

الفصل الثاني

الجانب النظري

2-1 المقدمة :

يتضمن هذا الفصل المنهجية النظرية للأطروحة اذ يتم فيه توضيح بعض المفاهيم والاساسيات كمدخل ومن ثم توضيح مفهوم السلاسل الزمنية، نماذج بوكس-جنكينز، الشبكات العصبية الاصطناعية والتنبؤ بالسلاسل الزمنية من خلال اسلوب الشبكات العصبية الاصطناعية.

2-2 السلاسل الزمنية: ، Time Series 1],2,5,6,9,11,12,14,15,19,26,39,50 54,61,63,69,70,73,75,84,88,89,90

يمكن ان تعرف السلسلة الزمنية على أنها مجموعة من المشاهدات العشوائية المتولدة عبر الزمن على وفق القوانين الاحتمالية، هذا من الناحية الرياضية.

أما تطبيقاً، فإن السلسلة الزمنية عبارة عن مجموعة من المشاهدات الخاصة بظاهرة معينة تولدت عبر فترات زمنية متتابة.

بعبارة أخرى هي مجموعة من القيم المشاهدة المأخوذة بفترات زمنية]

$$[Z_t]_{t=-\infty}^{\infty}$$

. وهذه المجموعة هي المقطع المحدد للمتتابة $[Z_1, Z_2, \dots, Z_n]$.

إن السلسلة الزمنية تكون على نوعين اعتماداً على طبيعة المشاهدات الموجودة في المتتابة، فأما أن تكون على شكل فترات متقطعة ثابتة أي تؤخذ في ازمان معينة ومحددة حيث أن:-

$$t = 0, +1, +2, \dots$$

عندئذ تسمى بالسلسلة الزمنية المتقطعة (Discrete)، أو أن تكون السلسلة الزمنية ذات مشاهدات متصلة عندما تكون مشاهدات هذه

المجموعة مستمرة مع الزمن t حيث أن $-\infty < t < \infty$ فتدعى بالسلسلة الزمنية المستمرة (Continuous). توجد في تحليل السلسلة الزمنية عدد من المراحل المتسلسلة لاسيما في عملية بناء النموذج، فبعد استقراره السلسلة الزمنية تبدأ مرحلة تشخيص النموذج الملائم وتحديدته وتليها مرحلة تقدير معالم النموذج، ثم مرحلة فحص ملاءمة النموذج، أما المرحلة الأخيرة فتتمثل بمرحلة التنبؤ المستقبلي. كما ان هناك اتجاهين في تحليل السلسلة الزمنية وهما:-

الاتجاه الأول:- التحليل في مجال الزمن (Time Domain Analysis)

يستخدم في هذا الاتجاه الدالة المولدة للتباين الذاتي (AutoCovariance Generating Function) ودوال الارتباط الذاتي (AutoCorrelation Function) التي يرمز لها (ACF)

ودوال الارتباط الذاتي الجزئي (Partial AutoCorrelation Function) التي يرمز لها (PACF).

اذ تكون السلسلة الزمنية مركبة خطية وبحدود متتابعة من الأخطاء العشوائية المستقلة والمتطابقة التوزيع، وهذا ما تم استخدامه في الدراسة الحالية.

الاتجاه الثاني:- التحليل في مجال التكرار (Frequency Domain Analysis)

يعتمد على دالة الطيف (Spectrum Function) ويسمى بالتحليل الطيفي (Spectral Analysis).

وفي هذا النوع من التحليل، توصف الدالة للسلسلة الزمنية في حدود سلوك الجيب والجيب تمام ولتكرارات مختلفة. ويتم ذلك من خلال

تحويل فوريير (Fourier Transform)، فإذا كانت $[Z_t]$ عملية مستقرة

بتباين ذاتي مشترك، γ_k لها خاصية المجموع المطلق)

(Absolutely Summable) فان تحويل فوريير لـ γ_k يحسب كالآتي:-

$$\dots\dots\dots(2-1)$$

$$P(W) = \frac{1}{2\pi} \sum_{k=-\infty}^{\infty} \gamma_k e^{-iWk}$$

في حال كون قيم السلسلة الزمنية حقيقية Real فان قدرة الطيف تكون :-

$$-\pi \leq W < \pi ; \dots\dots\dots(2-2)$$

$$P(W) = \frac{1}{2\pi} \gamma_0 + \frac{1}{\pi} \sum_{k=1}^{\infty} \gamma_k \text{Cos}(wk)$$

2-2-1 الاستقرارية (Stationarity):-

تعد دراسة استقراريه السلسلة من المراحل الأولى في بناء السلسلة الزمنية وتحليلها. إذ تعد السلسلة الزمنية المستقرة (Stationary Time Series) من العمليات التصادفية المقامة على افتراض إن العملية لها حالة خاصة من الموازنة الإحصائية (Equilibrium Statistical) وتكون السلسلة الزمنية تامة الاستقرارية (Strictly Stationary Time Series) إذا كانت الخصائص الاحتمالية لا تتأثر بتغير الزمن، وبعبارة أخرى فان دالة

التوزيع المشترك (Joint Distribution Function) للمجموعة المحددة من المشاهدات العشوائية على النحو الآتي:-

$$F_{Z_{t_1}, Z_{t_2}, \dots, Z_{t_n}}(\mathbf{z}_{t_1}, \mathbf{z}_{t_2}, \dots, \mathbf{z}_{t_n}) = F_{Z_{t_1+k}, Z_{t_2+k}, \dots, Z_{t_n+k}}(\mathbf{z}_{t_1+k}, \mathbf{z}_{t_2+k}, \dots, \mathbf{z}_{t_n+k})$$

أي أن التوزيع المشترك للاحتتمالية لأية مجموعة من المشاهدات لا يتأثر بأزمنة الإزاحات (الارتدادات Lags) ويرمز لها (k) الحاصلة على أزمنة المشاهدات كافة من خلال أي عدد صحيح لـ (k).

تعد حالة عدم الاستقرار في السلسلة الزمنية مشكلة رئيسة يواجهها الباحثون، ألا أن هنالك حلاً يمكن من خلالها تحويل العمليات غير المستقرة إلى عمليات مستقرة عن طريق الدراسة المتأنية للعوامل التي تؤثر فيها وتجعلها غير مستقرة، ففي العام [1992] بين (Gryer) وصفاً توضيحياً لجعل السلسلة غير المستقرة بسبب عزوم تلك السلسلة إلى سلسلة مستقرة وذلك على النحو الآتي :

(1) إذا كانت السلسلة غير مستقرة (Not Stationary) من ناحية المتوسط (Mean) ، فإن أسلوب الفروق (Differences) هو الأسلوب الأفضل لجعل السلسلة مستقرة (Stationary) كما يمكن جعلها كذلك من خلال تمثيل السلسلة بدلالة الزمن (Time).

(2) إذا كانت السلسلة غير مستقرة (Not Stationary) من ناحية العزوم (Moments) من الدرجات العليا كالتباين (Variance) أو التفلطح (Kurtosis) أو الالتواء (Skewness) فانه يمكن جعل تلك السلسلة مستقرة (Stationary) باتباع أسلوب التحويل كأسلوب (Box-Cox transform) الذي يعرف رياضياً من خلال الصيغة الآتية:

$$Y_t = [(X_t - 1) / \lambda , (X_t > 0, \lambda \neq 0) \text{ or } (X_t \geq 0, \lambda > 0) ; \ln(X_t), (X_t > 0, \lambda = 0)]$$

2-2-2 دالة الارتباط الذاتي: (ACF (Auto-Correlation Function

تستخدم دالة الارتباط الذاتي (Auto-Correlation function) والتي يرمز لها (ACF) في تحديد النموذج المناسب للسلسلة الزمنية المستقرة، وتعد الاساليب المهمة في معرفة استقرارية السلسلة الزمنية فضلا عن الوسط الحسابي والتباين الثابتين فاذا كان معامل الارتباط الذاتي بين قيم السلسلة الزمنية عند نقطتين من الزمن يعتمد على فترة الإزاحة (k) بينها ولا يعتمد على الزمن (t) نفسه، فالسلسلة مستقرة. ولدالة الارتباط الذاتي أهمية في مرحلة التشخيص.

ان صيغة دالة الارتباط الذاتي ρ_k كالآتي :-

$$\rho_k = \frac{\text{Cov}(Z_t, Z_{t+k})}{\sqrt{\text{Var}(Z_t)} \sqrt{\text{Var}(Z_{t+k})}} = \frac{Y_k}{Y_0}$$

حيث أن :-

$$\text{Var}(Z_t) = \text{Var}(Z_{t+k}) = \gamma_0$$

أما دالة الارتباط الذاتي للعينة $\hat{\rho}_k$ (Sample Auto-Correlation Function) فهي كما يأتي :-

$$\hat{\rho}_k = \frac{\hat{Y}_k}{\hat{Y}_0} = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2}$$

حيث أن Z_t تمثل متوسط العينة للسلسلة الزمنية \bar{Z} .

2-2-3 دالة الارتباط الذاتي الجزئي Partial AutoCorrelation Function (PACF):

تستخدم دالة الارتباط الذاتي الجزئي (Partial AutoCorrelation Function) والتي يرمز لها اختصاراً بـ (PACF) في تحديد النموذج المناسب للسلسلة الزمنية المستقرة. وتعرف دالة الارتباط الذاتي الجزئي بأنها معاملات

المتأية من الارتباط الذاتي بين Z_t و Z_{t+k} بعد إزالة تأثير ϕ_{kk}

$$Z_{t+1}, Z_{t+2}, \dots, Z_{t+k-1}$$

اي ان :-

$$\text{Corr}(Z_t, Z_{t+k} / Z_{t+1}, Z_{t+2}, \dots, Z_{t+k-1}) \dots\dots\dots(2-3)$$

ويتم حسابها على وفق الصيغة الآتية:-

$$\rho_i = \phi_{k1} \rho_{i-1} + \phi_{k2} \rho_{i-2} + \dots + \phi_{kk} \rho_{i-k} \quad , \quad i = 1, 2, \dots, k \dots\dots\dots(2-4)$$

2-2-4 نموذج الانحدار الذاتي (Autoregressive Model) :-

ان نموذج الانحدار الذاتي ((Autoregressive Model يمكن تمثيله بدلالة

(Z_{t-1}, Z_{t-2}, \dots) المجموع الموزون للقيم السابقة والحالية للسلسلة الزمنية

مضافة اليه قيمة الخطأ العشوائي. لذا فان الصيغة العامة للنموذج ومن الرتبة p والذي يرمز له $(AR(p)=ARMA(p,0)$ كما يأتي:

$$t = P + 1, P + 2 \quad ; \quad Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + a_t \quad (2-18)$$

$$\phi_p (B) Z_t = a_t$$

حيث أن:

a_t
: يمثل الخطأ العشوائي والذي يتبع التوزيع الطبيعي Gaussian بوسط

σ_a^2
حسابي مقداره صفر وتباين .

ϕ_i
: يمثل المعلمات "Parameters" للنموذج ولـ $(i=1,2,\dots,p)$ وفيها تحقق
صفة الاستقرار Stationarity للنموذج عندما تكون جذور المعادلة $=0$

$\phi(B)$
خارج حدود الدائرة التي نصف قطرها واحد.

2-2-5 نموذج الانحدار الذاتي من الرتبة الاولى - First Order Auto- Regressive Model

يمكن كتابة نموذج الانحدار الذاتي من الرتبة الاولى First Order Autoregressive Model والذي يرمز له بـ $AR(1)=ARMA(1,0)$ وبعد التعويض $(p=1)$ في الصيغة (2-18) وعليه فأن الصيغة الرياضية لهذا النموذج تكون كالآتي:-

$$Z_t = \phi_1 Z_{t-1} + a_t \quad \dots\dots\dots(2-5)$$

ويعبر هذا النموذج عن القيمة الحالية للسلسلة Z_t بدلالة القيم السابقة

للسلسلة Z_{t-1} مضافاً له حد الخطأ a_t ويدعى ايضاً بعملية (ماركوف Markov Process) .

وان a_t يمثل الخطأ العشوائي والذي يتبع التوزيع الطبيعي بوسط حسابي

مقداره صفر وتباين σ_a^2 .

2-2-6 نموذج الوسط المتحرك Moving Average Model

يمثل نموذج الوسط المتحرك Moving Average Model القيمة الحالية للسلسلة الزمنية بدلالة المجموع الموزون للقيم الحالية والسابقة

للاخطاء ($a_t, a_{t-1}, a_{t-2}, \dots$) او يعبر عنه دالة للمتغير العشوائي للقيم السابقة والحالية، ويمكن كتابة الصيغة العامة للنموذج من الرتبة q والذي يرمز بـ $(MA(q) = ARMA(0,q,q))$

$$z_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}$$

or $z_t = \theta(B) a_t$ (2-6)

حيث أن

θ_i : تمثل المعلمات للنموذج الاوساط المتحركة ولـ ($i=1,2,\dots,q$) وفيها تحقق شرط الانعكاسية (invertibility) للنموذج عندما تكون جذور المعادلة

$$\theta(B) = 0$$

خارج الدائرة التي نصف قطرها واحد.

2-2-7 نموذج الوسط المتحرك من الرتبة الاولى First Order (MovingAverageModel)

يمكن تمثيل نموذج الوسط المتحرك من الرتبة الاولى بـ $(MA(1)=ARMA(0,1))$ بالصيغة الاتية:

$$Z_t = a_t - \theta_1 a_{t-1} \dots\dots\dots(2-7)$$

$$Z_t = (1 - \theta_1 B) a_t$$

$$Z_t = \psi(B) a_t$$

ومن خلال هذا النموذج يمكن التعبير عن القيم الحالية للسلسلة بدلالة القيم الحالية والسابقة للأخطاء.

2-2-8 النماذج المختلطة (Mixed Models):

توجد أنواع من العمليات العشوائية^١ (Stochastic processes) كعمليات الانحدار الذاتي (Auto-Regressive) ويرمز لها (AR) أو عمليات الأوساط المتحركة (Moving Average) والتي يرمز لها (MA) وعمليات تحتوي على خصائص هذين النوعين (انحدار ذاتي- وسط متحرك) مثل هذه العمليات تسمى النماذج المختلطة (Auto Regressive-Moving

Average) ويرمز لها (ARMA). إذا كان الانحدار الذاتي من الرتبة (p)

والأوساط المتحركة من الرتبة (q) فتسمى بـ $ARMA(p,q)$.

إن النماذج الاحتمالية التي تحتوي على أقل عدد من المعلمات تكون أسهل وأكثر وضوحاً للفهم، ونتيجة لهذه الاعتبارات فإنه يتم اختيار النموذج الملائم الذي يسهم في تمثيل الظاهرة المدروسة بأقل عدد ممكن من المعلمات.

^١ العملية العشوائية عبارة عن عائلة من المتغيرات العشوائية التي تنشأ خلال الزمن وتتمثل بـ (Z,W,T). حيث أن: W تشير إلى فضاء العينة.

تشير T إلى الزمن.

فإذا كانت $Z_t; t = 0, \pm 1, \pm 2, \dots$ سلسلة زمنية مستقرة أحادية المتغير

فان صيغة النموذج المختلط $ARMA(p, q)$ ستكون كالآتي:-
(2-8)

$$Z_t - \phi_1 Z_{t-1} - \phi_2 Z_{t-2} - \dots - \phi_p Z_{t-p} = a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q}$$

أي ان:

$$\phi(B) Z_t = \theta_1(B) a_t$$

حيث أن:

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$$

$$\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$$

2-2-9 النموذج المختلط (Auto-Regressive-Moving Average model) $ARMA(1,1)$

يرمز للنموذج الانحدار الذاتي-الوسط المتحرك (Average model) $ARMA(1,1)$ عندما $p=1, q=1$ وعليه فان الصيغة الرياضية للنموذج $ARMA(1,1)$ وبالاعتماد على الصيغة رقم (2-40) تكون كالآتي:-

$$\left. \begin{aligned} Z_t &= \phi_1 Z_{t-1} + a_t - \theta_1 a_{t-1} \\ \phi_1(B) Z_t &= \theta_1(B) a_t \end{aligned} \right\} \dots\dots\dots(2-9)$$

حيث أن:

$$\phi_1(B) = (1 - \phi_1 B)$$

$$\theta_1(B) = (1 - \theta_1 B)$$

حيث أن a_t يمثل الخطأ العشوائي والذي يتبع التوزيع الطبيعي Gaussian بوسط حسابي يساوي صفر وتباين σ_a^2 .

يتضمن النموذج ARMA(1,1) على المعلمات (ϕ_1, θ_1) ويكون النموذج مستقراً (Stationary) عندما يقع جذر المعادلة $\phi_1(B) = 0$ خارج الدائرة التي نصف قطرها واحد، وهذا يعني أن $|\phi_1| < 1$.
ويكون النموذج ARMA(1,1) قابلاً للانعكاس (Invertible) عندما يقع جذر

$$\theta_1(B) = 0 \quad \text{خارج دائرة الوحدة، وهذا يعني أن } |\theta_1| < 1$$

لذا فإن النموذج ARMA(1,1) مستقراً (Stationary) وقابل للانعكاس ((

Invertible عندما تكون: $-1 < \theta_1 < 1$ and

$$-1 < \phi_1 < 1$$

2-3 طريقة بوكس-جنكينز: Box – Jenkins Method

إنّ عملية بناء نموذج $ARIMA(p,d,q)$ لتمثيل بيانات السلسلة الزمنية واستخدامه لأغراض التنبؤ تسمى بطريقة بوكس-جنكينز إذ تعد هذه الطريقة واحدة من الطرائق العامة للتنبؤ بمختلف انواع السلاسل الزمنية (المستقرة وغير المستقرة، الموسمية وغير الموسمية)، لأنها لا تفترض وجود نمطاً معيناً في بيانات السلسلة قبل تطبيقها كما هو الحال بالنسبة لطرائق التنبؤ الأخرى مثل (طرائق التمهيد الاسي) وإنما تبدأ بنموذج تجريبي يحدد بالاعتماد على دالتي (ACF) و $(PACF)$ وبعد ذلك يتم تقدير معلماته بالاعتماد على مشاهدات السلسلة الزمنية بحيث تجعل اخطاء التنبؤ اقل ما يمكن، وتعتمد في هذه الطريقة عدداً من المؤشرات بحيث تجعل الباحث قادراً على الحكم فيما اذا كان النموذج ملائماً ام لا.

2-4 مراحل بناء النموذج حسب طريقة بوكس-جنكينز :

اقترح كل من بوكس و جنكينز عام 1970 هذا الاسلوب وعلى الرغم من ان منهجية عمل العديد من هذه المراحل كان معروفاً قبل عام 1970 الا ان بوكس-جنكينز هما اول من وحد هذه الخطوات في الاسلوب المعروف باسميهما، إنّ مراحل بناء النموذج بحسب طريقة بوكس-جنكينز يمكن تمثليه من خلال المخطط الاتي:

المخطط (1-2) يمثل المسار الانسيابي لتحليل السلسلة الزمنية

2-4-1 Identification : التشخيص

ان مرحلة تشخيص النموذج تعد من المراحل المهمة والصعبة للوصول للنموذج الملائم. إن المهمة الرئيسة لهذه المرحلة هي التشخيص واختبار النموذج الافضل، الذي يمثل السلسلة الزمنية من النماذج العامة (ARMA(p,q) او ARIMA(p,d,q) باستعمال معاملات الارتباط الذاتي والارتباط الذاتي الجزئي. فإذا كانت معاملات دالة الارتباط الذاتي تتناقص أسياً وكانت معاملات الارتباط الذاتي الجزئي تنقطع بعد الفترة الفاصلة (p فإن النموذج هو AR(p). أما إذا تناقصت معاملات الارتباط الذاتي الجزئي أسياً وانقطعت معاملات الارتباط الذاتي بعد الفترة الفاصلة (q فهذا يعني وجود النموذج MA(q). أمّا في حالة ARMA(p,q) فإن معاملات الارتباط الذاتي ومعاملات الارتباط الذاتي الجزئي تنحدران أسياً. ويتضمن الجدول الاتي على ملخص للأنماط المختلفة لدالتي الارتباط الذاتي والارتباط الذاتي الجزئي للنماذج غير الموسمية.

جدول (1-2) يمثل ملخص تشخيص نموذج بوكس- جنكينز

| النموذج | دالة الارتباط الذاتي ACF | دالة الارتباط الذاتي الجزئي PACF |
|------------------------|-----------------------------|-------------------------------------|
| ي قطع بعد p من الأبحاث | أسي | AR(p) |
| أسي | ي قطع بعد q من الأبحاث | MA(q) |
| أسي | أسي | ARMA(p,q) |

2-4-2 التقدير Estimation :

هنالك عدة طرائق لتقدير معاملات النموذج منها ، تعتمد على معرفة التوزيع الاحتمالي للسلسلة الزمنية، ومن هذه الطرائق: طريقة الإمكان الأعظم التامة Exact Maximum Likelihood ، وطريقة الإمكان الأعظم

التقريبية Approximate Maximum Likelihood، وتستعمل اعتيادياً البرامجيات الجاهزة الكفوءة لهذا الغرض.

2-4-3 فحص ملاءمة النموذج Model Diagnostic checking :

ان مرحلة ما بعد تقدير معلمات النموذج المشخص هي اجراء الفحص والتدقيق فيما إذا كان النموذج ملائم ام لا. ويتم ذلك بطرائق مختلفة منها:

2-4-3-1 اختبار الارتباط الذاتي للبواقي (الاحطاء) Auto correlation test :

يجب اجراء تحليلاً كمي للأخطاء المتكونة من النموذج ويفترض أنّ هذه البواقي تتوزع توزيعاً طبيعياً ومستقلاً بعضها عن بعض، ومتى ما كان

النموذج المشخص صحيحاً فإنّ \hat{u}_t يجب ان يتصف تقريباً بصفات u_t أي أنّها دالة الخطأ العشوائي ويفترض عدم ترابط البواقي ببعضها الاخر (nearly uncorrelated)؛ لذلك فإنّ الارتباط الذاتي العيني للبواقي يقترب من الصفر عندما $k > 1$ وصيغة النموذج المختلط هي كما يأتي:

$$u_t = (\hat{\theta}^{-1}/\beta) \hat{\phi}(\beta) \hat{W}_t \quad \dots\dots\dots(2-10)$$

إذا كانت السلسلة كبيرة فإنّ \hat{u}_t يقترب من u_t فدراسة البواقي \hat{u}_t تساعد على التحقيق من دقة وملائمة النموذج. إنّ الارتباطات الذاتية المقدره اي (العينية) $r_k(u)$ للنموذج المختلط، تتوزع بصورة تقريبية توزيعاً طبيعياً

بمتوسط صفرًا وتباين $\left(\frac{1}{\sqrt{N}}\right)$ اي:

$$r_k(u) \sim N\left(0, \frac{1}{\sqrt{N}}\right)$$

وتستخدم هذه المعلومة في تحديد نسبة المعنوية الاحصائية (أختبار المعنوية) لانحرافات الارتباطات الذاتية المقدره عن قيمتها الصفرية النظرية وبما أنّ هذه المعلمات غير معروفة في التطبيق، فنلجأ الى تقديرها واحتساب بواقياها عن طريق المعادلة رقم (2.78) ثم حساب

الارتباط الذاتي التقديري $r_k(\hat{u})$ وإذا كانت معاملات الارتباط الذاتي للأخطاء واقعة في حدود الثقة باحتمال 95% فهذا يعني أنّ الاخطاء غير نظامية اي عشوائية ومن ثم يعني أنّ النموذج المشخص ملائم وحدود الثقة هي:

$$-1.96 \frac{1}{\sqrt{N}} \leq r_k(\hat{u}) \leq 1.96 \frac{1}{\sqrt{N}} \quad \dots\dots(2-11)$$

أي إن :

$$r_k(\hat{u}) = \frac{\sum_{t=1}^{N-k} \hat{u}_t \hat{u}_{t+k}}{\sum_{t=1}^N \hat{u}_t^2} \quad \dots\dots(2-12)$$

N : هو حجم السلسلة الزمنية.

$r_k(\hat{u})$

: الارتباطات الذاتية المقدره للاخطاء.

2-4-3-2 اختبار حسن المطابقة : Goodness of fit test

في عام 1970 توصل كلُّ من (Box and Pierce) للنموذج (ARIMA(p,d,q))

$r_k(\hat{u})$

وبافتراض أنّ يكون لدينا m من الارتباطات الذاتية المقدره للبواقيا .

إذ ان $(k=1, \dots, m)$ وإن:

$$Q = n \sum_{k=1}^m r_k^2(\hat{u}) \sim \chi_{(m-p-q)}^2 \quad \dots\dots(2-13)$$

وإن :
n : يمثل عدد المشاهدات للنموذج المشخص.

N : عدد المشاهدات الاصلية للسلسلة الزمنية.

d : يمثل الفروق المأخوذة لتحقيق الاستقرارية للسلسلة حول متوسطها.

وحيث ان : n= N- d .

وتقارن قيمة Q مع قيمة χ^2 الجدولية بدرجة حرية (m-p-q) وبمستوى دلالة α معين فعندما تكون القيمة المحتسبة اكبر من القيمة الجدولية فيعني ان اخطاء معاملات ACF ليست عشوائية وعدم ملائمة الفرضية

الخطية للنموذج المشخص. اما فإذا كانت قيمة Q اصغر من قيمة χ^2 الجدولية، هذا يعني أن معاملات ACF للأخطاء المقدرة تتوزع عشوائياً مع عدم وجود فروقات معنوية وان النموذج المشخص ملائم

لقد قام كل من (Ljung,G.M&Box,G.E.P) بتعديل صيغة اختبار Q الاصلية التي اقترحها كل من (Box & Pierce) بالشكل الآتي:

$$Q' = n(n+2) \sum_{k=1}^m (n-k) \bar{r}_k^2(\hat{u}) \quad \dots\dots(2-56)$$

وقد اثبتا ان لها الافضلية في الاستخدام؛ لأن مستوياتها المعنوية قريبة من القيم المتوقعة.

Forecasting : التنبؤ 2-4-4

بعد الحصول على نموذج (ARIMA) ملائم لتمثيل بيانات السلسلة الزمنية فان هذا النموذج يستخدم للتنبؤ بالقيم المستقبلية للسلسلة الزمنية على النحو الاتي:

اذا رمزنا للقيمة الحالية للسلسلة الزمنية بـ Y_t وارادنا التنبؤ بقيمة

السلسلة الزمنية في الفترة $t+L$ وفرضنا أنّ $\hat{Y}_t(L)$ تمثل هذه القيمة عند زمن الاصل (t) ، فإننا نستطيع الحصول على التنبؤات بأخذ التوقع الشرطي عند زمن الاصل (t) للنموذج وبعد كتابته عند الفترة $(t+L)$ اي

$$\hat{Y}_t(L) = E_t(Y_{t+L} / Y_t, Y_{t-1}, \dots)$$

إذ باستعمال التوقع الشرطي نحصل على التنبؤات

بمتوسط مربعات خطأ التنبؤ (MSE) اقل ما يمكن.

فإذا فرضنا أنّ النموذج الملائم والذي تمّ التوصل اليه عن طريق المراحل السابقة هو $ARIMA(p,d,q)$ فإننا نستطيع التنبؤ بالقيم المستقبلية الى $(L=1, 2, \dots)$ فترة قادمة وباستعمال صيغة معادلة الفروق Difference equation form لهذا النموذج وكما يأتي:

$$\phi(\beta) Z_t = \theta(\beta) u_t \quad \dots\dots(2-14)$$

$$\phi_{(p+d)}(\beta) = \phi(\beta)(1-\beta)^{-1} = (1-\phi_1\beta - \dots - \phi_{p+d}\beta^{p+d}) \quad Z_t = Y_t - \mu$$

و حيث

ويسمى بمعامل الانحدار الذاتي غير المستقر من الدرجة $(p+d)$.

ويمكن كتابة المعادلة (2.83) على النحو الآتي:

$$Z_t = \phi_1 Z_{t-1} + \dots + \phi_{p+d} Z_{t-p-d} - \theta_1 u_{t-1} - \dots - \theta_q u_{t-q} + u_t \quad \dots\dots(2-15)$$

وبكتابة المعادلة (2.84) عند الفترة $(t+L)$ واخذ التوقع الشرطي عند الفترة (t) نحصل على معادلة التنبؤ عند زمن الاصل (t) والى $(L=1, 2)$... فترة تنبؤة. أي أنّ

$$E_t(Z_{t+L}) = \hat{Z}_t(L) = \phi_1 E_t(Z_{t+L-1}) + \dots + \phi_{p+d} E_t(Z_{t+L-p-d}) - \theta_1 E_t(u_{t-1}) - \dots - \theta_q E_t(u_{t+L-q}) + E_t(u_{t+L}) \quad \dots(2-16)$$

وبعد احتساب التنبؤات يكون من الضروري احتساب دقة النتائج ويتمّ هذا عن طريق احتساب الحدود الاحتمالية العلى ا والدنيا لكل قيمة تنبؤة ولأي مستوى مناسب من المستوى المعنوي (90%,95%,99%) وبحسب بحسب الصيغة

$$Y_{t+\ell} \text{ الاتية وهي حدود الثقة للقيمة المستقبلية و باحتمال } (1-\alpha)$$

$$Y_{t+\ell}(\pm) = \hat{Y}_t(\ell) \pm U_{\alpha/2} \left(1 + \sum_{j=1}^{\ell-1} \Psi_j^2 \right)^{\frac{1}{2}} S_a \quad \dots\dots(2-17)$$

$$S_a^2 = \frac{S(\hat{\phi}, \hat{\theta})}{n-p-q} = \frac{\sum_{t=1}^n \hat{u}_t^2}{n-p-q}$$

S_a : هو تقدير لـ σ_u^2 من المشاهدات

$$U_{\frac{\alpha}{2}}$$

: قيمة التوزيع الطبيعي القياسي اي القيمة الجدولية المستخرجة
(1- α)

من جداول التوزيع الطبيعي باحتمال والشئ المتوقع ان حدود
الثقة للتنبؤ ستكون اوسع كلما صار كبيراً، لان التباين لخطأ التنبؤ سيزداد
(ℓ)
كلما كبر .

2-5 النماذج الموسمية Seasonal Models :

هي نوع من انواع السلاسل الزمنية التي تتضمن تغيرات موسمية في
تكوينها أي ان السلسلة المذكورة تمتلك سلوك دوري "Periodic" وتعيد
نفسها في فترات زمنية ثابتة، وهذه الفترات تعتمد على طبيعة بيانات
السلسلة الزمنية. وتستخدم لتمثيل السلاسل الزمنية الموسمية ومن هذه
النماذج:

1- نموذج الانحدار الذاتي الموسمي: ويكتب بالشكل الآتي:

$$X_t = \mu + \theta_S X_{t-S} + \theta_{2S} X_{t-2S} + \dots + \theta_{PS} X_{t-PS} + Z_t \quad \dots\dots(2-61)$$

ويرمز لهذا النموذج بـ $SAR(P)$ حيث P تمثل درجته.

2- نموذج المتوسطات المتحركة الموسمي: وصيغته هي:

$$\dots(2-18)$$

$$X_t = \mu + Z_t - \phi_S Z_{t-S} - \phi_{2S} Z_{t-2S} - \dots - \phi_{QS} Z_{t-QS}$$

ويرمز لهذا النموذج بـ $SMA(Q)$ حيث Q تمثل درجته.

3- نموذج الانحدار الذاتي والمتوسطات المتحركة الموسمي: ويكتب

كالآتي:

$$\dots(2-19)$$

$$X_t = \mu + \theta_S X_{t-S} + \theta_{2S} X_{t-2S} + \dots + \theta_{PS} X_{t-PS} + Z_t - \phi_S Z_{t-S} - \phi_{2S} Z_{t-2S} - \dots - \phi_{QS} Z_{t-QS}$$

ويرمز لهذا النموذج بـ حيث تمثلان درجته. $P, Q SARMA(P, Q)$

أما إذا كانت السلاسل الموسمية غير ساكنة فتحول إلى ساكنة عن طريق أخذ الفرق الموسمي وفق المعادلة الآتية:

.....(2-20)

$$W_t = X_t - X_{t-S}$$

ثم تمثل بنفس النماذج السابقة ولكن تضاف فقط كلمة متكاملة إلى اسم النموذج للدلالة على أن هذا النموذج استخدم لتمثيل سلسلة زمنية غير ساكنة.

النموذج الموسمي المضاعف: هو خليط من النماذج اللا موسمية والموسمية ويكتب بالشكل الآتي:

.....(2-21)

$$\theta_p(B)\theta_p(B^S)\nabla^d\nabla^D X_t = \phi_q(B)\phi_q(B^S)Z_t$$

حيث أن:

p درجة الانحدار الذاتي الاعتيادي، P درجة الانحدار الذاتي

الموسمي

q درجة المتوسط المتحرك الاعتيادي، Q درجة المتوسط

المتحرك الموسمي

D درجة الفروق الاعتيادية، D درجة الفروق الموسمية

S طول فترة الموسم

ويرمز للنموذج أعلاه بـ .

$ARIMA(p, q, d) \times (P, Q, D)_S$


2-6 الشبكات العصبية الاصطناعية : Artificial Neural Networks

[4,7,8,9,13,14,16,17,18,20,22,23,25,27,30,31,32,33,35,36,37,40,41,44,45,47,48,49,50,55,56,57,59,60,77,83,84,87,89,92,94,95]

سميت الشبكات العصبية الاصطناعية ANN بهذا الأسم كونها شبكة من وحدات الأتصالات الداخلية، إذ أن هذه الوحدات مستوحاة من دراسة أنظمة الأعصاب الحيوية.

إن فكرة عمل الشبكات العصبية الاصطناعية هو عملية محاكاة البيانات للوصول الى نموذج لهذه البيانات لغرض التحليل أو التصنيف أو التنبؤ أو أي معالجة اخرى دون الحاجة الى نموذج مقترح لهذه البيانات، لذلك فقد حازت الشبكات العصبية الاصطناعية اهتمام الكثير من الباحثين والعلماء إذ لها المرونة العالية بالمقارنة مع الأساليب الرياضية المستخدمة في عملية التعلم على نموذج البيانات و تخزين المعلومات وبثها في الشبكة العصبية الاصطناعية. لقد انصرف الباحثون للتعلم والتأمل في فهم الية التفكير البشري فقابلية الانسان وكفاءته ترجع الى هيكل دماغه المتكون من عدد هائل من الخلايا العصبية ويحتوي المخ البشري الاعتيادي على الف مليار (10^{12}) خلية عصبية ولكل واحدة منها ما يقارب 10000 مشبك مع الخلايا. وبعد أن يبلغ الانسان عامه العشرين يتعرض إلى فقدان بعض العصبونات، حيث يموت عدد من العصبونات أو يختفي كل يوم وبصفة عامة، لا تعوض العصبونات الميتة خلال حياة الشخص، ولكن الفقد لايتجاوز 10% من العدد الكلي للعصبونات، طوال الحياة تتصل بلايين العصبونات بعضها ببعض، بشبكات معقدة ويعتمد أداء كل الوظائف العقلية

والجسدية على ترسُّخ (عملية ترسيخ) الشبكات العصبونية والحفاظ عليها،
 فعادات الشخص ومهاراته - مثل عض الأظافر أو العزف على آلة
 موسيقية- تكون مغروسة في الدماغ داخل الشبكات العصبونية المنشطة
 باستمرار وعندما يقف الشخص عن أداء نشاط معين، تتوقف الشبكات
 العصبية الخاصة بذلك النشاط عن العمل وقد تختفي في النهاية. فمجرد
 تخيل هذه الشبكة العجبية ليس بالأمر الهين "السهل". والشكل الاتي يبين
 الخلية العصبية البيولوجية.



ويتبين من الشكل اعلاه إن الخلية العصبية تتكون من :
 جسم الخلية (cell body):- هو جسم غير منتظم نجمي الشكل يتضمن
 على النواة.
 التفرعات او المداخل (Dendrites):- هي عبارة عن اذرع تربط الخلية
 بالخلايا المتجاورة وتنقل الاشارات الداخلة الى كل خلية مع الخلايا الاخرى
 المرتبطة بها.

المحور العصبي او المخرج (Axon):- هو عبارة عن ذراع يمتاز بطوله حيث يقوم بنقل الاشارة الخارجة من الخلية الى الخلايا الاخرى، تلتقي الاذرع الخارجة من الخلية مع الاذرع الداخلة الى الخلية الاخرى بوساطة مناطق اتصال (Synapses) وهي تمثل نقطة التقاء بين خلية عصبية مع خلية عصبية مجاورة ، تنتقل المدخلات والمخرجات عبر الخلايا العصبية على شكل نبضات كهروكيميائية لتحدث تفاعلاً كيميائياً في جسم الخلية ينتج عنه جهد كهربائي يولد نبضة كهربائية خارجة من الخلية الى الخلايا المرتبطة بها وتعتمد شدة النبضة الناتجة على مجموع النبضات الداخلة الى الخلية فاذا كانت قليلة ولم تصل الى مستوى العتبة (Thershold) فانها سوف لن تصدر نبضة خارجة، ولذلك كانت هناك محاولات للوصول الى اقرب نقطة لكفاءة الانسان من خلال التقليد ولو بشكل بسيط هيكلية الدماغ البشري باستعمال الشبكات العصبية الاصطناعية (Artificial Neural Networks) التي تقوم بحل المشاكل دون الحاجة الى وجود خوارزمية حل مما يؤدي الى تقليل كمية البرامجيات ومن ثم تقليل الوقت والكلفة.

1-6-2 تعريف الشبكات العصبية الاصطناعية:-

تعد الشبكات العصبية الاصطناعية ANN حالة ذكية من نظرية الشبكات في عملية التعلم على نموذج البيانات وخرن وبث المعلومات في الشبكة العصبية الاصطناعية. وهناك عدة تعاريف للشبكات، سيتم اجمال اهم التعاريف المعتمدة.

□ عرف العالم Nilsson الشبكات العصبية على انها نظام حسابي مكون من عدد من وحدات المعالجة (Processing units) المترابطة فيما بينها وتتصف بطبيعتها الديناميكية والمتوازية في معالجة البيانات الداخلة اليها.

□ عرف العام Haykin الشبكات العصبية في عام 1994 على انها متوازية هائلة توزع المعالج الذي لديه ميل او نزعة طبيعية لخرن المعرفة التجريبية وجعلها متاحة للاستعمال. انها تماثل الدماغ البشري في ناحيتين، تكتسب المعرفة بواسطة الشبكة من خلال عملية تعلم نقاط اتصال العصبون المعرفة باسم مشبكي Synaptic وتستعمل الاوزان لخرن المعرفة.

□ عرف العام Nigrin الشبكة العصبية في عام 1993 على انها دائرة مؤلفة من عدد كبير جدا من عناصر المعالجة النشيطة التي تعتمد النظام العصبي. كل عنصر يعمل فقط على المعلومات المحلية واطافة لذلك كل عنصر يعمل بشكل غير متزامن ولذلك ليس هنالك نظام شامل على مدار الساعة.

□ عرف العام Zurada الانظمة العصبية او الشبكات العصبية الاصطناعية في عام 1992 على انها انظمة خلوية فيزيائية التي يمكن فيها من كسب وخرن واستعمال المعرفة التجريبية.

ويمكن تعريف الشبكات العصبية على انها مجموعة مترابطة من الخلايا العصبية إذ ان مخرجات عصبون (Neuron) معين تكون مرتبطة ومن خلال الاوزان بمدخلات عصبون اخر بالاطافة الى العصبون ومن ثم يمكن تعريف الشبكات العصبية الاصطناعية على انها هيكل من المعلومات التي تتم معالجته بشكل متوازي، ويتكون من مجموعة من عناصر معالجة (Processing element) ترتبط مع بعضها بوساطة مجموعة من الموصلات (Connection) وتطبق عناصر المعالجة دالة تنشيط على مدخلاتها للحصول على المخرجات. ومن التعاريف الاخرى هي عبارته عن نماذج رياضية تقتنص خصائص معالجة المعلومات التي تتصف بها الانظمة البيولوجية. ويمكن ايجازها بالاتي: **الشبكات العصبية هي نظام معالجة بيانات يستند على نماذج رياضية بسيطة له مميزات أداء معينة بأسلوب يحاكي الشبكة العصبية "النظام العصبي" البيولوجية، وتعد إحدى النماذج غير الخطية.**

:مراحل تطور الشبكات العصبية الاصطناعية 2-6-2

ان فكرة نشوء الشبكات العصبية الاصطناعية بدأت من خلال محاكاة بعض خصائص الشبكات العصبية البيولوجية، إذ تمتلك الشبكات العصبية الاصطناعية القدرة على تحليل البيانات أو تصنيفها وتبويبها الى اشكال وانماط مختلفة دون الحاجة الى أي نموذج مسبق يصف طبيعة العلاقات بين تلك البيانات وما يمكن ان تتضمنه هذه البيانات.

وبصيغة اكثر حداثة، درست الشبكات العصبية الاصطناعية كأسلوب مقابل الى اساليب النماذج غير الخطية المشتقة -Non-Linear Model driven، وبسبب خصائصها فإنها تنتمي الى اسلوب البيانات المشتقة Data-driven approach، بمعنى ان التحليل يعتمد على البيانات المتوفرة مع قليل من العلاقات الأولية حول العلاقات بين المتغيرات وحول النماذج .

في عام 1943 صمم العالمان (Pitts and Warren McCulloch) المفهوم العام لأول الشبكات العصبية اذ تم تعريفها بانها انظمة تتكون من عدد من العقد البسيطة التي تعد المصدر الرئيس في زيادة القدرات الحسائية.

ان الشبكات التي صممها هذين العالمين تتكون من مجموعة عقد مترابطة مع بعضها بواسطة أوزان، ولقد استخدمت هذه الشبكات في انجاز دوال منطقية خاصة، ويمكن لهذه الشبكة ان تنظم عقدها لتوليد استجابة لعدة دوال منطقية معا .

ومن ابرز النظريات التي ظهرت، نظرية (Donald Hebb) في عام 1949 إذ تنص هذه النظرية على ان عملية التعلم والذاكرة (& Learning Memory) هي ظاهرة تنتج من تقوية الأرتباط في عقد الشبكة العصبية، أي بمعنى آخر أن التحفيز المتكرر (Repeated Stimulation) لبعض العقد الفعالة في الشبكة العصبية يؤدي الى حدوث زيادة في قوة الأرتباط العصبي بين العقد الفعالة، وهذه العملية تؤدي الى تخزين (Encoding) التغيرات في قوة الأرتباط العصبي بين العقد الفعالة

في الشبكة لأختيار افضل اوزان، وهذا معنى التعلم في الشبكة العصبية، وبذلك تتعلم الشبكة نموذجاً للبيانات التي تدرت عليها. وان شبكة الخلية العصبية الاصطناعية متمثلة بالأدراك الحسي (Perceptron) والذي يحاكي الخلية العصبية البيولوجية في طريقة عمله وقد اقترحت هذه الطريقة من قبل العالم (Frank Roseblatt) في عام 1958. إذ يتكون الإدراك الحسي من وحدات ادخال (Input Units) ووحدات جمع (Summing Units) ترتبط وحدات الإدخال مع وحدات الجمع، وتمرر وحدات الجمع في دالة غير خطية ذات قيمة معينة تسمى دالة العتبة (Threshold Function) لكي نحصل على مخرجات الشبكة العصبية الاصطناعية. وكانت تلك هي النواة الأولى في عملية التعلم على مدخلات شبكة الخلية العصبية الاصطناعية المتكونة من طبقة واحدة (Single Layer) ولذلك فقد كانت عملية التعلم مقتصرة على النماذج الخطية للبيانات لغرض التقدير أو التبويب أو التصنيف أو التنبؤ. ولهذا السبب فقد قل الاهتمام بالبحوث والدراسات في مجال الشبكات العصبية لسنوات عدة، الى ان تم التوصل الى شكل جديد للإدراك الحسي ويتمثل بأضافة مستوى جديد يطلق عليه الطبقة المخفية (Hidden Level) وبذلك اصبحت عملية الربط بين المدخلات والمخرجات لا تتم بشكل مباشر وإنما عن طريق الطبقة المخفية. إذ اكتسب الإدراك الحسي القدرة على حساب الدوال والعلاقات للبيانات ذات النماذج الخطية او اللاخطية، وبعد ذلك فقد تطورت هذا الطبقة المخفية بأضافة أوزان تربط بين طبقة المدخلات (Input Level) والطبقة المخفية من قبل العالم (Paul Werbos) في عام 1974. وقد ادى إخفاق شبكات Perceptron في حل بعض المشاكل وضعفها في التعلم بالنسبة للشبكات متعددة الطبقات على ايجاد شبكات اخرى قادرة على حل مثل هذه المشاكل وكانت شبكات الانتشار العكسي البديل لهذه الشبكات، إذ يعاد الخطأ المرتكب في مستوى المخرجات الى الطبقة المخفية وقد أكتشفت في مرحلة السبعينات (Werbos) عام 1974 ولكنها لم تنشر على نطاق واسع، وأول من أوجد هذه الشبكات هو العالم (David Parker) عام

1985 والعالم (Lecun) عام 1986 قبل ان تصبح معروفة بشكل واسع. وثمة تطور اخر حصل في هذه الفترة، إذ طور Seinowski في عام 1986 شبكة اطلق عليها Nettek لها القابلية على خلق الاصوات. كما شهدت هذه الفترة تطوراً مهماً في تعلم الشبكات إذ تمكن العلماء Rumelhart و Hinton و Williams من بناء صيغة جديدة تعرف بالانتشار العكسي للخطأ Backpropagation وعرضها في كتاب تعلم التمثيل الداخلي من قبل الخطأ المرجع او العكسي عام 1986. ان الفترة الممتدة من عام 1987 حتى وقتنا الحالي سميت بعصر Neo-connectionism حيث ساعد التطور المذهل الذي حصل في تقنيات الحواسيب الشخصية والحواسيب الصغيرة وسعات خزنه عالية فضلاً عن تطور البرمجيات وتوافر ادواتها مما ساعد كثيراً على انتشار البحوث في هذا المجال افقياً وعمودياً وذلك من خلال اضافة انواع جديدة من الشبكات وابتكار خوارزميات جديدة لتعلم الشبكات العصبية وزيادة كفاءته. كانت ومازالت شبكة البث العكسي للخطأ Backpropagation تستحوذ بالكثير من الاهتمام والبحث، وكان هناك الكثير من الجدل حول ما إذا كان يمكن أن تنفذ بطريقة تماثل التعلم في المخ أم لا، ويرجع ذلك إلى جزئية آلية الإشارات العكسية الذي لم يكن واضحاً في ذلك الوقت، ولكن الأهم من ذلك أنه لم يكن هناك مصدر معقول لـ 'التعلم' أو 'الهدف' الاشارة.

ومع ذلك منذ عام 2006، اقترحت عدة إجراءات غير خاضعة للرقابة تعلم الشبكات العصبية مع أكثر من الطبقة "تعدد الطبقات"، وذلك باستعمال ما يسمى بعمق خوارزميات التعلم deep learning algorithms.

يمكن ايجاز مراحل تطور الشبكات العصبية الاصطناعية بأربعة مراحل رئيسية، كالآتي:

□ عام 1958 **اقترح** العام Frank Roseblatt نموذج الخلية العصبية الاصطناعية، ممثلة بالمدرک الحسي (Perceptron)، إذ كانت

الشبكة العصبية الاصطناعية تتكون من طبقتين فقط هما المدخلات و المخرجات.

عام 1974 **أضافة** العام Paul Werbos مستوى جديد يطلق عليه الطبقة المخفية (Hidden Level) وبذلك اصبحت عملية الربط بين المدخلات والمخرجات لا تتم بشكل مباشر وإنما عن طريق الطبقة المخفية.

عام 1986 تمكن العلماء Rumelhart و Hinton و Williams (فريق علميات التوزيع المتوازي) من صياغة صيغة جديدة تعرف **بالانتشار العكسي للخطأ** Back propagation .

عام 1987 انعقاد **اول مؤتمر** دولي لشبكات العصبية وتشكيل الجمعية الدولية للشبكات العصبية INNS وفي عام 1988 تشكيل مجلة الشبكات العصبية.

في فترة التسعينات وما بعدها وبسبب التطور الهائل في تقنيات الحواسيب تزايد الاهتمام في الشبكات العصبية الاصطناعية وتم **اضافة** انواع جديدة من الشبكات وابتكار خوارزميات جديدة لتعلم الشبكات العصبية وزيادة كفاءتها فضلا عن اضافة طبقات متعددة في طبقة المخفية. واسهمت البرامجيات التطبيقية الجاهزة في تزايد استخدام وتطبيق الشبكات العصبية الاصطناعية في شتى الحقول.

3-6-2 لماذا الشبكات العصبية الاصطناعية:


بالرغم من التطور الهائل في الحواسيب الالكترونية وتقنياتها فقد عجزت البرمجة التقليدية في حل بعض المعضلات الصعبة التي لا يمكن صياغتها او ايجاد اطار عام لها ضمن هذه التقنيات وذلك لانها ظلت أسيرة للاسلوب التسلسلي في تنفيذ الايعازات والبرامج التي تنفذها بشكل آلي، وهو ما يطلق عليه نماذج فون نيومان (Von Neuman models) الذي يقضي بمعالجة سيل من الايعازات بصورة متسلسلة وهذا يتطلب صياغة

المشكلة بشكل محدد ودقيق وتحولها الى سلسلة من الابعازات القابلة للتنفيذ، وقد يصبح من المستحيل صياغة بعض المعضلات المعقدة والتي تتطلب تفاعلاً آتياً مع الظروف المحيطة بها باسلوب البرمجة التقليدية مثل الرؤية (Vision) والكلام (Speech)، مما حدا بالباحثين للبحث عن آليات جديدة تتيح لهذه الآلة نوعاً من الذكاء والية استنتاج لاتخاذ رد فعل مناسب في الوقت المناسب فاتخذت البحوث مساراً جديداً في تطبيقات الذكاء الاصطناعي وبناء قواعد المعرفة (Knowledge Base System). ولكنها ظلت دون مستوى الطموح في مجالات معينة. وفي مطلع السبعينات اتجهت البحوث نحو استثمار اليات الانظمة الطبيعية الموجودة في الكائنات الحية ومنها الانسان، مثل التكيف والاستنتاج والتعلم والادراك والالتقاء العشوائي في المنظومة الوراثية "الجينية" ومن هنا انطلقت فكرة الشبكات العصبية الاصطناعية لايجاد منظومة حسابية لها القدرة على التكيف والتعديل عن طريق التعلم لايجاد دوال الربط بين المدخلات والمخرجات او استنتاج قرار معين مبني على الاف الاحتمالات والعلاقات فضلا عن قابليتها في معالجة المعلومات الناقصة.

2-6-4 وصف عام لآلية عمل العصبون الاصطناعي:

بشكل عام يمكن وصف اي شبكة عصبية الى طبقات من الخلايا الاصطناعية وكالاتي: طبقة المدخلات وطبقة المخرجات والطبقة المخفية التي تتواجد بين طبقتي المدخلات والمخرجات. وكل خلية في إحدى هذه الطبقات تتصل بكافة العصبونات الموجودة في الطبقة التي تليه وكافة العصبونات في الطبقة التي تسبقه، وكما مبين في الشكل الاتي:

شكل (2-2) يمثل نموذج لعصبون اصطناعي.



وجدوا الباحثون في البداية ان الخلايا العصبية تقوم بعملية جمع لإشارات بمعنى انه يوجد وصلتين لخلية عصبية وكل وصلة عليها إشارة تكون النتيجة هي محصلة الإشارات بالجمع العادي ومن ثم وجدوا ان كل عصبون يستطيع ان يقوم بعمل تكبير أو تصغير، فتم إضافة عامل اسمه عامل الوزن (Weighting Factor) بمعنى انه إذا كان هناك خلية لها مدخلان فيتم ضرب الإشارة الأولى في المعلمات الخاصة بالعصبون هذا للمدخل الثاني ومن ثم يتم جمعهم وعلى ذلك تم بناء النظام الهندسي للخلايا الصناعية مع الاخذ في الاعتبار انه ليس صحيح بالنسبة 100% للخلايا العصبية البيولوجية.

1-4-6-2 طريقة معالجة المعلومات:

كل اتصال بين عصبون وآخر يتميز بارتباطه بقيمة تدعى الوزن (Weighting) وهي تشكل مدى أهمية الارتباط بين هذين العنصرين، يقوم العصبون بضرب كل قيمة دخل (input) وارداً من عصبونات الطبقة السابقة بأوزان الاتصالات مع هذه العصبونات، من ثم جمع نواتج الضرب جميعاً، ثم إخضاع النتيجة لدالة تحويل يختلف حسب نوع العصبون، ناتج دالة التحويل يعتبر خرج (output) العصبون الذي ينقل إلى عصبونات الطبقة اللاحقة.

2-4-6-2 أختلاف مع الخلايا العصبية البيولوجية:

الخلايا العصبية البيولوجية هي اعقد كثيراً فيوجد مثلاً ثلاثة أنواع للخلايا اما خلايا متواجدة داخل مكان واحد (Local Network Cell) وفي الغالب تكون مستقبلية excitatory أو محدثة inhibitory للإشارة Spike أو خلايا وهي خلايا تربط بين أجزاء مختلفه من المخ وفي الغالب تكون مستقبلية أو خلايا حساب المجموع. يسمى Dendrite بالعصبون وهذا في النموذج الهندسي عبارة عن سلك ليس له تأثير على الإشارة الداخلة للخلية اما في الحقيقة فان ذلك الجزء يعتبر مجموعة من الدوائر الإلكترونية القادرة على أحداث الإشارة ذاتياً وهي تعامل معاملة المكثفات والملفات Active Component كما أنه وجد ان هذه العصبونات لها تأثير على بعض فمثلاً إذا تواجدت العصبونات بجانب بعض فتجمع الإشارة بجمع غير خطي nonlinear اما إذا

كان العصبونات بعيدة عن بعض فتجمع جمع خطي عادي. الخلايا العصبية البيولوجية قادرة على تغيير معاملات العصبونات وهذا معناه انها قادرة على تغيير تشكيلها لمناسبة اقصى مجهود مطلوب باقل الوصلات.

2-6-5 مكونات الخلية العصبية الاصطناعية:

الخلية العصبية الاصطناعية تتكون من أربعة اقسام وهي كالآتي:

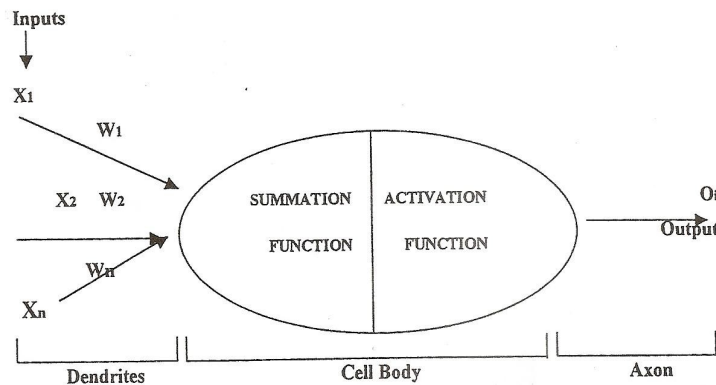
1- قنوات الإدخال (synapse): تتسلم الخلية العصبية من هذه القنوات الإشارات القادمة من الخلايا المرتبطة بها وتسمى الإشارات الداخلة بالمدخلات ويرمز لها (($x_i, i=1,2,\dots,n$))

2- دالة الجمع (summation function): مهمة هذه الدالة جمع او توحيد الإشارات الداخلة في إشارة واحدة .

3- دالة التنشيط (Activation function): مهمة هذه الدالة نشر القيمة الداخلة إليها على وفق نوع الدالة المستعملة على وفق مقياس حدود القيمة الخارجة.

4- قناة الإخراج (Axon path's): تقوم هذه القناة بإرسال إشارة الإخراج إلى خلايا عصبية أخرى وتعد إشارة ادخال لتلك الخلايا وتسمى إشارة الإخراج بالمخرجات. والشكل الاتي يبين مكونات الخلية العصبية.

شكل (2-3) يمثل المنهجية العامة للشبكات العصبية



2-6-6 دوال التنشيط: Activation Function

دوال التنشيط عبارة عن دوال لمعالجة البيانات الداخلة الى الوحدات او

العقد العصبية، وهناك العديد من دوال التنشيط التي قدمت من قبل

الباحثين والتي اختلفت تبعاً لاختلاف نوعية المخرج الذي يتم الحصول عليه واهداف الشبكة المراد تحقيقها. ومن اهم المواصفات الواجب توافرها في الدوال التنشيط هي: ان لا تكون ثنائية القيمة ولها القدرة على النمذجة غير خطية وقابلة للتفاضل او للاشتاق، هذا شرط اساسي تفرضه شبكة الانتشار العكسي للخطأ في عملية التدريب. واهم هذه الدوال هي كالاتي:


1- دالة العتبة أو الخطوة Step Function:

تحدد هذه الدالة مخرج العصبون بين 0 و 1 بحيث يصبح الخرج مساوياً الى الواحد إذا كان الدخل أكبر أو مساوياً للصفر ويصبح الخرج مساوياً الى الصفر إذا كان الدخل أصغر من الصفر وبموجب الصيغة الاتية:

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

وتسمى ايضاً بدالة العتبة Threshold ، والشكل الاتي يوضح هذه الدالة:

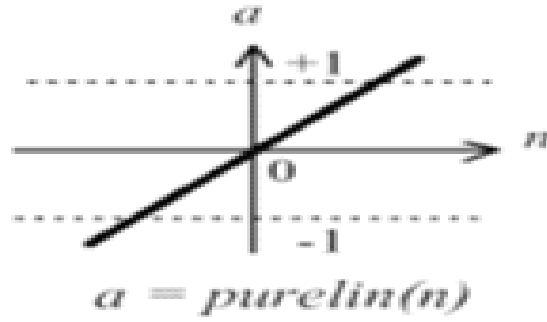
شكل (4-2) يمثل دالة العتبة



2- الدالة الخطية: Linear Function

تستخدم هذه الدالة في المرشحات التلاؤمية الخطية للعصبونات، وكما موضح في الشكل الاتي:

شكل (5-2) يمثل دالة الخطية



3- الدالة السيكمويد او السينية Sigmoid :

تأخذ هذا الدالة قيم الدخل المحصورة بين $-\infty$ و $+\infty$ وتكون المخرجات محصورة بين 0 و 1 وهي أكثر الدوال استخداماً بسبب سهولة اشتقاقه التي تأخذ الصيغة الآتية ضمن المجال (0,1):

$$F(x) = \frac{1}{1 + \exp(-\mu x)}$$

حيث ان:


X: تمثل حاصل ضرب قيمة الادخال مع الوزن المناظر لها .

μ تمثل ميل الدالة وتكون قيمتها مساوية الى الواحد:

ومشتقة الدالة $F(x)$ هي:

$$f'(x) = f(x)[1 - f(x)]$$

شكل (6-2) يمثل دالة السينية




وتعد دالة السنية اوالسيكمويد من اهم الدوال المستخدمة في الشبكات العصبية الاصطناعية وذلك لقدرتها على نشر القيم بين (0-1) بشكل انسيابي وتساعد في تحقيق القيمة الخارجة لكافة قيم المدخلات ومهما كانت واطئة وكذلك تمتاز بسهولة الحساب والتنفيذ.

2-6-7 البنية المعمارية للشبكات العصبونية:

معمارية الشبكة العصبية الاصطناعية، هي الطريقة التي ترتبط بها العصبونات مع بعضها البعض لتشكل الشبكة، وفي الشكل الاتي ترتبط كل مركبة من مركبات شعاع الدخل P بكل عصبون من خلال مصفوفة الوزن W، وكما موضح في الشكل الاتي:

شكل (7-2) يمثل معمارة الشبكة العصبية الاصطناعية



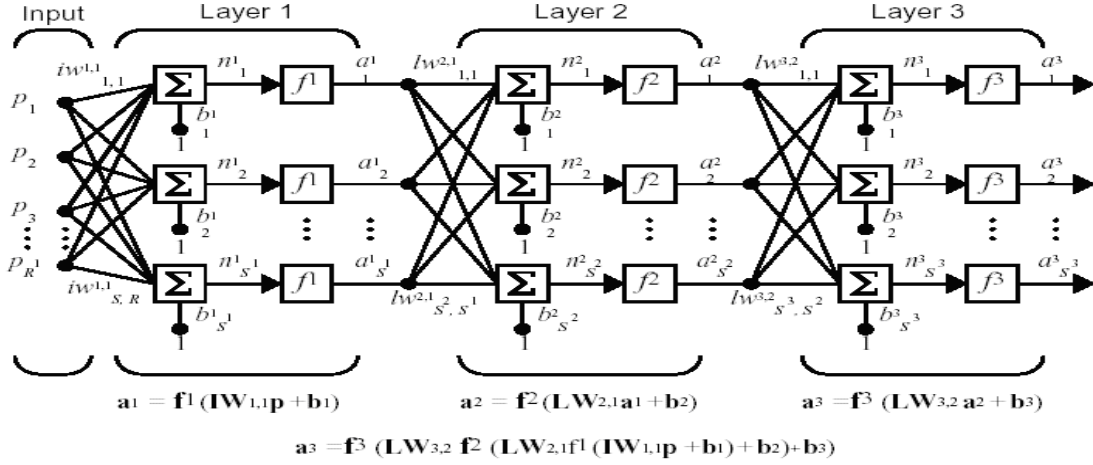
كل عصبون يحتوي وصلة جامع تقوم بجمع الدخل الموزون مع الإزاحة لتشكيل الخرج العددي للعصبون، وفي النتيجة إن مركبات خرج طبقة العصبونات تشكل شعاع الخرج (مصفوفة من عمود واحد). ومركبات شعاع الدخل تدخل إلى الشبكة من خلال مصفوفة الأوزان الاتية:

$$W = \begin{bmatrix} w_{1,1} & w_{1,2} & \dots & w_{1,R} \\ w_{2,1} & w_{2,2} & \dots & w_{2,R} \\ \dots & \dots & \dots & \dots \\ w_{S,1} & w_{S,2} & \dots & w_{S,R} \end{bmatrix}$$

مؤشرات السطر لعناصر هذه المصفوفة تدل على العصبون الهدف أما مؤشرات العمود تدل على مركبات الدخل المصدر. أي أن المؤشرات في

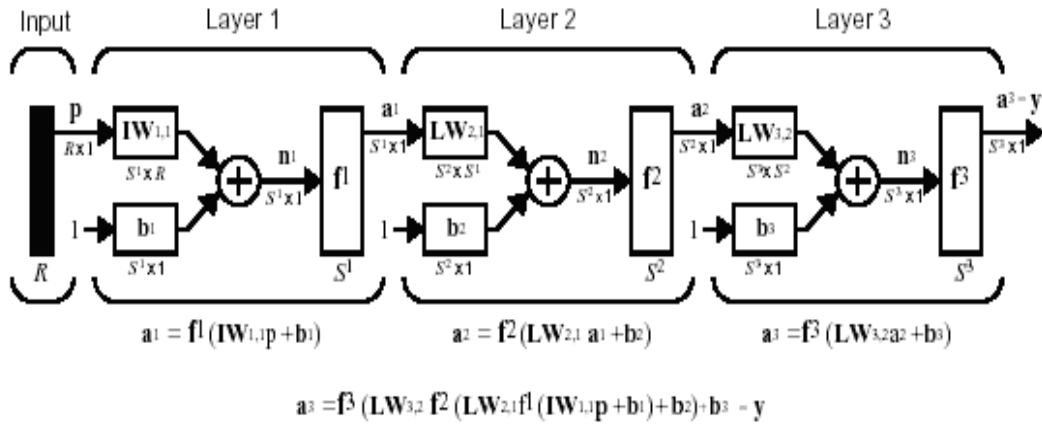
العنصر W_{12} تدل على أن هذا الوزن يتعلق بالعصبون الأول، وأن مركبة الدخل لهذا العصبون هي المركبة الثانية. والشكل الاتي يبين الشبكة الأمامية ذات الطبقات المتعددة.

شكل (8-2) يمثل الشبكة الأمامية ذات الطبقات المتعددة



الشبكة العصبونية يمكن أن تتألف من عدة طبقات وفي هذه الحالة يكون لكل طبقة مصفوفة وزن W ، وشعاع إزاحة b وشعاع خرج. ومن أجل التمييز يضاف رقم الطبقة كدليل علوي لكل من المتحولات المستعملة من خلال الشبكة المبينة مركبة الدخل، عصبون في الطبقة الأولى، عصبون في الطبقة الثانية، وهكذا بنفس الأسلوب. ومن الملاحظ أيضاً أن خرج كل طبقة متوسطة هو دخل للطبقة التي تليها وبذلك تعتبر كل طبقة في هذه الشبكة كأنها شبكة ذات طبقة وحيدة. والطبقة التي تعطي الخرج تسمى طبقة الخرج، أما الدخل فلا يعتبر طبقة، وبقية الطبقات تسمى الطبقات الخفية. ويمكن تمثيل الشبكة الثلاثية من خلال الشكل الاتي:

شكل (9-2) يمثل الشبكة العصبية الثلاثية



الشبكات متعددة الطبقات هي شبكات ذات فعالية كبيرة وخاصة الشبكات التي تتضمن طبقتين، فهي مستخدمة بشكل واسع. حيث تستطيع هذه الشبكات من حل العديد من المشاكل المعقدة ولكن يستغرق تدريبها وقتاً أطول.

2-6-8 الشبكات ذات التغذية الخلفية: Back propagation

Networks

هذا النوع يحوي على الأقل حلقة تغذية خلفية "عكسية" واحدة، ويمكن أن يتألف من طبقة واحدة أو عدة الطبقات وكل عصبون يعود خرجه إلى دخل كل العصبونات المتبقية، ويكون هناك تغذية خلفية ذاتية أي أن خرج العصبون يعود إلى دخله ولكن هذه الشبكات قليلة الاستخدام في المجال الحيوي لانه يمكن تحقيق الأهداف الحيوية من خلال شبكات أمامية.

2-6-8-1 طرائق تعلم الشبكة العصبونية:

تتعلم الشبكة عن طريق إعطائها مجموعة من الأمثلة أو المتجهات، التي يجب أن تكون مختارة بعناية، لأن ذلك سيساهم في سرعة تعلم الشبكة. ومجموعة الأمثلة هذه تسمى مجموعة أو فئة التدريب. وتنقسم طرائق تعلم الشبكة العصبية إلى قسمين حسب فئة التدريب التي تعرض على الشبكة وهما:

التعلم المراقب (بواسطة معلم) ANN's : Supervised Learning of

تقوم كل طرائق التعلم أو التدريب بواسطة معلم للشبكات العصبية الاصطناعية على فكرة عرض البيانات التدريبية أمام الشبكة على هيئة زوج من الأشكال، هما الشكل المدخل input والشكل المستهدف target. وتسمى هذه الشبكات بالشبكات العصبية المراقبة لأنها تحتاج أثناء عملية التدريب إلى مراقب ليبين لها المخرج المستهدف أو المطلوب لكل من المدخلات، ويتم مقارنة المخرج الفعلي مع المخرج المستهدف من أجل تحديث الأوزان للوصول إلى المخرجات المرجوة والتي لا تحتاج بعدها إلى التدريب أو الإشراف خارجي.

التعلم غير المراقب (بدون معلم) : Unsupervised Learning

في هذه الطريقة تكون مجموعة أو فئة التدريب عبارة عن متجه المدخلات فقط دون عرض الهدف للشبكة، وتسمى هذه الطريقة بالتعلم الذاتي حيث تبني الشبكات العصبونية الاصطناعية أساليب التعلم على أساس قدرتها على اكتشاف الصفات المميزة لما يعرض عليها من أشكال وقدرتها على تطوير تمثيل داخلي لهذه الأشكال وذلك دون معرفة مسبقة وبدون عرض أمثلة ما يجب عليها أن تنتج وذلك على عكس المبدأ المتبع في أسلوب التعلم بواسطة معلم.

من أساليب التعلم بدون معلم هي: التعلم الهيبباني Hebbian، والتعلم التنافسي Competitive وبما أن الأسلوب الذي اتبعناه هو التعلم بواسطة معلم، لذلك سنتطرق إليه لاحقاً بالتفصيل، حيث أن التعلم بوجود معلم يمكن أن يتم إما بتصحيح الخطأ أو بالاعتماد على الذاكرة.

9-6-2 التعلم بواسطة معلم على نمط تصحيح الخطأ:

يستخدم هذا النوع من التدريب لتعلم الشبكات الخطية ذات الطبقة الواحدة التي تستخدم لحل مسائل التقابل الخطي بين الدخل والخروج، حيث تقوم الشبكة بحساب إشارة الخطأ من خلال الفرق بين خرج العصبون والخرج المطلوب، ويتم تعديل قيم الأوزان عن طريق دالة

الخطأ المسماة بدالة الكلفة بهدف تصغير الفارق عن طريق اشتقاق هذه الدالة بالنسبة للأوزان الشبكية (المشبكية). تعد هذه الطريقة في التعلم من طرائق التعلم المهمة بواسطة معلم وأكثرها شيوعاً. وهناك نوع آخر من التعلم هو التعلم بواسطة معلم المعتمد على الذاكرة، يتم في هذا النوع من التعلم تخزين المعلومات المتوفرة عن البيئة في الشبكة العصبونية أي تخزين مجموعة التدريب التي هي شعاع الدخل وشعاع الخرج المقابل له ويتطلب هذا النوع من التعلم وجود معيار لتحديد تشابه الأشعة ووجود قاعدة تعلم.

2-6-10 خوارزميات تعلم الشبكة:

تمثل الأوزان المعلومات الأولية أو الابتدائية التي ستتعلم أو تتدرب بها الشبكة، لذا لا بد من تحديث الأوزان خلال مرحلة التدريب. ومن أجل هذا التحديث تستخدم عدة خوارزميات مختلفة حسب نوع الشبكة. من أهم هذه الخوارزميات، خوارزمية الانتشار العكسي للخطأ Back Propagation Algorithm التي تستخدم في تدريب الشبكات العصبونية كاملة الارتباط وذات التغذية الأمامية ومتعددة الطبقات وغير الخطية، وتعد هذه الخوارزمية حالة عامة من طريقة التدريب بنمط تصحيح الخطأ. وفي هذه الشبكة يتم إيجاد الخطأ بين المخرج المستهدف والفعلي ويرجع بهذا الخطأ عكسياً من الطبقة الأخيرة إلى الطبقات الخفية ثم أخيراً إلى طبقة المدخلات واثناء هذا الارتداد أو التغذية العكسية يتم تغيير أو تحديث الأوزان في الاتجاه الذي يجعل الخطأ يتناقص باتجاه الصفر. ويتم تنفيذ هذه الخوارزمية من خلال مرحلتين رئيسيتين هما :

- مرحلة الانتشار الأمامي Feed forward Propagation

• مرحلة الانتشار العكسي Back Propagation

أولاً : مرحلة الانتشار الامامي:

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

ثانياً : مرحلة الانتشار العكسي:

وهي مرحلة ضبط أوزان الشبكة. إن خوارزمية الانتشار العكسي القياسية هي خوارزمية الانحدار التدريجي gradient descent algorithm والتي تسمح لأوزان الشبكة أن تتحرك على الجانب السلبي من دالة الأداء. إن دور الانتشار العكسي يعود إلى الطريقة التي يتم بها حساب الميل لطبقات الشبكة المتعددة اللاخطية، حيث يتم في أحد مراحل التعلم إعادة انتشار الإشارة من الخرج إلى الدخل بشكل عكسي ، ويتم خلالها ضبط أوزان الشبكة.

حيث ان:

α_k : معدل التعلم

g_k : الميل الحالي

وهناك طريقتان لحساب الانحدار التدريجي:

أولاً: النموذج التدريجي (المتزايد): Incremental mode

وفق هذه الطريقة يتم حساب الميل ومن ثم تعدل الأوزان بعد كل دخل يعطى للشبكة.

ثانياً : نموذج الدفعة الواحدة: Batch mode

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

11-6-2 عملية تدريب أو تعلم الشبكة العصبية الاصطناعية:

Artificial Neural Network Training or Learning Process

إن ظاهرة التعلم لدى الإنسان تكسب مهارات وقابليات يمكن ملاحظتها من خلال تغير إنجازة.

اما في الشبكات العصبية الاصطناعية فإن التعلم يعني تغيير اوزان الأتصال (Connected Weight) بين الخلايا العصبية المتصلة مع بعضها اي ان الخلية تغير سلوك الإدخال الى سلوك الأخراج وحسب استجابتها للظروف المحيطة بها. إن عملية التعلم أو التدريب للشبكة العصبية الاصطناعية تبدأ بإدخال البيانات الى الشبكة، إذ تتعلم الشبكة العصبية على الخصائص والمزايا لهذه البيانات التي يتم تمثيلها بشكل متجه (Exemplar) حيث يتكون كل متجه من جزئين، يمثل الجزء الأول مجموعة المتغيرات التوضيحية، اما الجزء الثاني فيمثل قيم المعيار (Criterion Section)، اذ يكون الجزءان معاً المتجهات (Exemplars) الذي يتم إدخاله الى الشبكة العصبية، إذ ان كل عقدة من عقد المدخلات تمثل أحد قيم الجزء الأول من متجه (المتغيرات التوضيحية). ويتم إدخال المتجه بشكل مصفوفة الى الشبكة العصبية، ثم تتدرب الشبكة على البيانات ونتيجة التدريب نحصل على الأوزان المثلى التي تعطي أفضل تقدير لقيم المعيار وهي تمثل مخرجات الشبكة العصبية. ثم يتم مقارنة هذه المخرجات المولدة بواسطة الشبكة مع مخرجات الهدف (المتغيرات المعتمدة) لنحصل على الخطأ (خطأ التدريب) (Training Error) الذي يمثل الفرق بين مخرجات الشبكة وقيم مخرجات الشبكة المرغوب فيها ويستخدم كأساس في عملية تعديل أو تحديث اوزان الشبكة. وتحدث طبقات الأوزان في الشبكة العصبية الاصطناعية حسب منهجية الأنتشار العكسي للخطأ (Error Back Propagation approach) التي تحدث اوزان

الطبقة الأولى طبقة المدخلات الى الطبقة المخفية (Input-Hidden Weights)، ثم من طبقة اوزان الطبقة المخفية الى طبقة المخرجات (Hidden-Output Put Weights).

إن هدف تدريب الشبكة العصبية الاصطناعية على البيانات، هو الحصول على اقل خطأ تدريب وبالنتيجة نحصل على الأوزان المثلى التي يتم اعتمادها في التنبؤ لبيانات جديدة لم تخضع للتعلم. في حين ان قيم الأوزان الابتدائية (Initializing Weights) عند بدأ عملية التدريب تؤخذ كقيم عشوائية يتم توليدها من توزيعات احصائية، ان عملية التدريب او التعلم اعلاه تعد من اكثر الطرائق شيوعاً واهمها، ويطلق عليها تسمية التعلم المراقب او المشرف (Supervised Learning of ANN's).

2-6-12 منهجية الانتشار العكسي للخطأ: Error

Backpropagation Methodology

ان الخطوات الأساسية لمنهجية الانتشار العكسي (EBP) تتمثل في حساب خطأ طبقة المخرجات لتحديث اوزان الطبقة المخفية-المخرجات، ثم حساب خطأ الطبقة المخفية لتحديث اوزان طبقة المدخلات-المخفية، وبعد ذلك يتم حساب مخرجات الشبكة بالأوزان الجديدة لتستمر العملية في حساب الخطأ وتحديث الأوزان حتى الوصول الى اقل خطأ ممكن في الشبكة العصبية. إن الغرض من تدريب الشبكة العصبية على وفق منهجية الانتشار العكسي للخطأ هو الحصول على أوزان مثلى، والتي تعطي أقل خطأ بين مخرجات الشبكة العصبية وقيم المعيار (Criterion Section)، حيث تستعمل هذه الأوزان لحساب التنبؤات لبيانات جديدة لم يسبق للشبكة العصبية أن تدرت عليها.

إن الخطوات الأساسية وفق هذه المنهجية تتمثل بحساب أخطاء طبقة المخرجات لتحديث أوزان الطبقة المخفية-المخرجات، ثم حساب أخطاء الطبقة المخفية لتحديث أوزان طبقة المدخلات-المخفية، وبعد ذلك يتم حساب مخرجات الشبكة بالأوزان الجديدة لتستمر العملية في حساب الأخطاء لتحديث الأوزان حتى الوصول إلى أقل خطأ ممكن في الشبكة العصبية.

ومن الجدير بالذكر، إن القيم الأولية (الابتدائية) للأوزان (Initial Weights) في بداية عملية التدريب للشبكة تؤخذ كقيم عشوائية يتم توليدها من توزيعات إحصائية.

وتمتاز شبكة الانتشار العكسي للخطأ بميزات عدة منها: ضمان الحد الأدنى لمتوسط مربع الخطأ وقابليتها للتعامل مع البيانات المشوشة فضلاً عن قدرتها على معالجة الانظمة والدوال غير الخطية وغير القابلة للفصل الخطي.

2-6-13 خوارزمية الانتشار العكسي للخطأ: Error

Backpropagation Algorithm

إن تدريب الشبكة العصبية الاصطناعية باستعمال الانتشار العكسي يتضمن ثلاث مراحل هي كالتالي:

▫ مرحلة الانتشار الأمامي للخطأ. Forward Stage

▫ مرحلة الانتشار الخلفي للخطأ . Back Pass Stage

▫ مرحلة تحديث "توليف" أوزان الشبكة. Update Weights Stage

خلال مرحلة الانتشار الأمامي، تنتشر إشارة المدخلات إلى كل عقدة من عقد الطبقة المخفية ثم يتم حساب قيمة التنشيط لكل عقدة من عقد الطبقة المخفية لهذه الإشارة وبعدها ترسل هذه العقد إشارات إلى كل عقدة من عقد طبقة المخرجات ثم يتم حساب قيمة التنشيط لكل عقد من عقد طبقة المخرجات

لتشكل استجابة الشبكة لعينة المدخلات المعطاة.

وخلال مرحلة التدريب تقوم كل عقدة في طبقة المخرجات بمقارنة تنشيطاتها المحسوبة مع قيمة المخرجات الفعلية لتحديد قيمة الخطأ

الحاصل لتلك العقدة، واعتماداً على قيمة الخطأ يتم حساب معامل تصحيح الخطأ k ، حيث يستخدم معامل تصحيح الخطأ k لتوزيع الخطأ على العقد في طبقة المخرجات لتتم إعادته إلى كل عقدة في الطبقة السابقة، وكذلك يستعمل هذا المعامل لتحديث الأوزان في طبقة المخرجات والطبقة المخفية، وبطريقة مشابهة يتم حساب معامل تصحيح الخطأ z بالنسبة لكل عقدة من عقد الطبقة المخفية، ويستخدم هذا المعامل لتحديث الأوزان في الطبقة المخفية وطبقة المدخلات. وبعد تحديد كل عوامل تصحيح الخطأ k يتم توليف الأوزان بالنسبة لجميع الطبقات في نفس اللحظة. ويمكن ايجاز خوارزمية أو منهجية عمل هذه الشبكة بالخطوات الآتية:

- 1- توليد قيم أولية للأوزان "من إحدى التوزيعات الإحصائية".
- 2- تستقبل كل عقدة في طبقة المدخلات إشارة دخلها ثم إرسالها إلى جميع عقد الطبقة المخفية.
- 3- تجمع كل عقدة في الطبقة المخفية قيم إشارات دخلها الموزونة وبموجب المعادلة الآتية:

$$h_j = \sum_i (x_i w_{ij}) - 1 \quad (2-23)$$

- 4- تطبيق دالة التنشيط لتقدير مخرجات الطبقة المخفية، وترسل قيم التنشيط إلى جميع العقد في طبقة المخرجات.

- 5- تجمع كل عقدة في طبقة المخرجات إشارات دخلها الموزونة وبموجب المعادلة الآتية:

$$(y_k = 2 / (1 + \exp (- h_j w_{jk})) - 1 \text{ ----- (2-64)}$$

6- حساب الخطأ لعقدة الإخراج عن طريق حساب الفرق ما بين قيمة التنشيط أي قيمة مخرجات العقدة y_k والقيمة الحقيقية للعقدة بمعنى الهدف t_k أي ان:

$$(E_k = t_k - y_k \text{ ----- (2-25)}$$

حيث يتم مقارنة مخرجات الشبكة العصبية مع القيم الحقيقية لتقدير الخطأ وبموجب المعادلة الآتية: (2-26) ----- $(\delta_k = (t_k - y_k) \cdot f'(v)$

حيث أن $f(v)$ تمثل دالة اللوجستية Logistic أو دالة tansig عندما تكون ع قد المخرجات غير خطية وتساوي واحد في حالة كون الدالة خطية. ومن ثم حساب التغير في حجم الخطأ Δw_{jk} وبموجب المعادلة الآتية:

$$\Delta w_{jk} = \alpha \cdot \delta_k \cdot h_j \text{ ----- (2-27)}$$

7- تجمع كل ع قدة في الطبقة المخفية إشارات المدخلات الموزونة إلى Δ وبموجب المعادلة الآتية:

$$(\Delta_j = \sum_i \delta_k w_{jk} \text{ ----- (2-28)}$$

ومن ثم تضرب هذه القيمة بدالة التنشيط لحساب Δ_j وبعد ذلك يتم حساب التغير في حجم الخطأ Δv_{jj} وبموجب المعادلة الآتية: $\alpha \cdot \delta_j \cdot x_i = \Delta v_{jj}$ (2-29)

8- تحديث الأوزان لكل ع قدة في طبقة المخرجات وبموجب المعادلة الآتية:

$$(w_{jk} \text{ (new)} = w_{jk} \text{ (old)} + \Delta w_{jk} \text{ ----- (2-30)}$$

ومن ثم تحديث الأوزان بالنسبة لكل ع قدة في الطبقة المخفية وبموجب المعادلة الآتية:

$$(v_{ij} \text{ (new)}) = v_{ij} \text{ (old)} + \Delta v_{ij} \text{ ----- (2-31)}$$

9- تستمر الشبكة في تحديث الأوزان "أي عملية التعلم والتدريب" إلى أن يتم الحصول على الأوزان المثلى ومن ثم الحصول على المخرجات المرغوب بها أو المستهدفة أي التوصل إلى أفضل توفيق للنموذج قيد البحث.

حيث أن: x_i تمثل مدخلات الشبكة

w تمثل الأوزان ما بين المستويات

والمخطط الآتي يبين عملية المرور الأماميⁱⁱ للشبكة العصبية الاصطناعية

شكل (2-10) يمثل مخطط عملية المرور الأمامي "Forward Pass" للشبكة العصبية الاصطناعية

ii المخطط من اعداد الباحث

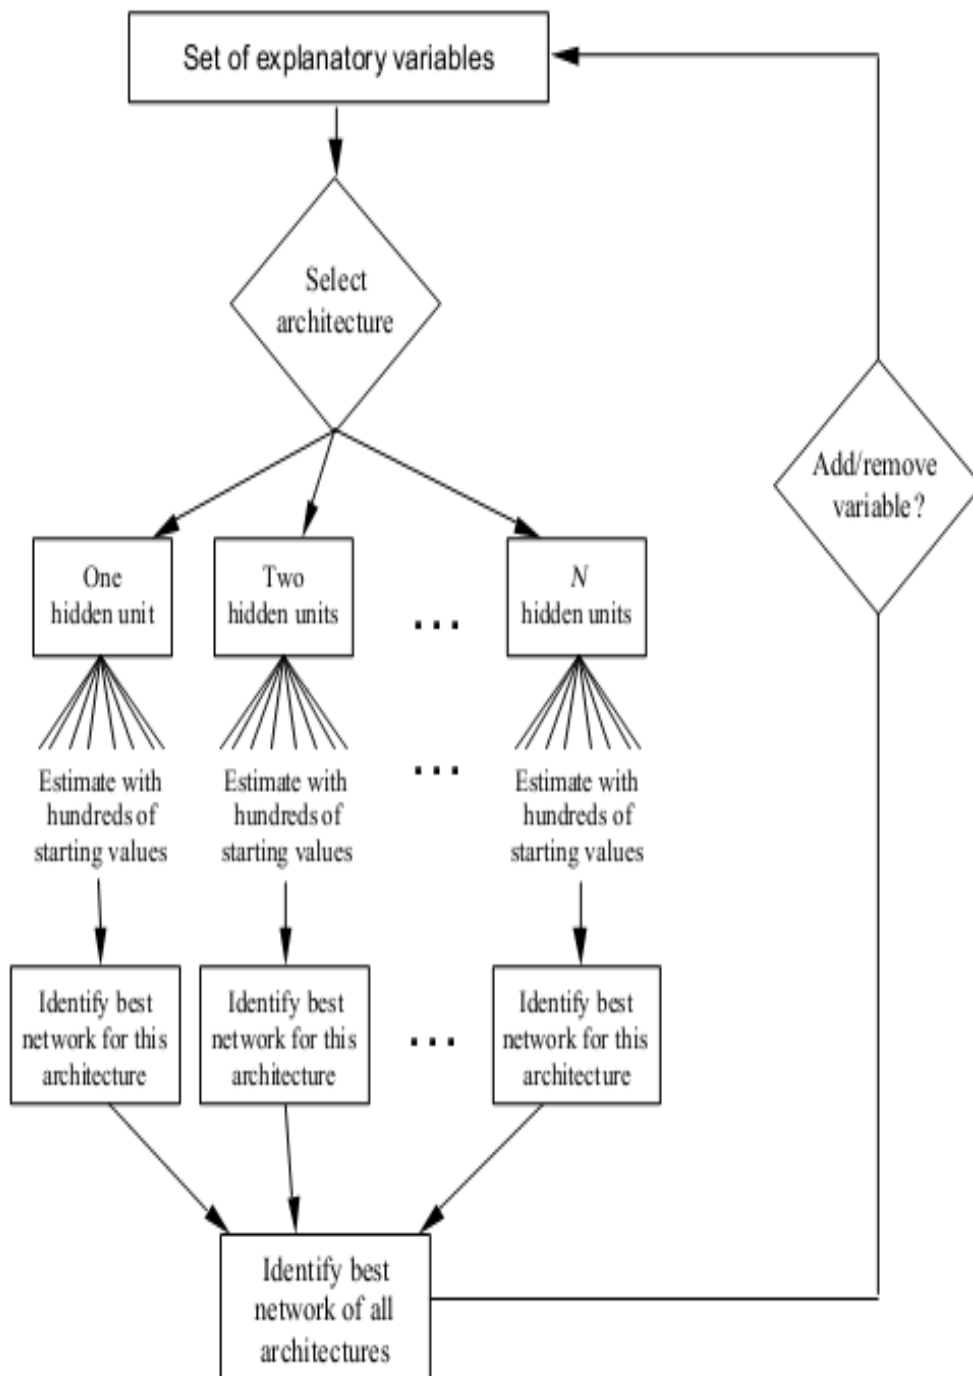
والمخطط الآتي يبين عملية المرور الخلفي أو الانتشار العكسيⁱⁱⁱ "Back pass" للشبكة العصبية الاصطناعية.

شكل (11-2) يمثل عملية المرور الخلفي Backward Pass

iii المخطط من اعداد الباحث

ويتم تصميم الشبكة العصبية الاصطناعية بالاستناد على المخطط
والمعطيات المبينة في الشكل الآتي:
شكل (2-12) يمثل آلية تصميم الشبكة العصبية الاصطناعية

Designing a neural network



2-7 العوامل المؤثرة في كفاءة تدريب الشبكة العصبية الاصطناعية:

Artificial Neural Network Performance Factor

هناك عوامل اخرى تؤثر في كفاءة الشبكة العصبية فضلاً عن العوامل السابقة (عامل الزخم، عامل معدل التعلم، عامل مشتقات الخطأ)، إذ أن جودة التنبؤات المستقبلية لظاهرة معينة تعتمد بشكل أساسي على مدى كفاءة تدريب الشبكة العصبية الاصطناعية على البيانات التاريخية لتلك الظاهرة، ومن العوامل يمكن ايجازها بالاتي:

2-7-1 عدد المتجهات أو النماذج الداخلة الى الشبكة:

Number of Exemplars in Neural Network

يؤثر عدد المتجهات أو النماذج التي يتم إدخالها إلى الشبكة العصبية عند إجراء عملية التدريب أو التعلم لها على أداء الشبكة حيث أنه يرتبط وبشكل مباشر بعدد المتغيرات المستقلة (الجزء الأول من المتجه) والتي تمثل المدخلات لعقد الشبكة، فعندما يكون عدد المتجهات أو النماذج الداخلة إلى الشبكة أكبر من عدد المدخلات أو المتغيرات المستقلة لكل نموذج في هذه الحالة تقوم الشبكة العصبية باستخلاص متجه من تلك البيانات لتمثيل كل العلاقات والخصائص ذات الطبيعة المعقدة التي استطاعت الشبكة تعلمها من تلك البيانات، بكلام آخر إذا كانت مدخلات الشبكة العصبية أي النماذج المقدمة لها على درجة من التعقيد فيجب إدخال عدد من تلك المتجهات أكبر من عدد المتغيرات المستقلة لكل نموذج عند ترتيب الشبكة على تلك المدخلات.

2-7-2 عدد العقد المخفية: Number of Hidden Nodes

يتم تحديد العدد المناسب من العقد المخفية للشبكة عند تدريبها من قبل المستخدم، وللبدء بتدريب الشبكة لابد من إعطاء تقدير أولي لعدد العقد المخفية، إن الاستراتيجية المثلى لتحديد عدد العقد المخفية تتمثل باختيار عدد قليل من العقد المخفية عند البدء بتدريب الشبكة العصبية، أي أن يبدأ تدريب الشبكة بعقدتين مخفيتين مثلاً ثم نقوم بمراقبة خطأ التدريب الذي يتناقص مع استمرار تدريب الشبكة، وعندما يصل إلى حد معين يتوقف فيه عن التناقص، أي حدوث تلكو لتدريب الشبكة، نقوم بزيادة عدد العقد المخفية بعقدة واحدة او عدد معين ليبدأ تدريب الشبكة من جديد بعدد جديد من العقد المخفية مع المراقبة المستمرة للخطأ.

إن هذه العملية المتمثلة بإضافة عقدة مخفية واحدة أو عدد معين في كل مرة والبدء بتدريب الشبكة من جديد، تكرر لحين الوصول إلى أقل قيمة ممكنة للخطأ. وعند إمكانية الوصول إلى تلك القيمة ينتهي تدريب الشبكة ليمثل التدريب الأمثل ويكون عدد العقد المخفية في الشبكة هو العدد الأمثل. إذ إن الهدف من هذه العملية هو تقليل الخطأ إلى أقل قيمة ممكنة.

2-7-3 عدد الطبقات المخفية: Number of

Hidden Layers

إن هذا العامل لا يقل أهمية عن العوامل السابقة، وكما هو الحال في العامل السابق (عدد العقد المخفية) يفضل البدء بعدد قليل من الطبقات المخفية، مبدئياً يتم البدء بتدريب الشبكة العصبية بطبقة مخفية واحدة وعدد قليل من العقد المخفية حيث تتم زيادة عدد العقد المخفية بالتدرج لحين الوصول إلى أقل خطأ ممكن، ولكن يحدث في بعض الحالات وعلى الرغم من زيادة عدد العقد المخفية في الطبقة الواحدة إن تدريب الشبكة العصبية لا يتم بالشكل الأمثل، أي لا يمكن الوصول إلى أقل خطأ ممكن في تدريب الشبكة العصبية، ويعزى ذلك إلى أن بعض العقد المخفية الموجودة في الطبقة الواحدة تستطيع تعلم خصائص مجموعة معينة من البيانات التي تم إدخالها إلى الشبكة بشكل جيد، في حين تفقد بقية العقد المخفية القدرة على الاستجابة والتعلم لخصائص البيانات، بكلام آخر، من الصعب تكوين شبكة عصبية اصطناعية بمجموعة من العقد المخفية، بحيث أن كل عقدة مخفية تستجيب لتعلم خصائص مجموعة معينة من البيانات بشكل صحيح، وللتغلب على هذه المشكلة يتم إضافة طبقة مخفية ثانية حيث تستطيع العقد المخفية الموجودة في هذه الطبقة المضافة من استكمال عملية التعلم التي لم تتم من قبل العقد المخفية في الطبقة الأولى، فإضافة هذه الطبقة الجديدة يصبح بمقدور الشبكة العصبية تعلم كل الخصائص والمزايا للبيانات التي تم إدخالها إلى الشبكة لغرض التعلم، وكل ذلك بالطبع يعتمد على طبيعة البيانات التي تم إدخالها إلى الشبكة، ففي بعض الحالات عندما تكون البيانات على درجة من


التعقيد قد تحتاج إلى إضافة طبقات مخفية أخرى لحين الوصول إلى التدريب الأمثل للشبكة.

2-8 الشبكات العصبية الاصطناعية والسلاسل الزمنية:

تكتسب الشبكات العصبية اهمية متزايدة في معالجة وتحليل السلاسل الزمنية ونماذج بوكس-جنكينز لقابليتها على التعلم الذاتي والتدريب. وتستند جميع فرضيات الباحثين على اسلوب بوكس-جنكينز وعلى دالتي الارتباط الذاتي والجزئي PACF، (ACF) بشكل عام ونموذج الانحدار الذاتي بشكل خاص اذ يتم تحديد مدخلات الشبكة من خلال ازاحة السلسلة بدرجة نموذج الانحدار الذاتي في نموذج الـ ARIMA ويتم التعويض عن درجة الفروق بالإزاحة السلسلة بدرجة الفرق اما مخرجات الشبكة فتمثل السلسلة الزمنية الحالية. وبغية عدم الاسهاب وتعذر عرض جميع البحوث التي لا يمكن حصرها، لذلك سيتم عرض عينة من تلك البحوث (وسيتم عرض بعض النصوص بصيغتها الاصلية بغية تناول الموضوع بدقة اكبر وموضوعية عالية).

(1) تستند فرضية الباحثين^[44] Jerome, Connor and Martin في تحديد مدخلات الشبكة العصبية لبيانات السلسلة الزمنية من خلال ازاحة السلسلة بدرجة نموذج الـ ARIMA وبموجب الصيغة الآتية:

$$\hat{x}_t = \hat{h}(x_{t-1}, \dots, x_{t-p}) = \sum_{i=1}^I W_i f \left(\sum_{j=1}^p w_{ij} x_{t-j} + \theta_i \right)$$




Different neural network architectures were evaluated with the statistics described in Section 5. The autoregressive single hidden-layer feedforward neural network model used in our work has the following form: $y_t = \beta_0' \mathbf{w}_t + \sum_{j=1}^q \beta_j G(\gamma_j' \mathbf{w}_t) + \varepsilon_t$ (3) forecast with a minimum S_{pred} (see Table 1), so the NN(1, 12, 13; 1) model was selected for further results. Use the proposed lags, i. e. $(x_{t-1}, x_{t-12}, x_{t-13})$, as the input to the neural network and where $\mathbf{w}_t = (1, y_{t-1}, \dots, y_{t-p})'$ as before and $\beta_j, j = 1, \dots, q$, are parameters, called "connection

(2) strengths" in the neural network literature. Furthermore, function $G(\cdot)$ is a bounded function (2)

تستند فرضية الباحثون [39] Allende, Moraga and Salas في تحديد مدخلات الشبكة العصبية لبيانات السلسلة الزمنية من خلال ازاحة السلسلة بدرجة نموذج ال ARMA وبموجب الصيغة الاتية:

(3) تستند فرضية الباحثون [86] Terasvirta, Dijk and Medeiros في تحديد مدخلات الشبكة العصبية لبيانات السلسلة الزمنية من خلال ازاحة السلسلة بدرجة نموذج ال ARMA وبموجب الصيغة الاتية :

(4) تستند فرضية الباحثون [67] Morariu, Iancu and Vlad في تحديد مدخلات الشبكة العصبية لبيانات السلسلة الزمنية من خلال ازاحة السلسلة بدرجة نموذج ال ARIMA وبموجب الصيغة الاتية :



(5) تستند فرضية الباحثين [71] Sandy and Ord في تحديد مدخلات الشبكة العصبية لبيانات السلسلة الزمنية من خلال ازاحة السلسلة بدرجة نموذج ال ARIMA وبموجب الصيغة الاتية:

the important relationships in the time series being forecast.

For a feedforward neural network with one hidden layer, the prediction equation, given by Faraway and Chatfield (1998), for computing forecasts \hat{x}_t using selected past observations, $x_{t-j_1}, \dots, x_{t-j_k}$ at lags (j_1, \dots, j_k) and h nodes in the hidden layer will be referred to as $NN[j_1, \dots, j_k; h]$. Thus, the network in Fig. 1 is $NN[1, 12, 13; 2]$. The functional form may be written as

$$\hat{x}_t = \phi_0 \left(w_{c0} + \sum_n w_{no} \phi_n \left(w_{cn} + \sum_j w_{jn} x_{t-j} \right) \right)$$

(6) تستند فرضية الباحثون [79] Sana, Smaoui and Gabr في تحديد مدخلات الشبكة العصبية لبيانات السلسلة الزمنية من خلال ازاحة السلسلة بدرجة نموذج ال ARIMA وبموجب الصيغة الاتية:

number of nodes in the input layer is equal to the number of delays or lagged variables $[y_{t-\tau}, y_{t-2\tau}, \dots, y_{t-k\tau}]$, where τ is a time delay, and k is the number of chosen delays. The output, y_{t+P} , is the predicted value of a time series defined as 7)

$$y_{t+P} = f(y_t, y_{t-\tau}, y_{t-2\tau}, \dots, y_{t-k\tau}), \quad (9)$$

where P is a prediction time into the future. Mehdi ^[61] الباحثين

Mehdi Bijari في تحديد مدخلات الشبكة العصبية لبيانات السلسلة الزمنية من خلال ازالة السلسلة بدرجة نموذج الـ ARIMA وبموجب الصيغة الاتية:

acyclic links (Fig. 1). The relationship between the output (y_t) and the inputs (y_{t-1}, \dots, y_{t-p}) has the following mathematical representation:

$$y_t = w_0 + \sum_{j=1}^q w_j \cdot g\left(w_{0j} + \sum_{i=1}^p w_{ij} \cdot y_{t-i}\right) + \varepsilon_t,$$

where, $w_{ij} (i = 0, 1, 2, \dots, p, j = 1, 2, \dots, q)$ and $w_j (j = 0, 1, 2, \dots, q)$

2-8-1- الاسلوب المعدل "المقترح":

ان الغرض من الاسلوب المعدل^{iv} هو تحسين مخرجات الشبكة العصبية الاصطناعية من خلال زيادة عدد العقد في طبقة مدخلات تلك الشبكة، وتنص فرضية الاسلوب المعدل على المزج بين اسلوبين هما السببية والسلاسل الزمنية، اذ يتم اضافة متغيرات توضيحية اخرى الى طبقة مدخلات الشبكة العصبية الاصطناعية للحصول على نتائج (مخرجات) ذات كفاءة عالية واكثر دقة ورصانة. يمثل الاسلوب المعدل نموذج هجين يجمع بين منهجية السلاسل الزمنية والطرائق السببية. وتستند المنهجية المعدلة الى الزيادة النوعية لعدد العقد في طبقة مدخلات الشبكة العصبية للوصول الى النتائج المرجوه التي تماثل "تطابق" الهدف "target" او

iv اسلوب مقترح من قبل الباحث

تقترب منه بشكل كبير، وذلك من خلال جعل قيمة الخطأ في عملية تدريب الشبكة العصبية الاصطناعية في قيمته الصغرى. **ويامضياً يمكن توصيف النموذج المقترح لحساب طبقة المدخلات من خلال**

الصيغة ^v الآتية:

$$y_t = w_0 + \sum_{j=1}^q w_j \cdot g \left(w_{0j} + \sum_{i=1}^p w_{ij} \cdot y_{t-i}, X_t, Z_t \right) + \varepsilon_t, \quad \text{.....(2-32)}$$

ARIMA
model

independent variable

:Where

$w_{i,j}$ ($i=0,1,2,\dots,p, j=0,1,2,\dots,q$) and w_j ($j=0,1,2,\dots,q$) are model parameters often called connection weights; y_p, X_t, Z_t is the number of input nodes; q is the number of hidden nodes and y_t is output nodes.

2-9 التنبؤ المستقبلي: Forecasting

ان احد الأهداف المهمة في تحليل السلاسل الزمنية هو التنبؤ بقيمها المستقبلية حتى وإن كان الغرض النهائي منه نمذجة السلسلة الزمنية للسيطرة أو التنفيذ.

^v معادلة رياضية مشتقة من قبل الباحث.

إن أغلب نتائج التنبؤ صيغت من النظرية العامة في التنبؤ الخطي المطورة من قبل Kolmogorov(1939-1941), Wiener(1949), Kalam(1960), (1983) (Yaglom(1962), ittle (1983) ، حيث يوجد نوعان من التنبؤ :

الأول: التنبؤ النقطي Point Forecasting

وهو التنبؤ بالقيمة المستقبلية للسلسلة الزمنية بقيمة واحدة (مفردة) ، وهذه القيمة عادة ما تكون ذات أقل متوسط مربعات خطأ تنبؤ ، حيث يرمز إلى القيمة التنبؤية إلى Z_{t+1} بـ $Z_{t|}$ حيث يسمى L بـ Lead و t بـ Origin .

الثاني: التنبؤ بفترة تنبؤ Forecasting with Interval Prediction

وهو التنبؤ بالقيم المستقبلية إلى Z_{t+1} بفترة أو مدى من القيم التنبؤية المحسوبة بحيث نكون واثقين عند مستوى احتمالية معين أن القيمة الحقيقية للتنبؤ تكون محتواة في هذه الفترة.

2-9-1 التنبؤ باستخدام اسلوب الشبكات العصبية الاصطناعية:

إن منهجية الشبكات العصبية الاصطناعية من الطرائق الحديثة التي لها الكفاءة العالية في إعطاء نتائج مرضية وجيدة، ففي موضوع البحث استخدمت منهجية الشبكات العصبية الاصطناعية في تحليل السلاسل الزمنية. ومن المميزات التي تملكها منهجية الشبكات العصبية الاصطناعية ، مرونة تحديد نوعية وعدد المدخلات وعدد العقد المخفية وعدد الطبقات المخفية للشبكات العصبية الاصطناعية إلى أن تصل إلى النموذج الأمثل.

وتستعمل الشبكة المدربة (net) للتنبؤ للفترة القادمة وبمدخلات جديدة.

إن النموذج الرياضي العام لشبكة العصبية يمكن ايجازه على شكل

مصفوفات في المعادلات أدناه :

$$Y_1 = \frac{(w_1 * x) + b_1}{2}$$

$$H = \frac{(1 + \exp(-2 * Y_1)) - 1}{2}$$

$$Y_2 = \frac{(w_2 * H) + b_2}{2}$$

$$Y = \frac{(1 + \exp(2 * Y_2)) - 1}{2}$$

Y =

الجدول الآتي يبين عملية التنبؤ، إذ يبين عدد المدخلات وعدد العقد المخفية وأبعاد مصفوفة أوزان (Input-hidden) W_1 وأبعاد مصفوفة أوزان (Hidden-output) W_2 .

جدول (2-2) يوضح جدول التنبؤ للشبكات العصبية الاصطناعية

| عدد المدخلات | عدد المخرجات | عدد العقد الطبقة المخفية | أوزان طبقة المدخلات - المخفية | أوزان طبقة المخرجات - المخفية |
|--------------|--------------|--------------------------|-------------------------------|-------------------------------|
| P | T | m | m * P | m * T |

وتبين الخوارزمية (1-2) خطوات التنبؤ (ومعايرة المدخلات جديدة) من خلال برنامج ماتلاب.

2-9-2 فترات التنبؤ للشبكات العصبية الاصطناعية [51]: Prediction:

Intervals for ANN

هنالك مجموعتان من المعلمات حيث أن التوزيع المقابل (x, y) يكون متماثل بسبب عدم إمكانية تعريف المعلمات وهي المشكلة النظرية للشبكات العصبية الاصطناعية، وبافتراض أن النموذج الإحصائي اللامعلمي الذي يربط y مع $g(x, w)$ بالشكل الآتي:

$$Y_i = g_{\theta}(x_i) + \varepsilon_i.$$

حيث أن مركبة ε العشوائية تتوزع حسب التوزيع الطبيعي بمتوسط مساوي إلى الصفر وتباين مساوي إلى σ^2 . إن الشبكات تتدرب على مجموعة البيانات $D_n = \{(x_i, y_i)\}^{1/2}$ بمعنى أن هذه البيانات تستخدم للتنبؤ بالمخرجات المستقبلية عند نقطة جديدة x_{n+1} بواسطة $y_{n+1} = g(x_{n+1}, w)$. ان

منهجية فترة الثقة وفترة التنبؤ المستندة على الشبكات العصبية الاصطناعية في حالة طبقة مخفية واحدة وبافتراض ان حجم العينة (n) كبير، تأخذ الصيغة الاتية التي قدمت من قبل الباحثين^[51] Hawang & Ding.

$$g_{\hat{\theta}}(\mathbf{x}_{n+1}) \pm t_{1-\alpha/2, n-(d+2)k-1} \hat{\sigma} \sqrt{1 + S(\hat{\theta})}$$

$$\hat{\sigma}^2 = \frac{1}{n - (d + 2)k - 1} \sum_{i=1}^n (Y_i - g_{\hat{\theta}}(\mathbf{x}_i))^2,$$

and

$$S(\hat{\theta}) = \frac{1}{n} \{ [\nabla_{\theta} g_{\theta}(\mathbf{x}_{n+1})]_{\theta=\hat{\theta}}^t \hat{\Sigma}^{-1}(\hat{\theta}) [\nabla_{\theta} g_{\theta}(\mathbf{x}_{n+1})]_{\theta=\hat{\theta}} \},$$

where

$$\hat{\Sigma}(\hat{\theta}) = \frac{1}{n} \sum_{i=1}^n [\nabla_{\theta} g_{\theta}(\mathbf{x}_i) \nabla_{\theta} g_{\theta}(\mathbf{x}_i)^t]_{\theta=\hat{\theta}}.$$

ان فترة الثقة لـ $g_{\theta^*}(\mathbf{x}_{n+1})$ تماثل احتمالية $1 - \alpha$ و $t_{1-\alpha/2, n-(d+2)k-1}$.

وتمثل $1 - \alpha/2$ كمية توزيع t بدرجة حرية $n - (d + 2)k - 1$.

حيث ان:

d: تمثل عدد المدخلات.

k: تمثل عدد العقد في الطبقة المخفية.

W: مصفوفة اوزان الطبقة المخفية- طبقة المخرجات.

2-10 المعايير الإحصائية للمفاضلة [12,74,64,63,54,95]:

تم اعتماد المعايير الإحصائية آتية بغية مقارنة نتائج الطرائق المعتمدة من خلال الخطأ العشوائي ولا بد من تعريف الخطأ، ويعرف الخطأ بأنه الفرق بين القيمة المتنبأ بها والقيمة الحقيقية.

جدول (2-3) يمثل معايير الخطأ

| المعيار | التوصيف | الصيغة الرياضية | قم المعادلة |
|--|--|--|-------------|
| Mean absolute error (MAE) | معدل القيم المطلقة للخطأ | $MAE = \frac{\sum_{t=1}^N E_t }{N}$ |(2-38) |
| Mean Absolute Percentage Error (MAPE) | معدل القيم المطلقة لنسب الخطأ | $MAPE = \frac{\sum_{t=1}^N \left \frac{E_t}{Y_t} \right }{N}$ |(2-39) |
| Mean squared error (MSE) | معدل مربعات الخطأ | $MSE = \frac{\sum_{t=1}^N E_t^2}{N}$ |(2-40) |
| Root Mean squared error (RMSE) | جذر معدل مربعات الخطأ | $RMSE = \sqrt{\frac{\sum_{t=1}^N E_t^2}{N}}$ |(2-41) |
| Coefficient of determination (R ²) | معامل التحديد يقيس جودة التوفيق أي يوضح نسبة الانحرافات لقيم الموضحة في النموذج بالنسبة للانحرافات الكلية، وهو عدد موجب محصور بين (0,1) و يرمز له بالرمز: R ² | R ² =SSR/SST |(2-42) |
| Forecast skill (SS) | مهارة التنبؤ أو درجة التنبؤ أو مهارة التنبؤ هو توصيف لمقياس خطأ التنبؤ الذي يتعلق بدقة التنبؤ لنموذج التنبؤ المعين لبعض | $SS = 1 - \frac{MSE_{forecast}}{MSE_{ref}}$ |(2-43) |

Where: SST =Total sum of square = $\sum (y(i)-\mu(y))^2$;for i=1,2, ..., n

SSR =Regression sum of square = $\sum (\hat{Y}(i)-\mu(y))^2$;for i=1,2, ...,

n

and

$$MSE_f = \frac{1}{N} \sum_{i=1}^N (f_i - O_i)^2$$

$$MSE_{Ref} = \frac{1}{N} \sum_{i=1}^N (\bar{O} - O_i)^2,$$

حيث ان: f_i : تمثل القيم المتنبأ بها.

O_i : تمثل المشاهدة.

وتنحصر قيمة مهارة التنبؤ (SS) بين الصفر وواحد (0-1)، فاذا كانت قيمتها واحد (1) فأن مهارة طريقة التنبؤ تامة (Perfect) اما اذا كانت قيمتها صفر (0) فان طريقة التنبؤ تكون غير كفوءة (اي ذات مهارة سالبة Negative skill) وفي حالة كون قيمتها اقل من واحد ($0 < SS < 1$) فان مهارة طريقة التنبؤ قليلة وتكون المهارة جيدة كلما اقتربت قيمتها من الواحد والعكس صحيح. وأية طريقة تعطي اصغر قيمة للخطأ واكبر قيمة لمعامل التحديد فتصبح الطريقة الأفضل "الامتثل".

2-11 مفهوم المحاكاة [41,5] : The Simulation Concep

هنالك العديد من الظواهر والانظمة الحقيقية التي لايمكن السيطرة عليها ميدانياً فضلاً عن النظريات والمشكلات الرياضية التي يصعب تحليلها منطقياً من خلال البرهان الرياضي ، الأمر الذي يدفع البعض نحو ترجمة هذه النظريات على مجتمعات حقيقية ثم اختيار عدد من العينات

العشوائية المستقلة ليتم التوصل وبشكل تقريبي إلى الحلول المثلى لتلك المشاكل.

غالباً ما يكون الحصول على هذه العينات ميدانياً غايةً في الصعوبة لما يتطلبه من تكلفة عالية ووقت وجهد، كما قد تكون عملية المعاينة هذه غير مقبولة نظرياً ، لذا فقد توجه الباحثون نحو تطبيق أسلوب المعاينة التجريبية (Sampling Experiment) وهو ما يعرف اليوم بالمحاكاة.

وبصورة عامة تعرف المحاكاة بأنها تقليد للظواهر والانظمة الحقيقية باستعمال نماذج رياضية، فيزيائية تحاكي جميع خصائص وسلوك النظام الحقيقي (الظاهرة، المشكلة) وذلك لايجاد الحلول المثلى لها من خلال اتخاذ القرارات المناسبة او المفاضلة بين الطرائق (الاختبارات، السياسات) المختلفة. ويتم تطبيقها على الصعيدين النظري والعملي وفي المجالات المختلفة الرياضية ، المختبرية ، الطبية ، الاحصائية، الاقتصادية ، الهندسية ، الخ.

لقد اشار Robinson الى اهم الميزات التي تمتاز بها تجارب المحاكاة مقارنة بالتجارب الحقيقية والتي يمكن تلخيصها بالنقاط الآتية:

- زيادة في فهم النظام Greater Understanding.
- اختزال الزمن Lead-time reduction.
- اختزال التكلفة Cost reduction.
- تقليل الخطورة Risk reduction.
- اسرع من حيث تغيير خطة التجربة Faster plan changes.

وتزداد تجارب المحاكاة اهمية تبعاً لما يأتي:

- مطابقة او اقتراب نتائج تجارب المحاكاة مع نتائج التجارب الحقيقية.

- المرنة (Flexible) في اجراء بعض التغيرات في النظام واقتراح نموذج جديد على ان ينتج عنه نتائج مقارنة لتلك الناتجة عن تغيير النظام الحقيقي.

وهناك العديد من طرائق المحاكاة التي تختلف تبعاً لطريقة المعاينة التجريبية اهمها:

▫ طريقة مونت كارلو Monte - Carlo Method.

▫ الطريقة التناظرية Analogue Method.

▫ الطريقة المختلطة Mixed Method.

تُعد طريقة Monte-Carlo اكثر طرائق المعاينة التجريبية شيوعاً واستخداماً إذ تعتمد هذه الطريقة على الفكرة التي مفادها امكانية تطبيق نظرية الاحتمال لتحويل اي دالة احتمالية الى التوزيع المنتظم Uniform distribution من خلال توليد عينة من الأرقام العشوائية ذات التوزيع المنتظم للفترة (0,1) ليتم على اساس ذلك ارجاع توزيع العينة الى التوزيع المطلوب. ولغرض تطبيق تجربة المحاكاة لابد من وجود أرقام عشوائية ليتم الاعتماد عليها في بناء نماذج المحاكاة ، ويمكن تحقيق العشوائية لمفردات العينة باستعمال أحد الأساليب التي تحقق نفس الفرصة بالظهور لجميع وحدات المجتمع غير انه يصعب تحقيق ذلك من

خلال الحواسيب، لذا اتجه الباحثون نحو توليد أرقام ليست عشوائية بشكل تام إنما تمتاز بخصائص تقترب من خصائص العشوائية الحقيقية تعرف بالأرقام العشوائية التي هي عبارة عن سلسلة من الأرقام الناتجة عن تنفيذ صيغة معينة.

واهم الميزات الواجب تحققها في سلسلة الأرقام العشوائية :

□ ان تكون السلسلة طويلة فلا تعاني من القطع المفاجئ ويعتمد ذلك على الصيغة المستخدمة.

□ السرعة في توليد الأرقام العشوائية.

□ إمكانية إعادة توليد بعض الأرقام Reproducibility وبخاصة عندما تكون السلسلة طويلة.

□ عدم وجود الارتباط (Correlation) بين الأرقام العشوائية.

هنالك العديد من الطرائق التي تستخدم لتوليد الأرقام العشوائية يُعرف كلٍ منها بالمولد (Generator) إذ ينتج عنها سلسلة من الأرقام العشوائية ذات التوزيع المنتظم، وتختلف هذه المولدات تبعاً لاختلاف الصيغة الرياضية لها. ان أهم الأرقام العشوائية هي مولدات الاتساق الخطي Linear Congruential Generators.

2-12 البرمجيات [83],96,84,98:

يعد برنامج MATLAB أحد أشهر لغات البرمجة التي لا تحتاج إلى احتراف أو مهارة عالية لاستخدامها ومع ذلك فإنها تقوم بمهام كبيرة بمجهود قليل قياساً بلغات البرمجة الأخرى. تم اشتقاق تسمية البرنامج من (Matrix Laboratory) حيث يعتمد في تخزين ومعالجة inputs و outputs على استخدام matrices. وهو من أفضل البرامج الموجودة لإجراء العمليات الحسابية وتحليل المعطيات وإظهار النتائج على هيئة جداول أو

رسوم بيانية. يستخدم البرنامج لعمل (curve fitting) لإيجاد أنسب معادلة تحقق عدد من النقاط (X,Y) حسب درجة المعادلة المطلوبة (خطية، درجة ثانية، درجة ثالثة....الخ). من السهل استخدام البرنامج لإيجاد الحل لعدد من المعادلات الجبرية مهما كان عددها. يمكن استخدام البرنامج لمعالجة الملفات بالقراءة منها أو تعديلها وإنشاء ملفات جديدة. يرافق البرنامج عدد كبير من صندوق الادوات (toolboxes) من أشهرها أداة (Simulink) التي تستخدم في نمذجة ومحاكاة وتحليل الأنظمة الديناميكية ثم إيجاد حلول هذه النماذج بطرائق سهلة. ما يميز هذا البرنامج هو امكانية البرمجة داخله حيث يتم الافادة من ذلك في برمجة خطوات تنفيذ الشبكات العصبية الاصطناعية ANN باستعمال برنامج ماتلاب من قبل الباحث.

ويمكن ايجاز مراحل برمجة شبكة البث العكسي للخطأ BP بواسطة برنامج ماتلاب فيما يلي:

- ▣ معايرة او تطبيع "Normalization" البيانات باستعمال الدالة `prestd`.
- ▣ انشاء الشبكة البث العكسي للخطأ BP باستعمال الدالة `newff`.
- ▣ تدريب الشبكة من خلال تعديل قيم الاوزان او المعلمات بالاعتماد على الخطأ وباستعمال الدالة `Trainparam` حتى تحقق احدى الشروط الاتية : تقيم اداء الشبكة باستعمال الدالة `Performfcn` بالاستناد على معدل مربع الخطأ MSE، او التكرار حتى 1500، او تحقيق الخطأ للمعلمات يساوي $1e-5$.
- ▣ استخراج المتنبأ بها باستعمال الدالة `Sim` للشبكة المدربة "net".
- ▣ اعادة تحويل البيانات الى الوحدات المعيارية باستعمال الدالة

.Potstd

□ حساب الخطأ المعياري واستخراج المعايير الاحصائية
للخطأ. واستخراج اورزان الشبكة باستعمال الدالة
`net.lw{1},net.lw{2,1},1` والتحيز "baise".

□ التنبؤ بالفترة القادمة باستخدام الشبكة المدربة "net" بعد معايرة
المدخلات الجديدة باستعمال الدالة `prestd`.

ويمكن تمثيل تلك الخطوات من خلال الخوارزمية^{vi} الآتية:

vi الخوارزمية من تصميم الباحث