

مدى فعالية استخدام نماذج الشبكات العصبية الاصطناعية كأحد الأدوات المقترحة لتحسين دقة التنبؤ بتكاليف الإنتاج - دراسة حالة

د/محمد مصطفى جمعة خميس محمد

مدرس المحاسبة والمراجعة بالمعهد المصرى

لأكاديمية الإسكندرية للإدارة والمحاسبة

ملخص البحث

تطورت بيئة الأعمال فى الفترة الأخيرة وأصبحت ديناميكية شديدة التغير، وذلك نتيجة لتعرضها لضغوط المنافسة والتحول المستمر نحو الآلية فى معظم النشاطات والعمليات، لذلك أصبح من المفترض على كافة المنشآت ضرورة مواكبة التطورات المتلاحقة فى التكنولوجيا الجديدة حتى تظل قادرة على تحسين الأداء والنمو والمنافسة. وتُعد تكنولوجيا المعلومات من أهم الأدوات الضرورية التى تساعد المنشأة على سرعة الإستجابة والتكيف بكفاءة وفعالية مع هذه التغيرات.

وقد حدث تطور فى المحاسبة الإدارية بما إنها تتأثر بالتغيرات البيئية المستمرة، الأمر الذى أدى إلى تغيير وتطوير أساليبها لتوفير المعلومات المناسبة لإتخاذ القرارات المناسبة وفى الوقت المناسب. الأمر الذى أدى إلى حدوث تغيير فى المهارات التى يمتلكها المحاسب الإداري، بحيث يتمكن من القيام بالمهام والوظائف المطلوبة منه وتنفيذ الممارسات والأساليب الجديدة. وتتمثل المشكلة الأساسية فى عدم الترابط أو قلة استخدام الشبكات العصبية الاصطناعية Artificial Neural Networks (ANN) كأحد التقنيات الحديثة فى مجال الذكاء الاصطناعى التى تعتمد على مقاييس رياضية وإحصائية، ولما لها من قدرة هائلة على التنبؤ والتصنيف بناءً على محاكاة مخ الانسان باستخدام نماذج مقبولة.

وتلعب الشبكات العصبية الاصطناعية (ANN) أحد أهم أدوات الذكاء الاصطناعى دوراً هاماً فى مساعدة المنشآت فى تحقيق أهدافها، ومواجهة التحديات التى تُفرض عليها. لذلك يحاول البحث ضرورة التعرف على أهمية استخدام الشبكات العصبية الاصطناعية (ANN) فى تحسين وتطوير عملية التنبؤ بالتكاليف، وتوصل البحث إلى أنه لى يتم التنبؤ بتكاليف الإنتاج بشكل صحيح فإن ذلك يساعد فى تطوير المحاسبة الإدارية من خلال المساعدة فى تطبيق العديد من الأساليب

الحديثة للمحاسبة الإدارية ومنها إمكانية تطبيق أسلوب التكلفة المستهدفة، والتحديد الدقيق لمسببات التكلفة وبالتالي التطبيق الصحيح لنظام التكلفة على أساس النشاط Activity Based Costing (ABC)، كما يسهل من تحليل سلسلة القيمة، ويمكن أيضاً الإستفادة من تقدير التكاليف فى التخطيط الإستراتيجى للمنتج خاصة فى مرحلة التصميم، كما يساعد تقدير التكاليف على تعزيز الموقف التنافسى للمنشأة وزيادة قدرتها على تطوير منتجات جديدة.

الكلمات المفتاحية: الشبكات العصبية الاصطناعية - المحاسبة الإدارية - التنبؤ بالتكاليف - التكلفة على أساس النشاط.

"The Effectiveness of Using Artificial Neural Networks Models as one of the proposed Tools to Improve the Accuracy of Production Cost Forecasting–Case Study"

Abstract

The Business Environment has evolved in the recent period and has become a highly variable dynamic, as a result of exposure to competitive pressures and ongoing shift toward Automated in most of the Activities and processes, so it became supposed to all facilities need to keep pace with the rapid developments in new Technology in order to remain able to improve the performance and growth and competition. The Information Technology of the most essential tools that help facility to respond and adapt efficiently and effectively to these changes speed.

Evolution in Managerial Accounting has happened since they are affected by the ongoing environmental changes, which led to the change and the development of methods to provide the appropriate information to make appropriate decisions and timely. Which led to a change in the skills possessed by the Managerial Accountant, so that it can carry out the tasks and functions required of it and implement new practices and methods. The basic problem in the lack of coherence or lack of use of Artificial Neural Networks(ANN) as one of modern technologies in the field of aArtificial Intelligence in the development of Managerial Accounting methods and increase their effectiveness in the costing Prediction.

Artificial Neural Networks (ANN) one of the most important Artificial Intelligence tools and play an important role in helping enterprises to achieve their goals and meet the challenges imposed on it. So Research aimed at the need to recognize the importance of the use of Artificial Neural Networks (ANN) in the improvement and development of Managerial Accounting in the Cost Prediction. And Research find that costing properly assist in the

development of Managerial Accounting by assisting in the application of many of the modern methods of Managerial Accounting, including the possibility of applying the style of the target cost, and accurate identification of the causes of cost and thus the correct application of the system of activity based costing (ABC), and facilitate the value chain analysis, and can also take advantage of costing a private in the strategic planning of the product in the design phase, and also help estimate the costs to strengthen the competitive position of the business and increase its ability to develop new products.

Keywords: Artificial Neural Networks- Managerial Accounting- Activity Based Costing-Cost Prediction.

1- مقدمة البحث

يعتمد نجاح المنشآت وقدرتها على البقاء والإستمرار إلى حد كبير على مدى وسرعة استجابتها للتكيف مع المتغيرات الهائلة التي حدثت في بيئة الأعمال المعاصرة وخصوصاً التطورات المتلاحقة في تكنولوجيا المعلومات، ومن جانب آخر تُعد تكنولوجيا المعلومات من أهم الأدوات الضرورية التي تساعد المنشأة على سرعة الاستجابة والتكيف بكفاءة وفعالية مع هذه التغيرات، وبذلك أصبحت بيئة الأعمال في الآونة الأخيرة بيئة ديناميكية شديدة التغير. فقد فرضت التطورات في بيئة التصنيع الحديثة، والتحول المستمر نحو زيادة الإعتماد على الآلية في معظم الأنشطة والعمليات على إدارة كافة المنشآت ضرورة مواكبة التطورات المتلاحقة في التكنولوجيا الجديدة حتى تظل قادرة على تحسين الأداء والنمو والمنافسة (AL-Mashari, 2001).

ومما لا شك فيه فإن تلك التغيرات السابق الإشارة إليها والتي واجهت المنشآت سواء في الظروف الداخلية أو الخارجية أوجدت الحاجة إلى ضرورة إحداث تغيرات جوهرية في أنظمة المحاسبة الإدارية حتى تستجيب لمثل هذه التغيرات، وحتى يتطور دور المحاسب الإداري كشريك في تحديد إستراتيجية المنشأة بحيث يعمل على تدعيم أنشطة وعمليات المنشأة. لذلك أصبح هناك اهتمام متزايد بتطوير وظيفة المحاسبة الإدارية ومن ثم الدور الذي يقوم به المحاسب الإداري في السنوات الأخيرة، وإذا لم تتطور المحاسبة الإدارية بالشكل المطلوب سوف تفقد ملاءمتها للمديرين ومستخدمي المعلومات الآخرين (Wanderley & Cullen, 2012).

لذلك فإن هناك مدخل حديث قد يكون أكثر دقة وفعالية للتنبؤ بصفة عامة، حيث تتم محاكاة ونقل أساليب الذكاء البشري في شكل برامج ونظم تجعل الحاسب قادراً على اقتحام مجالات تتسم بالذكاء عند محاولة الحصول على حلول لها، وبالتالي تم تعريف هذه البرامج والنظم على أنها برامج ونظم الذكاء المنقولة إلى الحاسب أو نظم الذكاء الاصطناعي. وتعتبر الشبكات العصبية الاصطناعية (ANN) أحد فروع علم الذكاء الاصطناعي، ذلك الفرع من علوم الحاسب الآلي الذي يمكن بواسطته تصميم برامج للحاسبات التي تحاكي أسلوب الذكاء الأنساني لكي يتمكن الحاسب من أداء بعض المهام بدلاً من الأنسان والتي تتطلب التفكير والفهم والسمع والتكلم والحركة (الشرقاوى، 1996). وتعتبر الشبكات العصبية الاصطناعية (ANN) نموذج/ إطار يمثل العلاقة بين المتغيرات بشكل مختلف عن الطرق التقليدية، فهي نظام حسابي يتكون من مجموعة من العناصر البسيطة والمرتبطة مع بعضها البعض لتشغيل البيانات على نحو ديناميكي كاستجابة لمدخلات

خارجية، لذا تعتبر الشبكات العصبية الاصطناعية (ANN) نظام معالجة للمعلومات له مميزات أداء معينة بأسلوب يحاكي الشبكات العصبية البشرية (السيد، 2012).

2- مشكلة البحث

لقد حدث تطور في المحاسبة الإدارية بما إنها تتأثر بالتغيرات البيئية المستمرة، الأمر الذي أدى إلى تغيير وتطوير أساليبها لتوفير المعلومات المناسبة لإتخاذ القرارات المناسبة وفي الوقت المناسب . وقد شمل العديد من المجالات مثل التخطيط، تقييم الأداء، إتخاذ القرارات، إدارة التكلفة، إدارة الجودة، إدارة الطاقة، القياس المتوازن للإداء، تحليل سلسلة القيمة. الأمر الذي أدى إلى حدوث تغيير في المهارات التي يمتلكها المحاسب الإداري، بحيث يتمكن من القيام بالمهام والوظائف المطلوبة منه وتنفيذ الممارسات والأساليب الجديدة. إلا أن المشكلة الأساسية للبحث تتمثل في عدم الترابط أو قلة استخدام الأساليب الرياضية المبنية على أساس نماذج الشبكات العصبية الاصطناعية (ANN) كأحد التقنيات الحديثة في مجال الذكاء الاصطناعي في تطوير أساليب وأدوات المحاسبة الإدارية وزيادة فعاليتها في عملية التنبؤ بتكاليف الإنتاج.

3- هدف البحث

يتمثل الهدف الرئيسي للبحث في محاولة التعرف على مدى فعالية استخدام نماذج الشبكات العصبية الاصطناعية (ANN) كأحد الأدوات المقترحة لتحسين دقة التنبؤ بتكاليف الإنتاج، وذلك من خلال دراسة الشبكات العصبية الاصطناعية (ANN) من حيث المفهوم، الأنواع، الخصائص، ومجالات تطبيقها في المحاسبة من أجل تحسين عملية تقدير التكلفة، وتحديد المتغيرات التي تؤثر على التكاليف ويتم استخدامها في بناء الشبكة.

4- أهمية البحث ودوافعه

تنبع أهمية البحث العلمية والعملية من الاعتبارات التالية:

- حاجة المستويات الإدارية المختلفة في المنشآت إلى توافر معلومات دقيقة تساعد في إتخاذ القرارات الإستراتيجية المؤثرة على بقاء المنشأة في السوق، حيث أن عملية تقدير التكلفة والتنبؤ بها تعتبر أداة فعالة للمنشآت لمساعدتها في تحقيق أهدافها، ومواجهة التحديات التي تفرض عليها، وبما يمكنها من النمو والاستمرار وتعزيز قدرتها التنافسية.

- القاء الضوء على مدى فعالية استخدام الشبكات العصبية الاصطناعية (ANN) كأحد النماذج الحديثة التي تستخدم الذكاء الاصطناعي، والتي تناولتها العديد من الدراسات العربية والأجنبية في الآونة الأخيرة في تحسين عملية التنبؤ في جميع المجالات بصفة عامة، ومن خلال تطبيق الشبكات العصبية الاصطناعية (ANN) في العديد من التطبيقات المحاسبية بصفة خاصة لما لها من مزايا في التعامل مع عدد كبير من المعالجات بأسلوب المعالجة المتوازية الأمر الذي ينتج عنه مخرجات أكثر دقة.

5- حدود البحث

- لن يتطرق البحث إلى تطبيق الشبكات العصبية الاصطناعية (ANN) في المنشآت والأنشطة الخدمية.
- يقتصر مجال البحث على التركيز بصفة أساسية على دراسة أحدث أدوات الذكاء الاصطناعي من خلال استخدام الشبكات العصبية الاصطناعية التنبؤية دون غيرها من أنواع الشبكات الأخرى.

6- خطة البحث

في ضوء مشكلة الدراسة الحالية وتحقيقاً لأهدافها، سوف يتناول البحث المحاور التالية:

- التأصيل النظري لمفهوم الشبكات العصبية الاصطناعية (ANN)، ومكوناتها، وأنواعها، وكيفية المعالجة داخل الشبكات العصبية.
- تحليل وتقييم الدراسات السابقة الخاصة باستخدام الشبكات العصبية الاصطناعية (ANN)، ووضع تساؤل البحث.
- الإطار العام لدراسة الحالة والإجابة على تساؤل البحث.
- الخلاصة والنتائج والتوصيات.

6-1- التأصيل النظري للشبكات العصبية الاصطناعية (ANN)

سيتناول هذا القسم الأساس النظري لماهية الشبكات العصبية الاصطناعية (ANN)، ومكوناتها، وكيفية المعالجة داخل الشبكة العصبية، والتعرف على بعض أنواع الشبكات العصبية.

6-1-1 مفهوم الشبكات العصبية

هناك العديد من المفاهيم الأساسية للشبكات العصبية، ولعل من أهمها الشبكة العصبية البيولوجية، فوفقاً لدراسة (Gerstner & Kistler, 2002) فإن الشبكة العصبية البيولوجية تستمد

من المخ البشرى الذى يحتوى على ما يقرب من عشرة بلايين خلية عصبية أو خلية عصبية واحدة (Neuron)، وتتصل كل خلية عصبية واحدة بالخلايا العصبية الأخرى من خلال عشرة الاف مشبك (Synapse)، وتعمل هذه الخلايا العصبية على تكوين شبكة كنظام معالجة معلومات متوازية هائلة.

أما بالنسبة للشبكات العصبية الاصطناعية (ANN) فهناك العديد من التعريفات التى تناولتها. فقد عرفها (جرجس، 2012- ص304) على أنها " نظام معالجة للمعلومات يستخدم أسلوب مبنى على محاكاة الشبكات العصبية الحيوية، حيث تتم معالجة المعلومات بطريقة الخلية العصبية الواحدة (Neuron)، وبعد ذلك يكون هناك ربط لنقل الاشارات بين تلك الخلايا العصبية وكل خط من هذه الخطوط يحمل أوزاناً معينة، وتلك هى التى تبين أثر العلاقات للمتغيرات التى يشكلها الترابط بين تلك الخلايا العصبية".

كما عرفها (مبارز، 1996- ص159) بأنها " نوع من الحاسبات الآلية غير التقليدية والتى تقوم بمحاولة تقليد مهارات العمل البشرى في اكتساب وتنظيم المعلومات والمفاهيم، وهى تتكون من مصفوفة من المعالجات البسيطة أو الخلايا مع وجود علاقات أو ارتباطات، وبالتالي فهى تعتبر بمثابة مجموعة كبيرة من الحاسبات الآلية المتوازنة".

وعرفها (أرسانيوس، 2006- ص701) بأنها "عبارة عن تطور فى الذكاء الاصطناعى فهى عبارة عن نظام حسابى يتكون من مجموعة من العناصر البسيطة والمرتبطة مع بعضها لتشغيل البيانات على نحو ديناميكى كاستجابة لمدخلات خارجية، وتمثل هذه الشبكات نظام لتشغيل المعلومات بخصائص أداء معينة تشبه الشبكات العصبية الطبيعية وذلك وفقاً لمجموعة من الافتراضات".

كما عرف (السجاعي، 2012- ص19) الشبكات العصبية الاصطناعية (ANN) بأنها " تكنولوجيا لتشغيل المعلومات التى تعتمد على الحاسب الآلى مستوحاة من دراسة العقل البشرى، وهى تتكون من عدد كبير من الخلايا العصبية الاصطناعية أو عناصر التشغيل والتى تتصل ببعضها البعض حيث يتم تنظيمها فى شكل طبقات هى طبقة المدخلات، وطبقة المخرجات، وتوجد بينهما طبقة وسيطة أو أكثر من عناصر التشغيل".

ويستخلص الباحث مما سبق أن الشبكات العصبية الاصطناعية (ANN) هي تكنولوجيا متطورة لتشغيل المعلومات التي تعتمد على الحاسب الآلى الذى من خلاله يتم تصميم برامج تحاكي مخ الانسان، حيث تقوم بتخزين المعرفة العملية من خلال التدريب والتعلم للوصول إلى إيجاد حلول مثلى للمشاكل المعقدة.

6-1-2 مكونات الشبكات العصبية الاصطناعية (ANN)

وفقاً لدراسة (Rajasekaran & Pai, 2003) فإن من المفاهيم الأساسية المتعلقة بتقنية مكونات الشبكات العصبية الاصطناعية (ANN) ما يلى:

6-1-2-1 الطبقات (Layers)

وهى تمثل العدد الكلى لطبقات الشبكة العصبية وتتمثل فى ثلاث طبقات هم طبقة المدخلات (input layer)، وطبقة المخرجات (output layer)، والطبقة الخفية (hidden layer)، حيث يتم توصيل هذه الطبقات ببعضها البعض ويتم بعد ذلك نقل المعلومات من خلال وحدات التشغيل والتي يطلق عليها العقد (Nodes) والتي يتم استخدامها لتوزيع الأوزان.

وتتمثل المعالجة داخل الشبكة العصبية من خلال ثلاث أنواع من الطبقات:

- طبقة المدخلات (Input Layer): وهى الطبقة التى تمثل المتغير أو المتغيرات المستقلة للمشكلة، فهى تعمل على استقبال البيانات ثم تقوم بتوزيعها، وهذه البيانات عبارة عن المؤثرات على المشكلة المراد حلها، حيث أن كل مدخل يكون له صفة مميزة يدخل بها الشبكة.
- طبقة المخرجات (Output layer): وتتمثل هذه الطبقة فى المتغير التابع، وتتكون من الخلايا العصبية الاصطناعية التى تمثل الناتج النهائي للمشكلة والمسئولة عن استقبال المخرجات الفعلية المطلوب تغذيتها للشبكة العصبية، كما أنها تعتبر الحل النهائي للمشكلة.
- الطبقة الخفية أو الوسيطة (Hidden " Middle" Layer): وهى الطبقة التى تقع بين طبقة المدخلات وطبقة المخرجات وتقوم عناصرها بإجراء عملية التجميع المرجح مع الأخذ فى الإعتبار القيم الحدية للإشارة من خلال الاعتماد على واستخدام دالة الانتقال.

6-1-2-2 الاوزان (Weights)

يعتبر الوزن هو العنصر الرئيسي في الشبكات العصبية الاصطناعية (ANN) بحيث يُعبر عن الأهمية النسبية للبيانات التي تم ادخالها أو الروابط المختلفة التي تنقل البيانات من طبقة الي طبقة أخرى، بمعنى أنه يعبر عن الأهمية النسبية لكل عنصر من المدخلات بالنسبة لوحدة المعالجة.

6-1-2-3 الدالة العصبية (جسم الخلية)

- دالة التجميع (Summation Function)

وهي دالة تقوم بحساب متوسط الوزن لكل من المدخلات إلى عنصر المعالجة وذلك من خلال ضرب كل نتيجة في وزنها ليتم في النهاية الحصول على المجموع .

- دالة الانتقال أو التحويل (Transfer Function Activation)

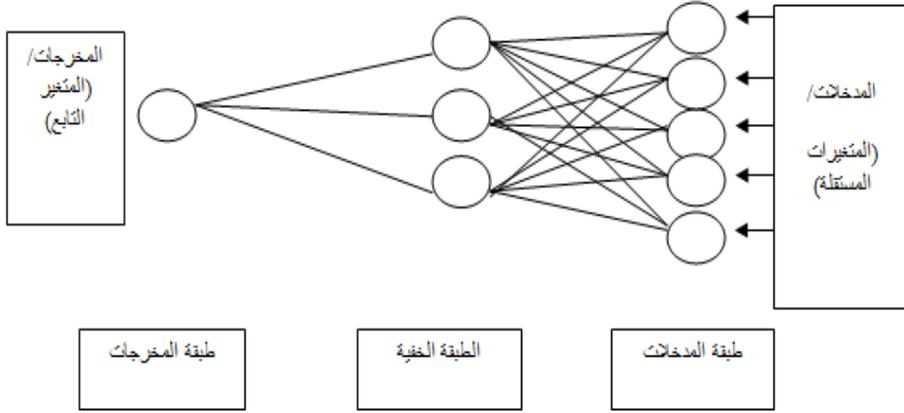
وهي الدالة التي تقوم بتحويل البيانات من طبقة إلى أخرى، فهي تقوم بتحديد قيمة المخرجات من خلال تجميع أوزان المدخلات في الخلية، وعادةً ما تكون العلاقة في الطبقات الخفية غير خطية، كما أن هناك أنواع عديدة من دوال الانتقال وكل نوع من هذه الأنواع يتحكم في عمل الشبكة.

6-1-3 أنواع الشبكات العصبية الاصطناعية (ANN)

توجد أنواع عديدة من نماذج الشبكات العصبية الاصطناعية وفيما يلي أهمها:

6-1-3-1 الشبكات العصبية متعددة الطبقات (Multilayer Networks)

وفقاً لدراسة (Detienne et al., 2003) هي تلك الشبكة التي تتكون من عدة طبقات تكون على شكل تسلسل منتظم حيث تبدأ بطبقة المدخلات وهي تلك الطبقة التي تقوم باستقبال البيانات وتوزيعها على باقى الطبقات وذلك عن طريق الخلايا العصبية المترابطة مع بعضها البعض، والطبقة الأخرى تتمثل فى طبقة المخرجات وهي التي ترتبط بعدد المتغيرات التابعة، وأخيراً بين هذه الطبقات توجد الطبقة الخفية وهي التي تعمل على اكتشاف العلاقات بين المتغيرات وهذا ما يوضحه الشكل رقم (1) التالى:

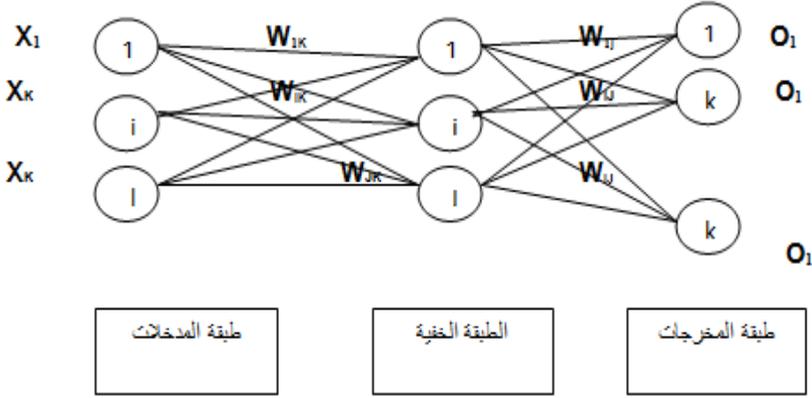


شكل (1): الشبكات العصبية متعددة الطبقات
المصدر: (Detienne et al., 2003)

ويوجد نوعين للشبكات العصبية متعددة الطبقات وهما:

1- الشبكات العصبية متعددة الطبقات أمامية التغذية (Layered Feed-Forward Networks)

وفقاً لما يرى (الجراح، 2011) هي الشبكات التي تتكون من ثلاث طبقات، طبقة المدخلات، الطبقة الخفية (Hidden Layer) (وقد يكون هناك أكثر من طبقة خفية)، وطبقة المخرجات، وتتكون كل طبقة من عدد من الوحدات التشغيلية (processing Elements) يطلق عليها الخلايا العصبية والتي تتصل بكل من الطبقات السابقة واللاحقة بنقاط اتصال يتم تمثيلها من خلال الأسهم والتي تربط بين الخلية عصبية إلى الأخرى، ولا يتم تغذية هذا النوع من الشبكات إلا من خلال المدخلات فقط وإلى الأمام حتى المخرجات وهذا ما يوضحه الشكل رقم (2) التالي.



شكل (٢): الهيكل النموذجي للشبكة العصبية للتغذية الأمامية

المصدر : (الجراح، ٢٠١١- ص١٧٨)

2- الشبكات العصبية عكسية التغذية (Back-propagation Neural Networks)

وفقاً لدراسة (جاب الله ، 2004) تتكون هذه الشبكات أيضاً من ثلاث طبقات هي طبقة للمدخلات، والطبقة الوسيطة (الخفية)، وطبقة للمخرجات ويتصل كل عنصر تشغيل في طبقة المدخلات بعناصر التشغيل في الطبقة الخفية، كما يتصل كل عنصر تشغيل في الطبقة الخفية بكل عناصر التشغيل في طبقة المخرجات، ويتحدد عدد عناصر التشغيل في الطبقة الخفية وفقاً لأسلوب التجربة والخطأ، كما أضافت دراسة (سيد، 2010) أن هذا النوع من الشبكات هو الأكثر انتشاراً خاصة في مجال المحاسبة والتمويل، حيث تقوم الطبقة المستترة بتعديل الأوزان داخل الشبكة ويتم تعليم الشبكة عن طريق التغذية المرتدة بمعنى أنه يتم تعليمها على مرحلتين وهما الانتقال للأمام لتقدير الخطأ ثم الرجوع للخلف لتعديل الأوزان وبالتالي تصحيح الخطأ. وهو ما أكدته أيضاً دراسة (السجاعي، 2012) بأن هذا النوع من الشبكات يستخدم قاعدة (الخطأ - التصحيح) لتعديل الأوزان الخاصة بالروابط أو المشابك بين الخلايا العصبية وبعضها البعض.

6-2 تحليل وتقييم الدراسات السابقة الخاصة بالشبكات العصبية الاصطناعية (ANN)

ووضع تساؤل البحث

قام الباحث من خلال استقراء الدراسات السابقة المرتبطة باستخدام الشبكات العصبية الاصطناعية (ANN) بتقسيم وتصنيف الدراسات السابقة إلى أربعة مجموعات كالتالى:

6-2-1 المجموعة الأولى: الدراسات التى أثبتت تفوق الشبكات العصبية على الانحدار

فى تقدير التكاليف

تقدير التكاليف هى عملية جوهرية تتم من خلال عملية حسابية فى محاولة للتنبؤ بالتكلفة النهائية للمشروع فى المستقبل. وبشكل عام، تختلف طرق تقدير التكاليف إلى حد كبير وفقاً للمعلومات المتاحة، وطبيعة المشروع، والوقت المتاح لإعداد التقدير. وقد تناولت العديد من الدراسات طرق عديدة لتقدير التكاليف، حيث استهدفت دراسة (Garza & Rouhana , 1995) تقدير تكلفة الأنابيب المعدنية وذلك من خلال المقارنة بين ثلاثة أنواع من النماذج المستخدمة فى تقدير التكاليف وهم نموذج الشبكات العصبية، ونموذج تحليل الانحدار الخطى، ونموذج تحليل الانحدار غير الخطى. وتوصلت الدراسة إلى أن الشبكات العصبية هى الأفضل بالمقارنة بنموذجي تحليل الانحدار الخطى وغير الخطى لما نتج عنها أقل متوسط لمربع الخطأ بالمقارنة بالنموذجين الآخرين. كما توصلت دراسات { Weckman et al., 2010 ; Kim et al., 2004 ; Shtub & Versano, 1999; Cavalieri et al., 2004; } إلى نفس النتيجة فى أن استخدام الشبكات العصبية الاصطناعية (ANN) تتفوق على غيرها من الطرق الأخرى مثل تحليل الانحدار الخطى أو غير الخطى فيما يخص عملية تقدير التكاليف، وذلك من حيث الدقة فى نتائج التقدير، وفيما يتعلق أيضاً بالاستخدام طويل الأجل، والمعلومات المتاحة من النتيجة، ومقارنات الوقت مقابل الدقة. كما أوضحت نتائج هذه الدراسات أن تقدير الخطأ بالنسبة لتحليل الانحدار يكون أعلى من تقدير الخطأ بالنسبة للشبكات العصبية وهو ما يدل على أفضلية استخدامها وتطبيقها فى تحسين عملية التنبؤ والتقدير. لذا يتفق الباحث مع نتائج هذه الدراسات على قدرة الشبكات العصبية فى تقدير التكاليف بصورة أكثر دقة، وذلك من خلال تطوير عملية تقدير التكاليف من خلال علاقات التكاليف، بما لها من مزايا عديدة فى التعامل مع البيانات غير المتجانسة أو البيانات المعقدة، الأمر الذى يؤكد مدى فعالية ودقة الشبكات العصبية الاصطناعية (ANN) فى مختلف الصناعات بما يعطى نتائج للتنبؤ بالتكاليف أكثر دقة من أساليب الانحدار من خلال الحصول على أقل تقدير

للخطأ، علماً بأن معظم الدراسات أكدت على أن تقدير الخطأ بالنسبة للشبكات العصبية يتراوح بين 5% - 10% مما يدل على كفاءة الشبكات العصبية في تقدير التكاليف.

6-2-2 المجموعة الثانية: الدراسات التي أثبتت تميز الشبكات العصبية في التنبؤ في المراحل الأولى من تصميم المنتج

يرى الباحث وفقاً لدراسات (Weckman et al., 2010 ; Ozcan & Figlah , 2014 ; Duran et al., 2008; Zhang & Fuh, 1998 ; Shtub & Versano, 1999} اتفاقاً على أن الشبكات العصبية الاصطناعية (ANN) تعتبر من النماذج الناجحة جداً بالنسبة لتقدير التكاليف في المراحل الأولى من عملية تصميم وتطوير المنتج، فتللك النماذج لا تقوم بعملية تقدير التكاليف بناء على المدخلات الناتجة عن التقدير الشخصي، كما أشارت إلى أنه يمكن لنموذج الشبكات العصبية الاصطناعية (ANN) أن يساعد المصممين على اتخاذ القرارات في المراحل الأولى من عملية التصميم من خلال مساعدة متخذى القرار في الحصول على نتائج دقيقة للتنبؤ حتى ولو لم تكن المعلومات كافية في المراحل المبكرة من عملية التصميم، وبررت ذلك بأن المعرفة المتوقعة من العلاقات السببية بين حلول التصميم وتكاليف الإنتاج تعتبر مفيدة للغاية سواء بالنسبة لأنشطة الصناعات التحويلية الداخلية أو الأجزاء المشتراه، وأن الشبكات العصبية الاصطناعية (ANN) هي القادرة على الحد من أوجه عدم اليقين المتصلة بتقدير التكاليف خلال المراحل الأولى من عملية التصميم. لذا يتفق الباحث مع نتائج هذه الدراسات ويؤكد على أن هناك تحسن كبير في تقدير التكاليف مما يعزى قدرة تعامل الشبكات العصبية مع البيانات المعقدة في ظل وجود العديد من المدخلات وعدد قليل من البيانات، كما يُمكن استخدام الشبكات العصبية كنقطة انطلاق لخلق علاقات تقدير التكلفة في الحالات التي يكون فيها المشروع في مرحلة الإبتكار والتصميم.

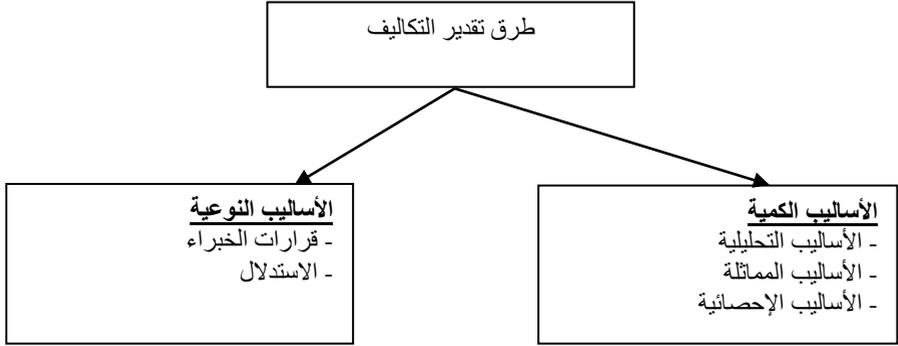
6-2-3 المجموعة الثالثة: الدراسات التي أوضحت أن تطبيق الشبكات العصبية يزيد من فاعلية تطبيق نظام التكلفة على أساس النشاط (ABC)

اتفقت دراسات هذه المجموعة (Amdee et al., 2016; Urkmez et al., 2008; Kim & Han 2003) على أن هناك دور لتقنيات الذكاء الاصطناعي في تحديد التكلفة بشكل دقيق، فالخوارزميات الوراثية تُستخدم لتحديد مسببات التكاليف المثلى أو الشبه مثالية، والشبكات العصبية تعمل على توزيع التكاليف غير المباشرة مع السلوك الغير خطى للمنتجات. كما أوضحت أنه يُمكن

الجمع بين تكاليف النشاط المباشرة وغير المباشرة قبل البدء في التصنيع وذلك عن طريق تجميع البيانات التاريخية، وبالتالي فيكون هناك فهم أفضل لتكاليف النشاط لإتخاذ القرارات المناسبة في عمليات التصميم والتصنيع. فقد أشارت دراسة (Kim & Han 2003) إلى تطوير قياس التكلفة علي أساس النشاط (ABC) باستخدام أسلوب تعلم الآلة بغرض تحديد التكلفة بشكل دقيق، حيث أن استخدام نظام (ABC) لديه مشكلتين أساسيتين، تتمثل المشكلة الأولى في أنه ليس لديه معايير عامة لتحديد عوامل التكلفة ذات الصلة، وتتمثل المشكلة الثانية في أن نظام (ABC) يفترض الخطية بين استخدام الأنشطة والكمية المخصصة للتكلفة غير المباشرة، فعندما يظهر سلوك التكلفة بنمط أو سلوك غير خطي فقد ينتج عن استخدام نظام (ABC) تشويه تكلفة المنتج. ولتحقيق هدف الدراسة تم وضع منهج مهجن للجينات مع الشبكات العصبية. واستخدمت الدراسة المنهج المهجن للجينات لتحديد التوليفة المثلى لمسببات التكلفة والتي تعظم وفورات التكلفة، كما تستخدم الشبكات العصبية لتخصيص التكاليف غير المباشرة ذات السلوك غير الخطي على المنتجات. وقد توصلت وأثبتت نتائج الدراسة التطبيقية أن النتائج التي تم التوصل إليها عند تطبيق المنهج المهجن أفضل مقارنة بتطبيق كل أسلوب على حدة. واتفقت مع هذه النتيجة دراسات كل من (عبد الرحمن، 2011 : مصطفى، 2017) من خلال الإشارة إلى المنافع التي يمكن أن تجنيها المنشآت نتيجة دمج نماذج الشبكات العصبية مع الإطار الجيني، أو إدخال المتغيرات الخاصة بالدراسة في الجينات الوراثية. حيث وجد الباحث أن كلا الدراستين توصلتا إلى أن قيمة معامل التحديد للإطار المختلط أعلى من قيمة معامل التحديد لكل من الشبكات العصبية وتحليل الانحدار، وهذا يعني أن نموذج الإطار المختلط يقوم بصورة أكثر دقة في عملية التنبؤ، وهو ما أكدت عليه دراسة (عبد الرحمن، 2011) من خلال تحقيق نموذج الشبكات العصبية معدلات أعلى في الأداء من خلال مقارنة معدلات الدقة قبل وبعد تطبيق الجينات الوراثية، حيث وصلت نسبة معدل الدقة إلى (86%) مقارنة بنسبة (83%) قبل التطبيق، وعليه يمكن القول أن تطبيق الجينات الوراثية ودمجها مع الشبكات العصبية أدى إلى تحديد أهم متغيرات الدراسة مع ارتفاع دقة النموذج ومعدلات القياس المختلفة مما يؤكد على أن دمج وسائل الذكاء الاصطناعي يؤدي إلى ارتفاع كفاءة النموذج مقارنة باستخدام الأداة منفردة. ويخلص الباحث إلى أنه يمكن تطبيق الشبكات العصبية الاصطناعية مع نظام التكلفة على أساس النشاط (ABC) لاختيار مسببات التكلفة وذلك لتحديد العلاقة بين تكلفة الأنشطة ومعلومات التكلفة غير المباشرة لهذه الأنشطة.

6-2-4 المجموعة الرابعة: الدراسات التي أثبتت تميز الشبكات العصبية فى تقدير التكاليف

اتفقت دراسات هذه المجموعة على أن تطبيق الشبكات العصبية يؤدي إلى الحصول على نتائج عالية الجودة فيما يتعلق بعملية تقدير التكلفة، وهذا تم إثباته على مختلف الصناعات وفى دول مختلفة. حيث استهدفت دراسة (Lyne & Maximino, 2014) إلى تطوير نموذج للشبكات العصبية الاصطناعية (ANN) للتعنبؤ بالتكاليف الهيكلية الإجمالية لمشاريع البناء فى الغالبين، وتوصلت إلى أن نموذج الشبكات العصبية الاصطناعية (ANN) يؤدي إلى توقع معقول للتكلفة الهيكلية الإجمالية لمشاريع البناء وذلك من خلال التدريب المناسب، ونتائج اختبارات المرحلة. واتفقت معها دراسة (سيد، 2010) بأن الشبكات العصبية لها قدرة هائلة فى تقدير التكاليف الإجمالية للمنشأة عن طريق إمداد هذه الشبكات ببيانات تاريخية عن التكلفة الإجمالية، كما توصلت النتائج إلى أن الشبكات العصبية لها فوائد عديدة من أهمها التعامل مع بيانات لا يوجد بها تجانس. ومن ناحية أخرى اتفقت معهم دراسة (دسوقى، 2002) على قدرة وتميز الشبكات العصبية بتقدير تكاليف العمالة مقارنة بأسلوب الانحدار المتعدد، حيث كان هدف الدراسة الحصول على معلومات دقيقة وملائمة عن عنصر العمل بما يؤدي إلى تخفيض الوقت، والاستفادة المثلى من العمالة المتاحة، ومن ثم تخفيض تكاليف الإنتاج. وبشكل أكثر تحديداً فقد ركزت دراسة (Ozcan & Figlah, 2014) أن هناك نوع من الشبكات العصبية يطلق عليها الشبكات العصبية التنبؤية، وهى التى تُستخدم للتعنبؤ بالتكاليف اعتماداً على القيمة المحددة لظواهر أخرى مرتبطة بها، وأوضحت هذه الدراسة أن أساليب تقدير التكاليف تستند إلى أساليب تقدير كمية ونوعية، فالأساليب النوعية هى تلك التى تعتمد على نظام ارشادى كقاعدة عامة وتستخدم للوصول إلى نتائج سريعة للمشاكل لإتخاذ القرارات، ويقدم هذا النظام الإرشادى نتائج قيمة، ولكن المعرفة السابقة تعتمد على أنها قد لا تكون قادرة على تحديد الظروف المتغيرة فهى فى الغالب تستند على قرارات الخبير. أما الأساليب الكمية فهى التى تصنف النماذج الإحصائية ونماذج أخرى مماثلة وتقوم بتقسيم تلك النماذج إلى مجموعتين وهما المعلمات، والشبكات العصبية. وفى الطرق المعلمية للتكاليف يتم تقييمها على أساس خصائص المنتج التى تكون فى شكل المعلمات. وبالتالي نستخلص مما سبق أن معظم عمليات تقدير التكلفة تقوم على الأساليب الكمية والنوعية كما هو موضح بالشكل رقم (3) التالى:



شكل (3): طرق تقدير التكاليف

المصدر: (Ozcan & Figlah , 2014 –P.718)

ويخلص الباحث مما سبق من تحليل وتقييم للدراسات السابقة إلى أن أسلوب الشبكات العصبية الاصطناعية (ANN) أثبت أن لديه قدرة فائقة علي الملائمة والتحقق من تقدير التكاليف، ف نموذج الشبكات العصبية لديه القدرة أيضاً علي فحص وتصنيف البيانات والتعامل مع النماذج الجديدة، بالإضافة إلى أنه يمكنه محاكاة مجموعة من البيانات الفعلية التي تستخدم في تحديد الانحرافات.

ونظراً لأهمية ودور نماذج الشبكات العصبية الاصطناعية (ANN) كأحد الأدوات المقترحة لتحسين دقة التنبؤ بالتكاليف، ومن هذا المنطلق تحاول الدراسة الإجابة على سؤال البحث التالي:
سؤال البحث: كيف يمكن تحسين دقة التنبؤ بالتكاليف الصناعية للإنتاج باستخدام نماذج الشبكات العصبية الاصطناعية (ANN) مقارنة باستخدام أسلوب الإنحدار المتعدد؟

3-6 الإطار العام لدراسة الحالة والإجابة على سؤال البحث

يتناول هذا القسم عرضاً للمنهجية المستخدمة في الدراسة الحالية، حيث يستعرض الهدف من الدراسة، وسؤال الدراسة، ومجتمع وعينة الدراسة، ومتغيرات الدراسة وأساليب قياسها، ومصادر الحصول على البيانات وأساليب تحليلها على النحو التالي:

1-3-6 الهدف من الدراسة

تهدف الدراسة إلى تحسين عملية التنبؤ بالتكاليف الصناعية للإنتاج وذلك من خلال إجراء دراسة الحالة للإجابة على سؤال الدراسة التالي:

كيف يمكن تحسين دقة التنبؤ بالتكاليف الصناعية للإنتاج باستخدام نماذج الشبكات العصبية الاصطناعية (ANN) مقارنة باستخدام أسلوب الانحدار المتعدد؟ ويشير منهج دراسة الحالة وفقاً لدراسات (Huang et al.,2009; Sadrzdehrafiei et al.,2013) بأنه المنهج المعتمد على دراسة حالة معينة بهدف جمع معلومات عنها بشكل أكثر عمقاً، كما أنه يساعد في إعطاء معلومات لا يمكن الحصول عليها بأساليب أخرى، فهو يعتبر بذلك مناسباً للاستخدام عندما يكون تركيز البحث على ظاهرة معاصرة، كما أنه يُفضل استخدامه عندما تكون هناك رغبة في دراسة حالة تحتوى على العديد من المتغيرات والعوامل المرتبطة مع بعضها البعض وحينما تكون هذه العوامل والمتغيرات يمكن ملاحظتها. ولتحقيق ذلك وللإجابة على سؤال البحث تم استخدام كل من أسلوب الانحدار المتعدد وأساليب الشبكات العصبية الاصطناعية (ANN) لتقدير التكاليف الصناعية للإنتاج، والتوصل إلى الأسلوب أو النموذج الذى يحقق أعلى درجات الدقة لتحسين عملية التنبؤ بتكاليف الإنتاج.

6-3-2 مجتمع وعينة الدراسة

يتمثل مجتمع الدراسة فى منشآت الأدوية الإنتاجية التى تعمل بجمهورية مصر العربية، حيث تعتبر صناعة الأدوية من الصناعات الإستراتيجية ذات التقنية العالية التى تتطلب تكنولوجيا معلومات متطورة متكاملة، فهى صناعة بالغة التعقيد وتحتاج إلى الإلتزام بالمعايير القياسية لمتطلبات الجودة وذلك لتحقيق أعلى درجات الكفاءة والأمانة للمستحضر الدوائى. ونظراً لكبر حجم مجتمع الدراسة وبعد استبعاد المنشآت التى تقوم بتوزيع الأدوية فقط دون الإنتاج، حيث أن هدف الدراسة هو التنبؤ بالتكلفة الصناعية للإنتاج. فمن هذا المجتمع تم الاعتماد على واحدة من الشركات المساهمة المصرية الرائدة فى صناعة وتحضير وتجارة جميع المستحضرات الطبية والتشخيصية والصيدلانية والبشرية والبيطرية ومستحضرات التجميل الخاصة وما يتبعها من مستلزمات واستخلاص وتجهيز وتركيب جميع المواد والعناصر الكيماوية والأعشاب وغيرها. وتم الاعتماد على هذه المنشأة لإجراء دراسة الحالة باعتبارها من المنشآت كبيرة الحجم من حيث رأس المال، وإمكانية الحصول على القوائم المالية والإيضاحات المتممة لها لفترات زمنية طويلة سابقة.

6-3-3 أسلوب جمع البيانات

قام الباحث بتجميع البيانات عن طريق استخدام القوائم المالية المنشورة فى دليل شركة مصر لنشر المعلومات والإيضاحات المتممة لها وتقرير مجلس الإدارة ومراقب الحسابات، حيث تم الاعتماد على

- القوائم المالية لإجراء التحليل المالي للمنشأة محل الدراسة، واستخراج النسب المالية التي يتم استخدامها كمدخلات للأسلوب الاحصائي والشبكات العصبية بناءً على:
- اختيار مجموعة النسب المحاسبية المالية الأكثر استخداماً والتي تم استخلاصها من نتائج البحوث السابقة ويكون لها تأثير على إمكانية التنبؤ بالتكلفة الصناعية للإنتاج الذي يُمثل المتغير التابع (Y) في هذه الدراسة.
 - دراسة وتحليل 13 متغير مستقل للمنشأة محل الدراسة تناولت بعضها جوانب النشاط والربحية والتعلم والنمو وذلك لفترة 17 سنة متتالية سابقة.

6-3-4 طرق قياس متغيرات دراسة الحالة

يوضح الجدول رقم (1) التالي متغيرات الدراسة وطرق قياسها:

جدول (1): متغيرات الدراسة وطرق قياسها

المجموعة	المتغير	الوصف	طريقة القياس
المتغير التابع	التكلفة الصناعية للإنتاج (Y)	تشير إلى ما يتم إنفاقه على الإنتاج من مواد أولية وتقوم بتحويلها إلى بضائع تامة بمزج و/أو تصنيع المواد الأولية، ولتحقيق ذلك عادة ما تستخدم العاملين والآلات الموجودة بالمنشأة. ويطلق على التكلفة التي تتحملها والتي يمكن ارجاعها مباشرة للمنتجات مصطلح تكاليف الإنتاج والتي تقع في ثلاث مجموعات: مواد مباشرة وأجور مباشرة والتكاليف الصناعية غير المباشرة. (Chang et al.,2012; Weckman et al.,2010; Gresse & Li,1995; Carza&Rouhana,1995;Shtub&Versano,1999;Caraliri et al.,2004;Kim et al., 2004; Mckim,1993)	مجموع كل من المواد المباشرة المستخدمة والأجور المباشرة والتكاليف الصناعية غير المباشرة.
	عدد المنتجات (X1)		عدد المنتجات التي تقوم المنشأة بانتاجها
	عدد العاملين (X2)		مجموع عدد العمالة الدائمة والمؤقتة
	تكلفة المواد الخام المباشرة (X3)	هي عبارة عن المواد الأولية التي يمكن ردها مباشرة إلى المنتج النهائي، وتعتبر من التكاليف المباشرة التي يمكن ارجاعها أو ايجاد ارتباط لها مع الغرض من التكلفة، كما انها تعتبر من التكاليف المتغيرة أى التي تتغير تكلفتها مع التغير في احجام الانتاج بنفس النسبة وفى نفس الاتجاه. (Chang et al.,2012; Shtub &Versano,1999; Gresse &Li,1995; Babad&Balachandran,1993;Smith&Lek	تكلفة مخزون المواد الأولية أول الفترة مضافاً إليها صافى مشتريات المواد الأولية ومخصوماً منها تكلفة مخزون المواد الأولية

آخر الفترة	san,1991; Ruffo et al.,2006; Caraliri et al.,2004)		المتغيرات المستقلة
اجمالي الأجر المدفوع لعمال الإنتاج فقط.	هي عبارة عن الأجر الخاصر بكافة العاملين مباشرة في تحويل المواد الأولية إلى منتجات تامة فضلاً عن أجر عمال الرقابة على الجودة القائمين بفحص المنتجات قبل بيعها للمستهلكين، وتعتبر من التكاليف المباشرة التي يمكن ارجاعها أو ايجاد ارتباط لها مع الغرض من التكلفة، كما انها تعتبر من التكاليف المتغيرة أي التي تتغير تكلفتها مع التغير في احجام الانتاج بنفس النسبة وفي نفس الاتجاه. (Chang et al.,2012; Babad & Balachandran,1993; Smith & Leksan,1991; Ruffo et al.,2006; Caraliri et al.,2004; دسوقي،2002)	تكلفة الأجر المباشرة (X4)	
مجموع التكاليف الصناعية غير المباشرة / اجمالي التكلفة الصناعية للإنتاج	هي التي يطلق عليها التكاليف العامة وهي تلك التكاليف التي ترتبط بأكثر من غرض من أغراض التكاليف. فإذا كان الغرض من حساب تكلفة منتج معين من المنتجات المتعددة فإن كافة تكاليف التصنيع بخلاف المواد المباشرة والأجر المباشرة تعتبر تكاليف صناعية غير مباشرة أي ما تم انفاقه على الأنشطة المسببة لحدوث تكلفة. (Smith & Leksan,1991; Ruffo et al., 2006; Caraliri et al.,2004;Amdee et al., 2016;Urkmez et al.,2008)	التكاليف الصناعية غير المباشرة كنسبة من تكلفة الإنتاج(X5)	
تكلفة البحوث والتطوير/ صافي المبيعات	يعتبر هذا المعدل من المتغيرات غير المالية الخاصة بالنمو، حيث يرى الباحث إن زيادة الانفاق على البحث والتطوير يُمكن المنشأة من اتباع وسائل انتاج حديثة وتكنولوجيا متطورة، الأمر الذي يؤدي إلى تحسين جودة العملية الإنتاجية، وتخفيض معدلات العيوب، وتحسين قدرات العاملين ورفع كفاءة نظم المعلومات، مما يؤدي إلى تخفيض تكلفة الإنتاج، وتحقيق وفورات مالية في الفترة الحالية والمستقبلية للمنشأة. (سيد،2010; Linyon & Ying,1996; Caraliri et al.,2004;)	معدل الإنفاق على البحوث والتطوير كنسبة من المبيعات (X6)	
مجمول الربح / صافي المبيعات	تعتبر هذه النسبة من نسب الربحية، وتشير النسبة المرتفعة لمجمول الربح المحقق إلى مدى كفاءة الإدارة في التعامل مع العناصر التي تكون تكلفة البضاعة المباعة، فكلما ارتفعت نسبة مجمول الربح دل ذلك على نجاح المنشأة في تخفيض التكاليف ومدى تقبل السوق لمنتجاتها. (Olsan&Mossman,2003; سيد،2010; جرجس،2012; متولى،2001)	نسبة مجمول الربح (X7)	
تكلفة تدريب العاملين	يعتبر هذا المعدل من المتغيرات الهامة التي تساعد في رفع كفاءة العاملين بالمنشأة لتحسين العملية الإنتاجية ومن ثم تخفيض التكاليف وزيادة الأرباح،	معدل الإنفاق على تدريب العاملين	

	(X8) حيث أن للعاملين تأثير كبير على مستوى الأداء داخل المنشأة وخاصة عمال الإنتاج، فكلما زاد مستوى تدريبيهم ورفع كفاءتهم كلما زادت جودة الإنتاج وتخفيض التكاليف. (دسوقي، 2002؛ سيد، 2010)	
تكلفة البضاعة المباعة/ متوسط تكلفة مخزون المواد الأولية	تعتبر هذه النسبة من نسب النشاط، ويقاس هذا المعدل مدى كفاءة الإدارة في تصريف المخزون على مدار العام. (Olsan&Mossman، 2003؛ سيد، 2010؛ متولى، 2001)	معدل دوران مخزون المواد الخام (X9)
		عدد خطوط الإنتاج (X10)
صافي المبيعات/ عدد العاملين	تشير هذه النسبة إلى أن مهارات العاملين أحد العناصر الهامة لضمان أداء العمليات الداخلية بالجودة المطلوبة، ومواجهة الضغوط التنافسية، حيث أنه كلما زادت إنتاجية العاملين كلما ساعد ذلك المنشأة على توفير معلومات تمكن المنشأة من تحديد برامج التطوير المطلوبة لتحسين الإنتاج وتخفيض التكاليف. (دسوقي، 2002؛ سيد، 2010)	متوسط إنتاجية العامل (X11)
قيمة الفاقد الصناعي/التكلفة الصناعية للإنتاج	قد يحدث هذا الفاقد نظراً لطبيعة إنتاج منتج معين وتعدد مراحلها وعمليات إعادة الفرز والفحص بالإضافة إلى بعض العيوب التي تظهر على المنتج بعد التعبئة.	معدل الفاقد الصناعي (X12)
قيمة التالف/إجمالي تكلفة المواد الأولية المستخدمة	يشير هذا المعدل إلى ان الكفاءة في عمليات التشغيل الداخلي تؤدي إلى كفاءة في استغلال الطاقات المادية والبشرية، وهذا بدوره يؤدي إلى تخفيض التكلفة في الأجل الطويل. بما يؤدي إلى تحقيق التميز التشغيلي عن طريق تحسين العمليات الداخلية، وتحقيق الكفاءة في استخدام الأصول وإدارة الطاقات والموارد المتاحة.	معدل التالف في استخدام المواد الأولية (X13)

3-5-6 الأدوات المستخدمة في تحليل البيانات

يتم استخدام البرنامج الإحصائي Minitab 18 باعتباره أحد البرامج الإحصائية المستخدمة في مجال البحوث التجارية، حيث يصف نموذج الانحدار العلاقة بين متغيرين أحدهما مستقل والآخر تابع. وتكون المعادلة الخاصة به على النحو التالي:

$$Y = B_0 + B_1X_1 + \dots + B_nX_n + E$$

حيث أن:

Y: ويمثل المتغير التابع وهو التكلفة الصناعية للإنتاج.

B0: الجزء الثابت.

B1-n: المتغير المستقل والذي يتمثل في المتغيرات المحاسبية.

E: الخطأ العشوائي.

بينما يتم استخدام برنامج Matlab 2015 في بناء نماذج الشبكات العصبية، ويتم تقسيم عملية التحليل والمقارنة إلى جزئين كالتالي:

6-3-5-1 استخدام أسلوب تحليل الانحدار المتعدد في التنبؤ بالتكلفة

في هذا الجزء يقوم الباحث باستخدام تحليل الانحدار المتعدد من خلال استخدام (13) متغير مستقل والتي تم ذكرها أعلاه للتنبؤ بالتكاليف الصناعية للإنتاج والذي يمثل المتغير التابع، حيث تم تشغيل البرنامج الإحصائي Minitab18 باستخدام كل المتغيرات السابق ذكرها للوصول إلى رقم التكاليف الصناعية للإنتاج .

وتوضح المعادلة التالية ما انتهى إليه تحليل الانحدار المتعدد للمنشأة محل الدراسة وكانت كالتالي:

$$Y = -110000000 - 85357 X_1 + 58284 X_2 + 0.547 X_3 + 0.31 X_4 + 22496095 X_5 - 241000000 X_6 - 42320443 X_7 - 1466 X_8 - 265803 X_9 + 5728279 X_{10} + 793 X_{11} - 5333090 X_{12} + 256000000 X_{13}$$

ومن خلال نتائج تشغيل البرنامج وجد الباحث أن معامل التحديد (R^2) يعادل 94.7% وهذا يعنى أن 95% تقريباً من التغيرات التي تحدث من المتغير التابع (Y) يمكن إرجاعها إلى تغيرات تحدث في المتغيرات المستقلة من ($X_{13}:X_1$)، أما الـ 5% تقريباً الباقية فهي يمكن إرجاعها إلى بعض المتغيرات التي لم تدرج بالنموذج، أو تلك التي تأتي نتيجة عوامل الصدفة.

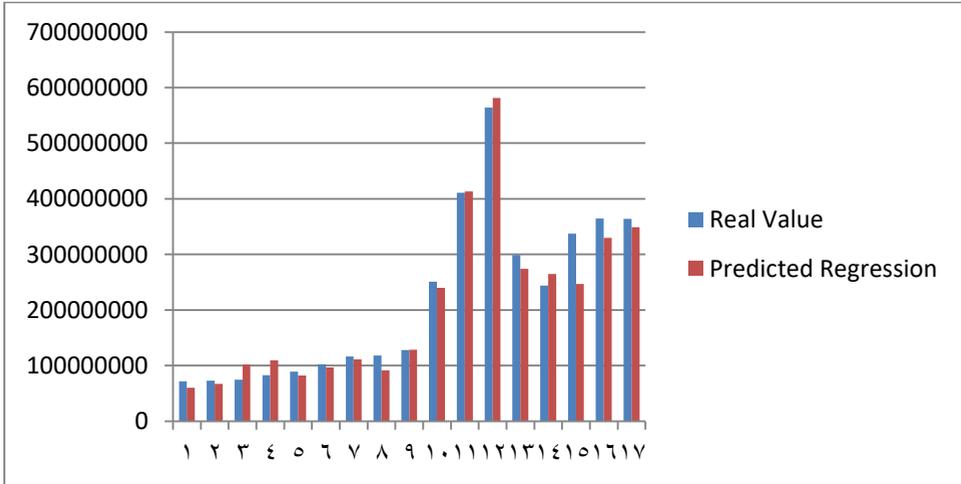
وطبقاً لمخرجات البرنامج في الجزء الخاص بتحليل التباين فإن نموذج تحليل الانحدار ككل يعتبر نموذج جيد، حيث أن قيمة F المحسوبة (مقياس اختبار معنوية أو عدم معنوية النموذج المستخدم) بلغت 300.43 ويقابلها P Value تعادل 0.000. بالنسبة للمنشأة محل البحث وبالتالي فهي أقل من 5%.

ويوضح الجدول رقم (2) التالي قيمة Y الفعلية مقارنة بـ Y المتنبأ بها من نموذج الانحدار.

جدول (2): المقارنة بين التكاليف الفعلية والمنتبأ بها من واقع نموذج الانحدار

year	Real Value	Predicted Regression
1	71521150	60069500
2	73089631	67107617
3	74762352	101919381
4	82747145	109483988
5	89287201	81929356
6	102646297	96420551
7	116165594	111327278
8	117972099	91565041
9	128060379	128568377
10	250836568	240044642
11	411046862	413470340
12	564308066	581477252
13	299077604	274073173
14	243916560	265058429
15	337299684	246689427
16	364738542	329610232
17	363975516	348735751

كما يوضح الشكل رقم (4) التالى المقارنة بين التكاليف الفعلية والمنتبأ بها بناءً على الأرقام المذكورة فى جدول (2) السابق للمنشأة محل الدراسة.



شكل (4): المقارنة بين التكاليف الفعلية والمنتبأ بها من واقع نموذج الانحدار

المصدر: (إعداد الباحث)

ويلاحظ الباحث من الشكل البياني السابق والأرقام الموضحة بالجدول رقم (2) السابق أن هناك بعض السنوات كانت فيها القيم المتنبأ بها من خلال نموذج الانحدار قريبة إلى حد ما من النتائج الفعلية، ولكن هناك سنوات أخرى كانت القيم فيها بعيدة عن بعضها وهناك فروق جوهرية وواضحة بين Y الفعلية و Y المتنبأ بها. مما يعنى أن هناك حاجة إلى تطوير نماذج جديدة من شأنها تحسين عملية التنبؤ، لذا يقترح الباحث استخدام نماذج الشبكات العصبية الاصطناعية (ANN) كأحد النماذج الحديثة التي تُستخدم في عملية التنبؤ خاصة أن معظم نتائج البحوث والدراسات السابقة أشاروا بأفضلية هذه النماذج لقدرتها الفائقة على تحقيق نتائج أفضل وأدق من الأساليب التقليدية للتنبؤ.

6-3-5-2 استخدام نماذج الشبكات العصبية الاصطناعية (ANN) في التنبؤ بالتكلفة

يوجد العديد من البرامج الجاهزة للشبكات العصبية حيث يوجد منها العديد والعديد على شبكة الإنترنت، وقد قام الباحث باختيار برنامج (MATLAB 2015) واختيار الجزء الخاص بالشبكات العصبية، حيث يعتبر هذا البرنامج من البرامج الرائدة في التطبيقات الرياضية والهندسية ويستخدم كوسيلة تحليل في مجالات عدة فهو يقوم بإجراء العمليات الحسابية المعقدة بسرعة فائقة، وتنفيذ واشتقاق الخوارزميات، ومحاكاة وتصميم الأنظمة المختلفة في جميع فروع العلوم والصناعة، وتحليل البيانات واستكشافها. وكان الهدف من نموذج الشبكات العصبية هي تحسين دقة التنبؤ بالتكاليف الصناعية للإنتاج، لذلك يجب اختيار نوع الشبكة بما يتلائم مع تحقيق هدف الدراسة فقد تم اختيار شبكات الانتقال للخلف أو ما يطلق عليها التغذية العكسية (Feed-Forward Back propagation Neural Network)، فهي أكثر الأنواع استخداماً في مجال المحاسبة والتمويل، حيث تقوم هذه الشبكات برسم العلاقة بين المدخلات والمخرجات من خلال البيانات الموجودة وبعدها تقوم الطبقة الخفية بتعديل الأوزان داخل الشبكة ويتم تعليم الشبكة عن طريق التغذية العكسية بمعنى يتم الانتقال للأمام لتقدير الخطأ ثم الرجوع للخلف لتعديل الأوزان وذلك لتصحيح الخطأ، كما أن هناك أنواع كثيرة من طرق التطبيق، كما قام الباحث باتباع طريقة التقريب الدالي لتكون هي الطريقة التي تم اختيارها للتطبيق بما يتناسب مع مجال وهدف الدراسة (Urkmez; et al.,2009; al,2008; السجاعي، 2012 جاب الله، 2004;).

1- معمارية نموذج الشبكات العصبية

تتمثل معمارية نموذج الشبكات العصبية كما يلي:

- عقد المدخلات

يتكون النموذج من (13) عقد وهي التي تمثل المتغيرات المستقة على أساس البيانات التي تم إعدادها، حيث أن كل نسبة مالية يتم تحميلها على خلية وتصيح عدد المدخلات مساوياً لعدد الخلايا الموجودة.

X1: عدد المنتجات، X2: عدد العاملين، X3: تكلفة المواد الخام، X4: تكلفة الأجور المباشرة، X5: نسبة المصاريف الصناعية الأخرى إلى تكلفة الإنتاج، X6: معدل الإنفاق على البحوث والتطوير كنسبة من المبيعات، X7: نسبة مجمل الربح، X8: مستوى الإنفاق على تدريب العاملين، X9: معدل دوران مخزون المواد الخام، X10: عدد خطوط الإنتاج، X11: انتاجية العاملين، X12: معدل الفاقد الصناعي، X13: معدل التالف في استخدام المواد.

- عقد الطبقات الخفية

تتمثل الطبقات الخفية في (12) عقد في طبقة خفية واحدة، وهذا العدد يحدده البرنامج المستخدم حسب احتياجات التدريب، وبناءً على قدرته على التعرف على البيانات.

- عقد طبقة المخرجات

تتمثل المخرجات في (Y) وتعبّر عن التكلفة الصناعية للإنتاج وهي بمثابة المتغير التابع.

2- طريقة ادخال البيانات

- خطوات تشغيل البرنامج

بعد الإنتهاء من إعداد البيانات على ملف الأكسيل والتي تتمثل في المدخلات بعدد المتغيرات المستقلة (X1:X13)، وتتمثل المخرجات بالتكلفة الصناعية للإنتاج وهي تمثل المتغير التابع (Y) هناك مجموعة من الخطوات التي يجب اتباعها للحصول على نتيجة الإختبار وكانت كالتالي:

- يتم فتح النافذة الرئيسية لبرنامج Matlab كما هو مبين بالملحق رقم (1)، ثم يتم اختيار أيقونة Work Space ليتم وضع البيانات التي تم إعدادها مسبقاً من ملف الإكسيل إلى البرنامج، كما أنه يجب أن يتم وضع المدخلات التي تتمثل في المتغيرات المستقلة وكذلك المتغير التابع في شكل صفوف داخل البرنامج. وذلك من خلال اختيار أيقونة NEW ويتم تقسيمها إلى Input والتي تأخذ قيم المتغيرات المستقلة من (X1:X13) على مدار 17 سنة متتالية، ثم بعد ذلك من

خلال أيقونة NEW أيضاً نفتح ملف جديد ويتم تسميته Target والذي يأخذ قيم (Y) لنفس عدد السنوات كما هو مبين بالملحق رقم (2).

- بعد ادخال البيانات يتم الذهاب إلى نافذة Command Window ببرنامج Matlab ونقوم بكتابة NNtool وهي الخاصة بأدوات الشبكات العصبية داخل البرنامج، ثم بعد ذلك يتم فتح شاشة Nural Network Manager ويتم الذهاب إلى جزء الـ Input Data ونختار منها الخاص بالمتغيرات المستقلة والذي تم رفعه من الـ Work Space، بعد ذلك يتم اختيار أمر Target ومنها يتم اختيار جزء المتغير التابع الذي يوجد به قيم Y. ثم يتم اعطاء أمر NEW فتظهر لنا شاشة Creat Network or Data يتم من خلالها تسمية الشبكة الخاصة بنا، وفي نفس الشاشة يتم اختيار نوع الشبكة الخاصة بنا وكانت (Feed – Forword Back (propagation Nural Network)، وبعدها يتم اختيار أمر Input من شريط Input data، واختيار أمر Target من شريط Target data، وفي نفس الشاشة يتم اختيار عدد الطبقات الخفية وكانت طبقة واحدة بها 12 عقد حسب احتياجات البرنامج وقدرته على التعرف على البيانات كما هو مبين بالملحق رقم (3).

- بعد تغذية الشبكة بعدد المدخلات والمخرجات وذلك الطبقة الخفية يتم بعد ذلك عمل Creat ثم OK كما هو مبين بالملحق رقم (3)، ثم يتم الرجوع مرة أخرى إلى شاشة New Network Data Manager ليظهر فيها أسم الشبكة التي تم انشاؤها واختيارها، بعد ذلك يتم اختيار أمر Open ليظهر شكل الشبكة التي تم تصميمها كما هو مبين بالملحق رقم (4) والتي تتمثل في 3 طبقات وهم طبقة المدخلات وبها 13 خلية عصبية والطبقة الخفية بها 12 خلية عصبية وطبقة المخرجات بها خلية عصبية واحدة. كما نجد من خلال الشكل المبين بالملحق رقم (4) أن هناك أوزان نسبية ما بين طبقة المدخلات والطبقة الخفية، كما أن هناك أوزان نسبية أيضاً بين الطبقة الخفية وطبقة المخرجات، ويعبر الوزن النسبي في الشبكات العصبية عن القوة النسبية من خلال التعبير عن الأهمية النسبية لكل عنصر من المدخلات بالنسبة إلى وحدة المعالجة.

- نقوم بعد ذلك بالذهاب إلى شاشة Network 1 ويتم اختيار أمر Train ومنها نختار (Input) و (Target) وهذا يعتبر الجزء الخاص بالتدريب كما هو مبين بالملحق رقم (5)، وبعد ذلك يتم اختيار Training Parameters من نفس الشاشة، ويتم من خلالها تهيئة الشبكة للتدريب من خلال تقسيم بيانات الدراسة (70% بيانات تدريب، 30% بيانات اختبار)، وإعداد عدد المحاولات التي تعظم تدريب الشبكة وكانت 1000 محاولة للوصول إلى الهدف، كما تم عمل حد أقصى للفشل وكان 350 كما هو مبين بالملحق رقم (6).

- بعد الإنتهاء من الجزء السابق وتهيئة الشبكة للتدريب نقوم باختيار أمر Train Network وهو الذى يظهر فيه النتائج الخاصة بالتدريب داخل الشبكة كما هو مبين بالملحق رقم (7)، بعد ذلك يتم الرجوع إلى Data Manager لإختيار Output Training لتظهر نتائج التدريب .
- وفى النهاية وبعد الإنتهاء من تدريب الشبكة نقوم بالرجوع إلى Network ونختار أمر Simulate كما هو مبين بالملحق رقم (8)، ومنها نختار Network Outputs من شاشة Data Manager لتظهر نتائج الاختبار النهائية وهو ما يعتبر نتيجة ال Target داخل الشبكة كما هو مبين بالملحق رقم (9)، والرسم البياني الخاص بالتدريب والاختبار ومدى التحقق من صحة النتائج، والذى أسفر بأن معامل التحديد (R^2) الناتج عن تطبيق الشبكات العصبية يمثل 98% تقريباً كما هو مبين بالملحق رقم (10).

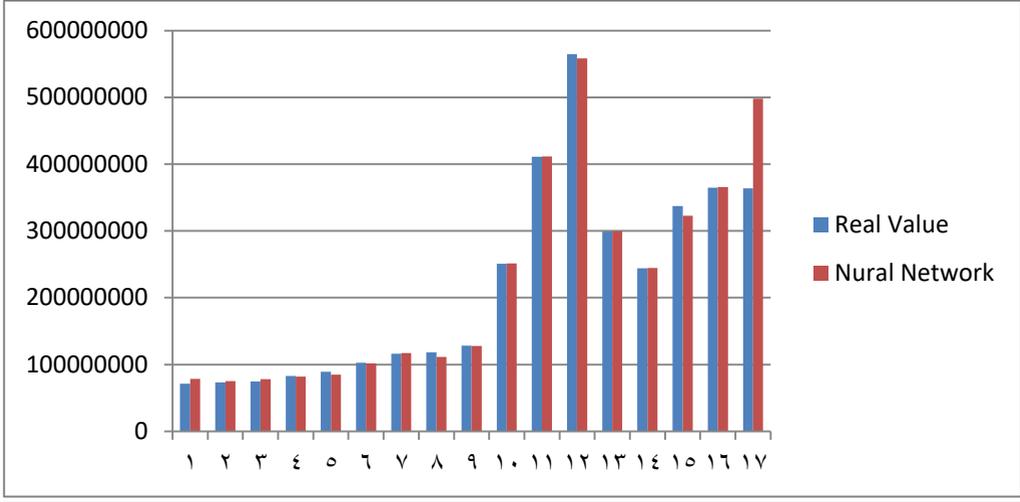
- نتائج تشغيل البرنامج

وبناءً على ماسبق يوضح الجدول رقم (3) التالى قيمة Y الفعلية والمتنبأ بها من خلال مقارنة مخرجات نموذج الشبكات العصبية مقارنة بالقيم الفعلية.

جدول (3): المقارنة بين التكاليف الفعلية والمتنبأ بها من واقع نماذج الشبكات العصبية

year	Real Value	Nural Network
1	71521150	78422958.6039
2	73089631	75217214.1932
3	74762352	78010213.7596
4	82747145	81921986.3975
5	89287201	84904043.2231
6	102646297	101785400.7435
7	116165594	117001829.0769
8	117972099	111557276.7515
9	128060379	127745515.4924
10	250836568	251463565.3229
11	411046862	411463132.2155
12	564308066	558205840.9933
13	299077604	299738733.4178
14	243916560	244587214.6261
15	337299684	322682841.7857
16	364738542	365583588.7520
17	363975516	497807928.1453

كما يوضح الشكل رقم (5) التالى بناءً على الأرقام المذكورة فى جدول رقم (3) السابق المقارنة بين التكاليف الفعلية والمتنبأ بها من نماذج الشبكات العصبية.



شكل (5): المقارنة بين التكاليف الفعلية والمنتبأ بها من واقع نماذج الشبكات العصبية
المصدر: (إعداد الباحث)

ويلاحظ الباحث من الشكل البياني رقم (5) السابق أن القيم المنتبأ بها من خلال نموذج الشبكات العصبية كانت قريبة جداً من النتائج الفعلية في معظم سنوات الدراسة، مما يدل على أفضلية الشبكات العصبية وقدرتها الفائقة في التنبؤ بتكاليف الإنتاج بصورة أكثر دقة.

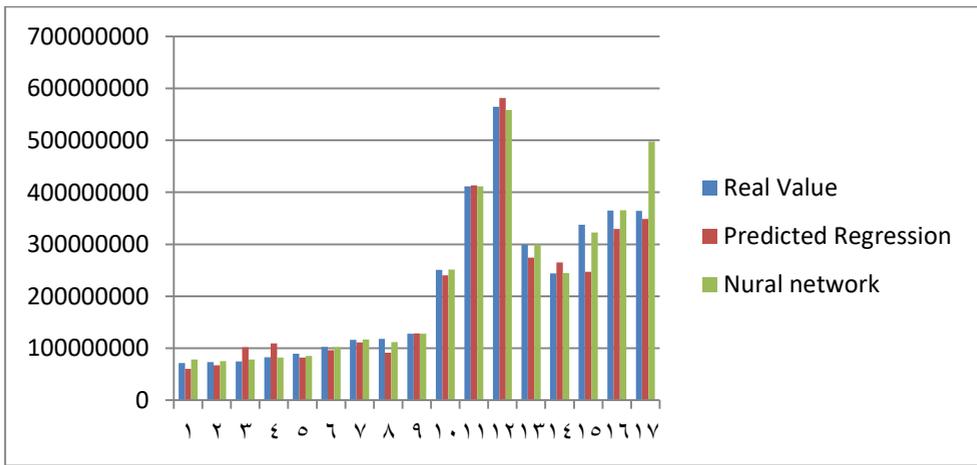
لذلك يعرض الجدول رقم (4) التالي الفروق بين القيم الفعلية للتكاليف الصناعية للإنتاج والقيم المنتبأ بها من خلال كل من نماذج الانحدار ونماذج الشبكات العصبية.

جدول (4): المقارنة بين التكاليف الفعلية والمنتبأ بها من نموذج الانحدار ونموذج الشبكات العصبية

year	Real Value	Nural Network Predict	Predicted Regression
1	71521150	78422958.6039	60069500
2	73089631	75217214.1932	67107617
3	74762352	78010213.7596	101919381
4	82747145	81921986.3975	109483988
5	89287201	84904043.2231	81929356
6	102646297	101785400.7435	96420551
7	116165594	117001829.0769	111327278

8	117972099	111557276.7515	91565041
9	128060379	127745515.4924	128568377
10	250836568	251463565.3229	240044642
11	411046862	411463132.2155	413470340
12	564308066	558205840.9933	581477252
13	299077604	299738733.4178	274073173
14	243916560	244587214.6261	265058429
15	337299684	322682841.7857	246689427
16	364738542	365583588.7520	329610232
17	363975516	497807928.1453	348735751

وفيما يلي الشكل رقم (6) الذى يوضح الفروق بين بين التكاليف الفعلية والمنتبأ بها من واقع نموذج الانحدار المتعدد ونموذج الشبكات العصبية. والذى يوضح مدى انخفاض الفروق بين قيم (Y) الفعلية وقيم (Y) المنتبأ بها من خلال نماذج الشبكات العصبية فى معظم سنوات الدراسة مقارنة بقيم (Y) المنتبأ بها من خلال نموذج الانحدار.



شكل(6): المقارنة بين التكاليف الفعلية والمنتبأ بها من نموذج الانحدار ونموذج الشبكات العصبية.

المصدر: (إعداد الباحث)

6-3-6 إجابة سؤال البحث

من خلال المقارنة بين نتائج نماذج الشبكات العصبية ونتائج أسلوب تحليل الانحدار، وجد الباحث أن أرقام التكاليف المنتبأ بها بواسطة نماذج الشبكات العصبية كانت أقرب إلى التكاليف الفعلية مقارنة بنتائج أسلوب تحليل الانحدار، حيث تم تدريب الشبكة على بيانات منشأة واحدة وتم

ادخال بيانات عن 13 متغير مستقل لمدة 17 سنة متتالية سابقة وذلك للتنبؤ بالتكلفة الصناعية للإنتاج الذي يمثل المتغير التابع، وأشارت نتائج الدراسة إلى أن التكاليف المتنبأ بها من خلال نماذج الشبكات العصبية كانت أقرب وأدق من نموذج الانحدار مقارنة بالتكاليف الفعلية، وهو ما يرجعه الباحث إلى أن هناك أدوات ونماذج حديثة مثل الشبكات العصبية الاصطناعية (ANN) تُمكن المنشآت الصناعية من تحسين قدرة التنبؤ بالتكاليف.

وأخيراً، يخلص الباحث إلى قدرة نماذج الشبكات العصبية على التنبؤ بالتكاليف بصورة أكثر دقة مقارنة بالأساليب التقليدية مثل أسلوب تحليل الانحدار. وهذا ما يثبت الإجابة على سؤال الدراسة الرئيسي وهو:

كيف يمكن تحسين دقة التنبؤ بالتكاليف الصناعية للإنتاج باستخدام نماذج الشبكات العصبية الاصطناعية (ANN) مقارنة باستخدام أسلوب الانحدار المتعدد؟

6-4 الخلاصة والنتائج والتوصيات

6-4-1 الخلاصة والنتائج

تناول الباحث في هذه الدراسة أداة من أدوات الذكاء الاصطناعي وهى الشبكات العصبية الاصطناعية (ANN) والتي تركز على مشاكل التنبؤ والتصنيف فى محاولة لمحاكاة مخ الإنسان. فنظراً للتقدم التكنولوجى الذى تتسم به بيئة الأعمال فى الوقت الحاضر، وتعدد المشاكل التى تواجه المنشآت، فقد أصبحت تكنولوجيا المعلومات تتسم بقدرة هائلة على حل المشاكل المعقدة بطرق مختلفة وبالأخص تلك المشاكل التى تواجه المحاسبة الإدارية، ومن ثم الدور الذى يقوم به المحاسب الإداري فى السنوات الأخيرة. لذلك كان موضوع تطوير وتغيير أدوار ووظائف المحاسبة الإدارية مجال اهتمام العديد من البحوث فى السنوات الأخيرة.

تناول البحث نماذج الشبكات العصبية الاصطناعية (ANN) على أنها نظام لمعالجة المعلومات يستخدم أسلوب محاكاة الشبكات العصبية الحيوية من خلال التدريب والتعلم للوصول إلى حل أمثل للمشاكل المعقدة. فهى تتكون من وحدات معالجة بسيطة ومرتبطة مع بعضها البعض لتشغيل المعلومات على نحو ديناميكي كاستجابة لمدخلات خارجية حيث يقوم بتخزين المعرفة العملية لتجعلها متاحة للمستخدم وذلك عن طريق ضبط الأوزان.

وتم التعرض إلى ثلاث مكونات للشبكات العصبية (طبقة المدخلات، وطبقة المخرجات، والطبقة الخفية)، ويعتبر الوزن هو العنصر الرئيسي في الشبكات العصبية الاصطناعية (ANN) ويعبر عن

الأهمية النسبية للبيانات التي تم ادخالها أو الروابط المختلفة التي تتقل البيانات من طبقة الي طبقة أخرى. كما تم التعرض إلى نوعين من الشبكات العصبية (الشبكات العصبية أمامية التغذية، الشبكات العصبية عكسية التغذية)، أما عن مجالات تطبيق الشبكات العصبية الاصطناعية (ANN) فقد تم التركيز على استخدامها كأداة هامة في تطوير وتحسين وظائف ودور المحاسبة فيما يخص عملية التنبؤ بالتكاليف، ولتوضيح ذلك تم التعرض للدراسات السابقة التي تناولت نماذج الشبكات العصبية الاصطناعية (ANN) في تقدير التكاليف بالمقارنة مع الأساليب الرياضية والأحصائية الأخرى، وأظهرت معظم نتائج الدراسات تفوق نماذج الشبكات العصبية عن غيرها من الأساليب، ومدى دقة النتائج الخاصة بالتكلفة التقديرية للمنتج وخاصة خلال المراحل الأولى من تصميم وابتكار المنتج، كما أوضحت نتائج الدراسات مدى فعالية هذه النماذج عندما يتم استخدامها مع نظم قياس التكلفة مثل نظام التكلفة على أساس النشاط (ABC).

لذلك يستخلص الباحث بناءً على تحليل وتقييم ما تناولته الدراسات السابقة، أن التنبؤ بالتكاليف بشكل صحيح يساعد في تطوير المحاسبة الإدارية من خلال المساعدة في تطبيق العديد من الأساليب الحديثة للمحاسبة الإدارية ومنها إمكانية تطبيق اسلوب التكلفة المستهدفة، والتحديد الدقيق لمسببات التكلفة وبالتالي التطبيق الصحيح لنظام التكلفة على أساس النشاط، كما يسهل من تحليل سلسلة القيمة، كما يمكن الاستفادة من تقدير التكاليف في التخطيط الاستراتيجي للمنتج خاصة في مرحلة التصميم، ويساعد أيضاً تقدير التكاليف على تعزيز الموقف التنافسي للمنشأة وزيادة قدرتها على تطوير منتجات جديدة. وأخيراً يتفق الباحث مع نتائج الدراسات السابقة على أن استخدام الشبكات العصبية الاصطناعية (ANN) يعمل على تحسين عملية التنبؤ بالتكاليف بصورة أدق.

وأخيراً، توصل الباحث إلى أن نماذج الشبكات العصبية الاصطناعية (ANN) استطاعت التنبؤ بجميع المدخلات الخاصة بالمنشأة محل البحث سواء على مستوى المتغيرات المستقلة أو على أساس السنوات التي تم تغذية الشبكة بها، وهو ما يعتبر من أهم مزايا الشبكات العصبية، على عكس أسلوب تحليل الانحدار الذي يحتاج إلى بيانات فعلية ومحددة عن السنة التي يتم فيها التنبؤ. كما توصل الباحث إلى أن استخدام نماذج الشبكات العصبية الاصطناعية (ANN) أدى إلى نتائج أكثر دقة مقارنة باستخدام أسلوب الانحدار المتعدد، وهذا ما يثبت الإجابة على السؤال الرئيسي للدراسة.

6-4-2 التوصيات

- بالإضافة إلى ما عكسه النتائج السابقة من توصيات يوصى الباحث بما يلي:
- ضرورة الاهتمام بإجراء المزيد من البحوث فى طرق تقدير التكاليف، فعملية تقدير التكاليف تعتبر الخطوة الأولى والرئيسية لإدارة التكلفة لإتخاذ القرارات الاستراتيجية .
- إجراء المزيد من البحوث والدراسات على تطبيق نماذج الشبكات العصبية الاصطناعية (ANN) فى مجالات محاسبية أخرى مثل المراجعة، والمحاسبة المالية، والمحاسبة الإدارية البيئية والاجتماعية.
- الاهتمام بتطبيق البرامج والأدوات الحديثة القائمة على الذكاء الاصطناعى ومنها نماذج الشبكات العصبية ونماذج الحينات الوراثية، وإمكانية الاستفادة منها فى بيئة الأعمال المصرية وخاصة القطاعات المالية وأسواق رأس المال لما لها من قدرة هائلة على التعامل مع البيانات ذات الأحجام الكبيرة والمعقدة .
- زيادة الاهتمام من قبل الباحثين بدراسة نظم معلومات المحاسبة الإدارية، لما لها من آثار داخلية وخارجية على الأداء، وذلك من خلال تطوير استخدام الأساليب الكمية باستخدام الشبكات العصبية، ومن ثم تطوير المحاسبة الإدارية.
- ضرورة توافر البرامج الخاصة بالشبكات العصبية فى المؤسسات التعليمية والجامعات، والتدريب والتعلم على كيفية عملها والاستفادة منها فى البحث العلمى وإجراء البحوث.
- تكنولوجيا المعلومات فى حياتنا، لذلك يجب ضرورة الاهتمام بها لما لها من قدرة هائلة على حل المشاكل المعقدة بطرق مختلفة وبالأخص تلك المشاكل التى تواجه المحاسبة الإدارية بصفة عامة، والمحاسبين الإداريين بصفة خاصة.

مراجع البحث

أولاً: المراجع العربية

- أرسانيوس، بدر نبيه، (2006)، "تطوير دور المراجع الخارجى فى التقرير عن القوائم المالية المضللة باستخدام الشبكات العصبية - دراسة تطبيقية"، مجلة الدراسات المالية والتجارية ، كلية التجارة ، جامعة بنى سويف ، العدد الأول.

- الجراح، نوال علاء الدين، (2011)، "كفاءة طريقتى الشبكات العصبية وطريقة بوكس جنكنز فى التنبؤ مع حالات تطبيقية فى العراق"، مجلة الإدارة والاقتصاد، كلية الإدارة والاقتصاد، الجامعة المستنصرية، العدد 89.
- السجاعي، عبد الباسط السجاعي، (2012)، "استخدام الشبكات العصبية لتحسين كفاءة وفعالية الأداء البيئى وانعكاستها على القوائم المالية- دراسة نظرية تطبيقية"، رسالة ماجستير غير منشورة، كلية التجارة، جامعة بنها.
- السيد، الشيماء إبراهيم، (2012)، "التنبؤ باستخدام الدمج بين الشبكات العصبية الاصطناعية ونماذج بوكس وجيبكينز - دراسة تطبيقية"، رسالة ماجستير غير منشورة، كلية التجارة، جامعة المنصورة.
- الشرقاوى، محمد على، (1996)، "الذكاء الاصطناعى والشبكات العصبية" الكتاب الأول ضمن سلسلة علوم تكنولوجيا وحاسبات المستقبل، مركز الذكاء الاصطناعى للحاسبات.
- جاب الله، سامية طلعت عباس، (2004)، "استخدام الشبكات العصبية فى مجال المحاسبة والمراجعة"، المجلة العلمية للاقتصاد والتجارة ، كلية التجارة ، جامعة عين شمس، العدد الثانى.
- جرجس، ماريان أسحق، (2012)، "أثر التكامل بين نموذج تحليل التمايز والشبكات العصبية فى دعم المحاسبة الإدارية بهدف رفع كفاءة الأداء المالى فى القطاع المصرفى- دراسة نظرية تطبيقية"، رسالة ماجستير غير منشورة، كلية التجارة، جامعة بور سعيد.
- دسوقى، محمد أحمد، (2002)، "استخدام اسلوب تحليل الشبكات العصبية فى معايرة عناصر تكاليف العمالة فى الشركات الصناعية"، مجلة الدراسات المالية والتجارية، كلية التجارة ،جامعة بنى سويف، العدد الثالث.
- سيد، كريمة أحمد، (2010)، "تحسين دقة التنبؤ بالأرباح باستخدام الشبكات العصبية الاصطناعية- دراسة ميدانية"، رسالة ماجستير غير منشورة ، كلية التجارة ، جامعة الأزهر، فرع البنات.

- عبد الرحمن، سلوى عبد الرحمن، (2011)، "إطار مقترح لتطوير الموازنة التشغيلية باستخدام نماذج الشبكات العصبية والإطار الجيني"، رسالة دكتوراه غير منشورة، كلية التجارة، جامعة طنطا.
- مبارز، شعبان يوسف، (1996)، "تقييم وتصنيف القوائم المالية للشركات بهدف إعادة هندسة عملياتها مالياً باستخدام الشبكات العصبية الاصطناعية"، مجلة الدراسات المالية والتجارة، كلية التجارة، جامعة القاهرة، فرع بنى سويف، العدد الثالث.
- متولى، طلعت عبد العظيم، (2001)، "استخدام تقنيات الشبكات العصبية فى التنبؤ باستمرارية الوحدة المحاسبية بالتطبيق على شركات قطاع الأعمال المصرى"، المجلة العلمية للتجارة والتمويل، كلية التجارة، جامعة طنطا، العدد الثانى.
- مصطفى، عصام حمدى، (2017)، "تصميم نموذج محاسبي لتقييم مخاطر الائتمان باستخدام الشبكات العصبية، الجينات الوراثية والاستدلال المبنى على الحالات السابقة - دراسة تطبيقية"، رسالة دكتوراه غير منشورة، كلية التجارة، جامعة الإسكندرية.

ثانياً: المراجع الأجنبية

- AL- Mashari,M., (2001), "Process Orientation Through Enterprise Resource Planning (ERP) : A Review of Critical Issues" *Knowledge and process Management* , Vol.3 , No.3 , PP. 175- 185.
- Amdee,N., Sonthipermpoon1,K., , Pongpattanasili1,C., Kreangsak Tamee,K., and Kritworakarn, C., (2016), "ANNs in ABC Multi-driver Optimization based on Thailand Automotive Industry", *Engineering Journal*, Vol. 20, Issue 2.
- Babad,Y and Balachandran,B., (1993)," cost driver optimization in activity based costing", *American Accounting Association*, Vol.68 , No.3 , PP.563-575.
- Cavalieri,S., Maccarrone,P., and Pinto,R., (2004), " Parametric Neural Network Models for the Estimation of production Costs: a case study in the automotive industry", *Int J Prod Econ.*,Vol. 91, PP.165-177.
- Chang,P., Lin,J., and Dzan,W., (2012), "Forecasting of manufacturing cost in mobile phone products by case-based reasoning and artificial neural network models", *J Intell Manuf*,Vol.23, PP.517-531.
- Chen,H., Huang, S., and Kuo,C., (2009), "Using the artificial neural network to predict fraud litigation: Some empirical evidence from emerging markets", *Expert Systems With Application*, Vol.36, No.2, pp.1478-1484.
- Detienne, K., Detienne, D., and Joshi, S., (2003), " Neural Networks as Statistical Tools for Business Researchers", *Organizational Research Methods*, Vol.6, No.2, pp.236-265.
- Duran,O., Rodriguez, N., and Consalter, L., (2008), "Neural Networks for Cost Estimation of Shell and Tube Heat Exchangers", *Proceedings of the*

International Multi Conference of Engineers and Computer Scientists,
Vol. II, PP. 978-988.

- Garza.J. and Rouhana.K., (1995), "Neural Networks versus Parameter-Based Applications in Cost Estimating", *Cost Engineering*, Vol.37 , No.2 , PP. 14- 18.
- Gerstner, W., and Kistler, W., (2002), "Spiking Neuron Models Single Neurons", *populations Plasticity*.
- Greese,R and Li, L., (1995), "Cost Estimation of Timber Bridges using Neural Network ", *Cost Engineering*, Vol.37 , No.5 , PP.17-22.
- Huang,S.Y. , Huang,S.M. , Wu, T.H.and Lin,W., (2009), "Process Efficiency of the Enterprise Resource Planning Adoption", *Industrial Management and Data Systems* , Vol. 109, No. 8, pp. 1085-1100.
- Kim, G., An, S., and Kang, K., (2004), " Comparison of Construction Cost Estimating Models based On Regression Analysis, Neural Networks And case-based reasoning", *Build Environ*, Vol. 39, PP.1235-1242 .
- Kim, K., and Han, I., (2003), "Application of Hybrid Genetic Algorithm and Neural Networks Approach in Activity based Costing", *Expert System with Application*, Vol. 24, PP.73-77.
- Layon,S and Ying,W., (1996), "Neural Network Model environmental Prediction Case Study for China", *Computer and Industrial Engineering*, Vol.3 , No.3 , PP.879-883.
- Lyne,R., and , Maximino, O., (2014), "An Artificial Neural Network Approach to Structural Cost Estimation of Building Projects in the Philippines", *Presented at the DLSU Research Congress*, De La Salle University, Manila, Philippines.

-
- Makim,R., (1993) ,"Neural Network and Identification to Cost Engineering", *Cost Engineering*, Vol.35 , No.7 , PP.31-35.
 - Oslan,D and Mossman,C., (2003), "Neural Network Forecasts of Canadian stock returns using Accounting Ratios", *international journal of Forecasting*, Vol.19 , No.3 , PP.453-465.
 - Ozcan, B., and Figlalı, A., (2014)," Artificial Neural Networks for the Cost Estimation of stamping dies", *Neural Comput & Applic*, Vol. 25, pp. 717-726.
 - Rajasekaran,S., and Pai, G., (2003), "Neural Networks, Fuzzy Logic, and Genetic Algorithms Synthesis and Applications.", *Prentice-Hall of India*, New Delhi, p.31.
 - Ruffo,M., Tuck,C., and Hangu, R., (2006), "Cost Estimation for Rapid Manufacturing – laser sintering production for low to medium volumes", *Engineering Manufacture*, Vol.220 , , PP.1417-1427.
 - Sadrzadehrafiei,S.,Chofrehb,A.,Hosseinia,N.,andSulaimana,R.(2013), "The Benefits of Enterprise Resource Planning (ERP) System Implementation in Dry Food Packaging Industry", *The 4th International Conference on Electrical Engineering and Informatics (ICEEI 2013)*, Available online at www.sciencedirect.com.
 - Shtub,A. and Versano,R., (1999), "Estimation Cost of steel pipe bending, a Comparison between Neural Networks and Regression Analysis", *international journal of production economics*, Vol.62 , PP. 201- 207.
 - Smith, Aand Leksan,M ., (1991), "A Manufacturing Case study on Activity Based Costing", *Journal of Cost Management*, Vol.5 , No.2 , PP.45-54.
 - Urkmez,S., Bilgili,E., Ziarati,R., and Stockton,D., (2008), " Application of Novel Artificial Intelligent Techniques in Ship Building Using Activity

Based Costing and Neural Networks", *De Montfort University, UK, Piri Reis University, Turkey.*

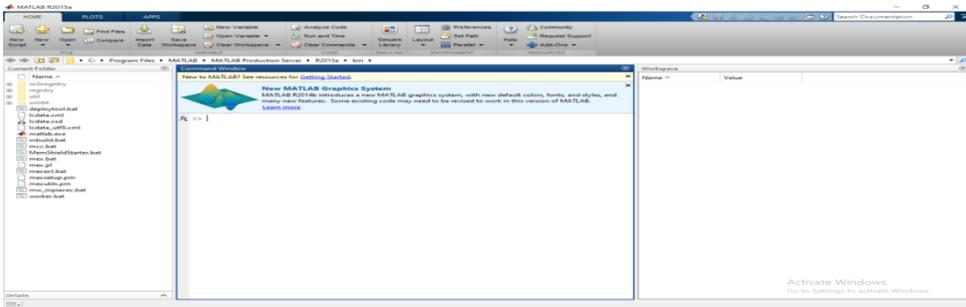
- Wanderley, C., and Cullen, J., (2012), "A Case of Management Accounting Change: the Political and Social dynamics", *Revista Contabilidade & Finance.*
- Weckman, G., Paschold, H., Dowler, J., Whiting, H., and Young, W., (2010), "Using Neural Networks with Limited Data to Estimate Manufacturing Cost", *Journal of Industrial and Systems Engineering*, Vol. 3, No. 4, pp 257-274.
- Zhang, YF., and Fuh, JYH., (1998), "A Neural Network Approach for early Cost Estimation of packaging products.", *Comput Ind Eng*, Vol.34 , No.2 , PP.433-450.

ملاحق البحث

الملاحق الخاصة بخطوات Nural Network Feed – Forward Back propagation بت تشغيل برنامج

ملحق (1)

النافذة الرئيسية لبرنامج Matlab



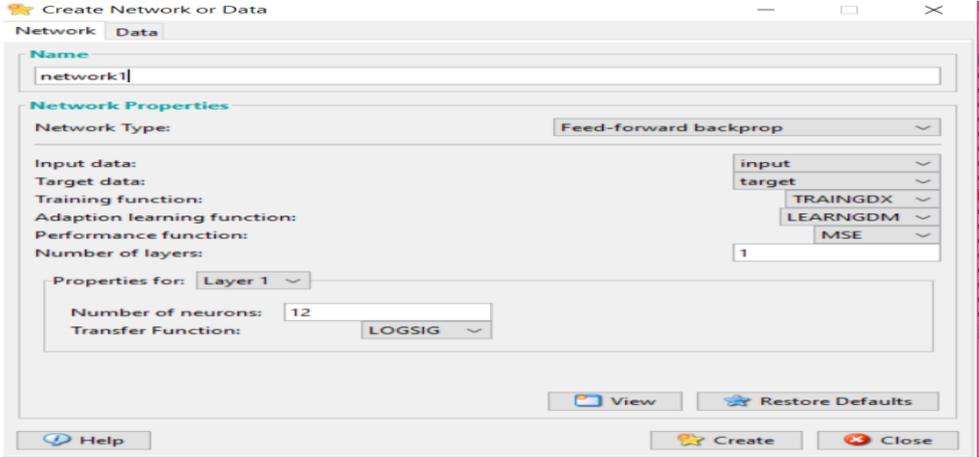
ملحق (2)

طريقة إدخال بيانات المتغيرات المستقلة وبيانات المتغير التابع

target	1	2	3	4	5	6	7	8	9	10
1		73095631	74762352	82747145	86287201	102646297	116165594	117972099	128060379	230831
2										
3										
4										
5										
6										
7										
8										
9										
10										
11										
12										
13										
14										
15										
16										
17										
18										
19										
20										
21										
22										
23										
24										
25										
26										

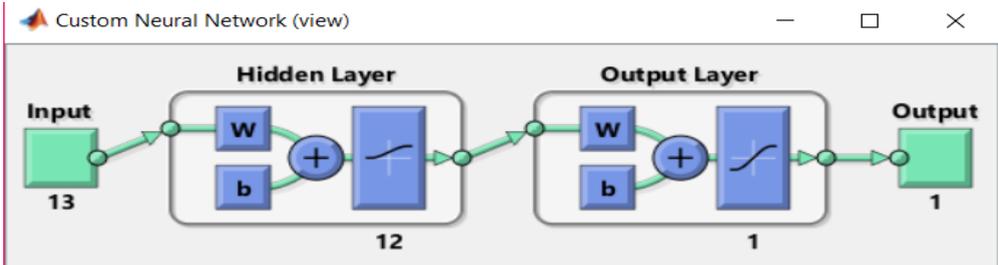
(3) ملحق

اختيار نوع الشبكة وادخال الأوامر للشبكة لتحديد طبقة المدخلات والطبقة الخفية وطبقة المخرجات



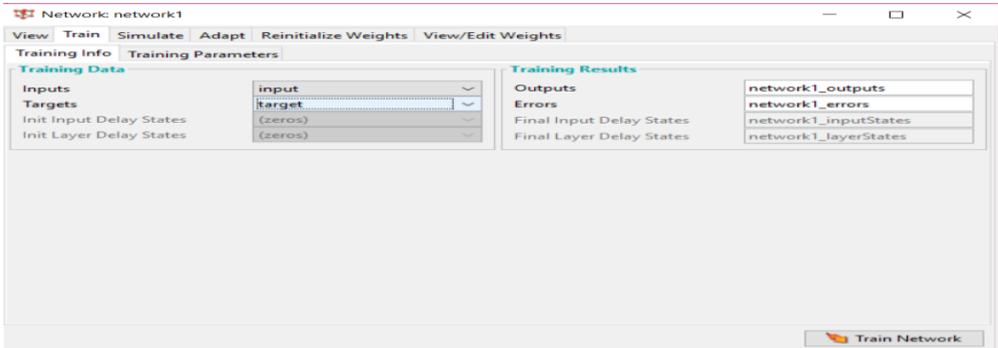
(4) ملحق

الشكل النهائي للشبكات العصبية



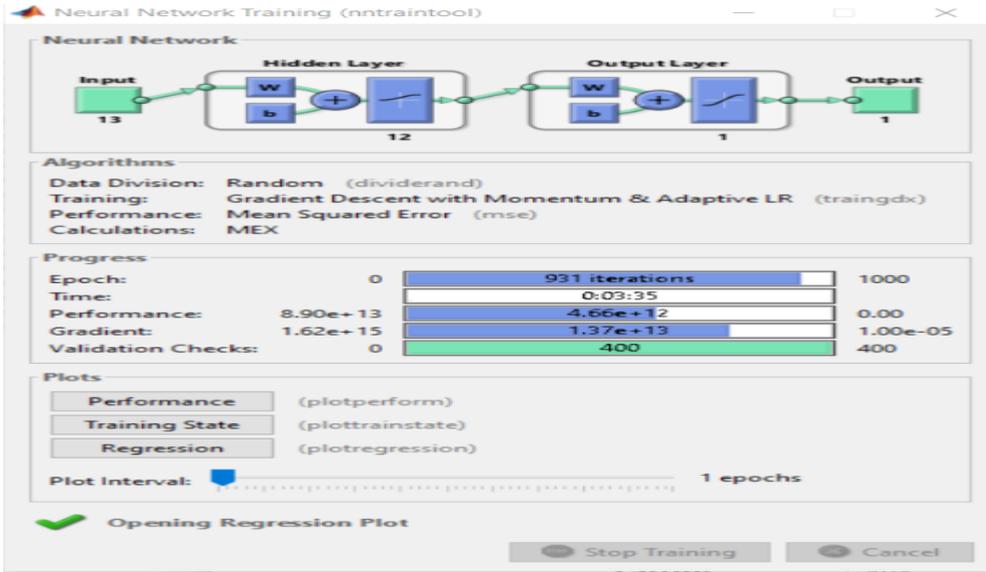
(5) ملحق

الشاشة الخاصة بتهيئة الشبكة للتدريب



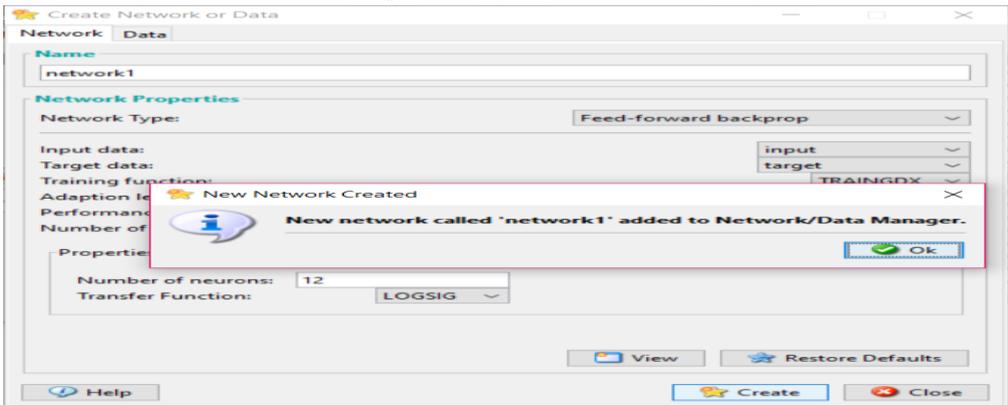
ملحق (6)

الشاشة الخاصة بتهيئة الشبكة للتدريب

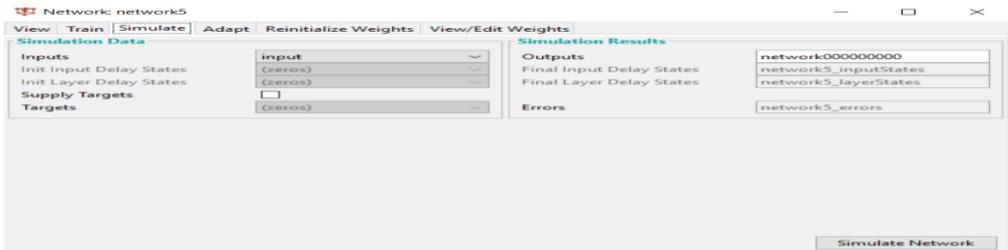


ملحق (7)

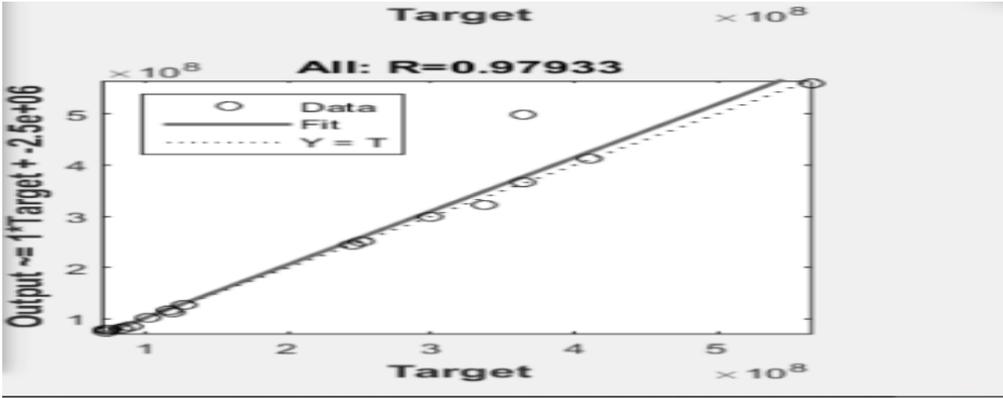
النتائج الخاصة بالتدريب



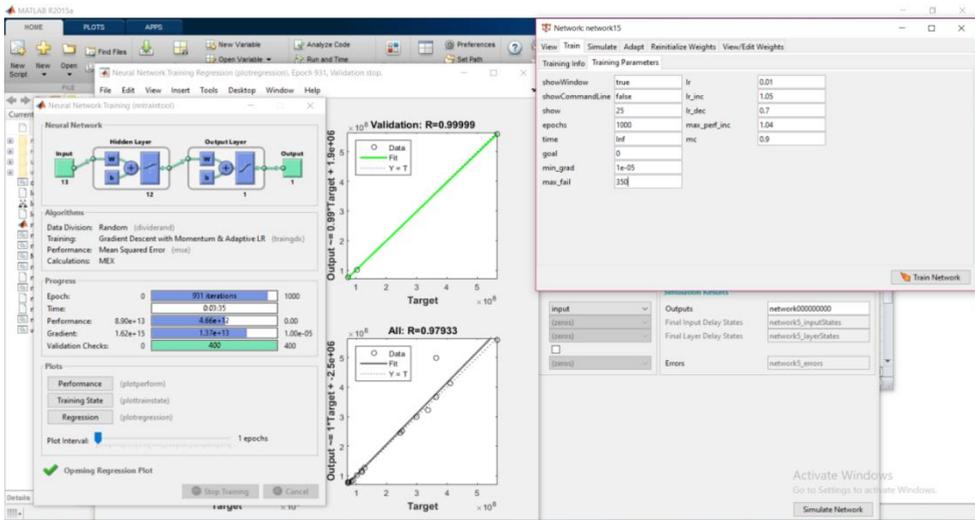
ملحق (8)



ملحق (9) النتائج النهائية للإختبار



ملحق (10) شكل مجمع لجميع نتائج الإختبار



الملاحق الخاصة بتحليل الإنحدار

Regression - Results

Control the Display of Results

- Display nothing
- Regression equation, table of coefficients, s, R-squared, and basic analysis of variance
- In addition, sequential sums of squares and the unusual observations in the table of fits and residuals

Response: y

Predictors: x1 x2 x3 x4 x5 x6 x7 x8 x9 x10 x11 x12 x13

Buttons: Graphs..., Options..., Results..., Storage..., OK, Cancel

Regression - Graphs

Residuals for Plots:

- Regular
- Standardized
- Deleted

Residual Plots

- Histogram of residuals
- Normal plot of residuals
- Residuals versus fits
- Residuals versus order
- Four in one

Residuals versus the variables:

Response: y

Predictors: x1 x2 x3 x4 x5 x6 x7 x8 x9 x10 x11 x12 x13

Buttons: Graphs..., Options..., Results..., Storage..., OK, Cancel

Regression - Storage

Diagnostic Measures

- Residuals
- Standardized residuals
- Deleted y residuals
- R (leverage)
- Cook's distance
- DFBETAs

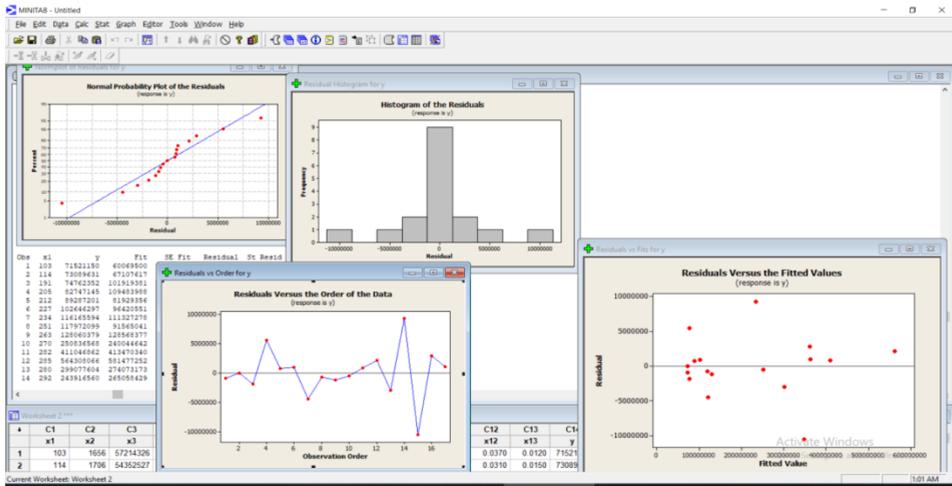
Characteristics of Estimated Equation

- Coefficients
- t-ratios
- MSE
- R-squared
- F-ratio
- F1 matrix

Response: y

Predictors: x1 x2 x3 x4 x5 x6 x7 x8 x9 x10 x11 x12 x13

Buttons: Graphs..., Options..., Results..., Storage..., OK, Cancel



Regression Analysis: y versus x1, x2, ...

The regression equation is

$$y = -1.10E+08 - 85357 x_1 + 58284 x_2 + 0.547 x_3 + 0.31 x_4 + 22496095 x_5 - 2.41E+08 x_6 - 42320443 x_7 - 1466 x_8 - 265803 x_9 + 5728279 x_{10} + 793x_{11} - 5333090 x_{12} + 2.56E+08 x_{13}$$

Predictor	Coef	SE Coef	T	P
Constant	-109535722	192950966	-0.57	0.610
x1	-85357	308326	-0.28	0.800
x2	58284	93321	0.62	0.577
x3	0.5473	0.3275	1.67	0.193
x4	0.309	1.342	0.23	0.833
x5	22496095	263558281	0.09	0.937
x6	-240887517	613529203	-0.39	0.721
x7	-42320443	174743074	-0.24	0.824
x8	-1466	14485	-0.10	0.926
x9	-265803	4512476	-0.06	0.957
x10	5728279	8047893	0.71	0.528
x11	792.5	733.0	1.08	0.359
x12	-5333090	1012098897	-0.01	0.996
x13	255842221	553706323	0.46	0.675

S = 9626214 R-Sq = 94.7% R-Sq(adj) = 71.6%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	13	3.61907E+17	2.78390E+16	300.43	0.000
Residual Error	3	2.77992E+14	9.26640E+13		
Total	16	3.62185E+17			

Source	DF	Seq SS
x1	1	1.95868E+17
x2	1	1.18156E+16
x3	1	1.52946E+17
x4	1	6.84694E+14
x5	1	3.21291E+13
x6	1	1.69450E+12
x7	1	3.13999E+14
x8	1	2.81526E+12
x9	1	2.90922E+13
x10	1	4.79238E+13
x11	1	1.43964E+14
x12	1	1.31427E+12
x13	1	1.97832E+13

Obs	x1	y	Fit	SE Fit	Residual	St Resid
1	103	71521150	60069500	72806629	11451650	0.30
2	114	73089631	67107617	76550819	5982014	0.20
3	191	74762352	101919381	71625903	-27157029	-0.67
4	205	82747145	109483988	73108149	-26736843	-0.70
5	212	89287201	81929356	81282841	7357845	0.55
6	227	102646297	96420551	71963922	6225746	0.16
7	234	116165594	111327278	77118018	4838316	0.17
8	251	117972099	91565041	70702858	26407058	0.62
9	263	128060379	128568377	82237500	-507998	-0.11
10	270	250836568	240044642	79956714	10791926	0.54
11	282	411046862	413470340	80316891	-2423478	-0.13
12	285	564308066	581477252	81726664	-17169186	-1.66
13	280	299077604	274073173	77788267	25004431	0.92
14	292	15645	65058429	71206986	-65042784	-1.57
15	316	337299684	246689427	58003044	90610257	1.55
16	323	264738542	329610232	65561581	-64871690	-1.30
17	340	363975516	348735751	74571431	15239765	0.44