



مجلة جامعة القدس المفتوحة للبحوث الإدارية والاقتصادية

اسم المقال: بناء نموذج شبكة عصبونية باستخدام التحليل العائلي وحوارزمية Means-K

اسم الكاتب: محمد لؤي عبد الرزاق دهان، أ.د. ياسر عبد الله الموسى

رابط ثابت: <https://political-encyclopedia.org/index.php/library/1781>

تاريخ الاسترداد: 2025/05/10 20:35 +03

الموسوعة السياسية هي مبادرة أكاديمية غير هادفة للربح، تساعد الباحثين والطلاب على الوصول واستخدام وبناء مجموعات أوسع من المحتوى العلمي العربي في مجال علم السياسة واستخدامها في الأرشيف الرقمي الموثوق به لإغناء المحتوى العربي على الإنترنت. لمزيد من المعلومات حول الموسوعة السياسية - Encyclopedia Political، يرجى التواصل على info@political-encyclopedia.org

استخدامكم لأرشيف مكتبة الموسوعة السياسية - Encyclopedia Political يعني موافقتك على شروط وأحكام الاستخدام المتاحة على الموقع <https://political-encyclopedia.org/terms-of-use>

تم الحصول على هذا المقال من موقع مجلة جامعة القدس المفتوحة للبحوث الإدارية والاقتصادية ورفده في مكتبة الموسوعة السياسية مستوفياً شروط حقوق الملكية الفكرية ومتطلبات رخصة المشاع الإبداعي التي ينضوي المقال تحتها.



بناء نموذج شبكة عصبونية باستخدام التحليل العاملي و خوارزمية K-Means

Building an Artificial Neural Network Model Using Factor Analysis and K-Means Algorithm

Mohamed Loay Abdulrazak Dahhan

PhD. Student / Aleppo University / Syria
mloaydahhan@alepuniv.edu.sy

محمد لؤي عبد الرزاق دهان

طالب دكتوراه / جامعة حلب / سورية

Yasser Almousa

Professor / Aleppo University / Syria
ymoussa@alepuniv.edu.sy

ياسر عبد الله الموسى

أستاذ دكتور / جامعة حلب / سورية

Received: 21/ 7/ 2020, Accepted: 7/ 3/ 2021.

DOI: 10.33977/1760-006-016-004

https://journals.qou.edu/index.php/eqtsadia

تاريخ الاستلام: 21 / 7 / 2020م، تاريخ القبول: 17 / 3 / 2021م.

E-ISSN: 2410-3349

P-ISSN: 2313-7592

فيها، ولما كانت الشبكات العصبونية الصناعية Artificial Neural Networks من الطرق الحديثة، والتي أثبتت كفاءتها مقارنة بالطرق الأخرى، لحل مشاكل التصنيف Classification كأحد أنواع المشاكل الإدارية، كان لابد من الوصول إلى طريقة لمعالجتها لتعطي قراراً بأسرع وقت ممكن، وأعلى نسبة لدقة القرار الصحيح. إن وقت بناء وتدريب الشبكة يعكس درجة تعقيدها Complexity، وبالتالي كلما زادت درجة تعقيد المشكلة الإدارية، أدى ذلك إلى زيادة تعقيد الشبكة العصبونية المناسبة لها ويزداد الوقت اللازم لمعالجتها، ولا يمكن تعميم Generalization هذه الشبكة حتى تصبح قادرة على التصنيف بدقة عالية. ويعتبر استخدام التحليل متعدد المتغيرات Multi-Variant Analysis مناسباً جداً لتخفيض عدد المتغيرات اللازمة لاتخاذ القرار، مع الحفاظ على أعلى نسبة ممكنة من التباين أي الحفاظ على أكبر قدر ممكن من المعلومات، وبالتالي يمكن دمج هذه التحليلات لتساعد في إعادة هيكلة بنية الشبكة العصبونية اللازمة لاتخاذ القرار الإداري. ونقدم في هذا البحث نموذجاً لشبكة عصبونية متعددة الطبقات من أجل اتخاذ قرار حول متغير ثنائي معتمدة على التحليل العاملي (FA Factor Analysis) وخوارزمية k-means كأحد خوارزميات التحليل العنقودي (-Cluster Analy) ومن ثم نلاحظ درجة تعقيد نموذج الشبكة العصبونية المقترح، وبعدها نقارنه مع نموذج شبكة عصبونية متعددة الطبقات بدون دمج التحليلات السابقة بحسب الزمن اللازم للبناء والتدريب، ونسبة التصنيف الصحيح.

مشكلة البحث:

إن تعقيد المشاكل الإدارية المدرجة ضمن مشاكل التصنيف، والناجمة عن تنوع البيانات، تحتاج للكثير من الوقت والجهد لمعالجتها، وفي كثير من الحالات يعتمد اتخاذ القرار على متغير واحد فقط للحكم على الصنف الواجب الانتماء له بدلاً من الاستفادة من كامل المعلومات المتاحة، الأمر الذي يؤدي إلى نقص في المعلومات، وبالتالي ضياع فرصة اتخاذ قرار سليم بشكل أكبر. ولما كانت الشبكات العصبونية الصناعية أحد التقنيات الحديثة في حل مثل هذه المشاكل بالاعتماد على قاعدة بيانات متعددة الأبعاد، كان لابد من تطوير نموذج الشبكة العصبونية الصناعية لتتناسب مع طبيعة المشاكل الإدارية المطروحة. وهذا ما يقودنا إلى صياغة مشكلة البحث وفق السؤال التالي:

هل يعطي بناء نموذج شبكة عصبونية صناعية باستخدام التحليل العاملي وخوارزمية k-means أداء أفضل في التصنيف؟

والذي يتفرع عنه الأسئلة التالية:

- هل يساعد النموذج المقدم متخذ القرار في الوصول إلى القرار السليم بالاعتماد على كامل متغيرات الدراسة مقارنة بالنموذج التقليدي للشبكة العصبونية؟

- هل يصنف النموذج المقدم البيانات بشكل أفضل من النموذج التقليدي للشبكة العصبونية؟

- هل يصنف النموذج المقدم البيانات بشكل أسرع وبزمن أقل النموذج التقليدي للشبكة العصبونية؟

ملخص:

يهدف البحث إلى اقتراح نموذج شبكة عصبونية متعددة الطبقات بالاعتماد على التحليل العاملي Factor Analysis وخوارزمية K-means، وذلك من خلال دمجها في معمارية الشبكة العصبونية، يقوم التحليل العاملي بتخفيض عدد أبعاد البيانات الأولية ووضع الناتج في طبقة المدخلات، ثم يتم تجميع البيانات حسب خوارزمية K-means بالاعتماد على العوامل المستخرجة لنحصل على عنقودين يمثلان متغير القرار، من خلال إشراك كل المتغيرات ذات الصلة في الخوارزمية، ومن ثم يتم وضع ناتج الخوارزمية في طبقة المخرجات، بعد ذلك يتم تدريب نموذج الشبكة العصبونية المقترح. وبهدف المقارنة تم اختبار النموذج على قاعدة بيانات متعددة الأبعاد Multivariat للمكتبة الإلكترونية في كلية الاقتصاد - جامعة حلب. أظهر النموذج المقترح انخفاض في درجة التعقيد، من خلال انخفاض عدد الأوزان بالإضافة إلى دقة تصنيف مرتفعة، وزمن تدريب أقل من نموذج شبكة عصبونية متعددة الطبقات ANN غير معدل.

الكلمات المفتاحية: شبكات عصبونية، تحليل عاملي، خوارزمية K-means، درجة تعقيد.

Abstract:

This paper aims to propose a multilayer neural network model based on Factor Analysis and K-means algorithm by integrating them into the neural network architecture. Factor analysis reduces the number of primary data dimensions and puts the output factors into the input layer. The data is then collected according to K-means Algorithm depending on extracted factors to obtain two clusters representing the decision variable by engaging all relevant variables in the algorithm. Hereafter, the output is placed in the output layer; then the proposed neural network model is trained. For the purpose of comparison, the model was tested on a database of Multivariat for the electronic library at the Faculty of Economics at the University of Aleppo. The proposed model showed a decrease in complexity degree through a decrease in the number of weights. In addition, it showed a high classification accuracy and a lower training time than an unmodified ANN model.

Keywords: Neural network, factor analysis, K-means algorithm, complexity degree.

المقدمة:

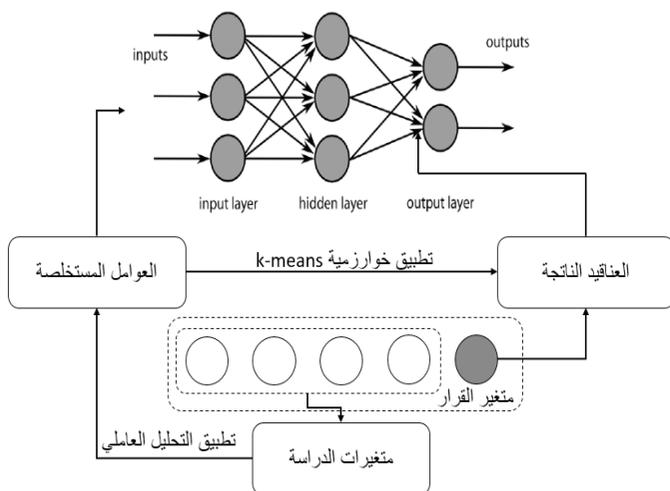
تتميز الإدارات بجودة اتخاذ القرار من خلال الوصول إلى القرار الصحيح وفي الوقت المناسب، بالإضافة إلى عدم تجاهل أي متغير يمكن أن يدخل في اتخاذ القرار، والابتعاد عن الحكم الفردي

4. بناء نموذج شبكة عصبونية بتحديد العوامل كطبقة مدخلات والعناقيد كطبقة مخرجات.

5. مقارنة النموذج الناتج مع نموذج شبكة عصبونية عامة تكون فيه المتغيرات هي طبقة المدخلات ومتغير القرار الفردي هو طبقة المخرجات.

والشكل (1) يبين نموذج البحث:

الشكل (1)
نموذج الدراسة



المصدر: من إعداد الباحثين

حدود البحث:

إن الهدف الأساسي لتحديد حدود البحث هو تحديد التطبيق الذي من خلاله تم اختبار النموذج المقترح، وعليه تم اختبار النموذج على مكتبة إلكترونية تعتمد على فكرة إضفاء الطابع الشخصي، هذه المكتبة موصولة على الشبكة المحلية في كلية الاقتصاد بجامعة حلب، وتم إيقاف العمل فيها بشكل مؤقت بداية عام 2018 وحتى اليوم، وبناء عليه نجد:

- الحدود الزمانية: تم تجميع البيانات خلال الفترة الواقعة من تاريخ 27 - 08 - 2015 وحتى تاريخ 1 - 2 - 2018.
- الحدود المكانية: المكتبة الإلكترونية في كلية الاقتصاد - جامعة حلب - سورية.

مجتمع وعينة البحث:

إن وجود مجتمع وعينة البحث في هذه الدراسة هو لتحديد الحد اللازم لتدريب واختبار النموذج المدروس، وبالتالي يشمل مجتمع البحث جميع الطلاب الذين استخدموا المكتبة الإلكترونية في كلية الاقتصاد، أما بالنسبة لحجم العينة يجب أن تحوي على عدد من المفردات يزيد عن عدد الأوزان الكلي في الشبكة من خمسة إلى عشرة مرات، واقترح كل من Baum و Haussler علاقة لتحديد الحد الأدنى لعدد المفردات مرتبطاً بنسبة الثقة المطلوبة في العينة حسب (Mehrotra, et al., 1997, P.86-88)، هي:

$$p = \frac{|W|}{(1 - \alpha)}$$

- هل يحافظ التحليل العاملي على جودة النتائج عند تطبيق النموذج المدروس من خلال تقليص أبعاد الدراسة؟

- هل تساعد خوارزمية k-means في استبعاد التصنيف بناء على متغير واحد، والتجميع في مجموعات بالاعتماد على كل المتغيرات المتاحة عند تطبيق النموذج؟

أهداف البحث:

يهدف البحث إلى إبراز دور طرق معالجة البيانات ذات الأبعاد المتعددة في تحسين أداء الشبكات العصبونية المستخدمة في التصنيف، من خلال تخفيض عدد الأبعاد باستخدام التحليل العاملي، وتجميع الحالات وفقاً لكل المتغيرات باستخدام خوارزمية K-means، ومن ثم دمج هذين التحليلين في هيكلية نموذج الشبكة العصبونية المدروس، وبالتالي فإن هدف البحث هو تحسين نموذج الشبكة العصبونية المستخدمة في التصنيف من خلال التحليلات متعددة المتغيرات، للوصول إلى قرار إداري سليم مستخدماً جميع المتغيرات ذات الصلة.

أهمية البحث:

تعود أهمية البحث إلى دمج التحليل العاملي FA الذي يخفض من أبعاد المتغيرات، مع الحفاظ على أعلى نسبة تباين ممكنة، وخوارزمية k-means التي تقوم بتجميع الحالات بناء على كل المتغيرات، في معمارية الشبكة العصبونية متعددة الطبقات ANN وتطبيقها على قاعدة بيانات متعددة الأبعاد، لاتخاذ قرار التصنيف بالاعتماد على جميع المتغيرات، ومن ثم مقارنة النموذج المدروس مع نموذج شبكة عصبونية دون تعديل لتبيان جدوى هذا النموذج، وقد تم تقييم النتيجة من خلال نسبة التصنيف الصحيح ودرجة التعقيد والزمن اللازم لبناء وتدريب كل نموذج منهما.

منهجية البحث:

اعتمد الباحثان على المنهج الوصفي التحليلي، ومن ثم بناء نموذج شبكة عصبونية بالاعتماد على التحليل العاملي وخوارزمية k-means وتدريبها للتنبؤ بقرار تصنيف في قاعدة بيانات ذات أبعاد متعددة، ومقارنة هذا النموذج مع نموذج شبكة عصبونية دون تعديل على ذات البيانات المدروسة من خلال نسبة التصنيف الصحيح، ودرجة التعقيد، والزمن اللازم لبناء وتدريب كل نموذج منهما.

نموذج البحث:

سيقوم الباحثان بالخطوات التالية:

1. تخفيض عدد أبعاد المشكلة المدروسة من خلال إجراء التحليل العاملي على كل المتغيرات عدا متغير القرار الفردي (وهو المتغير الوحيد الذي من خلاله يقوم متخذ القرار بالحكم على الصنف الواجب الانتماء له)، لنحصل على عدد من العوامل.
2. تطبيق خوارزمية k-means على العوامل الناتجة مع متغير القرار الفردي، لنحصل على عنقودي قرار في كلا الحالتين.
3. مقارنة أسلوب تنفيذ خوارزمية k-means السابقين، واعتماد الأفضل منهما حسب معيار مجموع مربعات الأخطاء SSE.

هناك مجالاً لتحسين بنية الشبكة العصبونية. يتفق الباحث مع هذه الدراسة في ضرورة تحديد معمارية الشبكة العصبونية، واقتصرت فقط على طبقة المدخلات وعقدها فقط، ولم تتناول تحديد عدد عقد طبقة المدخلات أو المخرجات، وإنما اكتفت فقط بعدد عقد الطبقات المخفية.

دراسة (Abuzir Yousef & Baraka AbdulRahman M.2018) بعنوان: "توقعات سوق الأسهم المالية باستخدام التنقيب عن البيانات في فلسطين":

قدمت الدراسة نموذج يهدف بشكل أساسي للتنبؤ بحركة الأسهم مؤلف من خمس مراحل، في المرحلة الخامسة تم بناء النموذج مستعيناً بالشبكة العصبونية الصناعية (1-5-6) المدربة وفق خوارزمية الانتشار الخلفي BP، وتوصلت إلى أن النتائج التي قدمتها هذه الشبكة لها دقة عالية في التنبؤ مقارنة ببقية الدراسات الأخرى، إن اختيار معمارية الشبكة (عدد العقد في الطبقات) تم من خلال أسلوب التجربة حيث قامت الدراسة بتجربة أعداد مختلفة من العقد في الطبقة المخفية، كما أنها درست المتغيرات التي تشكل عقد طبقة المدخلات، وتوصلت إلى المعمارية المناسبة بحسب جذر مربع الخطأ. يرى الباحث بأن الدراسة لم توضح أسباب اختيار معاملات الشبكة العصبونية (معامل التعليم Learning Coefficient والزخم Momentum وعدد مرات التدريب)، ربما تم الاعتماد على البرمجية التي قامت ببناء نموذج الشبكة العصبونية، وبالتالي فإن تعميم النتائج يجب أن يؤطر بالثوابت التي انطلق منها الباحث في تحديد معاملات الشبكة العصبونية الصناعية.

دراسة (Abuzir Yousef & Dweib Mohammad 2017) بعنوان: "تحسين معاملات الشبكات العصبية":

حاولت الدراسة تقديم طريقة لضبط معاملات الشبكة العصبونية الأساسية من خلال تطبيق خوارزمية الانتشار الخلفي BP بهدف جعل متوسط مربع الخطأ MSE أقل ما يمكن، وهي بحسب الدراسة قاعدة التعليم، learning rule ووسطاء التعليم لكل من الطبقة المخفية وطبقة الخرج (معامل التعليم Learning Co-efficient والزخم Momentum ودالة التفعيل Activation Function) وعدد العقد في الطبقات الثلاث (الدخل والمخفية والخرج). تم اختبار الدراسة على قاعدة بيانات خاصة بأحد المشافي لمرضى يعانون من نوبات قلبية، وتوصلت إلى مجموعة من النتائج من خلالها تحسن الشبكة العصبونية.

يختلف الباحث مع هذه الدراسة بأنها قامت بتحديد معاملات الشبكة العصبونية بالاعتماد على التجريب في قاعدة بيانات واحدة فقط، وبالتالي يصعب تعميم النتائج التي تم الوصول لها، بالإضافة إلى غياب الإثباتات الرياضية في اختيار مثل هذه المعلمات، ويرى الباحث أن المشكلة المثارة في هذا البحث تستحق البحث والوقوف عند الأساليب الرياضية والإحصائية الممكن استخدامها لتحديد معاملات الشبكة بعيداً عن مبدأ التجربة.

دراسة (Mosbah Hossam & El-Hawary M.E.) بعنوان: Stochastic Frac- \square tal Search لتقدير الحالة الديناميكية في ظل فشل الاتصال:

سعت هذه الدراسة لتحسين أداء الشبكة العصبونية من خلال

إذ إن: P عدد مفردات العينة، W عدد الأوزان الكلية في الشبكة، α نسبة الثقة المطلوبة في العينة، والشروط الكافي لضمان الأداء المطلوب يعطى، بالعلاقة:

$$p = \frac{|W|}{(1 - \alpha)} \log \frac{n}{1 - \alpha}$$

إذ إن n تمثل عدد العقد في الشبكة، وعليه فإن الحد الأدنى لحجم العينة اللازم عند مستوى ثقة 95 % هو:

$$p = \frac{|42|}{(1 - 0.95)} \log \frac{4}{1 - 0.95}$$

$$p = \frac{42}{0.05} * \log(80) = 840 * 1.903 = 1599$$

الدراسات السابقة:

يوجد العديد من الدراسات التي تناولت تدريب الشبكات العصبونية باستخدام التقنيات التقليدية والتقنيات المختلفة الأخرى، وجميعها تسعى للوصول إلى بنية شبكة عصبونية ذات قدرة عالية في التنبؤ، تباينت الدراسات من حيث كيفية تطوير الشبكة، إلا أن جميعها يتفق بشأن المنهجية المتبعة، والتي تكون من خلال بناء نموذج واختباره. كما أن النماذج المدروسة تعطي نتائج جيدة بالنسبة لكل دراسة. بعض الدراسات اعتمدت على التجربة والخطأ في بناء النموذج، وبعضها استخدم أساليب رياضية لتحسين كفاءة الشبكة العصبونية. معظم الدراسات التي قامت بتطوير نموذج الشبكة العصبونية استخدمت الأساليب الإحصائية أو أساليب الذكاء الصناعي، وفيما يلي استعراض لأبرز الدراسات السابقة:

دراسة (دهان والموسى 2020) بعنوان: «تخفيض درجة تعقيد الشبكة العصبونية متعددة الطبقات باستخدام مصفوفة التشبعات»:

قدمت هذه الدراسة ثلاثة نماذج مقترحة دمجت فيها مخرجات التحليل العاملي والمتمثل في مصفوفة التشبعات ضمن بنية الشبكة العصبونية متعددة الطبقات. إن النماذج المدروسة عدلت في معمارية الشبكة العصبونية من خلال طبقة المدخلات والطبقة المخفية فقط، كما أنها عدلت في الاتصالات بين عقد هاتين الطبقتين، ولم تتطرق أبداً إلى عقد طبقة المخرجات، الأمر الذي تم مناقشته من خلال خوارزمية K-means في الدراسة الحالية. تعتبر هذه الدراسة ذات أهمية نظراً لاعتمادها على أسلوب رياضي في اعتماد مخرجات التحليل العاملي ضمن بنية الشبكة العصبونية.

دراسة (Gupta & Raza 2019) بعنوان: "تحسين بنية الشبكة العصبية العميقة: نهج قائم على Tabu في البحث":

قدمت هذه الدراسة أسلوباً لتقدير عدد من معاملات الشبكة العصبونية تتمثل في عدد الطبقات المخفية وعدد العقد في هذه الطبقات، بالإضافة إلى عدد الاتصالات بين هذه العقد، قامت الدراسة ببناء العديد من النماذج بشكل عشوائي تجريبي لتحصل على أفضل النماذج، ومن ثم قامت بتطبيق تقنية Tabu وخوارزمية الميل المتناقص في بناء الشبكة، ما يميز الدراسة أنها اعتمدت على الاختبارات الإحصائية T-test في تحديد أي النماذج أفضل، وتوصلت الدراسة إلى أن النموذج المقترح أعطى نتائج أسرع وأدق، كما أن

دراسة (Sanja Pfeifer وآخرون 2013) بعنوان: "الجمع بين تحليل PCA والشبكات العصبونية الصناعية في نمذجة توجهات الطلاب":

لم تتطرق هذه الدراسة إلى تغيير معمارية الشبكة العصبونية، وإنما استخدمت تحليل المركبات الأساسية PCA كمرحلة أولى ما قبل المعالجة لاستخراج العوامل المهمة ومن ثم استخدمت الشبكة العصبونية كمرحلة ثانية متضمنة العوامل السابقة في النمذجة، برهنت على قدرة تحليل PCA على تحسين أداء الشبكة العصبونية الصناعية المستخدمة في التصنيف. وأثبتت أن استبدال المتغيرات بالعوامل في طبقة المدخلات أعطى نتيجة أفضل، دون تغيير في معمارية الشبكة العصبونية المستخدمة في التصنيف.

دراسة (J. Li وآخرون 2012) بعنوان: "مقدمة موجزة لخوارزمية الشبكة العصبونية للانتشار الخلفي (BP) وتحسينها":

تم تقديم دراسة تحليلية للخصائص والنظريات الرياضية المستخدمة في خوارزمية الانتشار الخلفي، ورأت هذه الدراسة حسب (Wang, X., Cao, L) أنه يوجد ثلاث أمور لتحسين أداء الخوارزمية هي تحسين سرعة تدريب الشبكة العصبونية، وتحسين دقة التدريب، وتجنب الوقوع في قيم صغرى محلياً، وارتأت الدراسة لتحقيق ذلك يجب تحسين كل من قيمة الزخم momentum من خلال خوارزمية الميل المتناقص، واختيار معدل التعليم المناسب Learning Rate، وتهيئة قيم أولية للأوزان الذي يعتبر عامل مهم؛ لأن اختيار قيم سيئة عشوائياً يؤدي إلى زمن أطول في التدريب، واقترح الباحث تطبيق الخوارزمية الوراثية لتساعد في عملية التهيئة. يرى الباحث أن الدراسة اقتصرت على معلومات قليلة لتحسين تدريب الشبكة العصبونية، وتجاهلت بعض المعلومات لتحديد بنية الشبكة اللازمة وتحديد توابع التفعيل بين الطبقات ...، إلا أن الباحث يتفق مع الدراسة من حيث مناقشة تقديم خوارزمية الانتشار الخلفي المطورة بشكل رياضي.

دراسة (Shifei Ding وآخرون 2011) بعنوان: "دراسة خوارزمية الشبكة العصبونية بالاعتماد على التحليل العاملي والتحليل العنقودي":

ما يميز هذه الدراسة هو اقتراح خوارزمية الشبكة العصبونية ذات الانتشار الخلفي (BP) على أساس تحليل العوامل (FA) والتحليل العنقودي (CA)، من خلال الدمج بين معمارية الشبكة BP ومبادئ كل من FA و CA، تخفض الخوارزمية المقترحة أبعاد البيانات الأولية من خلال التحليل العاملي لتبسيط بنية الشبكة؛ ثم تقسم العينات إلى فئات فرعية مختلفة من خلال التحليل العنقودي، ويتم تدريب الشبكة لتحسين قدرتها على التكيف. استخدم الباحث التحليل العاملي Factor Analysis لتخفيض أبعاد البيانات الأساسية، وتبسيط معمارية الشبكة، وتحسين سرعة التدريب الشبكة. بينما كان الهدف من عنقدة العينات من خلال استخدام خوارزمية العنقدة الهرمية Hierarchical cluster analysis HCA هو استبعاد النسبية والتشابه بين العينات موضوع الدراسة. خلصت هذه الدراسة لبناء نموذج شبكة عصبونية FA-CA-BP بالاعتماد على خوارزمية الانتشار الخلفي في التدريب بعد معالجة البيانات من خلال التحليل العاملي والعنقودي، حيث إن النموذج المقترح FA-CA-BP قد كان له الأثر في تحسين دقة التنبؤ بشكل كبير، وتقليل مقدار الخطأ، وخطوات

معلومات الشبكة العصبونية متعددة الطبقات MLP المثلى والمتمثلة بالأوزان والعتبات thresholds خلال المرحلة الثالثة من النموذج المقترح، تم استخدام تقنية SFS للحصول على مجموعة من الأوزان والعتبات الأولية المناسبة، وتضمنتها في الشبكة العصبونية من خلال نظام هجين MLP-SFS، قامت الدراسة بإجراء عشرة حسابات مختلفة تضمنت تغيير توابع التفعيل لكل من الطبقة المخفية وطبقة الخرج، وتغيير حجم المجتمع، وعدد الخلايا الكلي في الشبكة، تمت مقارنة هذه الطريقة مع عدة طرق أخرى بالاعتماد على متوسط مربع الخطأ MSE، وأعطت نتائج تشير إلى أن النظام الهجين المقترح أعطى دقة أعلى من النماذج الأخرى بين 20% إلى 50%، واحتاج لوقت تدريب أقل من 30% إلى 50%.

يرى الباحث أن هذه الدراسة ذات أهمية لتناولها معظم معلومات الشبكة العصبونية (الأوزان وعدد العقد في الطبقات وتوابع التفعيل ...) بالإضافة إلى إثبات فعالية النموذج المقترح من خلال مقارنته مع شبكة عصبونية تقليدية MLP ومن ثم مقارنته مع شبكات عصبونية هجينة أخرى.

دراسة (Inthachot Montri وآخرون، 2016) بعنوان: "التهجين الذكي للشبكات العصبونية الاصطناعية والخوارزمية الوراثية للتنبؤ بقيمة مؤشر الأسهم التايلاندية":

تساهم هذه الدراسة في تطبيق الخوارزمية الوراثية لإيجاد عدد فعال من المجموعات الجزئية لمدخلات الشبكة العصبونية لتحسين دقة تنبؤ الشبكة العصبونية. تقترح هذه الدراسة استيراد المؤشرات الفنية لأحد الأسهم وعددها 11 مؤشراً، كل مؤشر منها يتكون من 4 فترات سابقة، وذلك من أجل مجموعات جزئية متنوعة من المدخلات تتكون من 44 متغيراً، والتي يتم تخفيضها إلى عدد يمكن التحكم فيه من العناصر الفعالة بواسطة الخوارزمية الوراثية (GA) وتميرها إلى ANN للتنبؤ باتجاه مؤشر السهم. تم تطبيع جميع متغيرات الإدخال بشكل متماثل واختيار مجموعات فرعية منها بواسطة الخوارزمية الوراثية GA ومنها إلى نموذج الشبكة العصبونية ANN للتنبؤ بحركة مؤشر السهم. خلصت الدراسة إلى أن النموذج المقترح قد حقق زيادة في دقة التنبؤ بقيمة السهم المدروس بمعدل 12% خلال سنوات الدراسة مقارنة بالدراسات السابقة. إن أعلى نسبة لدقة التنبؤ بقيمة المؤشر المدروس قد وصلت لـ 63.60%، والتي ما تزال ضعيفة نوعاً ما، ويؤخذ على الدراسة عدم مقارنة النموذج المقترح بنماذج أخرى مطبقة على أسهم مختلفة، بالإضافة إلى عدم إمكانية تعميم نتائج الدراسة.

دراسة (نصار هلا وآخرون 2014) بعنوان: "تصنيف تعابير الوجه باستخدام شبكة عصبونية وخوارزمية PCA":

قدمت هذه الدراسة نظام خبير يقوم بتطبيق تحليل المكونات الأساسية PCA كمرحلة سابقة لتحديد المدخلات لنموذج شبكة عصبونية متعددة الطبقات، تم تطبيقها لتحديد انتماء وجه إلى التعابير النموذجية للأوجه، خفضت الدراسة من عدد الأبعاد المدخلة في الشبكة العصبونية، واختارت الأهم منها بحسب تحليل PCA خلافاً للدراسات المعهودة في هذا المجال التي تعتمد على الوجه بالكامل. يرى الباحث بأن الدراسة وفقت في تخفيض عدد الأبعاد، وبالتالي تم تخفيض درجة تعقيد نموذج الشبكة العصبونية المقترح.

طبقات مخفية (Mehrotra K., et al., 1997)، w عدد الأوزان والتي يمكن حسابها وفق المعادلة التالية (Dang Tuan Linh, Hoshino, Yukinobu, 2019):

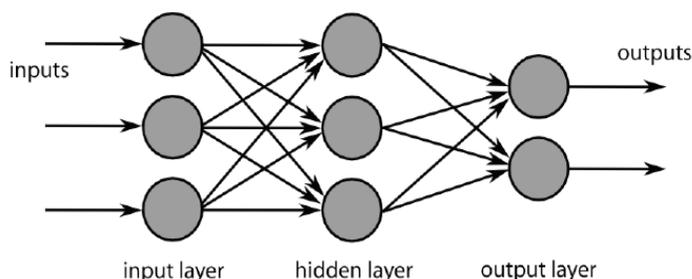
$$\omega = (N_i + 1) N_h + (N_h + 1) N_h * N_i + (N_h + 1)$$

حيث N_i و N_h و N_o هي عدد العقد في طبقة الإدخال والطبقة المخفية وطبقة المخرجات على التوالي. كما هو موضح في الشكل (2).

تتم تفعيل العقد في كل طبقة من خلال دالة تفعيل Activa-tion Function، وفي مشاكل التصنيف، إن الدالة Softmax هي الدالة الأكثر شيوعاً لتفعيل العقد في الطبقات. لأن شعاع الإخراج يحتوي على مكون مطابق لكل فئة مستهدفة، ويتم تفسير إخراج softmax على أنه احتمال المدخلات التي تنتمي إلى الفئة المقابلة.

الشكل (2)

معمارية الشبكة العصبونية



المصدر: من إعداد الباحثين

إذا كانت $x = [x_1, x_2, \dots, x_n]$ عندئذ تكون الدالة softmax وفق التالي (Leskovec Jure, et al., 2020):

$$\mu(x) = [\mu(x_1), \mu(x_2), \dots, \mu(x_n)]$$

حيث:

$$\mu(x_i) = \frac{e^{x_i}}{\sum_j e^{x_j}}$$

خوارزمية تدريب الشبكة العصبونية متعددة الطبقات:

تعد خوارزمية الانتشار العكسي الخوارزمية الأكثر شيوعاً لتدريب الشبكة، وهي تعميم لخوارزمية المربعات الصغرى التي تعدل أوزان الشبكة لتقليل الخطأ بين المخرجات المرغوبة والفعليّة للشبكة. يستخدم الانتشار العكسي التعلم المراقب supervised learning الذي يتم فيه تدريب الشبكة باستخدام البيانات التي تُعرف بها المدخلات والمخرجات المطلوبة. يعد الانتشار العكسي طريقة تدريب بسيطة تستخدم الميل المتناقص للشبكة العصبونية لضبط أوزان الشبكة العصبونية. عندما يتم تعديل هذه الأوزان، يجب أن تعطي الشبكة العصبونية دقة أعلى في التصنيف. وبالتالي يجب أن تنخفض قيمة الخطأ الإجمالي للشبكة أثناء تدريبها (Heaton Jeff, 2011).

درجة تعقيد الشبكة العصبونية متعددة الطبقات:

يمكن قياس درجة تعقيد الشبكة العصبونية متعددة للطبقات من خلال الوقت اللازم لتعليمها وتعميمها General-

التدريب مقارنةً فيما لو تم تدريب الشبكة العصبونية بالاعتماد على خوارزمية الانتشار الخلفي BP، أو بالاعتماد على العوامل الناتجة عن التحليل العاملي للمدخلات FA-BP.

على الرغم من تحسن دقة التنبؤ وتقليل زمن التدريب والمعالجة للشبكة باستخدام النموذج المقترح FA-CA-BP إلى أن النموذج المقترح قد ساهم في زيادة تعقيد الشبكة، وهو من أحد المآخذ على هذه الدراسة. وما يؤخذ على هذه الدراسة أيضاً أن كفاءته تقتصر على التعامل مع عينات البيانات الكبيرة ذات أبعاد عديدة، وبالتالي محدودية استخدامه على عينات البيانات الصغيرة نسبياً بأبعاد أقل.

وبمراجعة الدراسات السابقة تبين أن: جميع الدراسات السابقة لم تستخدم تقنيات تساعد في استخدام جميع المتغيرات في اتخاذ القرار، وإنما اكتفت بمتغير وحيد يمثل عقد طبقة المخرجات، كما أن الدراسة الحالية تتميز عن الدراسات السابقة في الاعتماد على خوارزمية k-means في تحديد عقد طبقة المخرجات، والتي تمثل متغير القرار، حيث يتم تجميع الحالات بالاعتماد على كل المتغيرات لمعرفة القرار المناسب، بينما جميع الدراسات السابقة كان فيها المتغير المشكل لعقد طبقة المخرجات هو متغير وحيد.

الإطار النظري للبحث:

معمارية الشبكة العصبونية Neural Networks Architec-

ture

الشبكة العصبونية الاصطناعية هي نوع من أنواع الذكاء الاصطناعي الذي يحاول تقليد الطريقة التي يعالج بها الدماغ البشري المعلومات ويخزنها. تعمل عن طريق إنشاء اتصالات بين عناصر المعالجة الرياضية، تسمى الخلايا العصبونية. يتم ترميز المعرفة في الشبكة من خلال قوة الاتصالات بين الخلايا العصبونية المختلفة، تسمى الأوزان، عن طريق إنشاء مجموعات، أو طبقات، من الخلايا العصبونية التي تعمل بشكل متوازي (Taylor, Brian J., 2006). تتعلم الشبكة من خلال عملية تحديد عدد الخلايا العصبونية أو العقد وضبط الأوزان للاتصالات بناءً على بيانات التدريب. تتكون بنية الشبكة العصبونية من طبقتي المدخلات والمخرجات بالإضافة إلى طبقة وسيطة أو أكثر تسمى الطبقات المخفية. إن وظيفة الخلايا العصبونية المخفية هي التدخل بين متغيرات طبقة المدخلات ومتغيرات طبقة المخرجات بطريقة مفيدة لتعليم الشبكة (P. Arumugam, R. Ezhilarasi, 2017). يعتمد أداء الشبكة بشكل كامل على اختيار المعمارية وخوارزمية التدريب. يمكن تعديل بنية الشبكة متعددة الطبقات باستخدام العديد من المعلمات، مثل عدد الطبقات المخفية وعدد الخلايا العصبونية في كل طبقة منها وعدد الاتصالات بين الطبقات (Gupta, et al., 2018).

إن المعمارية الأكثر استخداماً في الشبكات العصبونية هي الشبكات متعددة الطبقات (MLP)، المدربة باستخدام خوارزمية تعلم الانتشار الخلفي (Shafi Imran et al., Back Propagation BP, 2006). في هذه المعمارية، يتم تقسيم العقد إلى طبقات مرقمة من 0 إلى L، حيث يشير رقم الطبقة إلى مسافة العقدة من عقد الإدخال. الطبقة الأولى هي طبقة الإدخال المرقمة كطبقة 0، والطبقة الأخيرة هي طبقة الإخراج المرقمة كطبقة L. الطبقات المرقمة بين 0 و L هي

العاملية حسب هذه الطريقة وفق (ريتشارد، جونسون، دين، وشرن، 1998):

$$X_1 - \mu_1 = \ell_{11} F_1 + \ell_{12} F_2 + \dots + \ell_{1m} F_m + \epsilon_1$$

$$X_2 - \mu_2 = \ell_{21} F_1 + \ell_{22} F_2 + \dots + \ell_{2m} F_m + \epsilon_2$$

⋮

$$X_p - \mu_p = \ell_{p1} F_1 + \ell_{p2} F_2 + \dots + \ell_{pm} F_m + \epsilon_p$$

حيث تم تقليص عدد الأبعاد من m إلى p ، واستحداث متغيرات جديدة F_i ; $i: 1, 2, \dots, p$ كل منها مربوط بعلاقة خطية مع متغيرات الأساس X ، وبذلك يتم تقليص الأبعاد، يسمّى المعامل ℓ_{ij} بمعامل تحميل Loading المتغير i على العامل j ، و ϵ قيمة البواقي (الخطأ المقدّر) الذي يتبع التوزيع الطبيعي بأمل رياضي معدوم وتباين محدد.

يهدف التحليل العاملي إلى الوصول إلى أقل عدد ممكن من العوامل تمكّننا من التعبير عن أكبر قدر ممكن من التباين بين المتغيرات. وتحميل المتغير على العامل هو عبارة عن ارتباطه به، أي هو مقدار إسهام المتغير في العامل، ومجموع مربعات التبعيات (مجموع مربعات ارتباطات المتغير على العوامل) تمثل مقدار التباين الذي أمكن استخلاصه عاملياً في التحليل العاملي. يجب أن يحوي حجم العينة على مشاهدات بمعدل 5 مشاهدات لكل متغير كحد أدنى، وكما يجب تفحص مصفوفة الارتباط العاملية بحيث تزيد الارتباطات عن 3. ، ويتم الاستفادة أيضاً من اختباري Bartlett و (Kaiser-Meyer-Olkin KMO) لتقدير عاملية المصفوفة، ويتحقق ذلك -أي تكون العاملية محققة- عندما تكون قيمة اختبار Bartlett كبيرة ومعنوية، وقيمة مؤشّر اختبار KMO أكبر من 6. (العباسي عبد الحميد، 2001).

تحديد عدد العوامل المستخرجة:

لا توجد حتى الآن قاعدة رياضية مقبولة من قبل الباحثين للتوقّف على استخلاص العوامل، وبالتالي فإن تقدير عدد العوامل يعتبر من المشاكل الهامة، حيث إنه يمكن استخلاص عدد من العوامل يساوي عدد المتغيرات التي بدأنا بها، يوجد عدد من المعايير Criterion التي يمكن استخدامها لهذا الغرض، أشهرها هو معيار كايزر المعتمد على حجم التباين الذي يعبر عنه العامل (الجزر الكامن Eigenvalue) بحيث يجب ألا يقل عن الواحد الصحيح. ويمكن الاسترشاد بالقواعد التالية عند تحديد عدد العوامل بحيث تكون كمية التباين التي يساهم بها العامل (الجزر الكامن) يزيد أو يساوي الواحد الصحيح، وألا يقل معيار نسبة التباين الكلية عن 60 % (العباسي عبد الحميد، 2001).

اعتمد البحث على تدوير المحاور لإعادة تحديد مواضع العوامل للوصول إلى قدر أكبر من الثبات والاتساق، واستخدم التدوير المتعامد Orthogonal Rotation للحفاظ على الاستقلالية بين العوامل.

خوارزمية المتوسطات K-Means:

اقترحت هذه الخوارزمية من قبل MacQueen لوصف طريقته التي تضع كل مفردة في المجموعة التي يكون وسطها الحسابي أقرب لها، وتعتبر من أفضل خوارزميات العنقدة غير الهرمية Nonhierar-

ization، ويختلف هذا الوقت باختلاف معمارية الشبكة المرتبطة بطبيعة المشكلة المطروحة. يتم تدريب الشبكات العصبونية من الالام تحديث الأوزان، ويكون عادة باستخدام الطريقة (Per-Ep-och P-E) والتي تقوم بتحديث الأوزان بعد إدخال كامل الأنماط، وتكون الشبكة قادرة على التعميم عند انتهاء تعليمها، في بعض الأحيان يتم ضبط عملية التعليم من خلال الوقت. إن درجة التعقيد تتأثر بعدد المضاعفات اللازمة لتنشيط جميع الخلايا (العقد) في كل طبقة موجودة ضمن الشبكة، وعدد المرات اللازمة لتكرار هذه العملية وعدد الأنماط الكلية، بالإضافة إلى عدد الأوزان والتي تمثل الاتصالات بين العقد الناتجة عن معمارية الشبكة (Du Ke-Lin, Swamy M. N. S., 2019).

إن أهم عامل يؤثر في تعقيد بنية شبكات MLP هو عدد الاتصالات بين عقد الطبقات المتتالية، وبالتالي يمكن تقدير درجة تعقيد الشبكة العصبونية متعددة الطبقات بشكل عام من خلال عدد الأوزان التي تربط بين الطبقات، والذي يتم تقديره من خلال عدد العقد في كل طبقة (Hagan Martin, et al). ويتم حساب عدد الأوزان الاجمالي في الشبكة العصبونية من خلال مجموع الأوزان بين كل طبقتين متتاليتين، وتحسب الأوزان بين كل طبقتين متتاليتين من خلال جداء عدد العقد في الطبقة الأولى بعدد العقد في الطبقة التي تليها، وذلك في حال كانت جميع العقد في الطبقة الأولى ترتبط بجميع العقد في الطبقة التي تليها، ويمكن تمثيل ذلك وفق التالي مع الأخذ بعين الاعتبار مدخل الإزاحة الإضافي:

$$\omega = \sum_{i=0}^{i=L-1} (b_i + b_i) * \omega_{(i+1)}$$

حيث ω تمثل عدد الأوزان الكلي في الشبكة، i تمثل عدد العقد في الطبقة i و b_i تمثل مدخل إزاحة اضافي في الطبقة i و L تمثل عدد الطبقات في الشبكة، و $\omega_{(i+1)}$ تمثل عدد العقد في الطبقة $i + 1$.

تحاول بعض خوارزميات التدريب أن تهمل الأوزان بين العقد غير المؤثرة في هدف الشبكة من خلال تقريب قيمها إلى الصفر عند كل محاولة تدريب جديدة.

للتحليل العاملي للبيانات متعددة الأبعاد Factor Analysis for Multivariate Data:

يستخدم التحليل العاملي لتخفيض أبعاد البيانات من خلال استحداث متغيرات جديدة وبعلاقات خطية Linear مع المتغيرات الأصلية. إن الغرض الأساسي من التحليل العاملي هو دراسة العلاقات بين عدد من المتغيرات المشاهدة بدلالة مجموعة من العناصر الفرضية غير المشاهدة تسمى عوامل مشتركة Com-mon Factor هي التي نهتم بها، ويتم اعتمادها في بناء النموذج. وبالتالي يمكن القول إن العامل الواحد مكون من مجموعة من المتغيرات المشاهدة للظاهرة بحيث يكون لكل عامل دالة تربطه ببعض أو كل هذه المتغيرات.

من أبرز طرائق إجراء التحليل العاملي هي طريقة المكونات الأساسية، التي تستخدم لتشكيل مجموعات خطية غير مترابطة من المتغيرات. يفسر المكون الأول أكبر تباين، ومن ثم تليه بقية المكونات لتفسر التباين وبشكل تدريجي. ويكون نموذج التحليل

ويحصل على مجموعة من العوامل ستشكل طبقة المدخلات في الشبكة العصبونية، وبعد ذلك سيقوم بتطبيق خوارزمية K-Means بإدخال العوامل بدلاً من المتغيرات بالإضافة إلى متغير القرار الفردي، ونتيجة هذه الخوارزمية هي عنقودان أساسيين الأول يمثل العملاء الجيدين، والثاني يمثل العملاء العاديين، هذا المتغير يمثل عقد طبقة المخرجات، ومن أجل التنبؤ بصنف مستخدم جديد هل هو عميل جيد أو عادي تم تطبيق شبكة عصبونية متعددة الطبقات مدموج بها نتائج التحليل العاملي وخوارزمية k-means، ومن ثم قام ببناء نموذج شبكة عصبونية دون تعديله، واعتمد في تقييم النتائج على دقة التصنيف والزمن اللازم لبناء وتدريب النموذج.

متغيرات الدراسة Variables Selection

فيما يلي متغيرات الدراسة بعد معالجتها لتناسب غرض الدراسة:

الجدول (1)

متغيرات الدراسة

الوصف	الرمز
المتغيرات المستمرة	
العمر	X1
التفاعل مع الإنترنت	X6
عدد ساعات الإنترنت يومياً	X7
عدد حسابات البريد الإلكتروني	X8
عدد الكتب المقرؤة شهرياً	X9
عدد مرّات إضافة كتاب	X14
عدد المرّات للتعليق على الكتاب	X15
عدد المرّات الإجمالية لتقييم الكتاب	X16
متوسط تقييم الكتاب	X17
عدد مرّات تحميل الكتاب	X20
المتغيرات الثنائية (1 تعني نعم، 0 تعني لا)	
فئة العميل (زائر المكتبة الإلكترونية من الطلاب) بحسب شراء منتج (تنزيل كتاب)	X21
هل هو عميل (زائر) جيد أم عميل (زائر) عادي	
المتغيرات الفئوية (اسمية وترتيبية)	
الجنس	X2
محااسبة، إدارة وتسويق، رياضيات واحصاء، نظم وحاسوب، اقتصاد وعلوم مالية، علمي، أدبي، أخرى	X3
اللغات التي يفضلها للكتب	X4
نوع الإنترنت المستخدم	X5
الاستخدام الأكثر للإنترنت	X10
الدرجة العلمية	X11

chical Clustering. وهي فعالة في حال وجود عدد كبير جداً من المفردات بسبب أنها لا تتطلب حساب جميع الاحتمالات لمصفوفة التقارب بين جميع المفردات كما هو الحال في خوارزميات العنقدة الهرمية الأخرى. وتعمل هذه الخوارزمية وفق الخطوات التالية (Rencher, Alvin C, 2002):

تم اختيار عدد من العناصر K لتمثل المراكز الأولية -Initial Centroids (يقوم المستخدم بتحديد قيمة K)، فيما بعد سيتم استبدالها بقيم مراكز العناقيد Centroids. ومن ثم يتم إسناد كل مفردة إلى العنقود الأقرب (المركز الأقرب) بالاعتماد على مقاييس التقارب بين المفردة ومراكز العناقيد، ثم يتم تحديث المراكز بالاعتماد على المفردات المسندة إليها بحساب قيمة المتوسط. تتكرر عمليتا الإسناد والتحديث لحين الوصول إلى حالة الثبات أي عدم انتقال أية مفردة من عنقود لآخر، أو عدم تغير قيمة المراكز الجديدة للعناقيد. إن تحديد المراكز الأولية ومقاييس التقارب المستخدم يؤثران في تنفيذ الخوارزمية.

يتم استخدام مجموع مربعات الأخطاء (SSE Sum Square Errors) لقياس جودة العنقدة كهدف، حيث يتم حساب المسافة الإقليدية لكل مفردة عن مركز العنقود الأقرب والذي يمثل الخطأ، ومن ثم يتم حساب المجموع الكلي لمربعات الأخطاء، والهدف هو جعل هذه القيمة أقل ما يمكن، فمثلاً في حال اقتراح طريقتين لعنقدة البيانات فإن الطريقة الأفضل هي الطريقة ذات القيمة الأقل لمجموع مربعات الأخطاء SSE، والتي تأخذ الصيغة التالية:

$$= \text{Min} \sum_{i=1}^K \sum_{x \in C_i}^N \text{dist}(c_i, x)^2$$

$$c_i = \frac{1}{m_i} \sum_{x \in C_i} x$$

حيث أن: dist هي المسافة الإقليدية التقليدية، X مفردة البيانات، Ci العنقود، ci مركز العنقود، Ci مركز جميع المفردات، mi عدد المفردات في العنقود i، m عدد المفردات الكلي، K عدد العناقيد. وبشكل عام عند استخدام عدد أكبر من العناقيد K، تخفض قيمة مجموع مربعات الأخطاء، ونحصل على نتيجة أفضل للعنقدة (Tan, Pang-Ning, et al. 2006).

اختبار النموذج:

تم اختبار النموذج على مشكلة إدارية (مكتبة إلكترونية) تتمثل في تصنيف العملاء (زوار المكتبة الإلكترونية من الطلاب) إلى عملاء (زوار) جيدين وعملاء (زوار) عاديين، إن متغير القرار الفردي الذي نحكم من خلاله على جودة العملاء هو القيام بعملية شراء (تنزيل - Download) فقط لأحد منتجات المكتبة (الكتاب الإلكتروني): أي هل قام الطالب بتنزيل الكتاب الإلكتروني من المكتبة بعد قيامه بسلسلة من التنقلات داخل الموقع. حصل الباحثان على 2400 مستخدم تفاعلوا مع المكتبة، بالإضافة إلى 1482 كتاب. إن خطوات تطبيق النموذج ستشتمل على تحديد المتغيرات اللازمة للدراسة انطلاقاً من قاعدة بيانات المكتبة الإلكترونية والمبينة في ملحق البحث (الموسى والجاسم ودهان، 2015)، وبعد ذلك سيقوم بإدخال هذه المتغيرات على نموذج التحليل العاملي،

لمتغير نوع الإنترنت المستخدم X5 والبالغة 81.1. تشير إلى أنّ 81.1% من التباينات في قيم المتغير تفسرها العوامل المشتركة، وبملاحظة قيم الاشتراكيات نجد بأن العوامل المشتركة تفسر نسبة جيدة من التباينات.

الجدول (2)

الاشتراريات Communalities

المتغير	القيمة الأولية	القيمة المستخلصة	المتغير	القيمة الأولية	القيمة المستخلصة
X1	1	.8280	X11	1	.8750
X2	1	.8510	X12	1	.6930
X3	1	.7570	X13	1	.8320
X4	1	.6560	X14	1	.7200
X5	1	.8110	X15	1	.7890
X6	1	.7730	X16	1	.7880
X7	1	.7540	X17	1	.5500
X8	1	.7240	X18	1	.8380
X9	1	.4890	X19	1	.6000
X10	1	.5780	X20	1	.8290

المصدر: من إعداد الباحثين باستخدام برنامج SPSS.

التباين الكلي المفسر **Total Variance Explained**: نلاحظ من الجدول (3) بأنه تم تقسيم المتغيرات إلى سبعة عوامل أساسية، حيث إن العامل الأول له أكبر قيمة مميزة (تباين للعامل) ويساوي 3.773. ويفسر نسبة 18.864% من التباينات الكلية للمتغيرات المدروسة وهكذا

الجدول (3)

التباينات الكلية للعوامل

العامل	الجذر الكامن	نسبة التباين المفسر	نسبة التباين التراكمية
F1	3.846	19.228	19.228
F2	2.259	11.294	30.522
F3	2.058	10.290	40.812
F4	1.853	9.263	50.075
F5	1.749	8.747	58.822
F6	1.722	8.612	67.435
F7	1.249	6.244	73.678

المصدر: من إعداد الباحثين باستخدام برنامج SPSS.

وتحسب نسبة التباين المفسر للعامل من خلال قسمة قيمة

الرمز	الوصف	المتغيرات المستمرة
X12	عدد مرّات استخدام زر البحث	أقل من 100 مرة، بين 100 و200، بين 200 و300، بين 300 و400، أكبر من 400
X13	صافي رصيد التفاعل	أقل من 10000 نقطة، بين 10000 و20000، أكبر من 20000.
X18	المدة الاجمالية التي قضاها العميل في الموقع	أقل من 10 دقائق، بين 10 دقائق وساعة واحدة، أكثر من ساعة واحدة.
X19	عدد مرّات استخدام المحادثات	أقل من 100، أكثر من 100

المصدر: من إعداد الباحثين بالاعتماد على عينة الدراسة

بيانات الدراسة:

إنّ كامل البيانات محفوظة ضمن بيئة SQL Server وموزعة في أكثر من جدول كما هو موضح في الملحق، وفيما يلي تبيان آلية حساب بعض هذه المتغيرات:

- حساب قيم متغير التفاعل مع الإنترنت يكون بجمع متغيرات امتلاكه لحساب في مواقع Facebook, Twitter, Google وامتلاكه لمدونة، فإذا امتلك كامل الحسابات يأخذ القيمة 4، وإذا لم يمتلك أي حساب يأخذ القيمة 0، إن هذه المتغيرات محفوظة جميعها في قاعدة البيانات للمكتبة استفاد منها الباحثان في الوصول إلى متغير واحد فقط يمثل تفاعل زائر المكتبة الإلكترونية مع الإنترنت.

- حساب قيم متغير صافي رصيد التفاعل: ويكون بجمع الرصيد الذي أنفقه المستخدم على تحميل الكتب من الموقع، والرصيد الذي حصله من خلال تفاعله عن طريق التقييم والتعليق (حسب نظام المكتبة الإلكترونية لكل عميل رصيد من النقط يزداد من خلال التعليق والتقييم على الكتب الإلكترونية، وينقص عند تنزيل الكتاب).

- حساب قيم متغير عدد مرّات استخدام المحادثات: ويكون بحساب مجموع عدد الرسائل الصادرة والواردة من وإلى المستخدم.

أولاً: استخدام التحليل العاملي لتخفيض أبعاد الدراسة:

تم تطبيق التحليل العاملي على المتغيرات من X1 وحتى X20 باستخدام برنامج SPSS وحصلنا على النتائج التالية:

الارتباط الخطّي **Multi-Collinearity**: من خلال قيمة محدد مصفوفة الارتباط تم اختبار وجود مشكلة الارتباط الخطي، وبما أن قيمة المحدد 005 - 3.241E، وهي مختلفة عن الصفر، لذلك نستنتج عدم وجود مشكلة للارتباط الخطي بين المتغيرات، ويمكن إجراء التحليل العاملي عليها بشكل كامل دون حذف أي متغير.

اختبار **KMO Test and Bartlett's Test**: يتم تقييم كفاية حجم العينة من خلاله، حيث بلغت قيمة إحصائية اختبار KMO 0.663 وهي أكبر من الحد الأدنى، وبالتالي يمكننا أن نحكم بكفاية حجم العينة، وقيمة احتمال الدلالة Sig=0 أقل من 0.05. لذا نرفض فرضية العدم ومصفوفة الارتباط ليست مصفوفة الواحدة.

الاشتراريات **Communalities**: إنّ القيم المستخلصة للاشتراريات تشير إلى نسبة التباين في قيم المتغير المفسرة من خلال العوامل المشتركة الناتجة، فمثلاً نجد أنّ القيمة المستخلصة

الجذر الكامن على إجمالي عدد المتغيرات، أي نجد أن نسبة التباين المفسر للعامل الأول:

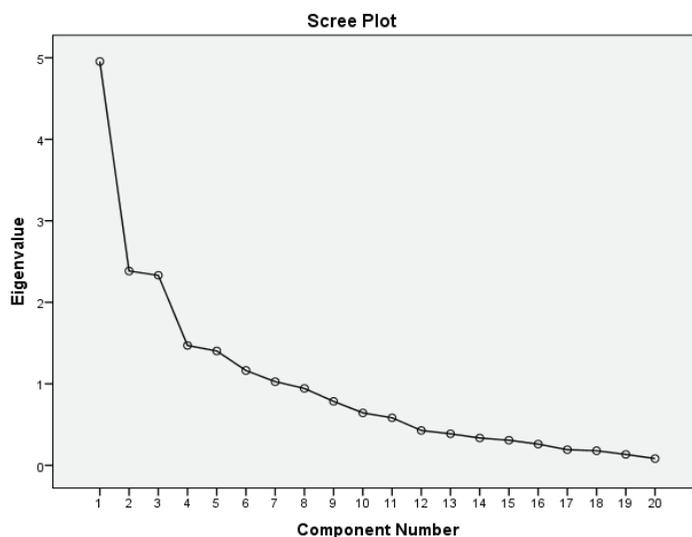
$$\frac{3.846}{20} * 100\% = 19.228\%$$

يمكن اعتماد العوامل المقترحة لأنها أكبر من 60
التمثيل البياني للعوامل Scree Plot: يستخدم هذا الشكل كأحد طرق تحديد عدد العوامل المستتجة والصالحة للدراسة، كل نقطة فيه تمثل قيمة الجذر الكامن لعامل، يتم استبعاد العوامل المقابلة للانحدار الضعيف الأفقي، ويتم قبول العوامل ذات الانحدار الشديد الشاقولي، نلاحظ بأنه عند العامل السابع بدأ الشكل بالتسطح، وهذا ما أكدته الجدول (3).

إن إجمالي نسبة التباين التي استطاع أن يفسرها النموذج العائلي كما هو واضح في الجدول (3) هي 73.678 % وبالتالي

الشكل (3)

التمثيل البياني للعوامل Scree Plot



المصدر: من إعداد الباحثين باستخدام برنامج SPSS.

مصفوفة العوامل بعد التدوير - Rotated Component Matrix

اعتمد الباحثان على طريقة Varimax لتدوير المحاور بشكل متعامد، تعرض هذه المصفوفة تحميلات Loadings المتغيرات على العوامل وتعبير أرقامها عن درجة ارتباط كل متغير بكل عامل، تم تجاهل القيم التي تقل عن 0.5. (J, Salkind Neil, 2010).

الجدول (3)

مصفوفة العوامل بعد التدوير Rotated Component Matrix

		العوامل						
		F7	F6	F5	F4	F3	F2	F1
	X1					.896		
	X2	.904						
	X3				-.809			
	X4		.742					
	X5			-.866				
	X6					.848		
	X7					.750		
	X8					.641		

		العوامل						
		F7	F6	F5	F4	F3	F2	F1
	X9	.657						
	X10				-.555			
	X11				.884			
	X12						.713	
	X13						.858	
	X14							
	X15						.864	
	X16						.865	
	X17						.545	
	X18	.729						
	X19						.628	
	X20				.608			

المصدر: من إعداد الباحثين باستخدام برنامج SPSS.

إن متغير عدد مرّات إضافة كتاب X14 غير مدرج ضمن أي عامل لعدم تشبعه بشكل كافٍ على أحدها.

ثانياً: تطبيق خوارزمية K-means على البيانات:

إن الهدف من تطبيق الخوارزمية هو الحصول على متغير قرار يدخل في حسابه كل متغيرات الدراسة، وبالتالي يمكن الحكم على صنف العميل (زائر المكتبة الإلكترونية من الطلاب) من خلال سلوكه، وليس من خلال الحكم الشخصي بناء على متغير واحد فقط، تم تطبيق خوارزمية المتوسطات K-Means على العوامل المستخلصة مع متغير القرار بدلاً من كل المتغيرات حسب (الموسى والجاسم ودهان 2015) حيث إن المتغير X21 هو متغير القرار الذي من خلاله تم تفسير نتائج الخوارزمية، تم تقييم النتائج من خلال مجموع مربعات الأخطاء الكلي Min SSE، وباستخدام برنامج SPSS حصلنا على النتائج كما في الجدول (4):

(الجدول 4)

نتيجة خوارزمية K-Means

(X21 2)	(X21 1)	N	SSE	K
2684	1716	7	10782.52	2
2651	1749	11	9953.35	4
2508	1892	6	8130.54	8
1452	2948	6	6667.46	16

المصدر: من إعداد الباحثين باستخدام برنامج SPSS.

حيث أن K تمثل عدد العناقيد واختار الباحث عدد عناقيد مختلف للوقوف على أفضل تمثيل ممكن للخوارزمية، و SSE مجموع مربعات الأخطاء الكلي و N عدد الدورات اللازمة للحل و (X21 1) عدد الحالات المجمعّة 1 لمتغير القرار و (X21 2) عدد الحالات المجمعّة 2 لمتغير القرار، ونلاحظ بأنه كلما زاد عدد العناقيد انخفض مجموع مربعات الأخطاء الكلي، وبالتالي فإن الحالات والتي تمثل العملاء (زوار المكتبة الإلكترونية من الطلاب) تنتمي إلى أصنافها الصحيحة بشكل أفضل كلما ازداد عدد العناقيد. اختبار تحليل التباين ANOVA لمعنوية متغيرات خوارزمية K-means

العوامل المؤثرة في النموذج (دهان، 2015): إن العوامل المستخلصة تمثل بيانات العملاء وسلوكهم وعددها سبعة عوامل مبنية وفق التالي:

1. التفاعل مع الموقع: تم تحميل هذا العامل بخمسة متغيرات (X12, X13, X15, X16, X19) هي عدد مرّات استخدام زر البحث وصافي رصيد التفاعل مع الموقع، وعدد مرّات إضافة تقييم، وعدد مرّات إضافة تعليق، وعدد مرّات استخدام المحادثات، وفسّر هذا العامل ما نسبته (19.228%) من التباين الكلي.

2. استخدام الإنترنت: تم تحميله بأربعة متغيرات هي التفاعل مع الإنترنت، وعدد ساعات الإنترنت يوميا، وعدد حسابات البريد الإلكتروني، ومتوسط التقييم (X6, X7, X8, X17)، وقد فسّر هذا العامل ما نسبته (11.294%) من التباين الكلي للمتغيرات.

3. المستوى العملي: فقد تمّ تحميله بمتغيرين (X1, X11) هما العمر والدرجة العلمية وقد فسّر هذا العامل نسبة قدرها (10.290%) من التباين الكلي للمتغيرات.

4. الاهتمام: فقد تمّ تحميله بثلاثة متغيرات (X3, X10, X20) هي مجال الاهتمام، وغرض استخدام الإنترنت، وعدد مرّات تحميل الكتب، وقد فسّر هذا العامل نسبة قدرها (9.263%) من التباين الكلي للمتغيرات.

5. التنقل في الإنترنت: فقد تمّ تحميله بمتغيرين (X5, X18) هما نوع الإنترنت المستخدم وإجمالي المدة التي قضاها في الموقع، وقد فسّر هذا العامل نسبة قدرها (8.747%) من التباين الكلي.

6. مستوى القراءة: فقد تمّ تحميله بمتغيرين (X4, X9) هما اللغات التي يفضلها للكتب، وعدد الكتب التي يقرأها شهرياً، وقد فسّر هذا العامل نسبة قدرها (8.612%) من التباين الكلي للمتغيرات.

7. الجنس: فقد تمّ تحميله بمتغير واحد فقط (X2) هو الجنس، وقد فسّر هذا العامل نسبة قدرها (6.244%) من التباين الكلي.

ومنه نستنتج المعادلات الممثلة للنموذج العاملي:

$$F_1 = 0.713 X_{12} + 0.858 X_{13} + 0.864 X_{15} + 0.865 X_{16} + 0.628 X_{19}$$

$$F_2 = 0.848 X_6 + 0.750 X_7 + 0.641 X_8 + 0.545 X_{17}$$

$$F_3 = 0.896 X_1 + 0.884 X_{11}$$

$$F_4 = 0.608 X_{20} - 0.809 X_3 - 0.555 X_{10}$$

$$F_5 = 0.729 X_{18} - 0.866 X_5$$

$$F_6 = 0.742 X_4 + 0.657 X_9$$

$$F_7 = 0.904 X_2$$

الجدول (5)

اختبار تحليل التباين ANOVA

عدد العناقيد 16		عدد العناقيد 8		عدد العناقيد 4		عدد العناقيد 2		المتغير
Sig	F	Sig	F	Sig	F	Sig	F	
.000	100.676	.000	399.954	.000	28.642	.497	.421	F1
.000	51.436	.000	92.46	.000	117.91	.082	3.078	F2
.000	107.864	.000	126.446	.000	37.65	.000	34.928	F3
.000	116.754	.000	89.496	.000	42.924	.000	39.292	F4
.000	112.068	.000	162.932	.000	184.518	.000	15.946	F5
.000	107.926	.000	45.922	.000	225.8	.000	278.467	F6
.000	137.398	.000	79.296	.000	60.662	.000	49.289	F7
.000	64.264	.000	70.14	.000	36.236	.000	41.499	X21

المصدر: من إعداد الباحثين باستخدام برنامج SPSS.

رقم العنقود	عدد المفردات	النسبة %	المركز النهائي لمتغير القرار
3	672	28%	1
4	396	16.5%	1

المصدر: من إعداد الباحثين باستخدام برنامج SPSS.

المسافات بين العناقيد: يوضح هذا الجدول المسافات بين مراكز العناقيد النهائية، وكما هو واضح فإن أقرب عنقود إلى العنقود الأول هو المقابل لأقل قيمة والممثل بالعنقود الثاني، وبالمثل فإن أقرب عنقود للعنقود الرابع هو العنقود الثالث، لذا قام الباحثان بدمج العنقودين الأول والثاني بالنسبة لمتغير القرار واعتبار القيمة المتوسطة بينهما تمثل المركز الجديد، كما أنه دمج العنقودين الثالث والرابع بالنسبة لمتغير القرار، والجدول (8) يوضح المسافة بين العناقيد الأربعة الناتجة:

الجدول (8)

المسافات بين مراكز العناقيد النهائية

العنقود	1	2	3	4
1		2.516	2.716	2.935
2	2.516		2.870	2.624
3	2.716	2.870		2.709
4	2.935	2.624	2.709	

المصدر: من إعداد الباحثين باستخدام برنامج SPSS.

ثالثاً: تطبيق الشبكة العصبونية على البيانات:

سيتم تطبيق نموذجي شبكة عصبونية لمسألة التصنيف المدروسة، النموذج الأول هو نموذج شبكة عصبونية افتراضي ليس عليه أي تعديل، والنموذج الثاني هو النموذج المدروس. إن بنية الشبكة العصبونية هي شبكة متعددة الطبقات (Multilayer Layer Perceptron MLP)، وتم تحديد ثوابت الشبكة لكل نموذج وفق الجدول (9):

بإجراء اختبار تحليل التباين لاختبار أي المتغيرات ذي معنوية في الخوارزمية وعند معامل ثقة 95%. تظهر النتائج في الجدول (5) بأن جميع العوامل تقريباً معنوية ولكامل عدد العناقيد، حيث نلاحظ بأن جميع المتغيرات معنوية عند تنفيذ الخوارزمية لعدد عناقيد 4 وعدد عناقيد 8 وعدد عناقيد 16، والعوامل الثالث والرابع والخامس والسادس والسابع ومتغير القرار معنوية عند تنفيذ الخوارزمية لعدد عناقيد 2.

مراكز العناقيد المختارة: تم الاعتماد على عدد عناقيد 4 بسبب معنوية جميع المتغيرات، والجدول (6) يوضح المراكز النهائية للعناقيد الناتجة في الخوارزمية:

الجدول (6)

المراكز النهائية للعناقيد

	1	2	3	4
F1	-0.630	0.039	0.333	-0.485
F2	1.284	-0.278	0.402	-0.842
F3	0.315	0.216	-0.261	-0.766
F4	0.153	0.167	0.047	-1.011
F5	-1.082	0.340	0.387	-1.357
F6	0.749	0.481	-1.035	-0.163
F7	-0.803	0.402	-0.349	-0.179
X21	2	2	1	1

المصدر: من إعداد الباحثين باستخدام برنامج SPSS.

وفيما يلي توزع المفردات على العناقيد مع تبيان المركز النهائي لمتغير القرار عند تحديد عدد العناقيد بأربعة عناقيد K=4:

الجدول (7)

توزع المفردات على العناقيد

رقم العنقود	عدد المفردات	النسبة %	المركز النهائي لمتغير القرار
1	228	9.5%	2
2	1104	46%	2

الجدول (11)

موجز عن البيانات Case Processing Summary

النموذج الأول		النموذج الثاني	
العدد N	النسبة %	العدد N	النسبة %
2160	90 %	2142	89.3 %
240	10 %	258	10.8 %

المصدر: من إعداد الباحثين باستخدام برنامج SPSS.

مصفوفة التشويش Confusion Matrix: وهي عبارة عن جدول يستخدم لوصف أداء نموذج التصنيف على مجموعة من البيانات المعروفة بالقيم الحقيقية، وفيما يلي مصفوفة التشويش الخاصة بكل نموذج:

النموذج الأول: إن دقة تصنيف النموذج لعينة التدريب هي 92.77 %، حيث نجد أن عدد الحالات المصنفة بشكل صحيح هو 2004 حالة، ودقة تصنيف النموذج لعينة الاختبار هي 97.50 %، حيث نجد أن عدد الحالات المصنفة بشكل صحيح هو 234 حالة كما هو واضح في الجدول (12):

الجدول (12)

مصفوفة تشويش النموذج الأول

المصنّف		الفعلي	نسبة التصنيف الصحيح
b = 1	a = 2		
104	1067	a = 2	92.77 %
937	52	b = 1	
5	156	a = 2	97.50 %
78	1	b = 1	

المصدر: من إعداد الباحثين باستخدام برنامج SPSS.

النموذج الثاني: إن دقة تصنيف النموذج لعينة التدريب هي 92.48 %، حيث نجد أن عدد الحالات المصنفة بشكل صحيح هو 1981 حالة، ودقة تصنيف النموذج لعينة الاختبار هي 98.06 %، حيث نجد أن عدد الحالات المصنفة بشكل صحيح هو 253 حالة كما هو واضح في الجدول (13):

الجدول (13)

مصفوفة تشويش النموذج الثاني

المصنّف		الفعلي	نسبة التصنيف الصحيح
b = 1	a = 2		
103	1097	a = 2	92.48 %
884	58	b = 1	

الجدول (9)

ثوابت الشبكة العصبونية

حجم البيانات	4200
طريقة تدريب واختبار الشبكة	Training Set 90% Testing Set 10%
طريقة قياس المتغيرات Variables Scaling	الطريقة المعيارية Standarded
دالة التفعيل Activation Function	الدالة Softmax في عقد طبقة المخرجات الدالة Sigmoid في عقد الطبقة المخفية.
خوارزمية تحقيق الأمثلية Optimization Algorithm	طريقة الانحدار Gradient Descent المترافقة مع خوارزمية الانتشار الخلفي Backpropagation
قيم الأوزان الابتدائية Seeds	0
قيمة معدل التعليم Learning Rate	$\eta = 0.4$
قيمة وسيط عزم التحريك Momentum	$\alpha = 0.3$
معيّار التوقف validationThreshold	وهو عدد المرات التي يمكن أن يزداد فيها الخطأ في مجموعة التحقق من الصحة قبل انتهاء التدريب: 20

المصدر: من إعداد الباحثين

معمارية النماذج Models Architecture: تمثّل طبقة المدخلات في النموذج الأول عدد متغيرات الدراسة، وبالتالي فإن عدد عقد طبقة المدخلات 20، بينما تمثّل طبقة المدخلات في النموذج الثاني المدروس ناتج تحليل المركبات الأساسية PCA كأحد طرق التحليل العاملي FA على البيانات قيد الدراسة، وبالتالي فإن عدد عقد طبقة المدخلات هو 7 عقد بحسب عدد العوامل. وفي كلا النموذجين فإن عدد عقد طبقة المخرجات هو عقدتين؛ لأن متغير القرار يحوي تصنيفين فقط (النموذج الأول للمتغير X21، والنموذج الثاني من ناتج خوارزمية k-means). وقد حدد الباحثان طبقة مخفية واحدة فقط لكلا النموذجين بعد الاعتماد على برنامج SPSS في تحديد عدد الطبقات بشكل أوتوماتيكي، وترك عدد العقد للبرنامج ضمن الطبقة، حيث يعتمد النظام على مبدأ التجريب لحين الوصول إلى عدد عقد يعطي حل جيد. والجدول (10) يبين عناصر معمارية الشبكة العصبونية باختلاف النماذج:

الجدول (10)

عناصر معمارية الشبكة العصبونية حسب النموذج

النموذج Model	النموذج الأول	النموذج الثاني
طبقة المدخلات Input	20 عقدة	7 عقدة
طبقة المخرجات Output	2 عقدة	2 عقدة

المصدر: من إعداد الباحثين.

تقسيم البيانات على العينات: قسّمت البيانات وفقاً للنسبة المحددة كما هي في الجدول (11):

يمثل الخط المائل منحنى خط الأساس Baseline Curve

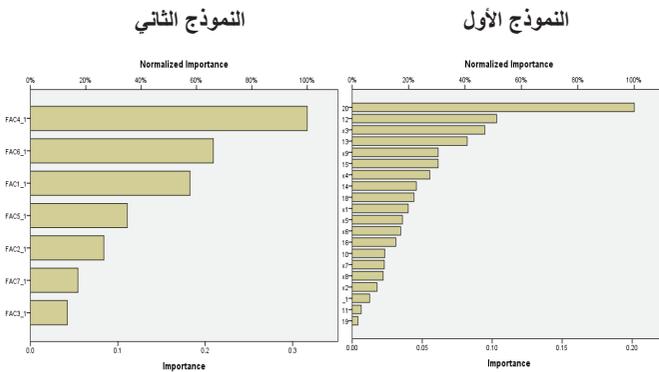
الذي يعني بأن 10% من الحالات تقابل 10% من العائد المتوقع التي تأخذ القيمة نعم، ونلاحظ من مخطط النموذج الأول مثلاً أن النقطة الأولى لمنحنى الفئة 1 (ذو اللون الأزرق) تقع في الإحداثيات (10%، 20%)، وهذا يعني التوقع بأن أكثر من 10% من الحالات تحوي ما يقارب على 20% من الحالات التي تأخذ فعلياً القيمة 1، وبالمثل فإن 20% من الحالات تحوي ما يقارب 48% وهكذا ... حتى الوصول إلى 100% من الحالات والعائد. ، وبما أن كامل النقط أعلى من منحنى خط الأساس، فالشبكة جيدة في التنبؤ للحالات التي تكون نتيجتها 1، وللحالات التي تكون نتيجتها 2 في كلا النموذجين، كما نلاحظ أن المساحة التي تقع تحت المنحنى في النموذج الأول 96. أقل من المساحة التي تقع تحت المنحنى في النموذج الثاني 99. وهذا يعني أن النموذج الثاني له مقدرة أعلى بشكل بسيط على التصنيف.

أهمية المتغيرات المستقلة Independent variable im-

portance: وهو شكل يعكس مقياس توقع نموذج الشبكة لتغيرات القيم وفقاً للمتغيرات المستقلة، وتُكمن أهمية القيم المطبوعة Normalized بحساب النسبة المئوية لكل متغير من خلال قسمة قيمته على أعلى قيمة موجودة، وكما هو واضح بالنسبة للنموذج الأول فإن المتغير x20 عد مرات تحميل كتاب ذي أهمية كبيرة يليه المتغير x12 عد مرات استخدام زر البحث وهكذا...، وهذا منطقي لأن هذين المتغيرين يعتبران حاسمين في عملية التصنيف. وبالنسبة للنموذج الثاني فإن العامل الرابع ذو أهمية كبيرة وهو عامل الاهتمام والمشعب عليه كل من المتغيرات مجال الاهتمام، وغرض استخدام الإنترنت، وعد مرات تحميل الكتب يليه العامل السادس مستوى القراءة والمشعب عليه المتغيرات اللغات التي يفضلها للكتب، وعدد الكتب التي يقرأها شهرياً وهكذا...، والشكل (5) يوضح أهمية هذه المتغيرات حسب النموذج:

الشكل (5)

أهمية المتغيرات المستقلة Independent variable importance



المصدر: من إعداد الباحثين باستخدام برنامج SPSS.

رابعاً: مناقشة النتائج:

يعرض الجدول (15) مقارنة بين نتائج تنفيذ النموذجين، فنلاحظ أن عدد الحالات المصنفة بشكل صحيح في النموذج المقترح هي الأعلى، وهذا واضح من خلال نسبة التصنيف الصحيح، فكانت النسبة الأعلى للنموذج المقترح بمقدار 98.06%. تفسر قيمة مقياس Kappa نسبة التوافق بين القيم الفعلية، والقيم الناتجة عن النماذج، فنلاحظ أن النموذج المدروس له القيمة الأعلى حيث بلغت

المصنّف		الفعلي	الإجمالي
b = 1	a = 2		
3	129	a = 2	نسبة التصنيف الصحيح
124	2	b = 1	

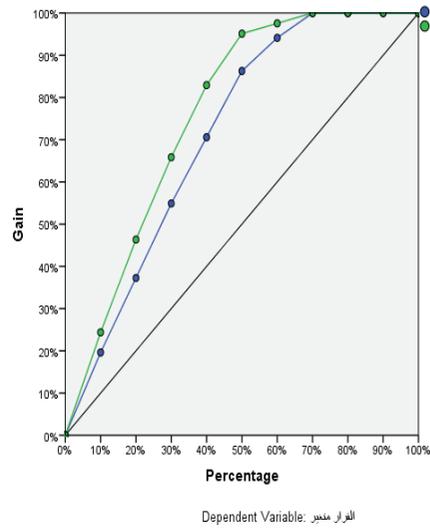
المصدر: من إعداد الباحثين باستخدام برنامج SPSS.

مخطط العائد التجمعي Cumulative Gains Chart:

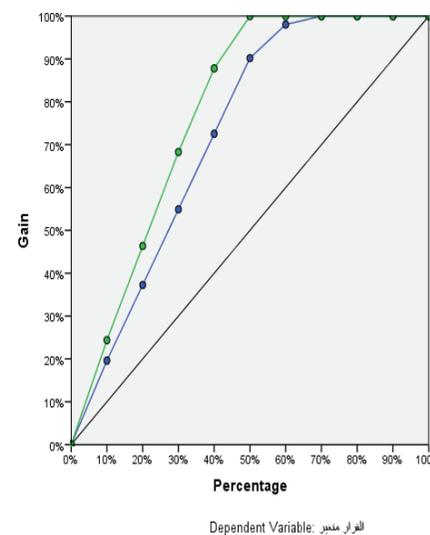
يعرض هذا المخطط نسبة العدد الإجمالي للحالات التي كسبتها الفئة الواحدة، من خلال استهداف نسبة العدد الإجمالي للحالات.

الشكل (4)

مخطط العائد التجمعي Cumulative Gains Chart النموذج الأول



النموذج الثاني



المصدر: من إعداد الباحثين باستخدام برنامج SPSS.

خوارزمية K-means للحصول على متغير قرار بعيد عن القرار الشخصي، ويأخذ كامل المتغيرات في الحسبان، واعتماد العناقد في طبقة المخرجات بدلاً من متغير القرار الشخصي.

التوصيات لأبحاث مستقبلية:

1. دراسة النموذج المقدم في المشاكل الإدارية ذات الطبيعة التصنيفية باختلاف المتغيرات، وتطبيقه في قطاعات التأمين والمصارف وغيرها، ومقارنة أداء النموذج مع النماذج التقليدية الأخرى.

2. دراسة إمكانية الاعتماد على التحليل العاملي FA وتحليل المركبات الأساسية PCA في تقدير الأوزان بين جميع العقد في الشبكة العصبونية متعددة الطبقات، بدلاً من الاعتماد على العشوائية في تقديرها، مما يساهم في سرعة تعليم النموذج وبالتالي السرعة في اتخاذ القرار.

3. تقدير عدد العقد في الطبقة المخفية من خلال أسلوب كايزر المعتمد على القيم الذاتية Eigenvalues، كأحد الطرق المستخدمة في تحليلي FA وPCA، بدلاً من الاعتماد على مبدأ التجربة والخطأ Try and Error في تحديد عدد عقد هذه الطبقة، مما يساهم في الحصول على ذات النتائج عند تطبيق النموذج في كل مرة.

4. دراسة العلاقة بين نتيجة نموذج الشبكة العصبونية واختلاف الدوال المستخدمة للانتقال بين الطبقات المختلفة للنموذج، ما يساهم في تخفيض درجة تعقيد الشبكة، من خلال الاختيار المناسب لهذه الدوال لتناسب مع طبيعة كل متغير في طبقة الدخل.

قائمة المصادر والمراجع باللغة العربية:

- الموسى، ياسر. الجاسم، عبد الناصر، دهان، محمد لؤي. (2015)، بناء نموذج تسويق الكتروني لإضفاء الطابع الشخصي في المكتبة الالكترونية. مجلة بحوث جامعة حلب، حلب، سورية، العدد 16.
- الموسى، ياسر. الجاسم، عبد الناصر، دهان، محمد لؤي. (2015)، تحسين خوارزمية العنقدة K-means باستخدام التحليل العاملي. مجلة بحوث جامعة حلب، حلب، سورية، العدد 16.
- العباسي عبد الحميد. (2001)، التحليل العاملي: تطبيقات في العلوم الاجتماعية باستخدام SPSS. معهد الدراسات والبحوث الإحصائية، جامعة القاهرة، القاهرة، ص7.
- دهان، محمد لؤي. (2015)، بناء نموذج عنقدة باستخدام الشبكات العصبية لدعم عملية التسويق الالكتروني. رسالة ماجستير، جامعة حلب، حلب، سورية.
- ريتشارد، جونسون، دين، وشرن. (1998)، التحليل الإحصائي متعدد المتغيرات من الوجة التطبيقية. تعريب، عزام عبد المرضي، دار المريخ، الرياض، ص580 - ص848.
- نصار هلا، سلوم كمال، أبو صالح ناصر. (2014)، تصنيف تعابير الوجه باستخدام شبكة عصبونية وخوارزمية PCA، مجلة بحوث جامعة البعث،

961. مقابل 944. للنموذج الأول. كما ونجد أن الزمن اللازم لبناء النموذج وتدريبه في النموذج الأول بلغ 11.6 ثانية، وهو زمن مرتفع مقارنة بالنموذج المقترح 3.8 ثانية.

الجدول (15)

ملخص النماذج المدروسة

النموذج الثاني	النموذج الأول	النموذج Model
2234	2238	عدد الحالات المصنفة بشكل صحيح Correctly Classified Instances
166	162	عدد الحالات المصنفة بشكل خاطئ Incorrectly Classified Instances
0.961	0.944	معامل كبا لعينة الاختبار Kappa statistic
98.06 %	97.5 %	نسبة التصنيف الصحيح لعينة الاختبار Correctly Classified
3.8 ثانية	11.6 ثانية	زمن بناء النموذج وتدريبه Time taken to build and train model
42	163	عدد الأوزان الكلي Complexity

المصدر: من إعداد الباحثين باستخدام برنامج SPSS.

النتائج:

1. إن تطبيق النموذج في المكتبات الإلكترونية يساعد على معرفة زوار المكتبة بشكل فعال بسبب الاعتماد على كامل البيانات في التصنيف، مما يعطي إدارة المكتبات الأفضلية في إدارة العملاء الممثلين بزوار المكتبة.

2. إن استخدام نموذج التحليل العاملي FA لتخفيض عدد الأبعاد واستبدال المتغيرات الأصلية بالعوامل الناتجة في طبقة المدخلات في الشبكة العصبونية خفض من درجة تعقيد الشبكة العصبونية، وأعطى نتيجة قريبة من النموذج الأصلي في دقة التصنيف وبزمن بناء وتدريب أقل.

3. إن خوارزمية K-means جعلت البيانات بالاعتماد على كل المتغيرات، وبالتالي فإن القرار أصبح بناء على كل متغيرات الدراسة وليس على متغير واحد فقط.

رؤية تطبيقية للنتائج:

بناء على نتائج الدراسة ينصح الباحثان بالاعتماد على النموذج المقترح في حل المشاكل الإدارية المدرجة ضمن مشاكل التصنيف والنتيجة عن تنوع البيانات، لاعتماده على كامل المعلومات المتاحة بدلاً من متغير قرار واحد فقط. كما ينصح المكتبات الإلكترونية بالاعتماد على قدرته على تصنيف الزوار بحسب تفاعلهم مع المكتبة إلى زوار جيدين لهم أثر في المكتبة وزوار عاديين.

كما ينصح الباحثان باستخدام التحليل العاملي في حال استخدام الشبكات العصبونية للتصنيف لحل مثل هذه المشاكل الإدارية بالاعتماد على قاعدة بيانات متعددة الأبعاد، واعتماد العوامل الناتجة بدلاً من المتغيرات في طبقة المدخلات لما لها من تأثير في تخفيض درجة تعقيد الشبكة، وبالتالي السرعة في الأداء مع الحفاظ على نسبة تصنيف مرتفعة. كما يُنصح باستخدام

سورية.

- Edition, Kindle Edition, SAGE Publications, pp. 460-466.
- Leskovec Jure, Rajaraman Anand, Ullman Jeffrey David. (2020), *Mining of Massive Datasets, Third edition*, Cambridge University Press, pp. 517-520.
 - Li J., Cheng J., Shi J., Huang F. (2012), *Brief Introduction of Back Propagation (BP) Neural Network Algorithm and Its Improvement*. In: Jin D., Lin S. (eds) *Advances in Computer Science and Information Engineering. Advances in Intelligent and Soft Computing*, vol 169. Springer, Berlin, Heidelberg, 2012.
 - Mehrotra K., Mohan C., Ranka S. (1997), *Element of Artificial Neural Networks*, MIT Press, USA.
 - P. Arumugam, R. Ezhilarasi. (2017), *Data Mining based Neural Network Model for Rainfall Forecasting*, *International Journal of Computer Applications*, Volume 170 – No.4.
 - Rencher, Alvin C. (2002), *Methods of Multivariate Analysis*, Wiley-Interscience, United States of America, Second Edition, P 482.
 - Shafi Imran et al. (2006), *Impact of Varying Neurons and Hidden Layers in Neural Network Architecture for a Time Frequency Application*, *IEEE International Multitopic Conference*.
 - Tan, Pang-Ning, Steinbach, Micheal, Kumar, Vipin. (2006), *Introduction to Data Mining*, Addison-Wesley, Boston, United States of America, P.507.
 - Taylor, Brian J. (2006), *Methods and Procedures for the Verification and Validation of Artificial Neural Networks*, Springer Science & Business Media.
 - Zekić-Sušac Marijana; Šarlija Nataša; Pfeifer Sanja. (2013), *Combining PCA analysis and neural networks in modelling entrepreneurial intentions of students*, *Croatian Operational Research Review*, Croatia, 4, P306-317.

ترجمة المصادر والمراجع العربية:

- Al-Mousa, Yasser. Al-Jasem, Abdulnser, Dahhan, Mohamed Loay. (2015), *Building an electronic marketing model to personalize the electronic library*. *Research Journal of Aleppo University*, Aleppo, Syria, Issue 16.
- Al-Mousa, Yasser. Al-Jasem, Abdulnser, Dahhan, Mohamed Loay. (2015), *Improve the Result of K-Means Algorithms using Factor Analysis*. *Research Journal of Aleppo University*, Aleppo, Syria, Issue 16.
- Al-Abbasi, Abdul Hamid. (2001), *Factor Analysis: Applications in Social Sciences using SPSS*. Institute of Statistical Studies and Research, Cairo University, Cairo, p. 7.
- Dahhan, Mohamed Loay. (2015), *Building a clustering model using artificial neural network to support electronic marketing operation*. Master thesis, Aleppo University, Aleppo, Syria.
- Johnson, Richard. Schorn, Den. (1998), *Applied Multivariate Statistical Analysis. The translation of Abd al-Mardi Azzam*, Dar al-Merikh, Riyadh, p. 850, p. 848.
- Nassar Hala, Salom Kamal, AboSaleh Naser. (2014), *Face Expression Classification Using Neural Network and PCA algorithm*, Al-Baath University Research Journal, Syria.

قائمة المراجع باللغة الإنكليزية:

- Abuzir Yousef & Baraka AbdulRahman M. (2019), *Financial Stock Market Forecast Using Data Mining in Palestine*. *Palestinian Journal of Technology & Applied Sciences - No. 2 – January*.
- Abuzir Yousef & Dweib Mohammad. (2018), *Optimization of the Neural Networks Parameters*. *Palestinian Journal of Technology & Applied Sciences - Vol. 1 - No. 1- January*.
- Dahhan, M. L., Almousa, Y. (2020), *Reducing the Complexity of the Multilayer Perceptron Network using the Loading Matrix*. *International Journal of Computer Applications*, 975, 8887.
- Dang Tuan Linh, Hoshino Yukinobu. (2019), *Improved PSO Algorithm for Training of Neural Network in Co-design Architecture*, *International Journal of Computer Applications*, Volume 182 - No.44.
- Ding Shifei et al. et al. (2011), *Research of neural network algorithm based on factor analysis and cluster analysis*, *Neural Comput & Applic* (2011) 20:297–302 springer-Verlag London Limited.
- Ding Shifei, Jia Weikuan, Xu Xinzhen, Zhu Hong. (2010), *Neural Networks Algorithm Based on Factor Analysis*, Springer-Verlag Berlin Heidelberg, Germany, Part I, LNCS 6063, pp. 319–324.
- Du Ke-Lin, Swamy M. N. S. (2019), *Neural Networks and Statistical Learning*, Springer-Verlag London, UK.
- Gupta Tarun Kumar, Raza Khalid. (2018), *Optimizing Deep Neural Network Architecture: A Tabu Search Based Approach*. *Computer Science*, springer.
- Hagan Martin, Demuth Howard, Beale Mark, De Jesús Orlando. *Neural Network Design*, Oklahoma State University, Stillwater, OK, United States, 2nd Edition, P13-1.
- Heaton Jeff. (2011), *Introduction to the Math of Neural Networks*, Heaton Research, Inc., USA.
- Hossam Mosbah and M.E. El-Hawary. (2017), *Optimization of neural network parameters by Stochastic Fractal Search for dynamic state estimation under communication failure*, *Electric Power Systems Research*, Volume 147.
- Inthachot, M., Boonjing, V., & Intakosum, S. (2016). *Artificial Neural Network and Genetic Algorithm Hybrid Intelligence for Predicting Thai Stock Price Index Trend*. *Computational Intelligence and Neuroscience*, 1–8.
- J,Salkind Neil, 2010. *Encyclopedia of Research Design*, 1st