استخدام أسلوب الشبكات العصبية الاصطناعية في التنبؤ بحجم المبيعات في المؤسسة الجزائرية (دراسة تطبيقية)

أ. بوادو فاطيمة

طالبة دكتوراه – جامعة ابن خلدون– تيارت/ الجزائر

note22@hotmail.fr

د. مداني بن شهرة

أستاذ محاضر(أ)، جامعة ابن خلدون– تيارت/ الجزائر جامعة قالمة / الجزائر

madani_benchohra@yahoo.fr

ملخص:

تهدف هذه الورقة البحثية في محاولة تطبيق أسلوب السلاسل الزمنية من خلال تقنية الشبكات العصبية الاصطناعية في التنبؤ بحجم المبيعات في مؤسسة سونلغاز بشلف / الجزائر، وقد أجريت هذه الدراسة على البيانات الشهرية لمبيعات الكهرباء بـ KWh - خلال الفترة الزمنية من جانفي 2006 إلى ديسمبر 2012. حيث تم بناء نماذج الشبكات العصبية باستخدام شبكة البيرسبترون متعدد الطبقات (MLP) والذي تكونت بنيته المعمارية من ثلاث طبقات (طبقة مدخلات "2"، طبقة خفية "3"، طبقة مخرجات "1") واستخدمت الدالة اللوجستية كدالة تحفيز في الطبقة الخفية وفي طبقة المخرجات واستخدم لتدريب هذه الشبكات خوارزمية الانتشار السريع.

وقد بينت نتائج الدراسة أن الشبكة الناتجة جيدة وأعطت تنبؤات دقيقة وقريبة من الواقع في الفترة من 1 جانفي إلى غاية 31 ديسمبر 2013.

الكلمات المفتاحية: التنبؤ، الشبكات العصبية الاصطناعية، شبكة البيرسبترون Perceptron .

Résumé

Le but de ce papier dans une tentative pour appliquer la méthode de la série de temps grâce à la technique des réseaux de neurones artificiels pour prédire le volume des ventes dans l'institution Sonelgaz : Chlef /Algérie, cette étude a été menée sur des données mensuelles pour les ventes (kWh) d'électricité au cours de la période de janvier 2006 -décembre 2012, où il a

été construit des modèles de réseaux de neurones utilisant le réseau Perceptron multicouche (MLP), qui a formé son architecture en trois couches (la couche d'entrée "2", couche cachée "3", les sorties de la couche "1") et utilisé la fonction de logistique en fonction des mesures de relance dans la classe caché dans la production de la couche et utilisé pour former ces réseaux algorithme propagation rapide.

Les résultats de l'étude ont montré que le réseau résultant est bon et a donné des prévisions précises et proches de la réalité dans la période allant du 1er Janvier jusqu'au 31 décembre 2013 .

Mots clés: la prévision, les réseaux de neurones artificiels, réseau Perceptron.

مقدمة

يعتبر التطور الاقتصادي لأي بلد ونموه الديمغرافي وكذا التنامي في الاحتياجات اليومية، كلها سبب في الطلب الفائق للطاقة الكهربائية نتيجة لأنها إحدى عوامل التقدم الاقتصادية وتعد كدعم قانوني على المستوى الاجتماعي، التعليمي وغيرهم من المستويات، وباعتبار ذلك تعد الكهرباء عصب هذا الاقتصاد وبالتالي يمكن القول أنها منتوج غير مخزن يتطلب إنتاجها، نقلها، وتوزيعها استثمارات ضخمة وتسيير محكم، وهذا ما يوجب على الشركة الوطنية للكهرباء والغاز ربط سياساتها بما يساعد على تقدمها وتطورها مع الأخذ بعين الاعتبار مبيعات الكهرباء خلال السنوات السابقة من أجل وضع خطة محكمة للوصول إلى نتائج جيدة تزيد من أرباحها.

ومن أجل تلبية الطلب الوطني على منتجاتها لابد لها إتباع إستراتيجية دقيقة لضمان السير الجيد وتحقيق الاستغلال الأمثل لمواردها المتاحة وذلك باستخدام طرق مبنية على أسس علمية تمكنها من ممارسة جميع وظائفها الاقتصادية، حيث يعتبر تطور البارز في الدراسات الاقتصادية هو استخدام طرق القياس الكمية والإحصائية وذلك لتحديد الخصائص وإبراز الاتجاهات العامة للظواهر الاقتصادية والاجتماعية والإدارية وكذا تحليل العلاقات بين الظواهر على أساس علمي دقيق، ومجال الإحصاء والرياضيات قد أعطى العديد من الأساليب الكيفية وكذا الكمية للقيام بالدراسات والبحوث حيث يعتبر التنبؤ بظاهرة ما

في المستقبل أسلوب وتقنية تساعد على فهم سلوك الظاهرة مع الزمن وبالتالي كيفية مواجهتها فلا يمكن عمل خطة مستقبلية لمواجهة الظاهرة إلا بتحديد أبعادها المستقبلية ومعرفة شكل هذه الأبعاد وأنماطها.

فتقنية الشبكات العصبية الاصطناعية تعتبر من بين أهم تقنيات وأساليب القياس الاقتصادي الإحصائية الحديثة وكإحدى أهم طرق التنبؤ فهي تستخدم بكثرة في عدة مجالات لما لها من دقة في نتائجها. فجاءت هذه الدراسة لتساهم في معرفة كيفية بناء نماذج السلاسل الزمنية بما يمكن من التنبؤ الدقيق بمبيعات الكهرباء للسنوات القادمة في مؤسسة الجزائرية بصفة عامة ومؤسسة Sonelgaz بصفة خاصة حيث تعتبر من أقدم المؤسسات التي تؤدي خدمة عمومية فهي تمتلك خبرة طويلة في مجال إنتاج توزيع الكهرباء، وتوزيع الغاز.

إشكالية البحث:

تحكم المؤسسة العديد من العوامل الداخلية و الخارجية تحدد قدرتها على التسيير الأمثل من خلال اعتمادها على أساليب لتقدير حجم مبيعاتها التي تعتبر العامل هام والمهم في زيادة إيراداتها، هذا ما قادنا إلى طرح السؤال التالي:

ما مدى كفاءة تقنية الشبكات العصبية الاصطناعية في الحصول على تنبؤات دقيقة يمكن للمؤسسة الاعتماد عليها مستقبلا؟

من خلال تسليط الضوء على إحدى مؤسسات الاقتصادية الجزائرية، وهي الشركة Sonelgaz بولاية شلف/ الجزائر.

فرضيات البحث:

وقد أدت بنا الإشكالية المطروحة إلى صياغة مجموعة من الفرضيات التي سيتم دراستها واختبار صحتها واستخلاص نتائجها، والتي تتمثل في:

- **الفرضية الأولى:** التنبؤ باستخدام تقنية الشبكات العصبية الاصطناعية من بين أفضل الطرق المستخدمة للتنبؤ المستقبلي؛

- **الفرضية الثانية:** استخدام الطرق الإحصائية في المؤسسات الجزائرية عامة ومؤسسة Sonelgaz – شلف– بصفة خاصة من شأنه تعزيز قدرة الإدارة على توقع مبيعاتها القادمة من الكهرباء بشكل دقيق.

أهمية البحث:

تكمن أهمية هذه الدراسة في التنبؤ بمبيعات الكهرباء خلال السنوات القادمة وذلك باستخدام تقنية الشبكات العصبية الاصطناعية بالاعتماد على بيانات شهرية للمؤسسة والتي تمثل الكميات المباعة للكهرباء متوسطة التوتر خلال الفترة الممتدة من 2006 إلى ديسمبر 2012. بالإضافة إلى أن النتائج التي ستتوصل إليها هذه الدراسة يمكنها أن تساعد المؤسسات الاقتصادية على التنبؤ مبيعاتها المستقبلية وكذا تحسين مستوى أدائها.

منهجية الدراسة و الأدوات المستعملة

حتى نتمكن من دراسة الإشكالية الرئيسية وتحليل أبعادها ومحاولة اختبار صحة الفرضيات اعتمدنا المنهج التحليلي الوصفي من خلاله تم تحليل أهم العوامل التي تؤثر على مبيعات الكهرباء في مؤسسة Sonelgaz بولاية شلف في الفترة الممتدة من جانفي 2006 إلى ديسمبر 2012. ولذلك فقد تم تقسيم البحث إلى محورين هما الجانب النظري والذي تم التطرق فيه إلى مفاهيم وتعريفات نظرية حول كل من التنبؤ باستخدام السلاسل الزمنية وكذا تقنية الشبكات العصبية الاصطناعية المستخدمة في عملية التنبؤ من حيث الشكل العام ومراحل بناء النموذج، في حين يتناول الجانب التطبيقي إجراء دراسة تطبيقية من خلال تطبيق النموذج بالاعتماد على بيانات خاصة بمبيعات الكهرباء متوسطة التوتر للحصول على أمثل نموذج يستخدم للتنبؤ بكمية مبيعات الكهرباء لفترة لاحقة، لنستخلص في الأخير أهم النتائج والاستنتاجات الخاصة بالدراسة. أما الأدوات المستخدمة فهي تتمثل في برنامج Neuro Intelligence Alyuda.

أهدف البحث:

تهدف هذه الدراسة إلى تحليل مبيعات الكهرباء كسلسلة زمنية شهرية خلال الفترة الممتدة (2006-2012) من خلال المرور بخطوات بناء نموذج دقيق باستخدام تقنية الشبكات العصبية الاصطناعية كأحد أهم الطرق الإحصائية المستخدمة في التنبؤ.

أولا: الإطار النظري للدراسة

للتنبؤ أهمية بالغة في جميع المجالات لذلك أخد اهتمام الباحثين وذوي الخبرات في هذا المجال، حيث قاموا بوضع العديد من التقنيات والنماذج التنبؤية واستخدامها للوصول إلى نتائج أكثر دقة ومن بين هذه النماذج تقنية الشبكات العصبية الاصطناعية التي أثبتت كفاءتها في عدة مجالات ومن بينها التنبؤ بالمبيعات.

1. الشبكات العصبية الاصطناعية:

هي إحدى فروع الذكاء الاصطناعي والتي تضم مجموعة من الخلايا العصبية الاصطناعية لمحاكاة طريقة عمل الشبكات العصبية البيولوجية للمخ البشري للتعلم والتذكر المبنية على تجارب وخبرات سابقة مكتسبة، وكذا التمكن من استخدام الحاسبات لتطبيق النماذج والأساليب اللامعلمية في تحليل البيانات المرتبطة بعلاقات لاخطية غير محددة بشكل دقيق.[1] تستخدم كطريقة حسابية تشبه إلى حد ما عمل الدماغ في انجاز المهام،[2] مكونة من وحدات معالجة بسيطة تسمى العصبون أو عقد التي تقوم بتخزين المعرفة عن طريق ضبط الأوزان.

[1]- مصطفى كمال إسماعيل مظهر، أفضل مزيج لسياسات إعادة التأمين في السوق المصري باستخدام المحاكاة بالشبكات العصبية الاصطناعية، مجلة الدراسات والبحوث التجارية، السنة الرابعة والعشرون، العدد الأول، 2003، مصر، ص211.

[2]- عائدة يونس مُحَمَّد المراد، مقارنة بين الانحدار الكلاسيكي والشبكات العصبية الاصطناعية في التنبؤ بمستويات نتائج بحوث طلبة كلية التربية الرياضية، المجلة العراقية للعلوم الإحصائية، جامعة الموصل، 2012، ص289.

وعرفت أيضا على أنها:[3]

- هي نظم معلومات محوسبة مصممة على غرار بنية الدماغ وبمحاكاة طريقة عمله؛
- تعتبر نظم معلومات ديناميكية تتعلم من التجربة؛
- تعتبر بذبذبة الأموال بصفة عامة؛
- تعمل بطريقة المعالجة المتوازية؛
- تربط القرارات داخل المؤسسة مع القرارات خارجها للوصول إلى القرار الصحيح؛
- تتعامل مع التقديرات الاحتمالية (عدم التأكد).

كما تتميز الشبكات العصبية الاصطناعية بالخصائص التالية: [4]

- القدرة على اشتقاق المعنى من البيانات المعقدة أو الغير دقيقة؛
- القدرة على التعلم كيفية القيام بمهام الاعتماد على البيانات بواسطة التدريب أو التجربة الأولية؛
- بإمكانها خلق تنظيمها الخاص، وتمثيل البيانات التي تستلمها أثناء عملية التعلم؛
- حسابات الشبكات العصبية الاصطناعية قد تنفذ بشكل متوازي.

2. مكونات الشبكات العصبية الاصطناعية

تتكون شبكة العصبية الاصطناعية من مجموعة عصبونات متصلة ببعضها البعض مما يسمح بوصول المعلومة. والعصبون الاصطناعي هو وحدة معلوماتية أساسية تعمل كنظام بسيط يقوم بجمع المرجح للمدخلات والمتمثلة في المعلومات التي يتلقاها من العصبونات المتصلة به، ثم يطرح من ذلك الجمع قيمة

[3]– شيماء أبو المعاطي عبد المطلب، استخدام أسلوب الشبكات العصبية في زيادة فعالية المراجعة الضريبية في ظل التحديات المعاصرة، المؤتمر الضريبي الثامن عشر، 28/26 يونيه 2012، ص 04.

[4]– فروم محمد الصالح وآخرون، مداخلة بعنوان: دور أنظمة المعلومات المعتمدة على الذكاء الاصطناعي في عملية صنع القرارات الإدارية، الملتقى الوطني السادس حول دور التقنيات الكمية في اتخاذ القرارات الإدارية، سكيكدة، يومي 27 و29 جانفي 2009.

معينة تدعى العتبة، ويطبق على النتيجة المتحصل عليها دالة التنشيط ويعطي جوابا على شكل قيمة رقمية تعبر على قيمة نشاط العصبون[5].

الشكل (01): مكونات الشبكات العصبية الاصطناعية

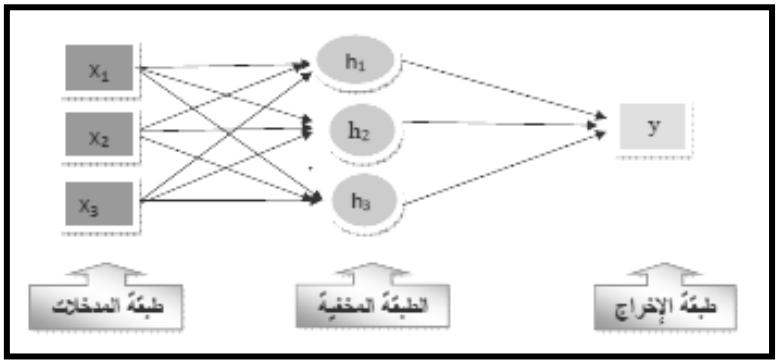

المصدر: هيام عبد المجيد حياوي، قصي أحمد طه، دراسة سلسلة الأوراق المالية باستخدام ARIMA وANN وPMRS، المجلة العراقية للعلوم الإحصائية، العدد 23، 2013، ص 101.

حيث أن حيث أن الشبكة العصبية متكونة من ثلاثة مستويات، وكل مستوى يتضمن عددًا من العقد:[6]

1-2. المستوى الثالث (المخرجات): أخر مستوى في الشبكة الاصطناعية الذي هو عبارة عن مخرجات الشبكة العصبية.

يتضمن كل مستوى من مستويات الثلاثة السابقة كلا من:[7]

---

[5]- عبادي محمد، **الشبكات العصبية الاصطناعية أداة لتقدير المخاطرة في البنوك التجارية**، الملتقى الوطني حول المنظومة المصرفية، المركز الجامعي جيجل، ص 09.

[6]- ايفان علاء ناظم، **دراسة وتحليل مستوى التذبذب للتضخم في الأرقام القياسية بالاعتماد على السلاسل الزمنية مقرونة مع نماذج الشبكات العصبية الاصطناعية**، مجلة كلية الرافدين الجامعة للعلوم، العدد 31، 2013، ص80.

[7]- هيام عبد المجيد حياوي، مرجع سبق ذكره، ص 101.

العقد (العصبونات) التي تمثل نقاط الترابط العصبي بين مستويات (طبقات) الشبكة العصبية عبر خطوط ربط ويرفق كل خط بوزن معين.

إذ إن الأوزان تشير إلى مدى قوة الارتباط العصبي بين مستويات (طبقات) الشبكة العصبية. فلكل عقدة وزن يربطها مع المستوي السابق، ووزن يربطها مع المستوي اللاحق، فضلا عن وجود التحيز Bias(b) الذي يعد أحد مكونات متجه الإدخال ويأخذ القيمة (X_0=1) دائما في متجه الإدخال $X=(1, X_1,\ldots, X_n)$، ويشبه عمل التحيز عمل الوزن الرابط بين الوحدات ولكنه يملك تنشيطًا ثابتًا مساويًا إلى القيمة (1). وان إضافة وحدة التحيز إلى وحدات الإدخال يغير من شكل دالة التنشيط (التفعيل) وفي العادة لا يتم إظهار هذه الوحدات في مخططات الشبكة.

3. استخدامات الشبكات العصبية

تعددت استخدامات الشبكات العصبية بشكل كبير نتيجة للتطور التقني السريع في مجالات الذكاء الاصطناعي وقد اتفق بعض الباحثين على مجموعة مهمة من المجالات التي اختبرت بها الشبكات العصبية والتي من أبرزها يلي:[8]

- العلوم الطبية؛
- قياس مستوى رضا الزبائن؛
- استخدام الشبكات العصبية من قبل المصارف المالية والبحث عن فرص الأسواق المالية وتحديد الأسواق غير الكفوءة؛
- التحليل المالي وقرارات قبول أو رفض القروض المالية المختلفة؛
- منع التلاعب ببطاقات الائتمان وأنواع البطاقات الأخرى بمختلف استخداماتها؛

[8]- المدرس احمد عبد الحسين الإمارة، **تصميم نظام معلوماتي مقترح لدعم كفاءات الكادر الوسطى باستخدام تقنية الشبكات العصبية**، القرى للعلوم الاقتصادية والإدارية، السنة التاسعة، العدد السابع و العشرون، ص 138.

– مساعدة شركات التأمين في منع حالات التلاعب، وعمليات الشراء والرقابة ومتابعة طلبات الزبائن؛

– التنبؤ بمسارات وكشف جرائم القتل ومحاولة منع وقوعها وتزويد الجهات المختصة بالمعلومات المناسبة والمماثلة للاستنتاج البشري.. ؛

– تخفيض تكاليف البحث عن الموارد الطبيعية كعمليات التنقيب عن النفط والغاز.

4. العوامل المؤثرة على كفاءة الشبكة العصبية الاصطناعية

إن جودة التنبؤات المستقبلية لظاهرة معينة التي يمكن الحصول عليها من الشبكة العصبية تعتمد على مدى كفاءة تدرب الشبكة العصبية على بيانات تاريخية لتلك الظاهرة ومن تلك العوامل:[9]

– عامل معدل التعلم؛

– عامل الزخم؛

– عامل عدد المتجهات في الشبكة العصبية؛

– عامل عدد العقد المخفية؛

– عامل عدد المستويات المخفية.

5. فوائد الشبكات العصبية

ومن بين أهم فوائد الشبكات العصبية فيما يلي:[10]

– الذكاء الاصطناعي؛

– التعرف على الأشخاص.

– التعرف على المواقف؛

– التعرف على الأنماط (مثل الكتابة اليدوية أو الصور أو بصمة اليد أو التوقيع) ؛

---

[9] – إيقان علاء ناظم ، **استخدام نماذج الشبكات العصبية الاصطناعية للتنبؤ والمقارنة.**

[10] – صوار يوسف وآخرون، **تقنية الشبكات العصبية الاصطناعية كأحد أساليب ذكاء الأعمال لتسيير مخاطر القروض**، المؤتمر العلمي السنوي الحادي عشر – ذكاء الأعمال واقتصاد المعرفة، 26/23 ابريل، 2012، الأردن، ص89.

– التعرف على الخطوط و الكتابة باليد؛

– التحكم؛

– محاكاة الأنظمة.

6. طرق تعلم الشبكات العصبية

تتعلم الشبكة العصبية عن طريق إعطاءها مجموعة من الأمثلة والتي يجب أن تكون مختارة بعناية لأن ذلك يساهم في سرعة تعلم الشبكة ومجموعة الأمثلة هذه بفئة التدريب وتنقسم طرق تعليم الشبكة العصبية إلى قسمين حسب فئة التدريب التي تعرض على الشبكة ويمكن توضيحها بإيجاز فيما يلي[11]:

6-1.التعليم المراقب بواسطة معلم: تقوم طرق التعلم أو التدريب بواسطة معلم للشبكات العصبية الاصطناعية على فكرة عرض البيانات التدريبية أمام الشبكة على هيئة زوج من الإشكال وهما الشكل المدخل و الشكل المستهدف، مع الملاحظة أن التعلم المراقب يمكن أن يتم بواسطة معلم.

6-2.نمط تصحيح الخطأ: حيث يستخدم هذا النوع من التدريب لتعلم الشبكات الخطية ذات الطبقة التي تستخدم لحل مسائل التقابل الخطي بين المدخلات والمخرجات حيث تقوم الشبكة بحساب إشارة الخطأ من خلال الفرق بين مخرجات العصبون والمخرجات المطلوبة، ويتم تعديل الأوزان عن طريق دالة الخطأ المسماة بتابع الكلفة بهدف تصغير الفارق عن طريق اشتقاق هذا التابع بالنسبة للأوزان الشبكية.

6-3.معتمدة على الذاكرة: حيث يتم تخزين المعلومات المتوفرة عن البيئة في الشبكة العصبية أي تخزين مجموعة التدريب التي هي شعاع المدخلات وشعاع المخرجات المقابل له ويتطلب هذا النوع من التعلم وجود معيار لتحديد تشابه الإشعاع ووجود قاعدة تعلم.

6-4.التعليم غير المراقب بدون معلم: في هذه الطريقة تكون فئة التدريب عبارة عن متجه المدخلات بدون عرض المخرجات على الشبكة، ويطلق عليها طريقة التعليم الذاتي حيث تبني الشبكات العصبية

[11]– أحمد حامي جمعة، **استخدام الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في البيانات المالية– دراسة تطبيقية**، المؤتمر العالمي السنوي الحادي عشر– ذكاء الأعمال واقتصاد المعرفة، 23–26 أفريل 2012، الأردن، ص 204.

الاصطناعية أساليب التعليم على أساس قدرتها على اكتشاف الصفات المميزة لما يعرض عليها من أشكال وأنساق وقدرتها على تطوير تمثيل داخلي لهذه الأشكال وذلك دون معرفة مسبقة وبدون عرض أمثلة لما يجب عليها أن تنتجه وذلك على عكس المبدأ المتبع في أسلوب التعلم بواسطة معلم.

7. الشبكات العصبية المستخدمة

هناك العديد من الشبكات العصبية الاصطناعية المستخدمة في معالجة أنماط البيانات وكل نوع من هذه الأنواع له خصوصية في المعمارية وآلية معالجة المعلومات من خلال عدد ونوع العقد في كل طبقة بالإضافة إلى نوعية دوال التنشيط وآلية تعديل الأوزان وقد تم اختيار شبكة الإدراك العصبية في هذه الدراسة.

7-1. شبكة الإدراك العصبية (PNN)

تعد شبكة الإدراك من أوائل الشبكات التي تم دراستها في منتصف 1950 وهي شبكة وحيدة الطبقة وذات تغذية أمامية وهي من الشبكات التي تتعلم بإشراف .كما إن خوارزمية التعليم لها أكتشفها العالم (Frank Rosenblatt) سنة 1958. وفي سنة 1969 برهن (Minsky and Papert) أن الشبكة تستطيع تعليم الدوال القابلة للفصل الخطي فقط مثل الدوال المنطقية (OR, AND) التي تحوي على نوعين من الإخراج فقط.[12]

فهي واحدة من أهم أنواع الشبكات العصبية هي الشبكة العصبية (Perceptron) وتتكون هذه الشبكة من طبقة المدخلات وطبقة واحدة أو طبقتين من طبقة المعالجة بحيث لا تزيد طبقة المعالجة عن طبقتين، بالإضافة إلى أنها يتم ضبط الأوزان لطبقة واحدة فقط من طبقات الوصلات البينية التي تربط بين الطبقات السابقة، لتبقى الطبقة الأخرى (إن وجدت) ثابتة الأوزان. وهذه الشبكة تتعلم عن طريق

[12]– عمر صابر قاسم، إسراء رستم مُحَّد، **دراسة رياضية تحليلية لخوارزميات الشبكات العصبية في ملائمة نموذج للتشخيص الطبي**، مجلة الرافدين لعلوم الحاسوب والرياضيات، المجلد 10، العدد 1، 2013، ص187.

معلم.ولهذه الشبكة مميزات، من مميزاتها أن بناء برنامج لها سهل جدا. وان تعليم هذه الشبكات العصبية بمرحلتين و هي مرحلة التعليم ومرحلة الاختبار.[13]

2-7.خطوات التنبؤ باستخدام شبكة الإدراك العصبية (Perceptron)

يعد التنبؤ باستخدام الشبكات العصبية من الأساليب الحديثة التي لاقت اهتماما واسعا في عدة مجالات، حيث يمكن تلخيص خطوات التنبؤ باستخدام شبكات العصبية الاصطناعية كما يلي:[14]

-**الخطوة الأولى:** تهيئة الأوزان الابتدائية $w=(w_1,w_2,....w_n)$

-**الخطوة الثانية:** اختيار زوج التدريب.

-**الخطوة الثالثة:** إيجاد قيمة الإخراج الحقيقي (Actual Output)

-**الخطوة الرابعة:** مقارنة الإخراج الحقيقي (Actual Output) مع الإخراج المطلوب (Target Output) أي إذا كان Err=Target-Actual=0 نرجع إلى الخطوة الثانية، وإلا نطبق الخطوة الخامسة.

-**الخطوة الخامسة:** تحديث الأوزان.

-**الخطوة السادسة:** تكرار الخطوات من الخطوة الثانية إلى الخطوة الخامسة إلى أن يتم الحصول على التقارب المطلوب (اقل متوسط الخطأ المطلق (MAE)).

ثانيا: الدراسة التطبيقية

نتطرق في هذا الجانب إلى اختيار الأسلوب الأمثل من بين أنواع الشبكات العصبية الاصطناعية حيث تم استخدام أسلوب شبكة البيرسبترون متعدد الطبقات (MLP) لبناء نماذج الشبكات لبيانات الدراسة.

---

[13]- محمد سرحان الزويني، **تطوير نموذج رياضي للتنبؤ بالإنتاجية الإنشائية في العراق باستخدام شبكة بيرسبترون العصبية الاصطناعية**، مجلة الهندسة والتنمية، المجلد الثامن عشر، العدد الثاني، 2013، ص09.

[14]- عمر صابر قاسم، مرجع سابق، ص188.

1. بيانات الدراسة

لدينا سلسلة زمنية تمثل المبيعات الشهرية للكهرباء بـ KWh تم الحصول عليها من مؤسسة سونلغاز لولاية شلف /الجزائر (الملحق رقم (01). وهذا بفترة زمنية تمتد من جانفي 2006- ديسمبر 2012.

الشكل (02): التمثيل البياني للمبيعات الشهرية للكهرباء MT

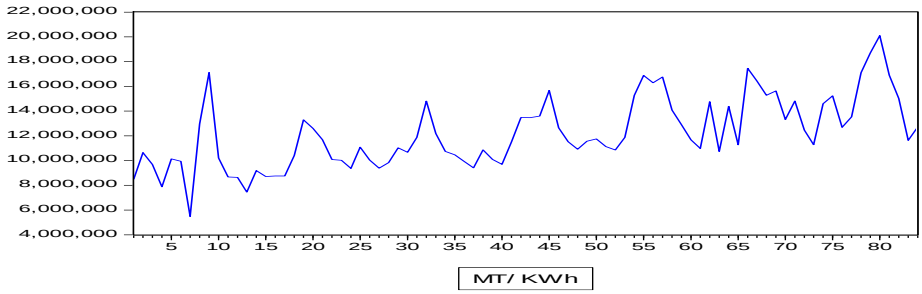

المصدر: مخرجات برنامج Eviews 7 بالاعتماد على معطيات المؤسسة.

2. تحليل الشبكات العصبية الاصطناعية:

تم استخدام أسلوب الشبكات العصبية في بناء نموذج السلسلة محل الدراسة وتم اختيار وتحديد هذه النماذج من خلال عدة مراحل بداية من استخدام أسلوب شبكة البيرسبترون متعدد الطبقات (MLP) لبناء نماذج الشبكة العصبية للبيانات وصولا إلى عملية بناء الشبكة العصبية الاصطناعية وفق المراحل التالية:

2-1. مرحلة تجميع و إعداد البيانات: تم تجميع البيانات المتمثلة في السلسلة الزمنية للمبيعات الشهرية من الكهرباء بـ KWh التي تم الحصول عليها من مؤسسة سونلغاز لولاية شلف /الجزائر. وهذا بفترة زمنية من جانفي 2006– ديسمبر 2012.

حيث تشتمل هذه المرحلة على عمليتين تتمثل في جمع البيانات وتجزئة البيانات المجمعة إلي فئتين هما فئة التدريب (Training set) لتدريب وتجهيز الشبكة وفئة الاختبار للتحقق من صلاحية الشبكة

(Test set) وتمت عملية التجزئة بصورة عشوائية وبعد عدد من المراحل التجريبية من أجل معرفة مدى كفاءة هذه التقنية في تحليل السلاسل الزمنية.

الجدول رقم (01): يمثل نتائج تحليل السلسلة واختبار المعطيات

Analysis	
Time series option	
Period	1
Look ahead (Forecasting)	12
Data Analysis Results	
1 column and 84 rows analyzed	
1 columns and 83 rows accepted for neural network training	
1 numeric columns	MT
Data partition method	
Random	
Data partition results	
57 records to Training set (68,67%	تدريب الشبكة
13 records to Validation set (15,66%)	اختبار صلاحية الشبكة أثناء التدريب
13 records to Test Set (15,66%)	اختبار الشبكة بعد التدريب

المصدر: من إعداد الباحثين باستخدام برنامج Alyuda NeuroIntelligence

-سيتم استخدام 68.67٪ للتدريب الشبكة، أي 57 مشاهدة من العينة.

-سوف تستخدم 15.66٪ (13 مشاهدة) لأجل التحقق من أن الشبكة معممة ووقف التدريب قبل الإفراط في التركيب، بمعنى عندما يصبح التدريب غير مفيد.

-سيتم استخدام النسبة 15.66٪ (13 مشاهدة) المتبقية كاختبار مستقل تماما عن تعميم الشبكة.

2-2. معالجة البيانات Preprocessin

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

الجدول رقم (02): يمثل نتائج معالجة البيانات

Data preprocessing completed	
Columns before preprocessing	2
Columns after preprocessing	3
Input columns Scaling range	[-1..1]
Output column Scaling range	[0..1]
Numeric columns Scaling parameters	
Min	5486590
Max	20102770
Mean	12224948.1566
Std deviation	2799619.08073
Scaling factor column #1	1,37E-07
Scaling factor column #1 : next	6,84E-08

المصدر: من إعداد الباحثين باستخدام برنامج Alyuda NeuroIntelligence

3-2. تحديد تركيبة الشبكة (Design)

يتم اختيار النموذج أو التركيبة الملائمة عادة بناءا علي الغرض من الدراسة وهناك العديد من تراكيب الشبكات العصبية:

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

الجدول رقم (03): نتائج تحديد معمارية الشبكة

Architecture Design	
Number of hidden layers	1
Layer 1 Neurons	2
Network properties	
Parameter	Value
Input activation Fx	Logistic
Output error Fx	Sum of squares
Output activation Fx	Logistic
5 network architecture verified	
[2-1-1] fitness	4,06E-07
[2-7-1] fitness	3,75E-07
[2-4-1] fitness	4,29E-07
[2-5-1] fitness	3,89E-07
[2-2-1] fitness	4,38E-07
[2-3-1] fitness	**4,76E-07**

المصدر: من إعداد الباحثين باستخدام برنامج Alyuda NeuroIntelligence

- **معمارية الشبكة المختارة Active Network**

تكونت من ثلاث طبقات (طبقة المدخلات – الطبقة الخفية – طبقة المخرجات) وهذه الطبقات كاملة الترابط فيما بينها بواسطة الوصلات البينية التي تحمل الأوزان وتم تحديد هذه المعمارية من خلال تجريب عدد من التراكيب المختلفة والمفاضلة بينه من خلال بعض المعايير الإحصائية مثل معامل الارتباط (R) بين مدخلات ومخرجات الشبكة ومعيار أكايكي للمعلومات (AIC) وقد توزعت عناصر المعالجة في طبقات الشبكة الثلاثة كما يلي:

- طبقة المدخلات بها اثنين من عناصر المعالجة ويتم تحديدها في هذه الطبقة بناءا على عدد مدخلات الشبكة.

●الطبقة الخفية عدد عناصر المعالجة في هذه الطبقة تختلف من شبكة إلي أخرى حيث يتم تحديد العناصر هنا عن طريق التجريب والبحث المستمر، وتم الاعتماد علي معامل الارتباط ومعيار (AIC) لتحديد العدد المناسب (3 عناصر).

● طبقة المخرجات وبها عنصر معالجة واحد فقط ويتم تحديدها أيضا بناءا علي مخرجات الشبكة وفي حالة التنبؤ دائما يساوي واحد.

●

الشكل رقم (03): الشبكة [1-3-2] الناتجة أثناء مرحلة. Design

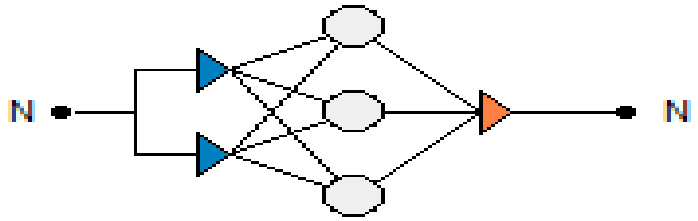

المصدر: :مخرجات البرنامج الإحصائي Alyuda NeuroIntelligence

- **دوال التحفيز وخوارزمية التدريب**

تم الاعتماد علي الدالة اللوجستية logistic function كدالة تحفيز في الطبقة الخفية وكذلك في طبقة المخرجات .

الشكل رقم (04): الشبكة الناتجة

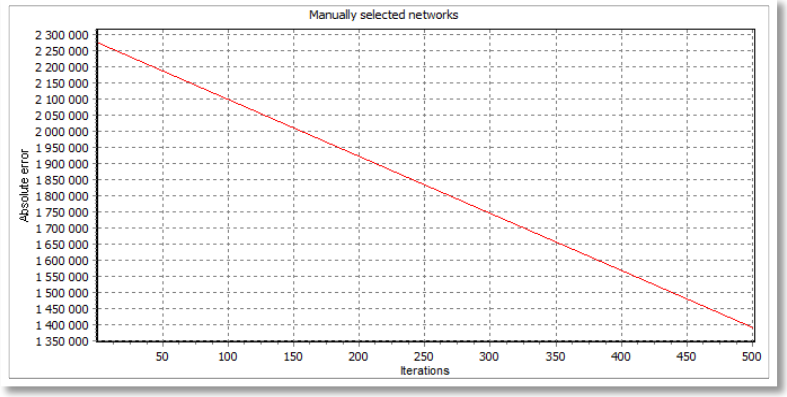

المصدر: مخرجات البرنامج الإحصائي Alyuda NeuroIntelligence

- .

الجدول رقم (04): نتائج خوارزمية تدريب الشبكة الناتجة.

Parameter	**Value**
ID	5
Architecture	[2-2-1]
# of weights	9
Fitness	3,57E-07
Test Error	1736122,25
Akaike s criterion	599,709656
R – squared	0,22559
Correlation	0,606487
Train Error	1817593,625
Stop Reason	All iterations done

المصدر: من إعداد الباحثين باستخدام برنامج Alyuda NeuroIntelligence

4-2. تدريب الشبكة (Training)

يتم تدريب الشبكة بتقديم بيانات التدريب التي تم تجهيزها ومن خلال التدريب تتغير الأوزان بشكل متكرر وباستمرار المحاولات التدريبية تتمكن الشبكة من الحصول علي فئة متوافقة من الأوزان التي تمكننا من الحصول علي المخرجات المطلوبة لكل المدخلات، ويتوقف زمن التدريب علي تركيبة الشبكة وعدد وحدات المعالجات وعدد الطبقات والقيم الابتدائية المختارة للأوزان ومعدل التعلم ويتم التوقف من التدريب عندما يصل خطأ الشبكة إلي المستوي المقبول إحصائيا.

ويتم استخدام خوارزمية الانتشار السريع Quick Algorithm لتدريب الشبكة.

الشكل رقم (05): التمثيل البياني لخوارزمية الانتشار السريع

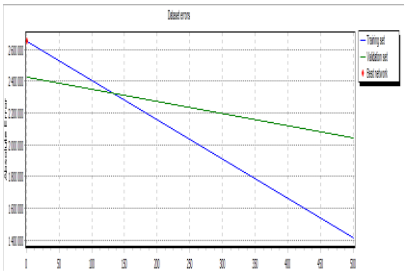

المصدر: بالاعتماد على مخرجات برنامج NeuroIntelligence Alyuda

الشكل رقم (06):الأخطاء والأوزان الناتجة أثناء تدريب الشبكة (Network Statistics)

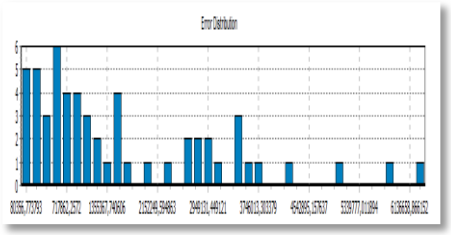

المصدر: بالاعتماد على مخرجات برنامج NeuroIntelligence Alyuda

في هذه المرحلة يتم تحديد خوارزمية التعلم التي تتناسب مع تركيبة الشبكة، حيث تم الاعتماد على الدالة اللوجستية logistic function كدالة تحفيز في الطبقة الخفية وكذلك في طبقة المخرجات.

وتم استخدام خوارزمية الانتشار السريع Quick Algorithm لتدريب الشبكة

.

الجدول رقم (05): قيم المعالم الناتجة أثناء عملية تدريب الشبكة

Parameters		
	Training	Validation
Absolute error:	2648291,64444	2421677,853389
Network error:	0,044654	0
Error improvement:	3,70E-07	
Iteration:	501	
Training speed, iter/sec:	2504,999963	
Architecture:	[2-2-1]	
Training algorithm:	Quick Propagation	
Training stop reason:	All iterations done	

المصدر: بالاعتماد على مخرجات برنامج NeuroIntelligence Alyuda

تم تدريب الشبكة لعدد من المرات المتكررة من اجل تعليم الشبكة وتم التوصل إلى أقل قيمة متوسط الخطأ المطلق (MAE) والذي يساوي: 0.044654 وهذا عن طريق إعادة التدريب، والذي يعكس مدى قدرة هذه التقنية على التنبؤ بحجم المبيعات، من اجل مراقبة عملية التعلم في الشبكة وصغر قيم هذه المعايير أو اقترابها من الصفر في بيانات التدريب والصلاحية يدل علي جودة تعلم الشبكة، وتعتمد هذه المعايير في حسابها علي الأخطاء الناتجة من فرق القيم المخرجة بواسطة الشبكة والقيم الفعلية للسلسلة.

5-2.الاختبار (Test)

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

الشكل رقم (07): البيانات الناتجة أثناء عملية التدريب مع البيانات الفعلية

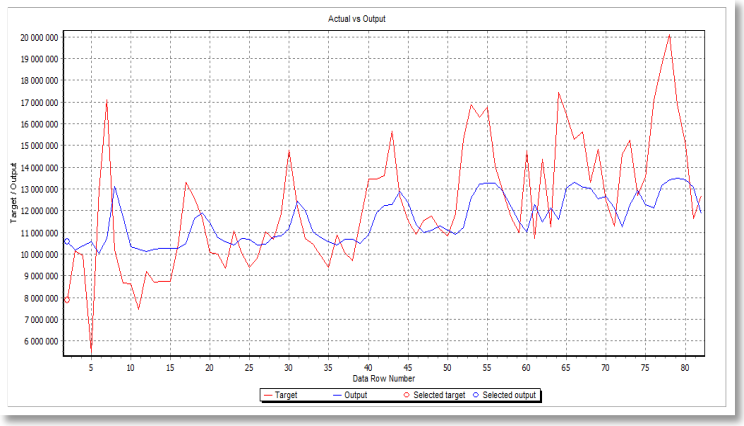

المصدر: بالاعتماد على مخرجات برنامج Alyuda NeuroIntelligence

- **Summary(all data)**

جدول رقم (06): قيم معالم البيانات الناتجة أثناء عملية التدريب مع البيانات الفعلية.

	Target	Output	AE	ARE
Mean:	12275826,308642	11576838,011197	1788762,053469	0,142813
Std Dev:	2813945,871243	1044099,080663	1588024,964417	0,131676
Min:	5486590	10050122,397239	668,588368	0,000052
Max:	20102770	13498572,441144	6669953,975398	0,924474

Correlation: 0,642525
R-squared: -4,248388

المصدر: مخرجات برنامج Alyuda NeuroIntelligence

الشكل رقم (08): البيانات التدريب الناتجة مع البيانات الفعلية.

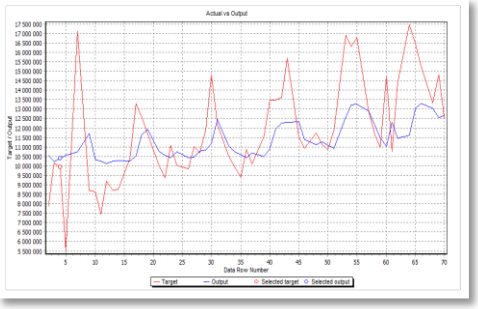

المصدر: مخرجات برنامج Alyuda NeuroIntelligence

6-2. التنفيذ Query (forecasting)

يتم في هذه المرحلة استخدام الشبكة للغرض الذي أنشأت من أجله ومن ثم المتابعة والتطوير المستمر لتحسين أداء الشبكة، والنتائج (Result graph) موضحة في الشكل التالي:

الشكل رقم (09): كميات الكهرباء منخفضة التوتر المتنبأ بها وحدي الثقة في الفترة من 1 جانفي إلى 31 ديسمبر 2013.

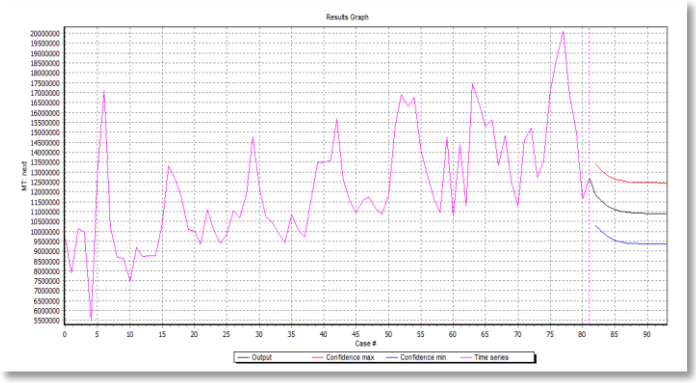

المصدر: بالاعتماد على مخرجات برنامج NeuroIntelligence Alyuda

جدول رقم (09): قيم كميات الكهرباء متوسطة التوتر المتنبأ بها وحدي الثقة في الفترة من 1جانفي إلى 31ديسمبر 2013.

الأشهر	كميات الكهرباء المتنبأ بها
1	11847274,11
2	11517194,55
3	11243794,23
4	11095963,06
5	11005405,25
6	10954986,02
7	10926368,80
8	10910499,27
9	10901676,51
10	10896799,95
11	10894104,23
12	10892616,28

المصدر: من إعداد الباحثين بالاعتماد على مخرجات برنامج NeuroIntelligence Alyuda

خـــاتمة:

التنبؤ بالسلاسل الزمنية تعتبر واحدة من المجالات الحيوية التي يكثر فيها استخدام تطبيقات الشبكات العصبية الاصطناعية. فقد استخدمت تقنية الشبكات العصبية الاصطناعية للتنبؤ بحجم المبيعات الشهرية للكهرباء لمؤسسة سونلغاز محل الدراسة، فقد توصل الباحثة في هذه الدراسة إلى جملة من النتائج:

- تم بناء نماذج الشبكات العصبية باستخدام شبكة البيرسبترون متعدد الطبقات (MLP) واستخدمت الدالة اللوجستية كدالة تحفيز في الطبقة الخفية وفي طبقة المخرجات واستخدم لتدريب هذه الشبكات خوارزمية الانتشار السريع واتضح أن الشبكة الناتجة جيدة وأعطت تنبؤات دقيقة وقريبة من الواقع في الفترة من جانفي إلى غاية 31 ديسمبر 2013؛
- درجة التغيرات العشوائية في السلسلة الزمنية يؤثر مباشر على النتائج المتحصل عليها باستخدام تقنية الشبكات العصبية الاصطناعية، فكلما ازدادت حدة التغيرات في السلسلة الزمنية زادت كفاءة نماذج الشبكات العصبية وهذا ما يثبت صحة الفرضية الأولى؛
- التوصل إلى أقل قيمة متوسط الخطأ المطلق (MAE) والذي يساوي: 0.044654 ، وبالتالي يمكن للمؤسسة الاعتماد عليها في عملية التقدير والتنبؤ بالمبيعات القادمة بشكل دقيق، وذلك لعدم وجود فروقات كبيرة بين القيم التنبؤية والقيم المحققة وهذا ما يثبت صحة الفرضية الثانية؛
- كلما كان حجم بيانات السلسلة كافيا كلما ارتفعت درجة التعلم في الشبكة وبالتالي يمكن تحسين كفاءة الشبكات العصبية الاصطناعية؛
- أثبت الدراسة أن استخدام الشبكات العصبية الاصطناعية في التنبؤ بالمبيعات تعطى نتائج ممتازة ودقيقة وقريبة من الواقع؛
- حاجة المؤسسات الاقتصادية إلى مجموعة إطارات ذات خبرة في استخدام الأساليب الإحصائية

بناء على النتائج السابقة تم التوصل إلى أهم الاستنتاجات:

- كلما ارتفعت درجة التعقيد في السلسلة يفضل استخدام نماذج الشبكات العصبية؛
- في البيانات التي تعاني من الاضطرابات وعدم ثبات التباين فإنه يفضل استخدام نماذج الشبكات العصبية؛
- من أجل رفع كفاءة نماذج الشبكات العصبية للتنبؤ في السلاسل الزمنية يجب الاهتمام بإزالة تأثيرات المتغيرات المختلفة من بيانات السلسلة الزمنية قبل تطبيق هذه الأساليب؛
- تعد الشبكات العصبية الاصطناعية هي الطريقة الأفضل والأكثر دقة للتنبؤ بالقيم المستقبلية للسلسلة الزمنية قيد الدراسة، مما يشجع استخدام هذا الأسلوب في التنبؤ بالسلاسل الزمنية المختلفة؛
- أهمية التعلم والتدريب والاستفادة من أنظمة الذكاء الاصطناعي وتطبيقاتها في مجالات التنبؤ بالمؤسسات الجزائرية وتطوير الأداء الموظفين بها عن طريق العمل بالبرامج الجاهزة المتعلقة بالشبكات العصبية الاصطناعية توفيرا للجهد والحصول على إيرادات أكبر.

قائمة المراجع:

مقالات:

1. ايفان علاء ناظم، **دراسة و تحليل مستوى التذبذب للتضخم في الأرقام القياسية بالاعتماد على السلاسل الزمنية مقرونة مع نماذج الشبكات العصبية الاصطناعية**، مجلة كلية الرافدين الجامعة للعلوم، العدد 31، 2013؛

2. عائدة يونس مُحَّد المراد، **مقارنة بين الانحدار الكلاسيكي و الشبكات العصبية الاصطناعية في التنبؤ بمستويات نتائج بحوث طلبة كلية التربية الرياضية**، المجلة العراقية للعلوم الإحصائية، جامعة الموصل، 2012؛

3.عمر صابر قاسم، إسراء رستم مُحَمَّد، **دراسة رياضية تحليلية لخوارزميات الشبكات العصبية في ملائمة نموذج للتشخيص الطبي**، مجلة الرافدين لعلوم الحاسوب والرياضيات، المجلد 10، العدد 1، 2013؛

4.مُحَمَّد سرحان الزويني، **تطوير نموذج رياضي للتنبؤ بالإنتاجية الإنشائية في العراق باستخدام شبكة بيرسبترون العصبية الاصطناعية**، مجلة الهندسة والتنمية، المجلد الثامن عشر، العدد الثاني، 2013؛

5.المدرس احمد عبد الحسين الإمارة، **تصميم نظام معلوماتي مقترح لدعم كفاءات الكادر الوسطى باستخدام تقنية الشبكات العصبية**، القرى للعلوم الاقتصادية والإدارية، السنة التاسعة، العدد السابع والعشرون؛

6.مصطفى كمال إسماعيل مظهر، **أفضل مزيج لسياسات إعادة التأمين في السوق المصري باستخدام المحاكاة بالشبكات العصبية الاصطناعية**، مجلة الدراسات والبحوث التجارية، السنة الرابعة والعشرون، العدد الأول، 2003، مصر؛

7.هيام عبد المجيد حياوي، قصي أحمد طه، **مقارنة التنبؤ باستخدام نماذج دالة التحويل ونماذج الأنماط المتماثلة المضببة مع التطبيق**، المجلة العراقية الإحصائية، العدد 22، 2012؛

مداخلات:

8.أحمد حامي جمعة، **استخدام الشبكات العصبية الاصطناعية في اكتشاف الأخطاء الجوهرية في البيانات المالية– دراسة تطبيقية**، المؤتمر العالمي السنوي الحادي عشر– ذكاء الأعمال واقتصاد المعرفة، 23–26 أفريل 2012، الأردن؛

9.شيماء أبو المعاطي عبد المطلب، **استخدام أسلوب الشبكات العصبية في زيادة فعالية المراجعة الضريبية في ظل التحديات المعاصرة**، المؤتمر الضريبي الثامن عشر، 28/26 يونيه، 2012؛

10.صوار يوسف وآخرون، **تقنية الشبكات العصبية الاصطناعية كأحد أساليب ذكاء الأعمال لتسيير مخاطر القروض**، المؤتمر العلمي السنوي الحادي عشر – ذكاء الأعمال واقتصاد المعرفة، 26/23 ابريل، 2012، الأردن؛

11. عبادي مُحَمَّد، **الشبكات العصبية الاصطناعية أداة لتقدير المخاطرة في البنوك التجارية**، الملتقى الوطني حول المنظومة المصرفية، المركز الجامعي جيجل؛

12. فروم مُحَمَّد الصالح وآخرون، مداخلة بعنوان: **دور أنظمة المعلومات المعتمدة على الذكاء الاصطناعي في عملية صنع القرارات الإدارية**، الملتقى الوطني السادس حول دور التقنيات الكمية في اتخاذ القرارات الإدارية ، سكيكدة، يومي 27 و29 جانفي 2009؛

الملحق رقم (01): يمثل المبيعات الشهرية لمنتوج الكهرباء (MT) **الوحدة:** KWh

السنة / الشهر	2006	2007	2008	2009	2010	2011	2012
جانفي	8487433	7454872	11085428	9412982	11566795	10978084	11283166
فيفري	10643876	9190058	10039204	10867497	11747146	14757210	14 593 268
مارس	9684890	8714703	9388109	10093163	11126629	10739323	15 234 523
أفريل	7878605	8758009	9831733	9695956	10852516	14383453	12 694 071
ماي	10140287	8751776	11034261	11513125	11877112	11270944	13 534 148
جوان	9943862	10403115	10669669	13477729	15270210	17456550	17 107 517
جويلية	5486590	13293631	11877202	13471867	16859921	16 429 279	18 699 297
أوت	12961333	12597167	14804537	13593456	16291038	15 274 497	20 102 770
سبتمبر	17114749	11684354	12180573	15669838	16759307	15 633 253	16 896 800
أكتوبر	10209414	10082017	10739468	12647938	14080395	13 318 763	15 021 553
نوفمبر	8676145	10022110	10462684	11520585	12891983	14 820 627	11 632 194
ديسمبر	8636599	9368732	9921029	10919106	11674731	12 458 038	12 715 826

المصدر: انطلاقا من معطيات المؤسسة