

## مقارنة بين طريقة شوارت ( لخارطي الوسط الحسابي والمدى ) والشبكات العصبية في

### السيطرة النوعية للتوزيعات المتوتية

م. علاء حسين عمران انصاف

المعهد التقني- كوت

### المستخلص

إن خارطة الوسط الحسابي وخارطة المدى تقترضان أن العينات مسحوبة من مجتمعات تتوزع توزيعاً "طبيعياً". وفي حالة عدم تحقق ذلك ، فهناك وسائل عديدة لمعالجتها منها : زيادة حجم العينة لجعل متوسط العينة يتوزع توزيعاً "طبيعياً" ، أو استعمال طريقة التحويل المسماة (Box – Cox power transformation) ، أو استعمال طريقة تصحيح الالتواء (SC). في هذا البحث استخدمت المحاكاة لمقارنة طريقة الشبكات العصبية الاصطناعية لمراقبة العمليات والمتغيرات مع الطريقة الكلاسيكية للمراقبة ( خارطة الوسط الحسابي وخارطة المدى). لقد تم التوصل إلى أنه إذا كان توزيع المتغيرات "طبيعياً" أو "قريباً" من توزيع ويبل ، كما ، اللوغاريتمي الطبيعي فإن المحاكاة أظهرت أن الخطأ من النوع الأول لطريقة الشبكات العصبية الاصطناعية أقل من الخطأ من النوع الأول لخارطي الوسط الحسابي والمدى. لذا فإن الشبكات العصبية الاصطناعية هي أكثر كفاءة من خارطي الوسط الحسابي والمدى في حالة التوزيعات المتماثلة وغير المتماثلة ولدرجات التواء مختلفة.

### Abstract

The  $\bar{x}$  - Chart and R-Chart are based on assumption that the Sample drawn from the process are normally distributed. When the normality assumption is not valid , there is several different actions , such that , increasing the size of Samples drawn from the process until the distribution of sample mean is considered normal , using Box- Cox power transformation on the original data to yield an approximate normal distribution, or use Skewness correction (SC). In this paper the Simulation is used to compare artificial neural network (ANN) technique for monitoring the process variability and Classical method of Statistical process Control Chart ( $\bar{x}$  - chart and R-chart) . We conclude that when the process distribution is normally distributed or in Some neighborhood weibull , Gamma and Lognormal ,Simulation Show that ANN technique have type I error is less than Type I error of  $\bar{x}$  - Chart and R- Chart. There for ANN is more efficient than  $\bar{x}$  - Chart and R- Chart for symmetric and non-symmetric distributions at different skewed process distribution .

## ١- الجانب النظري

### ١-١ المقدمة

تعد مخططات السيطرة النوعية إحدى الأدوات المهمة لعمليات السيطرة الإحصائية (Statistical Process Control). إن خارطة السيطرة باستعمال الوسط الحسابي (X- Bar Control Chart) وخارطة السيطرة باستعمال المدى (Range Control Chart) اللتين وضعتا من قبل شوارت Shewhart عام ١٩٣١ تشترطان أن تكون المتغيرات المراد اختبارها تتوزع توزيعاً طبيعياً (normally distributed) أو قريباً من التوزيع الطبيعي (Approximately normally distributed)<sup>[4]</sup>. إن هذا الشرط غالباً لا يتحقق حيث تكون التوزيعات للمتغيرات المراد اختبارها غير متماثلة. فإذا كان حجم العينة ليس كافياً وتوزيع البيانات لا يتبع التوزيع الطبيعي فإن استعمال طريقة شوارت لبناء حدود المراقبة ربما يؤدي إلى خفض قابلية اكتشاف الانحرافات في العمليات الإنتاجية، أي زيادة الخطأ من النوع الأول (الذي يعني رفض فرضية العدم عندما تكون صحيحة). وفي السيطرة النوعية يعني اتخاذ القرار أن العملية خارج حدود السيطرة علماً "إنها ضمن حدود السيطرة".

في مجال السيطرة النوعية اقترحت وسائل عديدة لمعالجة عدم التوزيع الطبيعي منها :-  
١- زيادة حجم العينة لجعل متوسط العينة يتوزع توزيعاً طبيعياً "أو قريباً" من التوزيع الطبيعي ، ولكن زيادة حجم العينة يتسبب بزيادة كلفة الفحص والاختبار .

٢- استعمال إحدى وسائل تحويل البيانات (Data transformation). لكنّ عدداً من المهتمين في هذا المجال يفضلون استعمال هذا الأسلوب إذا كان الالتواء ليس بدرجة كبيرة وكما في طريقة تحويل قوى بوكس - كوكس (Box-Cox power transformation) التي تعد من أكثر الأساليب استعمالاً " لتحويل البيانات لتحقيق فرض ثبات التباين وتقريب نمط توزيع البيانات من التوزيع الطبيعي، في ظل النماذج التي تحتوى على معلمتي الموقع والقياس فقط (location - scale)<sup>[1]</sup>.

٣- استعمال طريقة تصحيح الالتواء (Skewness correction (SC)). لإنشاء خارطتي الوسط الحسابي والمدى ، حيث إن هذه الطريقة تعتمد على درجة الالتواء وحجم العينة وقد وجد إن الحدود العليا لخطوط المراقبة تكون أعلى من خارطتي الوسط والمدى أما الحدود الدنيا فتكون أقل منهما وإن الخطأ من النوع الأول لهذه الطريقة أقل من سابقتها<sup>[3]</sup>.

**١-٢ هدف البحث** يهدف هذا البحث إلى مقارنة الشبكات العصبية الاصطناعية بخارطتي المراقبة للوسط الحسابي والمدى في السيطرة النوعية في حالتي التوزيع الطبيعي وعدم التوزيع الطبيعي للبيانات وعند درجات التواء مختلفة وحجم عينه مساوٍ و 10 وذلك باستعمال أسلوب المحاكاة.

### ١-٣ خرائط السيطرة (Control Charts)<sup>[4]</sup>

#### ١-٣-١ خرائط السيطرة على العمليات (Process Control Charts)

إن الفائدة الأساسية للأساليب الإحصائية وخرائط السيطرة النوعية على وجه الخصوص يمكن أن تتلخص في كونها مؤشراً "لبداية خروج العملية عن مسارها الصحيح، الأمر الذي ما أن يحصل حتى يتم البحث عن أسباب هذا الخروج والعمل على معالجته في الحال. وهي عرض بياني لنتائج

سير العملية التصنيعية خلال مدة زمنية معينة تستخدم لضبط سير العملية الإنتاجية، والتأكد مما إذا كانت تحت السيطرة أم أن هناك حالات شاذة خارجة عن نطاق السيطرة يجب معالجتها.

### ١-٣-٢ مخططات السيطرة للمتغيرات

وتستخدم هذه المخططات إذا كانت المواصفات النوعية للمنتج قابلة للقياس الكمي مثل الطول، والوزن، والكثافة، ودرجة الحرارة، ... الخ ومن أهمها :-

١- مخطط السيطرة للوسط الحسابي (Chart -  $\bar{X}$ ) ، يبين التغير الحاصل في قيمة متوسط العملية الإنتاجية، إذ يحدد في هذه المخططات حدي السيطرة الأدنى والأعلى. فإذا كانت العملية الإنتاجية تحت السيطرة فإن الوسط الحسابي يقع بين هذين الحدين باحتمال ٩٩.٧% ، أي أنه في ٠.٣% من الحالات يتخذ القرار الخاطئ بأن العملية الإنتاجية خارج السيطرة في حين أنها في الواقع تحت السيطرة. ويتم تحديد خطوط الرقابة في الخرائط كما يأتي:

أ- الخط الوسط Central Line، يمثل الوسط الحسابي لمتوسطات العينات  $\bar{X}$ .  
ب- الحد الأعلى للرقابة (Upper Control Limit (UCL)، يمثل الحد الأقصى المسموح به للانحرافات، ويستخرج من خلال المعادلة الآتية :-

$$UCL(\bar{X}) = \bar{X} + A_2 \bar{R}$$

حيث أن:

$\bar{X}$ : الوسط الحسابي لمتوسطات العينات.

$A_2$ : قيمة ثابتة.

$\bar{R}$ : الوسط الحسابي للمدى.

ج- الحد الأدنى للرقابة (Lower Control Limit (LCL)، يمثل الحد الأدنى المسموح به للانحرافات، ويستخرج وفقاً للمعادلة الآتية :-

$$LCL(\bar{X}) = \bar{X} - A_2 \bar{R}$$

٢- مخطط السيطرة للمدى (R-Chart)، يوضح درجة انتظام العمليات الإنتاجية ومدى تباين المواصفات فيما بينها. إذ يحسب حدي السيطرة الأعلى والأدنى للمدى بحيث يقسم المدى بأخذ ٩٩.٧% ما بين الحدين. ويكون الاحتمال كما يأتي :-

أ- الخط الوسط (Central Line)، يمثل الوسط الحسابي لمدى العينات  $\bar{R}$ .

ب- الحد الأعلى للرقابة (UCL)، يمثل الحد الأقصى المسموح به للانحرافات، ويستخرج من خلال المعادلة الآتية :

$$UCL(R) = D_4 \bar{R}$$

ج- الحد الأدنى للرقابة (LCL)، يمثل الحد الأدنى المسموح به للانحرافات، ويستخرج وفقاً للمعادلة الآتية :

$$LCL(R) = D_3 \bar{R}$$

وعادة ما تستخدم الخريطتان معاً (خريطة الوسط الحسابي وخريطة المدى) ، فالتماثل في الوسط الحسابي لعينتين لا يعني بالضرورة عدم وجود اختلافات بينهما، حيث أن الاختلافات قد تكون عالية في درجات التشقق مما يستوجب ضرورة التعرف على أسباب ذلك والعمل على التخلص منها. إن  $A_2$  ،  $D_3$  ،  $D_4$  ثوابت وجدولها موجودة في المصدر أعلاه.

١-٤ الشبكات العصبية الاصطناعية (Artificial Neural Networks (ANN)<sup>[5]</sup>

تعد الشبكات العصبية الاصطناعية إحدى مجالات الذكاء الاصطناعي، وهي عبارة عن نظام من البرامج تشبه عمل الدماغ البشري صممت لمعالجة البيانات وتتكون من عدد كبير من المعالجات موزعة على التوازي مما يجعلها ذات قدرة في معالجة البيانات بسرعة عالية، هذه المعالجات هي عناصر حسابية افتراضية تسمى عصبونات (Neurons) حيث تقوم بتخزين البيانات والمعلومات لتجعلها متاحة للمستخدم وذلك عن طريق ضبط الأوزان. كذلك فإن للشبكة القدرة على التعلم مما يجعلها قادرة على استيعاب متغيرات جديدة للمشكلة، إضافة إلى ذلك سهولة بناء نموذج الشبكة بكتابة برنامج والقيام باختبار المعطيات. كذلك؛ وبسبب انفراد كل خلية من خلايا الشبكة العصبية بوحدة ذاكرة خاصة بها تقوم بخزن البيانات، فإن فقدان أحد العناصر لا يسبب فقداناً للبيانات وإنما هو تغير هامشي على فعالية الخلايا.

ويمكن القول أن هيكليّة الشبكة العصبية النموذجية مكونة من ثلاث طبقات هي:-

1- طبقة الإدخال (Input layer)، وهي المستوى الأول في الشبكة وتحتوي على عدد من العقد تمثل عدد المتغيرات المستقلة.

2- الطبقة (الطبقات) المخفية (Hidden Layer(s))، وهي التي تقع بين المستوى الأول (الإدخال) والمستوى الأخير (الإخراج) ويتوقف اختيار عدد المعالجات في هذه الطبقة على التجربة والخطأ وبما يحقق أفضل أداء للشبكة.

3- طبقة الإخراج (Output layer)، وهي المستوى الأخير في الشبكة العصبية الذي يمثل المخرجات.

وتتكون كل من الطبقات الثلاث أعلاه من:-

أ- العقد (Nodes)، وهي تشكل نقاط الترابط العصبي بين طبقات الشبكة حيث تشكل البناء الهيكلي للشبكة العصبية ويقوم كل عنصر بأجراء بعض العمليات الحسابية بطريقة مستقلة عن غيره من عناصر المعالجة إلا أن جميع العناصر تقوم بذلك في وقت واحد. وتساعد كل عقد الانتقال في نقل القيم المختلفة بين هيكل الشبكة حتى يتم التفاعل والتكامل فيما بينهما من أجل التوصل إلى أفضل أداء للشبكة.

ب- المستوى (Level)، وهو يمثل مجموعة العقد التي تتسلم الإدخال والإخراج.

ج- الأوزان (Weights)، وهي تشير إلى مدى قوة الارتباط العصبي بين طبقات الشبكة، فكل عقدة وزن يربطها بالمستوى السابق ووزن يربطها مع المستوى اللاحق.

## ١-٤-١ أنواع الشبكات العصبية

هناك العديد من نماذج الشبكات العصبية يمكن تقسيمها إلى الأنواع الآتية:-

١- حسب تركيب بنية النموذج حيث تكون بالأشكال التالية:-

أ- شبكة مكونة من طبقة واحدة (One layer)، وهي لا تملك طبقة مخفية.

ب- شبكة مكونة من طبقتين (Two Layers)، حيث أن الطبقة الأولى هي طبقة الإدخال والثانية طبقة الإخراج.

ج- شبكة مكونة من عدة طبقات (Multilayer's)، حيث تمتلك طبقة مخفية أو أكثر إضافة إلى طبقة الإدخال وطبقة الإخراج، وهي ذات فاعلية كبيرة إذ تستطيع هذه الشبكات من حل العديد من المشاكل المعقدة ولكن تدريبها يستغرق وقت أطول.

٢- وفقاً لخصائص عناصر المعالجة (processing units)، ويمكن تصنيفها إلى:-

أ- شبكات التغذية الأمامية ( Feed-forward Artificial Neural Networks )، وهي الشبكات التي يخلو تركيبها من وجود حلقة مغلقة من الترابط بين الوحدات المكونة لها ، إضافة الى عدم وجود تقاعل (Interaction) بين دوال الطبقات المخفية وعدم وجود إرجاع خلفي (Backward)، كما أن دوال الطبقات المخفية تقوم بالتغذية نحو الأعلى إلى طبقة الناتج ( المخرجات ) أي أن جميع خطوط الربط باتجاه واحد من طبقة الإدخال حتى طبقة الإخراج.

ب- شبكات التغذية العكسية ( Feed-backward Neural Networks )، وهي الشبكات التي يمكن لمخرجاتها أن تجد طريقا لأن تكون مدخلات مرة أخرى ، أي أن لها خطوطاً عكسية أو قد تكون بشكل دوائر مغلقة .

٣- وفقاً لخصائص عناصر المعالجة (التعلم والتدريب) [7]

يمكن تعريف التعلم بأنه عملية ضبط الأوزان لجعل الخلية تطلق إشارة استجابة لتغير قوة الربط الداخلي وهذا يدعى (تكييف الوزن) ويحدث خلال عملية تدعى (مرحلة التدريب) ومجموعة الإدخال الخارجي تدعى (مجموعة التدريب للشبكة) وأنموذج الإدخال يسمى (متجه التدريب). و يوجد نوعان من الشبكات العصبية بحسب طريقة التعلم هي :-

أ- شبكات التعلم المراقب (بواسطة المعلم) (Supervised Learning Networks)، وهي الأكثر شيوعاً عند استعمال الشبكات العصبية ذات التغذية الأمامية حيث يتم فيها تحديد قيمة المخرجات المطلوبة للأنموذج قبل بداية التشغيل . إن هذا النوع من التدريب يتطلب وجود زوج من قيمة الإدخال وقيمة الإخراج المتوقع والتي تمثل زوج التدريب . إن الفرق بين قيمة الإدخال المطبق مع قيمة الإخراج المتوقع يمثل خطأ التدريب (Training Error).

ب- شبكات التعلم غير المراقب (بدون معلم) (unsupervised learning Network)، في هذا النوع من الشبكات تمتلك الشبكة العصبية إدخالاً فقط ولا نعرف ما هو الإخراج المطلوب أي عدم وجود إخراج مرغوب للشبكة يقارن مع النتائج.

٤- وفقاً لنوع المشكلة المراد حلها ، حيث يوجد العديد من الشبكات منها:-

أ- الشبكات العصبية التنبؤية (Prediction Networks)، وتستخدم للتنبؤ بظاهرة معينة اعتماداً على قيمة معينة لظاهرة أخرى.

ب- الشبكات العصبية التصنيفية (Classification Networks)، ويستخدم هذا النوع في عمليات التصنيف وتحديد المجموعة التي ينتمي إليها عنصر معين.

### ١-٤-٢ كيفية عمل الشبكات العصبية

يقوم العصبون بضرب كل قيمة إدخال واردة من عصبونات الطبقة السابقة  $x_i$  بأوزان العصبونات المرتبطة به  $w_i$  ومن ثم جمع نواتج الضرب  $\sum$  والتي تمثل الدالة التجميعية لكل من المدخلات وأوزانها ونتيجتها هي  $u_i$  ويعبر عن ذلك رياضياً بالآتي:

$$u_i = \sum_{i=1}^n w_i x_i$$


وبعد ذلك يتم إخضاع الناتج لتابع تحويل بحسب نوع العصبون . إن ناتج عملية التحويل يعتبر إخراج للعصبون الذي ينقل إلى عصبونات الطبقة التي تليها.

١-٤-٣ دوال التحفيز ( التنشيط ) (Activation Function)<sup>[9]</sup>

وهي عبارة عن دوال لمعالجة البيانات الداخلة إلى الوحدات أو الخلايا العصبية. وتوجد أنواع عديدة من دوال التحفيز وكل واحدة منها تصلح لنوع معين من التطبيق، ومن أشهرها:-

١- دالة الخطوة (Step function)، وتدعى أيضا " دالة العتبة (Threshold function)، هذه الدالة تجعل القيمة المخرجة من وحدة المعالجة محصورة بين ٠ و ١ كالنظام الثنائي لذا تسمى بتابع التنشيط الثنائي أو تابع الخطوة الثنائي ، وتأخذ الصيغة الآتية:


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



تحدد هذه الدالة من إخراج العصبون ، بحيث يصير الإخراج مساويا للواحد إذا كان الإدخال أكبر أو مساويا للصفر، ويصير الإخراج مساويا للصفر إذا كان الإدخال أصغر من الصفر.

2- الدالة الخطية (Linear function)، توفر دالة التنشيط الخطي مخرجات تساوي المدخلات الموزونة لوحدة المعالجة وعادة تستخدم وحدات المعالجة الدالة الخطية في التقريب ، وتأخذ الشكل الرياضي الآتية :

$$f(x) = x \quad \text{for all } x$$




وتستخدم هذه الدالة في الشبكات وحيدة الطبقة .

3- الدالة سيغمويد (Sigmoid)، هذه الدالة تجعل قيم المخرجات محصورة بين ٠ و ١ ، وهي أكثر الدوال استعمالا في خوارزميات تدريب شبكات الانتشار الخلفي، وتأخذ الصيغة التالية:

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

حيث أن  $\beta$  ميل معلمة الدالة . وعند قيم مختلفة لـ  $\beta$  يمكن الحصول على دوال سيغمويد مختلفة الميل.



#### ١-٤-٥ خوارزميات تعلم الشبكة<sup>[2]</sup>

كما ذكرنا سابقاً فإن الأوزان تمثل البيانات الأولية التي ستتعلم بها الشبكة، لذا لا بد من تحديث هذه الأوزان ، حيث تستخدم عدة خوارزميات أهمها خوارزميات الانتشار العكسي (Algorithm Back Propagation) الذي يتم من خلال مرحلتين هما:

1- مرحلة الانتشار الأمامي (Feed forward Propagation)، وهنا يخصص كل عنصر معالجة من طبقة الإدخال لأحد مكونات الشعاع الذي يمثل متجه الإدخال ، وتسبب قيم مكونات متجه الإدخال استثارة لوحدة طبقة الإدخال ويعقب ذلك انتشار أمامي لتلك الاستثارة عبر بقية طبقات الشبكة. مع العلم أن هذه المرحلة لا يوجد فيها تعديل للأوزان .

2- مرحلة الانتشار العكسي (Back Propagation)، وهي مرحلة تعديل أوزان الشبكة حيث تكون الشبكة متغيرة باستمرار لحين الوصول إلى نقطة التوازن، وتبقى كذلك إلى أن يتغير متجه الإدخال. وعند الحصول على متوسط مربعات الخطأ (MSE) الذي تم حسابه في مرحلة سابقة ، يتم انتشار الخطأ عكسياً طبقة بعد طبقة ابتداءً من طبقة الإخراج باتجاه طبقة الإدخال. وفي هذه المرحلة يتم تعديل الأوزان بإجراء هبوط تدريجي في قيمة الوزن باستعمال معادلة قاعدة السلسلة عند كل طبقة. ويمكن تلخيص خوارزمية مرحلة الانتشار العكسي باستعمال دالة سيغمويد كدالة تنشيط خلال مرحلة التعلم وكما يأتي<sup>[8]</sup>:-

١- توليد قيم أولية للأوزان من إحدى التوزيعات الإحصائية حيث تكون بالشكل الآتي :

أ-  $w_{1ij}$  أوزان بين العقدة  $i$  في طبقة الإدخال إلى العقدة  $j$  في الطبقة المخفية، وهي تأخذ قيم

ابتدائية محصورة بين  $(-0.1, 0.1)$  لجميع قيم  $i = 0, \dots, A$  ، وقيم  $j = 1, \dots, B$  .

ب-  $w_{2ij}$  أوزان بين العقدة  $i$  في الطبقة المخفية إلى العقدة  $j$  في طبقة الإخراج، وهي تأخذ قيم

ابتدائية محصورة بين  $(-0.1, 0.1)$  لجميع قيم  $i = 0, \dots, B$  ، وقيم  $j = 1, \dots, C$  .

2- إن قيم التنشيط (Activation values) للعقد من طبقة الإدخال إلى العقد في الطبقة المخفية يتم حسابها كما في الصيغة الآتية :

$$h_j = \frac{1}{1 + e^{-\sum_{i=0}^A w_{1ij} \cdot x_i}}, \quad j = 1, \dots, B$$

حيث إن  $x_i$  هي قيمة العقدة  $i$  في طبقة الإدخال، و  $x_0$  و  $h_0$  تكونان مساويتين لـ 1.0  
٣- إن قيم التنشيط (Activation values) للعقد من الطبقة المخفية إلى العقد في طبقة الإخراج يتم انتشارها (Propagated) باستعمال الصيغة الآتية :

$$o_j = \frac{1}{1 + e^{-\sum_{i=0}^B w_{ij} \cdot h_i}}, j = 1, \dots, C$$

٤- الأخطاء  $\delta_2$  في عقد الإخراج تحسب بالصيغة الآتية :

$$\delta_{2j} = o_j (1 - o_j) (y_j - o_j), j = 1, \dots, C$$

5- الأخطاء  $\delta_1$  في عقد الطبقة المخفية تحسب بالصيغة الآتية :

$$\delta_{1j} = h_j (1 - h_j) \sum_{i=1}^C \delta_{2w} w_{ij}, j = 1, \dots, B$$

6- تعديل الأوزان بين طبقة الإدخال والطبقة المخفية بالصيغة الآتية:

$$\Delta w_{1ij} = \eta \cdot \delta_{1i} \cdot x_i, i = 0, \dots, A, j = 1, \dots, B$$

حيث أن  $\eta$  تمثل معدل التعلم (Learning rate).

7- تعديل الأوزان بين الطبقة المخفية وطبقة الإخراج بالصيغة الآتية :

$$\Delta w_{2ij} = \eta \cdot \delta_{2j} \cdot h_i, i = 0, \dots, B, j = 1, \dots, C$$

٨- وأخيراً " فعندما تتدرب الشبكة بصورة كافية ( أي الحصول على الأوزان المثلى)، يتم الحصول على أنموذج عام للعلاقة بين المدخلات والمخرجات، وعندها يمكن معرفة تأثير مجموعة متغيرات المدخلات على مجموعة متغيرات المخرجات.

## ٢- الجانب التطبيقي.

### ١-٢ توليد البيانات (Data Generation)

اعتمد البحث على توليد بيانات باستعمال أسلوب المحاكاة (Simulation) بطريقة مونت كارلو (Monte Carlo) حيث تم عمل ما يأتي :-

١- توليد بيانات تتبع التوزيعات الآتية ، الطبيعي (Normal) ، وويل (Weibull) ، وكاما (Gamma)

واللوغاريتمي الطبيعي (Lognormal) وبدرجات التواء مختلفة، تشمل (٠، ٠.٥، ١.٠، ١.٥، ٢.٠، ٢.٥، ٣.٠) وعند حجم عينه مساو لـ ١٠، ٥، ١٠. إن اختيار التوزيعات وويل ، وكاما ، واللوغاريتمي الطبيعي لكونها تمثل درجات مختلفة من حالة التوزيع القريب من التماثل إلى ملتو بدرجة عالية .

٢- إعادة الخطوة (١) ٥٠ مرة أي أن عدد العينات هنا يكون مساوياً لـ ٥٠ عينة .

٣- في ضوء البيانات التي تم توليدها في الخطوة (٢) يتم حساب حدود السيطرة باستعمال المعادلات لخارطة المراقبة للوسط الحسابي ( $\bar{x}$ ) وخارطة المراقبة للمدى (R) . وفيما يخص طريقة الشبكات العصبية الاصطناعية يتم إضافة الإجراءات المذكورة في البند (٢-٣-٢) التي سيأتي ذكرها لاحقاً.

٤- إعادة الخطوة (١) ٥٠٠٠ مرة أي أن عدد العينات هنا يكون مساوياً لـ ٥٠٠٠ عينة.

٥- تحديد عدد العينات التي تقع خارج حدود السيطرة التي تم وصفها في الخطوة (٣) ثم حساب متوسط الخطأ من النوع الأول لكل حاله مذكورة في الخطوة (١) أعلاه.

### ٢-٢ دالة الكثافة الاحتمالية (Probability density function) [4]

١- دالة الكثافة الاحتمالية للتوزيع الطبيعي (Normal) تعطى بالصيغة الآتية :



$$f(x) = \frac{1}{\sigma \sqrt{2\pi}} e^{-\frac{1}{2} \left( \frac{x-\mu}{\sigma} \right)^2} \quad -\infty < x < \infty$$

حيث أن :  $\mu$  متوسط التوزيع وان  $\sigma$  الانحراف المعياري.

٢- دالة الكثافة الاحتمالية لتوزيع ويبيل (Weibull) تعطى بالصيغة الآتية :

$$f(x) = \beta \lambda^\beta x^{\beta-1} \exp(-x \lambda)^\beta \quad 0 < x < \infty$$

حيث أن :  $\beta$  معلمة الموقع و  $\lambda$  معلمة القياس.

٣- دالة الكثافة الاحتمالية لتوزيع كاما (Gamma) تعطى بالصيغة الآتية :

$$f(x) = \frac{1}{\Gamma(\alpha) \beta^\alpha} x^{\alpha-1} \exp\left(-\frac{x}{\beta}\right) \quad 0 < x < \infty$$

حيث أن :  $\alpha$  معلمة الموقع و  $\beta$  معلمة القياس.

٤- دالة الكثافة الاحتمالية للتوزيع اللوغاريتمي الطبيعي (Lognormal) تعطى بالصيغة التالية:

$$f(x) = \frac{1}{x \sigma \sqrt{2\pi}} \exp\left(-\frac{(\ln(x) - \mu)^2}{2\sigma^2}\right) \quad 0 < x < \infty$$

حيث أن :  $\mu$  معلمة الموقع و  $\sigma$  معلمة القياس.

وباستعمال برنامج (Easy 5.5 professional)، تم استخراج الالتواء لكل معلمة من المعالم التي تعتمد عليها التوزيعات الأربعة مع ملاحظة أن التوزيع الطبيعي قد اتخذت درجة التواءه صفراً".  
والجدول (١) يوضح قيم المعالم التي تم الحصول عليها عند درجة الالتواء المطلوبة لكل توزيع .

الجدول (١) درجة الالتواء المقابلة لمعالم التوزيعات الأربعة.

الالتواء	الطبيعي $\sigma$	ويبل $\beta$	كاما $\alpha$	اللوغاريتمي الطبيعي $\sigma$
٠.٠	١.٠٠	٣.٦٠٦٦	٤.٠٠٠	٠.٠٠٠١
٠.٥		٢.٢١٥٦	١٦.٠٠٠	٠.١٦٤١
١.٠		١.٥٦٣٩	٤.٠٠٠	٠.٣١٤٣
١.٥		١.٢١١١	١.٧٧٧٧	٠.٤٤٣٥
٢.٠		١.٠٠٠	١.٠٠٠	٠.٥٥١٤
٢.٥		٠.٨٦٣١	٠.٦٤٠٠	٠.٦٤٠٩
٣.٠		٠.٧٦٨٦	٠.٤٤٤٤	٠.٧١٥٦

## ٣-٢ بناء نموذج الشبكة العصبية

### ١-٣-٢ تعديل البيانات

لغرض تطبيق نموذج الشبكة العصبية لتصنيف العينات وما إذا كانت داخل حدود السيطرة أو خارجها نقوم أولاً "بتعديل قيم المعطيات وذلك بجعلها محصورة بين ٠ و ١ باستعمال الصيغة الآتية [6]:

$$x = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}}$$

حيث إن  $x$  : القيمة المعدلة ،  $x_i$  : القيمة الحقيقية ،  $x_{\min}$  : أصغر قيمة في العينة ،  $x_{\max}$  : أكبر قيمة في العينة.

## ٢-٣-٢ مراحل بناء النموذج

لغرض بناء النموذج فقد تم المرور بثلاث مراحل هي:

- ١- مرحلة الإنشاء ، حيث تم الاعتماد على شبكة تحتوي على ثلاث طبقات موضحة كالآتي:  
أ- طبقة الإدخال، مكونة من ٥ عقد في حالة حجم العينة مساوٍ لـ ٥ ، و ١٠ عقد في حالة حجم العينة مساوٍ لـ ١٠ حيث أن كل عقدة تمثل مشاهدة.  
ب- طبقتان مخفيّتان، واحدة مكونة من ٥ عقد والأخرى من ١٠ عقد إذ أن كل طبقة تكون طبقة إخراج واحدة.  
ج- طبقة الإخراج، مكونة من عقدتين أما أن تمثل العينة ضمن حدود السيطرة أو خارج حدود السيطرة .

٢- مرحلة التعلم، في هذه المرحلة تم إدخال مجموعة من البيانات للتعلم عليها. وقد اعتبر معدل التعلم مساوياً لـ (٠.٠٠١)، إذ أن معدل التعلم الصغير يؤدي إلى سرعة الحصول على الأوزان المثلى وبخطأ أقل كما تم اعتبار حجم الزخم (momentum Term) مساوياً لـ ٠.٦ استناداً لما أعطاه من خطأ أقل .

٣- مرحلة الاختبار، في هذه المرحلة يتم اختبار العينات التي تم توليدها في البند (٢-١) المذكور سابقاً حيث يتم تصنيفها إما إلى أن العينة داخل حدود السيطرة أو أنها خارج حدود السيطرة وبعدها يتم حساب معدلات الخطأ من النوع الأول .


## ٤-٢ النتائج

باستعمال برنامج spss ver. 20 تم الحصول على النتائج الآتية :-  
الجدول (٢) يمثل معدلات الخطأ من النوع الأول لخارطة المراقبة للوسط الحسابي ( $\bar{x}$ ) وخارطة المدى (R) والشبكات العصبية للتوزيع الطبيعي. حيث يلاحظ عدم وجود فروق واضحة في معدلات الخطأ من النوع الأول بين الطرائق المدروسة في حالة التوزيع الطبيعي للبيانات وعند حجم العينة ٥ و ١٠ .

الجدول (٢) معدلات الخطأ من النوع الأول للطرائق المدروسة في حالة التوزيع الطبيعي.

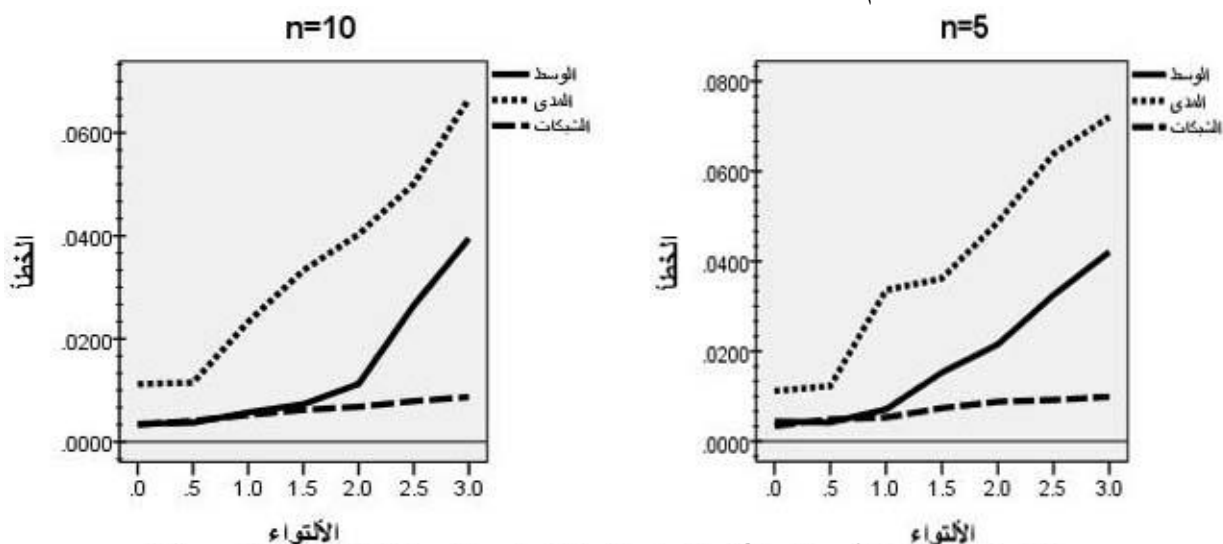
الطريقة			حجم العينة
ANN	R	$\bar{x}$	
0.005	0.006	0.005	n=5
0.004	0.006	0.005	n=10

أما الإشكال (١, ٢, ٣) فهي تمثل معدلات الخطأ من النوع الأول للطرائق الثلاث للتوزيعات ( وويل ، وكاما ، واللوغاريتمي الطبيعي ) وعند حجم عينة  $n=5$  ،  $n=10$  وبدرجات التواء مختلفة .



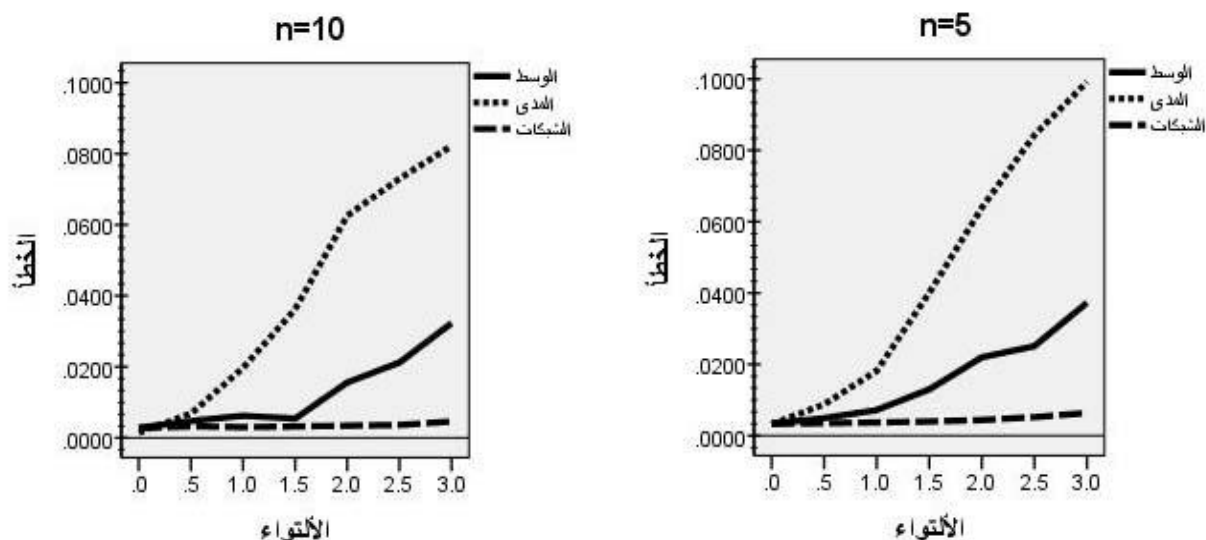
شكل (١) معدلات الخطأ من النوع الأول لخارطي الوسط الحسابي والمدى والشبكات العصبية لتوزيع وبيبل.

يلاحظ من الشكل (١)، عند حجم العينة ٥ إن معدلات الخطأ من النوع الأول لخارطي الوسط الحسابي والمدى متطابقة تقريباً عند مختلف درجات الالتواء وأن الخطأ من النوع الأول لطريقة الشبكات العصبية أقل منهما. وكما يلاحظ أن هناك فرقاً "قليلاً" بين معدلات الخطأ من النوع الأول لخارطة الوسط الحسابي وخارطة المدى عند حجم العينة ١٠. بينما لم نلاحظ أية فروق فيما يخص الشبكات العصبية باختلاف حجم العينة.



شكل (٢) معدلات الخطأ من النوع الأول لخارطي الوسط الحسابي والمدى والشبكات العصبية لتوزيع كاما.

يلاحظ من الشكل (٢)، أن معدلات الخطأ من النوع الأول لخارطة المدى أكبر من الخطأ من النوع الأول لخارطة الوسط الحسابي عند حجم العينة ٥ و ١٠ ودرجات الالتواء المختلفة. أما الخطأ من النوع الأول لطريقة الشبكات العصبية، فهو أقل من الخطأ لخارطتي الوسط الحسابي والمدى وعند مختلف درجات الالتواء.



شكل (٣) معدلات الخطأ من النوع الأول لخارطة الوسط الحسابي وخارطة المدى والشبكات العصبية للتوزيع اللوغاريتمي الطبيعي.

يلاحظ من الشكل (٣)، أن معدلات الخطأ من النوع الأول لخارطة المدى أكبر من الخطأ من النوع الأول لخارطة الوسط الحسابي عند حجم العينة ٥ و ١٠ ودرجات الالتواء المختلفة. وكما يلاحظ أن هناك تأثيراً لزيادة حجم العينة على الخطأ من النوع الأول لخارطة المدى، إذ يلاحظ أن هناك نقصاناً بمقدار الخطأ عند حجم العينة المساوي لـ ١٠ مقارنة بحجم العينة المساوي لـ ٥ وخاصة عند درجات الالتواء الكبيرة. وأما لخارطة الوسط الحسابي فيكون بدرجة أقل. ولا يوجد تأثير لزيادة حجم العينة على الخطأ من النوع الأول باستعمال طريقة الشبكات العصبية، الذي هو في جميع الحالات أقل من الخطأ لخارطتي الوسط الحسابي والمدى.

### ٣- الاستنتاجات والتوصيات

اعتماداً على المناقشات والتحليلات التي أظهرتها نتائج التحليل الإحصائي لخارطة المراقبة للوسط الحسابي والمدى وكذلك لطريقة الشبكات العصبية الاصطناعية، فقد تم الوصول إلى جملة من الاستنتاجات والتوصيات أهمها:-

#### ٣-١ الاستنتاجات

- ١- عندما يكون التوزيع طبيعياً أو قريباً من التماثل فإن الخطأ من النوع الأول لخارطتي المراقبة للوسط الحسابي والمدى وكذلك لطريقة الشبكات العصبية يكون قريباً من بعضه البعض.
- ٢- عندما يكون التوزيع متوسط الالتواء أو ملتوياً التواء كبيراً فإن الخطأ من النوع الأول للشبكات العصبية يكون أقل من الخطأ من النوع الأول لخارطتي المراقبة للوسط الحسابي والمدى.

- ٣- عندما يكون التوزيع ملتوياً التواء "كبيراً" فإن الخطأ من النوع الأول لخارطة المراقبة للمدى يكون اكبر من الخطأ لخارطة المراقبة للوسط الحسابي . وفي هذه الحالة فإن استعمال الخريطين يعطي استنتاجاً خاطئاً بسبب أن الخطأ من النوع الأول يزداد بزيادة درجة الالتواء .
- ٤- إن الخطأ من النوع الأول للشبكات العصبية قد بقي على حاله تقريباً عند مختلف التوزيعات ودرجات الالتواء.
- ٥- هناك فرق قليل بين معدلات الخطأ من النوع الأول يظهر بزيادة حجم العينة لخارطتي الوسط الحسابي والمدى و لجميع التوزيعات المدروسة وعند مختلف درجات الالتواء. أما بالنسبة للشبكات العصبية فلم تلاحظ فروقاً تذكر بزيادة حجم العينة.

### ٢-٣ التوصيات

إن استعمال طريقة الشبكات العصبية الاصطناعية في مجال السيطرة النوعية يعطي نتائج دقيقة لاكتشاف الانحرافات في العمليات الإنتاجية سواء أكانت التوزيعات متماثلة ام غير متماثلة وبدرجات التواء مختلفة ، لذا نوصي باستعمالها في هذا المجال .

### ٤- المصادر

- 1- Box G.E.P., Cox D.R., "An Analysis of Transformations" *Journal of the Royal statistical Society, Series B ( Methodological )*, Vol.26, No.2, pp.211-252,1964.
- 2-Cichoclar A. , Unbehaven R. , *Neural Networks for Optimization and signal processing*, John Wiley & Sons, 1993.
- 3-Lai K. Chan, Heng J. Cui, "Skewness Correction  $\bar{x}$  and R Charts for Skewed Distributions", *Naval Research Logistics*, Vol. 50, No. 6, pp 555–573, 2003.
- 4- Montgomery, D. C., *Introduction to statistical Quality Control*, Six Edition, John Wily & Sons , Inc ,U.S.A., 2009.
- 5-Samarasingha, S., *Neural Networks for Applied Sciences and Engineering*, Tayler & Francis Group, LLC., U.S.A., 2007.
- 6-Shahin ,M.A. , *Use of Artificial Neural Networks for predicting settlement of Shallow Foundations on Cohesion less Soils*, Ph.D. Thesis ,Department of Civil and Environmental Engineering, University of Adelaide,2003.
- 7-Smith, L., *An Introduction to Neural Networks* ,University of Stirling , UK., 2003.
- 8-Stich T.J, Spoerre J.k., Velasco T."The application of artificial neural networks to monitoring and control of an induction hardening process" ,*Journal of Industrial Technology*, Vol. 16,No.1, PP.1-11, 2000.
- 9-Wasserman, P.D., *Neural Computing Theory and Practice*, ANZA Research, Inc. ,New York, 1989.