أن قيم الأخطاء مستقلة عن بعضها البعض.

$$\epsilon(a_t, y_{t-s})=0$$

أي أن الخطأ الحالي مستقل عن المشاهدات y_t السابقة .

ولتبسيط الصيغ الرياضية نظرياً وتصغير الأرقام علمياً سوف نستخدم السلسلة الزمنية بدلالة الانحرافات:

$$Z_t = y_t - \mu$$

1-1-7-2 Autoregressive Model (AR): النموذج الإنحدار الذاتي

سميت هذه النماذج بنماذج الانحدار الذاتي لان فيها المتغيرات المستقلة تمثل التابع ولكن بأزمته ماضية بعني آخر هي نماذج إنحدار z_t علي z_{t-1}, z_{t-2}, \dots هذا بدلالة الانحرافات أما بدلالة القيم الأصلية يكون النموذج هو إنحدار y_t علي y_{t-1}, y_{t-2}, \dots إذن باختصار هي نماذج إنحدار المتغير علي نفسه.

الصيغة الرياضية للنموذج الإنحدار الذاتي من الدرجة (p) تاخذ الشكل الآتي:

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + a_t \quad (19-2)$$

في هذا النموذج لا يوجد مقطع لأنها كتبت بطريقة الانحرافات وهو يمر بنقطة الأصل.

$\phi_1, \phi_2, \dots, \phi_p$ تمثل المعلمات وهي معاملات المتغيرات المستقلة .

$Z_{t-1}, Z_{t-2}, \dots, Z_{t-p}$ علي التوالي تمثل الميول.

a_t هو الخطأ العشوائي والذي يسمى عادة في هذه النماذج بحد الضوضاء أو التشويش الأبيض (الأزعاج الأبيض) white noise term

ويمكن كتابة النموذج أعلاه بدلالة القيم الأصلية y_t بالصورة التالية:-

$$Y_t = \mu(1 - \phi_1 - \phi_2 - \dots - \phi_p) + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + a_t$$

حيث:

$\mu(1 - \phi_1 - \phi_2 - \dots - \phi_p)$ هو المقطع والحد الثابت.

2-1-7-2 Moving Average Model (MA): النموذج الاوساط المتحركة

الصيغة الرياضية للنموذج الأوساط المتحركة من الدرجة (q) تاخذ الشكل الآتي:

$$Z_t = -\theta_1 a_{t-1} - \theta_2 a_{t-2} - \theta_3 a_{t-3} - \dots - \theta_q a_{t-q} + a_t \quad (20-2)$$

حيث ان:

$\theta_1, \theta_2, \dots, \theta_q$ هي معلمات النموذج.

$a_t, a_{t-1}, a_{t-2}, \dots, a_{t-q}$ هي الأخطاء

3-2-7-2 نماذج الإنحدار الذاتي والمتوسطات المتحركة المختلطة:

Mixed Auto Regressive Moving Average Models ARMA(p,q)

الصيغة الرياضية للنموذج تأخذ الشكل التالي:

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \theta_3 a_{t-3} - \dots - \theta_q a_{t-q} + a_t \dots (21-2)$$

الفصل الثالث

3-1 الشبكة العصبية الاصطناعية (ANN) Artificial Neural Network

يتكون المخ من مجموعة من الخلايا العصبية تسمى عصبونات وتنتشر هذه الخلايا في مجموعات تسمى شبكات وكل شبكة تتكون من عدة آلاف من الخلايا العصبية المتصلة أو المتشابهة فيما بينها وهذه الخلايا العصبية أو الشبكات العصبية هي التي تمكن المخ من أداء وظائفه من تفكير وتذكر وغيره. الخلية العصبية أو العصبون عبارة عن وحدة معالجة بها نواة في المنتصف ولها بعض النهايات العصبية وهي المسؤولة عن المدخلات للخلية وكذلك يوجد بالخلية موصل طرفي مسئول عن المخرجات , وهذه النهايات الطرفية مندمج معها النهايات العصبية للخلية الثانية فيما يعرف بنقطة الإشتباك , وتنتقل الإشارة من عصبون إلي آخر عن طريق تفاعلات كهروكيميائية , ويقوم المخ عن طريق هذه الإتصالات والتفاعلات بمعالجة المعلومات بشكل متوازي أي في نفس اللحظة , ومن خلال هذه الخلايا العصبية يتم تخزين المعرفة عن العالم الخارجي في العقل البشري ونتيجة لذلك يكون للشبكات العصبية المقدرة علي التعلم من خلال الخبرة.

3-1-1 الشبكة العصبية البيولوجية الاصطناعية Biological and Artificial Neural Network:

من خلال عمل الشبكات العصبية البيولوجية تم إستيحاء فكرة الشبكات العصبية الاصطناعية وذلك عن طريق تقليد الشبكة العصبية البيولوجية في الحاسب فيما يعرف بالشبكة العصبية الاصطناعية , وتم تصميم نماذج محاكاة للطريقة التي يعمل بها مخ الإنسان بإستخدام الحاسوب لتعمل علي حل بعض المسائل التي تستخدم الطرق التقليدية لحلها.

بدأ الإهتمام فعليا بالشبكات العصبية الاصطناعية منذ العام 1943 م عند ما قام العالمان (Pitts & Worren Meculloch) بتصميم المفهوم العام للشبكات العصبية الاصطناعية

وبينا كيفية عمل العصبونات البسيطة , وفي العام 1945 م وضع العالم (Donald Hebb) أول قانون لتعلم الشبكات العصبية , وإزداد الإهتمام بصورة أكبر خلال فترة الستينات وفي السبعينيات والثمانينيات بدأت تظهر التطبيقات العملية للشبكات في حل كثير من المسائل وتوسعت التطبيقات للشبكة العصبية الاصطناعية في الوقت الحالي لتغطي مجالات مختلفة وواسعة في الحياة العملية. ولم يزل هذا الحقل يخضع لمزيد من الدراسات الأكاديمية بغرض التطوير في أساليبه المختلفة وكذلك تطوير وتوسيع مظلة تطبيقاته.

3-1-2 تعريف الشبكة العصبية الاصطناعية ANN :-

الشبكة العصبية الاصطناعية هي نموذج يحاكي الشبكة العصبية الطبيعية (البيولوجية) ويستخدم عددا من الطرق الأساسية المستخدمة في النظم العصبية الطبيعية بمساعدة برمجيات المحاكاة وأسلوب المعالجة المتوازية . أي أن الشبكة العصبية الاصطناعية تقوم بمعالجة المعلومات بأسلوب محاكاة العقل البشري. ومن الناحية الإحصائية يمكن اعتبار الشبكة العصبية عبارة عن نموذج رياضي أو مجموعة من الأدوات لنمذجة البيانات الإحصائية غير الخطية.

3-1-3 تطبيقات الشبكات العصبية الاصطناعية ANN :-

تمتد تطبيقات الشبكات العصبية الاصطناعية في كثير من مجالات الحياة وتتوسع في كل يوم جديد لتضم المزيد من المجالات كما يتم تطوير التطبيقات السابقة باستمرار لتعطي المزيد من الفعالية والدقة. ونذكر هنا بعض المجالات التي استخدمت فيها هذه التقنية وقد أعطت حلولاً مرضية وذات كفاءة لكثير من المسائل.

1- التطبيقات الاقتصادية والمالية لـ ANN

تستخدم الشبكات العصبية في تنفيذ بعضا من العمليات الاقتصادية وعمليات التحليل المالي مثل:-

أ- التنبؤ : التنبؤ بالمبيعات , التنبؤ بالأسعار ,....,

ب- بناء نماذج بحوث العمليات والنماذج الإحصائية والتي تستخدم في مسائل الأمثلة.

ت- إدارة المخاطر كالقروض المالية والرهن العقاري.

2- تطبيقات تحليل الصور والأنماط: -

تتنوع هذه التطبيقات لتعطي العديد من المجالات المتعلقة بعمليات تحليل الصور , حيث تستخدم الصور الخام أو الغير معالجة كمدخل رئيسي للشبكة ليتم التعرف علي الأمر المراد معرفته من تحليل الصورة و كأمثلة لهذه التطبيقات:

أ - عمليات تصنيف الصور .

ب- التعرف علي الصورة المشوهة أو الناقصة أو الغير واضحة كصور الأقمار الصناعية.

ت - التعرف علي الأهداف (مثلا التعرف الآلي علي خط اليد) .

ث - الفحوصات الطبية الآلية لتشخيص الأمراض ووصف المعالجات (الطبيب الفوري).

ج - التفقيش الصناعي : تشخيص أعطال الآلات وتحليل أسبابها.

3- تطبيقات التحكم الآلي:

تم استخدام الشبكات العصبية الاصطناعية في كثير من مشاكل التحكم الآلي مثل:

أ - مشاكل الحركة في الإنسان الآلي وكذلك الرؤية من أجل الوصول للأهداف.

ب - التسيير الذاتي للمركبات المتحركة.

ت - مسائل الإتزان (محاكاة القيادة).

4- تطبيقات معالجة اللغات الحية: -

استخدمت تطبيقات الشبكات العصبية الاصطناعية بنجاح في هذا المجال (الكلام المنطوق والكلام المقروء) ومن أمثلة ذلك.

أ - تحويل النص المكتوب إلي كلام منطوق ومثال لذلك (NET TWALK).

ب - التعرف علي الكلام المنطوق ومثال لذلك (الآلة الكاتبة الصوتية.)

5 -تطبيقات معالجة الإشارة:-

ومثال لذلك الشبكات العصبية المستخدمة في إزالة الضجيج من خطوط الهاتف أي عمليات التنقية.

3-2 مكونات الشبكة العصبية الاصطناعية: Components of Artificial Neural

Networks

3-2-1 المكونات الأساسية للشبكة العصبية الاصطناعية

تتكون الشبكة العصبية الاصطناعية من مجموعة من وحدات المعالجة والتي تسمى خلايا عصبية أو عصبونات والتي تتماثل مع العصبونات البيولوجية الموجودة في المخ , وهذه الوحدات متصلة فيما بينها في شكل ترابطات تسمى بالشبكة العصبية.

وتعمل الروابط علي تمرير الإشارات من عصبون لآخر ويكون لكل رابط وزن عددي يصاحبه ويستقبل كل عصبون عدد من المدخلات عن طريق تشابكاته وينتج إشارة مخرجات واحدة فقط وتنقل إشارة المخرجات عن طريق الرابط الخارجي للعصبون , وينقسم الرابط الخارج بدوره إلي عدد من الفروع التي تنقل نفس الإشارة وتنتهي الفروع الخارجة عند الروابط الواردة لعصبونات أخرى في الشبكة.

البنية العامة أو الشكل العام لهذه الشبكات تتألف من المكونات الأساسية التالية أو بعض منها علي الأقل حيث توجد بعض الشبكات لاتحتوي علي كل هذه العناصر وهذه العناصر هي:-

1.طبقة المدخلات.

2.طبقة المخرجات.

3. الطبقة الخفية.

4. الوصلات البيئية (الأوزان).

طبقة المدخلات Input Layer

هي الطبقة التي يتم عبرها تغذية الشبكة بالبيانات من الخارج وتستقبل البيانات بواسطة وحدات المعالجة (العصبونات) التي تتألف منها الشبكة , وقد تتألف هذه الشبكة من وحدة معالجة واحدة أو أكثر علي حسب تركيبة الشبكة. ومدخلات الشبكة يمكن أن تكون علي صورة بيانات خام (Raw Data) أو قد تكون مخرجات من عناصر معالجة أخرى. وهذه البيانات المدخلة إلي الشبكة قد تتخذ أحد شكلين إما بيانات ثنائية (Binary) أو بيانات متصلة (Continuous) ويتوقف ذلك علي نوع القيم العددية المستخدمة.

وحدات المعالجة في طبقة الإدخال لأ يتم فيها أي معالجات حسابية بل تقوم بنقل البيانات المدخلة من هذه الطبقة عبر الوصلات البيئية (الأوزان) إلي وحدات المعالجة في الطبقة الخفية أو مباشرة إلي وحدات المعالجة في طبقة المخرجات إذا كانت الشبكة لا تحتوي علي طبقة خفية وأي شبكة عصبية تحتوي علي طبقة واحدة فقط من وحدات الإدخال.

طبقة المخرجات: Output Layer

تتكون هذه الطبقة من وحدات المعالجة التي عبرها يتم إخراج الناتج النهائي للشبكة . وقد تحتوي هذه الطبقة علي وحدة معالجة واحدة أو أكثر من وحدة وفقا للبنية المعمارية للشبكة. تستقبل وحدات المعالجة في طبقة المخرجات الإشارات القادمة إليها من طبقة الإدخال مباشرة أو من الطبقة الخفية وبعد إجراء المعالجات اللازمة قد ترسل إشارة بالمخرجات النهائية أو قد تقوم بإعادة هذه المخرجات كمدخلات مرة أخرى للشبكة وذلك عندما لا تتم المعالجة المطلوبة للبيانات , وتحتوي الشبكة عادة علي طبقة مخرجات واحدة فقط.

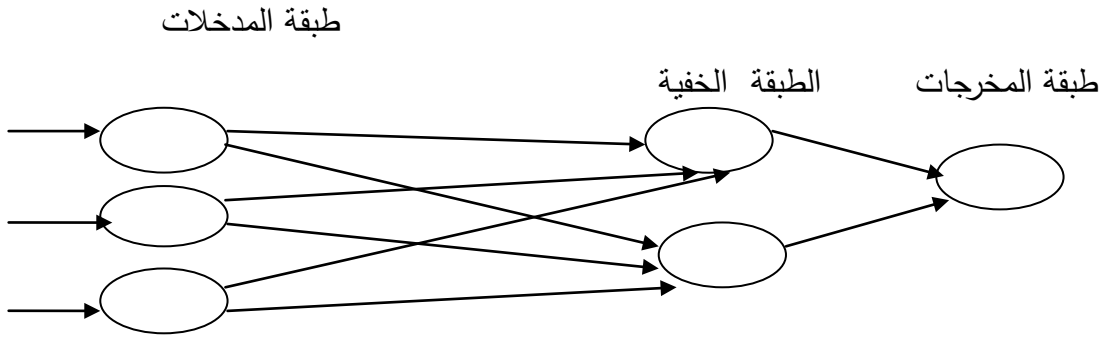
الطبقة الخفية: Hidden Layer

تقع هذه الطبقة بين طبقة المدخلات وطبقة المخرجات وقد لا تحتوي تراكيب بعض الشبكات علي الطبقة الخفية وقد تحتوي الشبكة علي طبقة خفية واحدة أو أكثر من طبقة خفية. تستقبل الطبقة الخفية الإشارات القادمة إليها من طبقة المدخلات عبر الوصلات البيئية فتقوم بمعالجتها وإجراء اللازم عليها ومن ثم إرسالها عبر الوصلات إلي طبقة المخرجات.

الوصلات البينية (الأوزان : Connections)

هي عبارة عن وصلات اتصال بين الطبقات المختلفة تقوم بربط الطبقات مع بعضها أو الوحدات داخل كل طبقة عبر الأوزان التي تكون مصاحبة أو مرفقة مع كل وصلة بينية ومهمة هذه الوصلات نقل البيانات أو الإشارات الموزونة بين وحدات المعالجة أو الطبقات. شكل (1-3) يوضح المكونات الأساسية للشبكة عصبية اصطناعية:

شكل (1-3) نموذج معماري لشبكة عصبية اصطناعية:



2-2-3 وحدات المعالجات (العصبونات) Processing Element :-

وحدات المعالجة أو العصبونات هي الوحدات التي تقوم بعملية 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. تتبع عناصر المعالجة نظام المعالجة المتوازنة (Parallel Processing) في إجراء الحسابات المسندة إليها أو معالجة البيانات ، وهي في ذلك تشبه عمل العقل البشري. وتتألف أي وحدة معالجة أو عصبون من المكونات الأساسية التالية:

1. معاملات الأوزان Weighting Coefficients .
2. دالة الجمع Summation Function.
3. دالة التحويل Transfer Function .
4. دالة المخرجات Output Function .

معاملات الأوزان weighting Coefficients :

يعتبر الوزن هو العنصر الرئيسي في الشبكات العصبية الاصطناعية ، فهي تمثل الروابط المختلفة التي يتم عبرها نقل البيانات من طبقة إلى أخرى ويعبر الوزن عن القوة النسبية أو الأهمية النسبية لكل مدخل

إلى عنصر المعالجة , وتمثل الأوزان الوسيطة الأساسية لذاكرة الشبكة العصبية من خلال ضبط الأوزان ويرمز للوزن بين عنصري معالجة (i) و (j) بالرمز w_{ij} .

دالة الجمع: - Summation Function

إن أول عملية تقوم بها وحدة المعالجة هي حساب مجموع المدخلات الموزونة القادمة إلى الوحدة باستخدام دالة الجمع , حيث تقوم هذه الدالة بحساب متوسط الأوزان لكل مدخلات وحدة المعالجة ويتم ذلك بضرب كل قيمة مدخلة في وزنها المصاحب ومن ثم إيجاد المجموع لكل حواصل الضرب. ويعطي ذلك رياضياً كما يلي:

$$S_j = \sum_{i=1}^n x_i w_{ij} \dots\dots\dots(1-3)$$

S_j ناتج عملية الجمع لكل وحدة معالجة j .

x_i القيمة المدخلة القادمة من الوحدة (i) والداخلية إلى الوحدة. (j)

w_{ij} الوزن الذي يربط وحدة المعالجة (j) بالوحدة (i) الموجودة في الطبقة السابقة.

ويمكن أن تكتب المعادلة السابقة على الصيغة التالية:

$$S_j = b_j + \sum_{i=1}^n x_i w_{ij} \dots\dots\dots(2-3)$$

حيث

يمثل إنحياز (bias) ويعتبر احد مكونات الدخل ويأخذ دائماً القيمة واحد $x_0=1$ وعمل الانحياز مشابه لعمل الأوزان لذلك يعامل معاملة أي وزن ويمكن ن يرمز له بالرمز $(b_j=w_{0j})$. وإضافة وحدة إنحياز إلى وحدات الدخل يغير من شكل تابع التنشيط أو دالة التحويل.

دوال التحويل :-

إن العملية الثانية في وحدة المعالجة بعد عمل دالة الجمع هو تحويل ناتج الجمع إلى أحد القيم التي يفترض أن تكون ضمن نواتج الشبكة المرغوب بها.

وتتم هذه الخطوة باستخدام دالة تسمى بدالة التحويل حيث تقوم هذه الدالة بتحويل ناتج عملية الجمع الموزون في الخطوة الأولى إلى قيمة محصورة في مدي معين ويتم ذلك بمقارنة نتيجة الجمع مع قيمة معينة تسمى قيمة العتبة (threshold) ويرمز لها بالرمز θ ليتحدد الناتج ويطبق على المجموع عادة قبل المقارنة تابع تنشيط معين (Activation function) .

ويسمى أحياناً بتابع التحويل وتتوقف مخرجات الشبكة بصورة أساسية على هذا التوزيع وبناءً على هذه التوابع أو الدوال تعطي الشبكة دائماً مخرجات محصورة ضمن المجال (0,1) أو المجال (-1,+1) .

دالة المخرجات: - *Output function*

بعد أن تقوم دالة الجمع بعملية الجمع الموزون للمدخلات ومن ثم دالة التحويل بتحويل ناتج الجمع إلى قيمة محصورة في مدي معين . فقد تكون المخرجات في اغلب الأحيان مساوياً 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 بالإخراج وكذلك تساعد المنافسة في تحديد الوحدات التي سوف تشترك في عملية التعلم والتدريب. ويمكن تلخيص عمل وحدة المعالجة في الشبكة العصبية في الخطوات التالية :-

- 1- إستقبال 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 بإستخدام 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 يبيث إلي عدة وحدات معالجة أخرى أو يمكن أن يكون هو الناتج النهائي للشبكة.

3-2-3 البنية المعمارية للشبكة العصبية *Architecture of ANN*:-

بنية الشبكة أو معمارية الشبكة العصبية هي الطريقة التي تربط بها وحدات المعالجة مع بعضها البعض داخل كل طبقة أو بين الطبقات المختلفة المكونة للشبكة , حيث ترتبط هذه الوحدات بطرق مختلفة ووفقا لكيفية هذا الترابط وعدد الطبقات المكونة للشبكة تظهر لنا البنية أو المعمارية العامة للشبكة العصبية. ويمكن تصنيف تراكيب الشبكات وفقا لعدد الطبقات إلي:

1 -شبكات وحيدة الطبقة Single Layer Networks

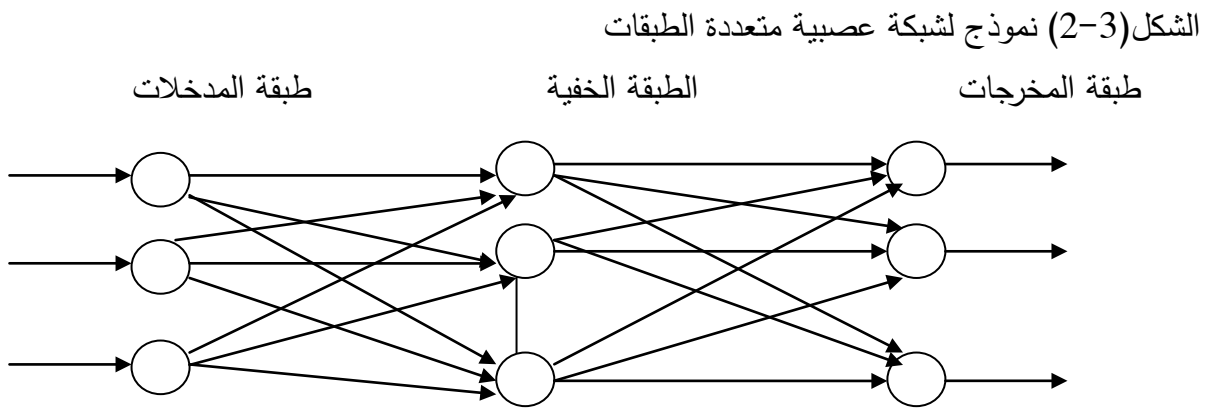
2 -شبكات متعددة الطبقات Mullti Layer Network

1 -شبكات وحيدة الطبقة: -

وهي من أبسط أنواع تراكيب الشبكات وتتألف عادة من طبقة واحدة من عناصر المعالجة تربط ربطا مباشراً مدخلات الشبكة مع مخرجاتها حيث يتم إجراء كل الحسابات في طبقة المخرجات وعادة يتم حساب عدد الطبقات في الشبكة بدون حساب طبقة المدخلات لأنها لا تقوم بانجاز أي حسابات.

2 - شبكات متعددة الطبقات: -

تحتوي تراكيب هذه الشبكة علي أكثر من طبقة من عناصر المعالجة التي تربط بينها الوصلات البينية (الأوزان) حيث تتكون الشبكة علي الأقل من طبقتين طبقة لإستقبال المدخلات وهي غير محسوبة و طبقة المخرجات، وبين طبقة المدخلات والمخرجات توجد الطبقة الخفية ، ويمكن أن تحتوي الشبكة علي أكثر من طبقة خفية ، ويتوقف ذلك علي نوع التطبيق المستخدم فيه الشبكة. وتعد الشبكات المتعددة الطبقات من أكثر الشبكات إستخداماً حيث تتميز بفعالية كبيرة في إنجاز التطبيقات المختلفة، الشكل (2-3) يوضح نموذج لشبكة عصبية متعددة الطبقات.



ويمكن تصنيف الشبكات العصبية وفقاً لطبيعة إنتشار البيانات عبر طبقات وحداتها وترابطها إلي الأنواع التالية:

- 1 - شبكات التغذية المتقدمة feed forward
- 2 - شبكات التغذية الراجعة feed Back
- 3 - شبكات الترابط الذاتي Auto Associative
- 4 - شبكات ذاتية التنظيم Self Organizing

3-3 خطوات بناء الشبكة العصبية:-

تمر عملية بناء الشبكة العصبية الإصطناعية بعدة مراحل يمكن تلخيصها في الآتي :-

1- تجميع وإعداد البيانات:

تشتمل هذه المرحلة علي عمليتين تتمثل في جمع البيانات وتجزئة البيانات المجمعة إلي فئتين هما فئة التدريب (Training set) وفئة الإختبار (Test set) وتتم عملية التجزئة للبيانات بصورة عشوائية حيث تستخدم الفئة الأولى لتدريب وتجهيز الشبكة والفئة الثانية للتحقق من صلاحية الشبكة.

وعملية تمثيل البيانات في الشبكة إما بالصورة الثنائية (1,0) أو بالتمثيل ثنائي القطبية (1,-1) ويعتبر التمثيل ثنائي القطبية هو الاختيار الأفضل لمعظم الشبكات .

2- تحديد تركيبة الشبكة:

يتم إختيار النموذج أو التركيبة الملائمة عادة بناءً على الغرض من الدراسة وهناك العديد من تراكيب الشبكات العصبية وعلى سبيل المثال:

- شبكات عصبية بنظام الذاكرة الترابطية.
- تراكيب ذات طبقات مزدوجة.
- تراكيب ذات طبقات خفية.

3- إختبار خوارزم التعلم :-

في هذه المرحلة يتم تحديد خوارزمية التعلم التي تتناسب مع تركيبة الشبكة ، حيث يتم إستخدام هذه الخوارزمية في تدريب الشبكة ومن أهم خوارزميات التدريب خوارزمية الإنتشار الخلفي Backward propagation Algorithm

4- تحديد قيم الأوزان الابتدائية ومعدل التعلم :-

قبل بدء تدريب الشبكة يتم وضع قيم إبتدائية للأوزان والإحيازات وكذلك وضع قيمه لمعدل التعلم.

5 - تدريب الشبكة :-

تدريب الشبكة بتقديم بيانات التدريب التي تم تجهيزها في الخطوة الأولى ومن خلال التدريب تتغير الأوزان بشكل متكرر، وبإستمرار المحاولات التدريبية تتمكن الشبكة من الحصول على فئة متوافقة من الأوزان تمكننا من الحصول على المخرجات المطلوبة لكل المدخلات ، ويتوقف زمن التدريب على تركيبة الشبكة وعدد وحدات المعالجة وعدد الطبقات والقيم الابتدائية المختارة للأوزان ومعدل التعلم. ويتم التوقف من التدريب عندما يصل خطأ الشبكة إلى المستوي المقبول إحصائياً.

6 - الإختبار :-

بعد الإنتهاء من عملية التدريب تبدأ عملية الإختبار وذلك بتقديم بيانات الإختبار للشبكة حتى يتم التأكد من أداء الشبكة ومدي مقدرتها على حساب المخرجات الصحيحة وتعتمد هذه المرحلة بصورة أساسية على الأوزان المتحصل عليها من مرحلة التدريب.

7 - التنفيذ :-

يتم في هذه المرحلة استخدام الشبكة للغرض الذي أنشئت من أجلها ومن ثم المتابعة والتطوير المستمر لتحسين أداء الشبكة. ويمكننا تلخيص أهم القرارات التي يجب إتخاذها أثناء بناء الشبكة في الآتي:-

- 1- الحجم الملائم لبيانات التدريب والإختبار.
- 2-خوارزميات التعلم المناسبة.
- 3- عناصر المعالجة وتوزيعها في طبقات فيما يعرف بمعمارية الشبكة.
- 4-دالة التحويل.
- 5-معدل التعلم في كل طبقة.
- 6- أدوات الكشف والتحقيق.

3-4التعلم في الشبكات العصبية الاصطناعية *Learning in ANN* :-

تعتبر عملية التعلم في الشبكات العصبية الإصطناعية الوسيلة الرئيسية التي تمكن الشبكة من إنجاز وظائفها أو ما يطلب منها من مهام , وتقوم عملية التعلم في الشبكة العصبية علي نفس الطريقة التي يكتسب بها الإنسان المعرفة حيث يتم عرض مجموعة من الأمثلة للشكل أو النمط المطلوب من الشبكة معرفتها وتقوم الشبكة عن طريق عملية ضبط أوزان الترابطات بين وحداتها المختلفة بتشكيل تمثيل داخلي للشكل أو النمط المطلوب وتخزينه في ذاكرتها لتكون متاحة للاستخدام بعد ذلك. وتنقسم طرق تعلم الشبكة العصبية إلي قسمين رئيسيين :-

-التعلم بواسطة معلم. Supervised Learning.

-التعلم بدون معلم (التعلم الذاتي Unsupervised Learning).

3-4-1 التعلم بواسطة معلم:-

تقوم طرق التعلم بواسطة معلم للشبكات العصبية علي فكرة عرض بيانات التدريب علي الشبكة علي هيئة زوج من الأشكال وهما الشكل المدخل والشكل المخرج أوالشكل المستهدف،وتسمي هذه البيانات بمجموعة التدريب ويتم تجهيزها عند بداية بناء الشبكة , حيث كل مجموعة من المدخلات تقابلها مجموعة من المخرجات المرغوبة , وتقوم الشبكة بمقارنة المخرجات الفعلية للشبكة بالمخرجات المطلوبة وتستخدم الفرق بين الشكليين في حساب الخطأ، وتستخدم هذه الأخطاء بعد ذلك في تعديل الأوزان لتقليل الفرق بين الشكل المخرج والشكل المستهدف وتتم عملية تعديل الأوزان باستخدام دالة تعرف بدالة تحديث الأوزان أو تسمي أحياناً بدالة التعلم , وتستمر محاولات التعديل بصورة تكرارية من أجل تصغير الأخطاء لكل وحدات المعالجة , وتتوقف عملية التعديل عندما يصل أداء الشبكة إلي المستوي المطلوب أي عندما تكون مخرجات الشبكة هي نفسها المخرجات المطلوبة.

تختلف الشبكات العصبية في طرق حساب الخطأ ويتوقف ذلك عادة علي خوارزمية التعلم المستخدم في الشبكة فهناك خوارزميات تعتمد علي تصحيح الخطأ في عملية التعديل وخوارزميات أخرى تعتمد علي الذاكرة.

مما سبق يمكننا تلخيص عملية التعلم في الثلاث مهام الآتية:-

أ -حساب المخرجات.

ب- تعديل الأوزان.

ث-إعادة المعالجة.

3-4-2 التعلم بدون معلم (التعلم الذاتي):-

تبنى أساليب التعلم الذاتي للشبكات العصبية علي أساس قدرة الشبكة في اكتشاف الملامح المميزة لما يعرض عليها من إشكال وأنماط , حيث تنتظر الشبكة للإنتظام في الإتجاه العام للبيانات المدخلة , ومن ثم تقوم بتطوير تمثيل داخلي لهذه الأشكال المدخلة , وذلك من خلال التكيف الذاتي لأوازن ترابطاتها ولأوضاع إستثارة عناصرها , ويتم كل ذلك من دون عرض أي أمثلة للشبكة لما يجب عليها أن تنتجه وذلك علي عكس المبدأ المتبع في أسلوب التعلم بواسطة معلم حيث يتم ضرب أمثلة للشبكة لما يجب أن تنتجه.

وتغذي الشبكة في حالة التعلم الذاتي فقط بمتجه المدخلات دون عرض الهدف علي الشبكة حيث تكون للشبكة بعض المعلومات عن كيفية تنظيم نفسها , وهذه المعلومات مبنية علي معمارية أو تركيب الشبكة وقوانين التعلم المتبعة. ومن طرق التعلم بدون معلم:-

-التعلم الهيبباني. Hebbian Learning

-التعلم التنافسي. Competitive learning.

3-5 العلاقة مابين الشبكات العصبية والنماذج الإحصائية :-

تعتبر العديد من الشبكات العصبية عبارة عن مجموعة واسعة من نماذج الانحدار الخطية وغير الخطية حيث نجد أن معظم نماذج الشبكات العصبية تشابه أو تكاد تطابق الكثير من النماذج الإحصائية المعروفة مثل:

- النماذج الخطية العامة.

- الانحدار متعدد الحدود.

- الانحدار اللامعلمي.

- المكونات الرئيسية.

- التحليل العنقودي.

- التحليل التمييزي.

أما نماذج الشبكات العصبية التي لا يوجد ما يماثلها من النماذج الإحصائية فهي لا تتعدى سوي العدد القليل مثل نماذج الانتشار المضاد Counter propagation ونماذج خرائط التنظيم الذاتي Self Organizing Maps ونماذج Learning Vector Quantization وهذه النماذج رغم عدم وجود ما يماثلها من النماذج الإحصائية إلا أنها كذلك تستخدم في تحليل البيانات. وتعتبر عملية تحليل البيانات واحدة من الإتجاهات الثلاثة الأساسية التي تستخدم في تطبيقات نماذج الشبكات العصبية.

3-5-1 استخدام خوارزمية الانحدار غير الخطي في الشبكات العصبية: -

أن الخوارزميات التي صممت لتدريب الشبكات العصبية تم تصميمها لتعمل في كمبيوترات تتبع نظام المعالجة المتوازية ولكنها في الواقع يتم تطبيقها في الكمبيوترات العادية التي تعمل بنظام المعالجة المتوالية، لذلك لأنجدها تعمل بكفاءة عالية في تدريب الشبكات العصبية.

تعتبر خوارزميات الأمثلة الرقمية المعيارية Standard Numerical Optimization Algorithm والتي تسمى بخوارزمية الانحدار الغير خطي لإستخدامها في الانحدار الغير الخطي ، هذه الخوارزمية يمكن أن تستخدم بكفاءة عالية في تدريب الشبكات العصبية ، وتؤدي عملها في تدريب الشبكات بصورة أسرع من خوارزميات الشبكات العصبية المعيارية.

وسبب آخر لعدم كفاءة خوارزميات الشبكات المعيارية ، أغلبها مصمم للحالات التي تكون فيها البيانات غير مخزنة بل متاحة في بيئة الزمن الحالي ،ومثل هذه البيانات غالباً غير ملائمة للتطبيقات الإحصائية ، لذلك تعتبر خوارزمية الانحدار الغير خطي هي الأنسب لتطبيقات تحليل البيانات.

ويعود عدم الإستفادة من الأدوات الإحصائية في تطوير الشبكات العصبية أن معظم باحثي الشبكات العصبية هم من المهندسين والفيزيائيين وخبراء الحاسوب والبيولوجيين وأن عدم معرفتهم التامة بالأساليب الإحصائية كان وراء ذلك وهذا يفسر لنا كذلك قلة التطبيقات الإحصائية في هذا المجال المتطور.

3-5-2 المصطلحات الإحصائية ومصطلحات الشبكات العصبية: -

بالرغم من التماثل والتشابه بين نماذج الشبكات العصبية والنماذج الإحصائية ، إلا أن المصطلحات التي تعبر بها نماذج الشبكات العصبية وتلك التي تعبر بها النماذج الإحصائية يوجد بينهما إختلاف كبير ، أدناه بعض التعبيرات الإحصائية وما يقابلها من الشبكات العصبية.

المتغيرات المستقلة تسمى مدخلات.

القيم المتنبأ تسمى مخرجات.

المتغيرات التابعة تسمى الأهداف وقيم التدريب.

البواقي تسمى أخطاء.

التقدير يسمى التدريب التعلم.
التكيف أو التنظيم الذاتي.
مقياس التقدير يسمى بدالة الخطأ أو دالة التكلفة.
المشاهدات تسمى الأنماط أو أزواج التدريب.
تقديرات المعلمة تسمى الأوزان المشابك.
التفاعلات تسمى عصبونات الرتبة العليا.
التحويلات تسمى الوصلات الوظيفية.
الإنحدار وتحليل التميز تسمى التعلم الموجه.
تقليل البيانات تسمى التعلم الذاتي أو الاتجاه الذاتي.
التحليل العنقودي تسمى بالتعلم التنافسي.
المتغيرات الداخلة والخارجة تسمى التعميم .

3-6 نماذج الشبكات العصبية والتنبؤ: -

تغطي تطبيقات الشبكات العصبية مجالات عديدة في الحياة العامة ويعتبر مجال التنبؤ واحد من الحقول التي طبقت فيها نماذج الشبكات العصبية بنجاح ، وقد أظهرت النتائج المتحصل عليها من تلك الدراسات دقة عالية بالمقارنة مع أساليب التنبؤ التقليدية.
وبما أن عملية التنبؤ هو تحليل البيانات السابقة للظاهرة المدروسة للتعرف علي النمط العام لهذه الظاهرة في المستقبل ، فان ذلك يعتبر من العمليات الأساسية التي تقوم بها الشبكات العصبية ،أي عملية تحليل الأنماط أو التعرف. وتتفق بذلك نماذج الشبكات العصبية مع أساليب تحليل السلاسل الزمنية المختلفة ونماذج بوكس جنكز ونماذج تحليل الإنحدار حيث يعتبر التنبؤ من الأهداف الرئيسية لهذه النماذج الإحصائية.

وما يميز نماذج الشبكات هو عدم وجود أي افتراضات أو شروط مسبقة عند تطبيقها في مجال التنبؤ كما في الأساليب الإحصائية التي يجب أن تتحقق بعض الافتراضات قبل تطبيقها فمثلاً في نماذج بوكس جنكز يجب أن يتحقق السكون قبل بناء النموذج ولا يوجد مثل هذا الشرط عند بناء نماذج الشبكات.

ومن المسائل التي تم تطبيق أسلوب الشبكات العصبية للتنبؤ بها ، التنبؤ بسعر سلعة ما في المستقبل فالشبكة العصبية التي تستخدم في هذه العملية أو في كل عمليات التنبؤ ، يتم تدريبها بأن تتلقي كمدخل رئيسي البيانات التاريخية الخاصة بالمتغير المراد التنبؤ به ، فمثلاً للتنبؤ بالأسعار يتم تغذية الشبكة بالتغير في السعر والكمية المخزونة وكلا من المؤشرات المالية والتسويقية الخاصة ، لنحصل كمخرج من هذه الشبكة علي السعر المتوقع لهذه السلعة مستقبلاً. الشبكات العصبية التي يكثر إستخدامها في عمليات

النتبؤ هي شبكات الإنتشار الخلفي ذو التغذية الأمامية (Feed Forward Back Propagation NN) والشكل الأكثر إستخداماً لهذه الشبكات هي شبكة ذو مخرج واحد وطبقة خفية واحدة أو اثنين مع عدد من وحدات المعالجة، دوال تحفيز أو تحويل آسية في الطبقة الخفية دالة تحويل خطية في طبقة المخرجات. كما توجد أنواع أخرى من الشبكات تستخدم في النتبؤ مثل الشبكة العصبية ذو الإنحدار العام (Generalized Regression NN) شبكات دالة القاعدة الإشعاعية (Radial Basis Function NN) .

وقد تؤثر نوعية المتغيرات المستخدمة كمدخلات للشبكة تأثير كبير في تحديد نوعية الشبكة العصبية التي ستستخدم في النتبؤ.

الشكل العام لدالة الشبكات العصبية المستخدمة في النتبؤ يمكن أن تكتب علي الصيغة التالية:

$$Y = F \left[H_1(X), H_2(X), \dots, H_n(X) \right] + U \quad (3-3)$$

حيث:-

Y: المتغير التابع يناظر مخرجات الشبكة output .

x: المتغيرات المستقلة تناظر مدخلات الشبكة input.

H :دوال تحفيز الطبقات الخفية في الشبكة العصبية.

F :مخرجات دالة التحفيز في الشبكة.

U :حد الخطأ في الدالة.

وفي مسائل النتبؤ عادة ما يتم دمج سمات المدخلات للأنواع المختلفة. وتعمل الشبكة العصبية بصورة أفضل عندما تتغير كل مدخلاتها ومخرجاتها في مدي يقع بين (1,0) وبالتالي يجب تغيير كل البيانات قبل أن تستخدم في نموذج الشبكة العصبية. وعملية تغيير البيانات تتم بأساليب مختلفة ويعتمد ذلك في الأساس علي نوع البيانات (مستمرة , متقطعة , تصنيفية ,) وبناء علي نوع البيانات يمكننا أن نتبع الأساليب التالية في عملية التغيير.

1- البيانات المستمرة : تتغير بين قيمتين سابقتي التحديد (اقل قيمة واكبر قيمة ,) ويتم التحويل أو

التغيير إلي المدى 0 إلي 1 كما يلي :-

القيمة المحولة = القيمة الفعلية - القيمة الدنيا

القيمة العليا - القيمة الدنيا

2- البيانات المتقطعة أو الوثابة : يكون لها أيضا قيم دنيا وقيم عليا مثال لقيم متقطعة عدد الغرف

بالمزمل قد يتراوح من 0 إلي 4 ويتم تحويل البيانات المتقطعة بأن يحدد مكانا لكل قيمة ممكنة

علي الفترة من 0 إلي 1 كما مبين في الشكل (3-3).

شكل (3-3) يوضح تغيير البيانات المنقطعة أو الوثابة

0	→	0
1	→	0.25
2	→	0.50
3	→	0.75
4>	→	1

وهذه الطريقة تستخدم لمعظم التطبيقات التي لها بيانات منقطعة أو وثابة تأخذ حتى القيمة 12 إلا إنه إذا زادت القيم عن 12 فيجب معاملة البيانات المنقطعة مثل المستمرة.

3- البيانات التصنيفية : -مثل الجنس ، الحالة الإجتماعية وغيرها ، تغير هذه البيانات يتم عن طريق إستخدام طريقة الترميز واحد من n , (1 of N coding) تشمل هذه الطريقة أن كل قيمة صنف تعامل كمدخلات مستقلة ، كمثال لذلك الحالة الإجتماعية التي يمكن أن تأخذ (أعزب - مطلق - متزوج - أرمل) تمثل بأربع مدخلات ويمكن أن تكون لكل من هذه المدخلات الأربعة القيمة 0 أو 1 فيمكن تمثيل الشخص المتزوج مثلا في هذا المثال بمنحة قيمة. (0 0 1 0) .

7-3 الشبكات العصبية والسلاسل الزمنية ANN and Time series :-

التنبؤ بالسلاسل الزمنية تعتبر واحدة من المجالات الحيوية التي يكثر فيها إستخدام تطبيقات الشبكات العصبية الإصطناعية.

فقد إستخدمت تقنية الشبكات العصبية كأسلوب بديل أو أسلوب موازي للأساليب الإحصائية التقليدية التي تستخدم في التنبؤ بالسلاسل الزمنية ، كالمتوسطات المتحركة والتمهيد الآسي ونماذج بوكس جنكنز وتعرف هذه الأساليب التقليدية بصورة عامة بأساليب تحليل السلاسل الزمنية ، وقد نافست نماذج الشبكات العصبية المستخدمة في التنبؤ أساليب التنبؤ التقليدية وتفوقت عليها في كثير من الحالات في دقة النتائج المتحصل عليها.

وتظهر مقدرة الشبكات العصبية في التنبؤ بالسلاسل الزمنية في قدرتها الكبيرة في التعامل مع سلوك عدم الخطية في البيانات ، حيث في الواقع تظهر معظم سلاسل البيانات علاقات غير خطية وهذا الأمر يضيف ميزة إضافية على الشبكات العصبية بالمقارنة مع الطرق التقليدية في التنبؤ حيث معظمها تعتبر أساليب خطية أي تتعامل مع بيانات خطية.

بدأ استخدام الشبكات العصبية الاصطناعية في التنبؤ بالسلاسل الزمنية في نهاية الثمانينات وأول محاولة كانت في العام 1987 م بواسطة (Farber)&(Laped) حيث استخدموا البيروسترون متعدد الطبقات وخوارزمية الانتشار الخلفي في التنبؤ بسلسلة زمنية غير مستقرة ، فيالعام 1988 م قدم (werbos) دراسة دعم فيها استخدام الشبكات العصبية في التنبؤ بالسلاسل الزمنية وشرح فيها استخدام خوارزمية الانتشار الخلفي في تدريب الشبكة ، وقد أعطت هذه الدراسة نتائج أفضل وذلك عند مقارنتها بالعديد من الأساليب الإحصائية التقليدية كالإنحدار الخطي أو طريقة بوكس جنكنز .
وتعتبر الآن الشبكات العصبية من الأساليب الأساسية التي يكثر استخدامها في التنبؤ بالسلاسل الزمنية.

3-7-1 القرارات المطلوبة لتطبيق الشبكات العصبية في التنبؤ بالسلاسل الزمنية: -

- إن عملية بناء شبكة عصبية تستخدم في التنبؤ بالسلاسل الزمنية ، يتطلب ذلك الاهتمام بالاتي:-
- 1 -تحديد معمارية الشبكة العصبية ، أي تحديد عدد الطبقات المطلوبة وعدد العصبونات داخل طبقة.
- 2 -عدد العصبونات في طبقة المدخلات تحدد مقدار البيانات التاريخية التي سوف تستخدم في توليد التنبؤ .
- 3 -طبقة المخرجات ستشتمل فقط علي العصبونات المتطابقة مع التنبؤ المنفرد.
- 4 -عدد العصبونات في الطبقة الخفية يحدد مقدرة الشبكة في تقريب العلاقة الغير خطية بين تباطؤات السلسلة الزمنية والتنبؤات الناتجة.
- 5 -القيام بتهيئة البيانات المدخلة إلي الشبكة العصبية فقد يساعد ذلك في تحسين أداء الشبكة وتتم تهيئة البيانات بإجراء بعض التحويلات الحسابية عليها.
- 6 -إختيار خوارزمية التدريب المناسبة تعتبر من أهم العوامل في تطبيقات الشبكات العصبية الاصطناعية.

3-7-2 أنواع الشبكات العصبية التي تستخدم في التنبؤ بالسلاسل الزمنية

هناك العديد من معماريات الشبكات العصبية التي تستخدم في التنبؤ بالسلاسل الزمنية وأكثر هذه المعماريات استخداماً .

- 1 -البيروسترون متعدد الطبقات. (MLP) Multilayer perceptron
- 2 -شبكات دالة القاعدة الإشعاعية. (RBF) Radial Basis Function
- 3 -شبكات الاسترجاع الخلفي. Recurrent Networks
- 4 -شبكات. Sigma – pi & pi Sigma
- 5 -شبكات. Ridge polynomial

وعلي سبيل المثال سنتطرق فيما يلي الي بعض منها بما فيها شبكات البيرسبترون متعددة الطبقات والتي تم إستخدامها في تحليل بيانات السلسلة الزمنية لفيضان نهر النيل.

شبكات البير سبترون متعدد الطبقات :- (MLP)

من أكثر الشبكات استخداما في التنبؤ بالسلاسل الزمنية ، تقوم فكرة هذه الشبكة علي إستخدام القيم السابقة للسلسلة الزمنية كمدخلات للشبكة ، ويتم تجميع الأوزان في الطبقة الخفية بالنسبة للمدخلات ، ويتم إستخدام التحويلة الغير خطية (السيغمويد) طبقة المخرجات للشبكة تستقبل مخرجات الطبقة الخفية وتطبق عليها التحويلة الخطية حيث يتم إنتاج القيم المنتبأ للسلسلة الزمنية.

الشكل القياسي لمعمارية شبكة MLP التي يكثر إستخدامها في التنبؤ تتصف بالاتي:

- 1 - شبكة ذو بنية معمارية كاملة الترابطات.
- 2 - تحيزوت و ترابطات مختصرة مباشرة من المدخلات إلي وحدات المخرجات.
- 3 - طبقة خفية واحدة مع دالة تحفيز لوجستية وذلك لتحسين عدم الخطية في الوحدات الخفية.
- 4 -طبقة مخرجات تستخدم مع وحداتها دالة خطية لوزن مدي المخرجات وغالبا يكون المدى بين (0,1)

النموذج العام لشبكة MLP الذي يستخدم في التنبؤ يعطي كالآتي:-

$$\tilde{X}(t) = w_0 + \sum_{j=1}^h w_{jf} [\sum_{i=1}^n w_{ij} x(k-i)] + w_{j0} \quad (4-3)$$

حيث

H: عدد وحدات الطبقة الخفية.

N: عدد وحدات المدخلات.

W_{ij} : الأوزان بين المدخلات والطبقة الخفية.

W_j : الأوزان بين الطبقة الخفية وطبقة المخرجات.

$F_j(.)$: دالة تحفيز سيغمويد في الوحدات الخفية j^{th}

شبكات Sigma - pi & pi Sigma

هي شبكات عصبية متعددة الحدود أو تسمى أحيانا بشبكات الرتبة العليا ، في هذه الشبكات يتم إرسال المجموع الموزون من الإشارات المدخلة من خلال دوال التحويل في الطبقة الخفية إلي طبقة المخرجات الهدف من شبكات الرتبة العليا هو تبديل العصبونات الخفية الموجودة في الشبكات ذو الرتبة الأولى ، وبالتالي تخفيض التعقيد في البنية المعمارية للشبكة.

شبكات Sigma – pi هي شبكات تغذية أمامية من طبقة خفية واحدة , مخرجات الطبقة هو نتاج الحدود المدخلة ، ومخرجات الشبكة هي مجموع هذه النتائج , هناك طبقة واحدة فقط من الأوزان المعدلة تنتج في عملية التدريب السريع.

الشكل العام لمخرجات هذه الشبكة تعطي كالآتي:

$$\tilde{X}(t) = w_0 \sum_{j=1}^h w_i \Phi_i(v_i) \quad (5 - 3)$$

Where

$$v_i = \sum_{j=1}^n a_{ij} x_j$$

Φ_i : دالة التحفيز في الطبقة الخفية.

A_{ij} : أوزان محددة (عادة توضع تساوي 1).

w_i : الأوزان المعدلة.

شبكة Pi – Sigma تتشابه هذه الشبكة في بنيتها المعمارية شبكة , Sigma – pi الاختلاف

بينهما نجد أن مخرجات الطبقة الخفية في شبكة Pi – Sigma هو مجموع الحدود المدخلة

ومخرجات الشبكة هي الناتج من هذه الحدود , بالإضافة إلى ذلك لهذه الشبكة طبقة واحدة من

الأوزان المعدلة ولكن هذه الأوزان تكون في الطبقة الأولى.

الشكل العام لمخرجات هذه الشبكة كالآتي—

$$x(t) = w_0 + \sum_{i=1}^h a_i \phi_i(v_i) \quad (6 - 3)$$

Where

$$v_i = \sum_{j=1}^n w_{ij} x_j$$

الفصل الرابع

الجانب التطبيقي

1-4 تمهيد:

في هذا الفصل سوف يتم تطبيق جميع الأساليب التي تم التطرق إليها في الإطار النظري في الفصل الثاني والفصل الثالث للبحث وذلك بهدف بناء النموذج المطلوب والتأكد من الإفتراضات الخاصة به ثم إيجاد القيم التنبؤية لكمية مياه فيضان نهر النيل وذلك إستناداً علي بيانات فيضان نهر النيل في الفترة من 1940 وحتى 2009. ثم إيجاد النتائج الوصفية المبدئية لهذه البيانات كما هو موضح في جدول (1-4).


جدول (1-4) وصف كمية مياه الفيضان

variable	Mean	Std error of Mean	Std. Deviation	Range	Maximum	Minimum
مياه الفيضان	48538.65	1052.269	8803.83071	38993.59	68726.92	29733.33

المصدر: إعداد الباحث بواسطة برنامج SPSS

من الجدول (1-4) بلغ متوسط كمية مياه الفيضان في الفترة من 1940 الى 2009 (48538.65) وقد بلغ الإنحراف المعياري (1107270)، وبلغت أكبر كمية لمياه الفيضان (68726.92) وكان ذلك في العام 2007م كما بلغت أقل قيمة (29733.33) وكان ذلك في العام 1985. شكل (1-4) يوضح السلسلة الزمنية لبيانات فيضان نهر النيل .

شكل 4-1 رسم الاتجاه العام لبيانات فيضان نهر النيل :



من إعداد الباحثة باستخدام برنامج EXCEL


المحور السيني = السنوات.

المحور الصادي = كمية مياه الفيضان.

4-2 إختبار السكون:


تم إستخدام إختبار السكون عن طريقة الرسم للارتباط الذاتية كما هو موضح في الشكل 4-2 و 4-3 حيث تم إختبار ماذا كانت بيانات مياه نهر النيل في الفترة من 1940 الي 2009 هي بيانات ساكنة.

شكل (4-2) معاملات الارتباطات الذاتية لبيانات فيضان نهر النيل من 1940 وحتى 2009



المصدر: إعداد الباحث بواسطة برنامج MINITAB

شكل (4-3) معاملات الارتباطات الجزئية لبيانات فيضان نهر النيل من 1940 وحتى 2009



المصدر:

إعداد الباحث بواسطة برنامج MINITAB

من الشكل (4-2) و (4-3) نجد أن السلسلة الزمنية ساكنة لأن جميع قيم الارتباط الذاتي تقع داخل حدود الثقة.

تم استخدام المعادلة (2-9) الموضحة في الفصل الثاني لغرض إجراء تحديد الرتبة ووجد أن نموذج AR(1) له أقل قيمة لكل من معيار اكاكي حيث ان $AIC = 1468.8577$. ومعيار شوارتر حيث $SBC = 1473.3547$ بالتالي يتضح ان AR(1) هو النموذج الأفضل كما هو في جدول (2-4).

جدول (2-4): معيار اكاكي ومعيار شوارتر

النموذج	AIC	SBC
AR(1)	1468.8577	1473.3547
AR(2)	1470.7018	1477.4473
AR(3)	1471.9169	1480.9190
MA(1)	1469.2475	1473.7445
MA(2)	1471.1634	1477.9089
MA(3)	1470.8847	1479.8786
ARMA(1,1)	1470.4817	1477.2272
ARMA(1,2)	1472.1898	1481.1638
ARMA(2,1)	1472.0545	1481.0485
ARMA(2,2)	1471.7942	1483.0367

تم تقدير معلمات النموذج وفق طريقة المربعات الصغرى كما هو موضح جدول (3-4) وتم الحصول علي النموذج المقدر التالي:

$$Z_t = 0.24988Z_{t-1}$$

جدول (3-4) : معلمات النموذج

Estimates of Parameters

Model	B	SEB	T	P- value
AR1	0.24988	0.11797	2.1181	0.038
CONSTANT	48451.4769	1361.9825	35.5740	0.000

المصدر: إعداد الباحث بواسطة برنامج SPSS

3-4 إختبار فحص توفيق النموذج:

لإختبار مدي مطابقة النموذج للسلسلة المشاهدة تم إجراء إختبار الفحص والتوفيق للنموذج أعلاه ووجد أن قيمة $P\text{-Value} = 0.458$ كما هو موضح في جدول (4-4) وهذه القيمة أكبر من 05. وبالتالي نستنتج ان النموذج ملائم ويمكن الإعتماد عليه.

جدول (4-4): فحص توفيق النموذج

Ljung-Box

	Chi-Square	DF	P- value
Ljung-Box	16.953	17	0.458

المصدر: إعداد الباحث بواسطة برنامج SPSS

4-4 تحليل نماذج الشبكات العصبية :

تم استخدام أسلوب الشبكات العصبية في بناء نموذج للسلاسل الزمنية لمياه نهر النيل وتم اختبار وتحديد هذا النموذج من خلال عدة اجراءات يمكن تمثيلها في الآتي :

جدول (4-5) وصف الشبكات العصبية لفيضان مياه نهر النيل

Net Name	Training Error	Test Error	Validation Error	Hidden Activitation
MLP 1-2-1	0.022542	0.034304	0.035998	Logistic

من إعداد الباحثة إستخدام برنامج STATISTICA

4-4-1 نوع الشبكة :

من الجدول (4-5) نلاحظ انه تم استخدام شبكة البيرسبترون متعدد الطبقات MLP لبناء نموذج الشبكة لبيانات فيضان مياه نهر النيل، وتعتبر MLP من أهم انواع الشبكات العصبية الي تستخدم في التنبؤ بالسلاسل الزمنية .

4-4-2 بنية النموذج :

تم تحديد معمارية وبنية الشبكة من خلال تجريب عدد من التراكيب المختلفة والمفاضلة بينها باستخدام معيار أخطاء التدريب وإخطاء الإختبار وإخطاء التحقق حيث أن هذه العملية تتكرر حتي تصل الي بنية معينة إعتقادا علي أقل أخطاء التدريب للبنيات المختلفة و يتم التكرار حتي يظهر التدني المستمر في قيمة الخطأ المصاحب لعملية التدريب وعندما نلاحظ أن قيمة الخطأ قد تدني كثيراً ، توقف في الإنخفاض عنده يتم التوقف في عملية التدريب والإعتماد علي البنية والمعمارية التي توقفت فيها عملية التدريب .

و نلاحظ من الجدول (4-5) أنه قد تم إختيار المعمارية MLP 1-2-1 للسلسلة فيضان نهر النيل
إعتماداً علي إخطاء التدريب التي توقف الإنخفاض فيها وهي 0.022542. وتعني هذه البنية 1-2-1
أنه توجد طبقة إدخال واحدة وهي البيانات المدخلة لكل نموذج حيث أننا أدخلنا متغير واحد فقط وهو
كمية فيضان نهر النيل ، وتوجد بالبنية طبقتين خفيتين وتوجد طبقة إخراج واحدة.

4-4-3 دوال التحفيز :

تم إستخدام دوال تحفيز أو دوال تنشيط حيث تم إستخدام الدالة اللوجستية وتم إستخدام خوارزمية الإنتشار
السريع للتدريب .

4-4-3 مدخلات الشبكة :

تم تغذية الشبكة العصبية بالسلسلة الزمنية لبيانات كمية فيضان نهر النيل، وتم تقسيم البيانات المدخلة
الي الشبكة بطريقة الثلث تلافيا لحدوث اي مشاكل في التدريب حيث تم تحديد ما يلي:

34% من البيانات لاجراء التدريب .

33 % من البيانات لاجراء الاختبار .

33% من البيانات لاجراء التحقق .

4-4-5 إحصائيات الشبكات العصبية لكمية فيضان نهر النيل:

جدول (4-6) احصائيات الشبكات العصبية لكمية فيضان نهر النيل

Samples	Water Flood
Minimum(train)	34582.89
Maximum(train)	68726.92
Mean(train)	47657.69
Standard deviation(train)	7920.35
Minimum(test)	29733.33
Maximum(test)	64401.00
Mean(test)	49504.66
Standard deviation(test)	9787.91
Minimum(validation)	34328.26
Maximum(validation)	66790.04
Mean(validation)	48491.91
Standard deviation (validation)	8937.58
Minimum(overall)	29733.33
Maximum(overall)	68726.92
Mean(overall)	48538.65
Standard deviation (overall)	8803.83

من إعداد الباحثة باستخدام برنامج STATISTICA

تم رصد إحصائيات الشبكات العصبية لكمية فيضان نهر النيل كما هو مبين في جدول (4-6) أعلاه و من خلال الإحصائيات تبين الاتي:

كمية فيضان نهر النيل:

إن القيمة الدنيا لبيانات التدريب هي 34582.89 بينما القيمة العليا لها 68726.92 وأما متوسطها 47657.69 وانحرافها المعياري يساوي 7920.35

إن القيمة الدنيا لبيانات الإختبار هي 29733.33 بينما القيمة العليا لها 64401.00 وأما متوسطها 49504.66 وانحرافها المعياري يساوي 9787.91


إن القيمة الدنيا لبيانات التحقق هي 34328.26 بينما القيمة العليا لها 66790.04 وأما متوسطها 48491.91 وانحرافها المعياري يساوي 8937.58

إن القيمة الدنيا للبيانات الكلية هي 29733.33 بينما القيمة العليا لها 68726.92 وأما متوسطها 48538.65 وانحرافها المعياري يساوي 8803.83

6-4-4 المقارنة بين نماذج الشبكات العصبية ونماذج بوكس جنكيز:

تمت المقارنة بين نماذج الشبكات العصبية ونماذج بوكس جنكيز باستخدام الرسم البياني كما هو موضح في الشكل (4-4) و (5-4) .

شكل (4-4) السلسلة الزمنية الحقيقية مع القيم المتنبأ بها باستخدام نماذج بوكس جنكيز لكمية مياه الفيضان:




من إعداد الباحثة باستخدام برنامج EXCEL

Series1 = القيم الحقيقية.

Series2 = القيم المتنبأ بها.

من الشكل (4-4) نلاحظ أن القيم المتنبأ بها باستخدام نموذج بوكس جنكيز لا تتقارب مع القيم الحقيقية للسلسلة الزمنية لكمية مياه الفيضان مما يدل على عدم دقة هذا النموذج عليه لا يمكننا التنبؤ بالمستقبل باستخدام هذا النموذج.

الشكل (4-5) يوضح السلسلة الزمنية الحقيقية مع القيم المتنبأ بها باستخدام نموذج الشبكة العصبية الاصطناعية MLP1-2-1 لكمية مياه الفيضان:



من اعداد الباحثة باستخدام برنامج EXCEL

Series1=القيم الحقيقية.

Series2= القيم المتنبأ بها.

من الشكل (4-5) نلاحظ أن القيم المتنبأ بها باستخدام نموذج الشبكات العصبية تتقارب بعض الشيء مع القيم الحقيقية للسلسلة الزمنية لكمية مياه الفيضان مما يدل على دقة هذا النموذج عليه يمكننا التنبؤ بالمستقبل باستخدام هذا النموذج .

ولتأكد تم تدريب الشبكة لعدد من المرات المتكررة من أجل تعليم الشبكة وتم الإعتماد على بعض المعايير الإحصائية للمفاضلة بين نموذج بوكس جنكيز والشبكة وهي متوسط الخطأ المطلق ومتوسط مربع الأخطاء.

جدول (4-7) المقارنة بين نموذج بوكس جنكيز ونموذج الشبكات العصبية .

النموذج	MAE	MSE
بوكس جنكيز	6825	73861409
الشبكات	6226.837	48436609

من إعداد الباحثة باستخدام برنامج STATISTICA

من الجدول (4-7) نلاحظ أن متوسط الخطأ المطلق ومتوسط مجموع مربعات الأخطاء لنموذج الشبكات أقل بكثير من نموذج بوكس جنكيز مما يدل على أن نموذج الشبكات العصبية أفضل بكثير من نموذج بوكس جنكيز .

5-4 التنبؤ باستخدام نموذج الشبكة العصبية:-

جدول (4-8) التنبؤ باستخدام نموذج الشبكة العصبية

القيم المتنبأ بها	السنوات
49606	2010
48904	2011
48698	2012
48637	2013
48619	2014
48614	2015
48613	2016
48612	2017
48612	2018
48612	2019

من إعداد الباحثة باستخدام برنامج STATISTICA

باستخدام نموذج الشبكات العصبية 1-2-1 MPL لكمية مياه فيضان نهر النيل للعام 1940 الي العام 2009، تم التنبؤ بكمية مياه الفيضان لأعوام 2010 الي 2019 كم هو موضح بجدول 4-8 وقد أوضح الجدول أن هنالك تقارب بين القيم المتنبأ بها وبين القيم الحقيقية مما يدل علي كفاءة النموذج المتنبأ به.

الفصل الخامس

النتائج والتوصيات

1-5 النتائج:-

من خلال هذه الدراسة توصلنا الي أهم النتائج التالية:

- ❖ توصلنا الي أن النموذج المناسب لتحليل السلسلة الزمنية لفيضان مياه النيل هو نموذج الإنحدار الذاتي من الرتبة الأولي حيث وجدنا $AIC = 1468.8577$
- ❖ السلسلة الزمنية لفيضان مياه النيل مستقرة.
- ❖ قد تم إختيار المعمارية MLP 1-2-1 للسلسلة فيضان نهر النيل إعتقادا علي أخطاء التدريب التي توقف الإنخفاض فيها وهي 0.022542 وتعني هذه البنية 1-2-1 أنه توجد طبقة إدخال واحدة وهي البيانات المدخلة لكل نموذج حيث أننا أدخلنا متغير واحد فقط وهو كمية فيضان نهر النيل ، وتوجد بالبنية طبقتين خفيتين وتوجد طبقة إخراج واحدة .
- ❖ توصلنا الي أن التنبؤ باستخدام نموذج الشبكات العصبية افضل من التنبؤ بإستخدام نموذج بوكس جنكيز .
- ❖ يمكن إستخدام النموذج الذي توصل إليه البحث لمعرفة إتجاهات السلسلة لإستخدامها من قبل الجهات التخطيطية والتنفيذية لتحليل ودراسة الظاهرة.

2-5 التوصيات:-

- ❖ نوصي بإستخدام نماذج الشبكات العصبية في تحليل السلاسل الزمنية.
- ❖ إجراء العديد من الدراسات حول نماذج الشبكات العصبية وأنوعها وتطبيق هذه النماذج في السلاسل الزمنية متعدد المتغيرات.
- ❖ نوصي بإستخدام نماذج الشبكات العصبية في تحليل السلاسل الزمنية لبيانات الشهرية لسلسلة فيضان مياه نهر النيل لحصول علي نتائج أكثر دقة.

