مُقارنة الشَّبكاتِ العصبيَّةِ الاصطناعيَّة وتحليلِ الانحدارِ المتعدِّد في التنبُّؤ ببعضِ المتغيِّرات النَّفسيَّة لدى عيِّنة من طالبات الجامعة

د/ نسرين محمد سعيد يوسف

أستاذ مساعد علم النَّفس- كُليَّةُ التَّربية- جامعةُ القصيم

المُستخْلصُ:

هدفَ البحثُ الحالي الكشفَ عن كفاءةِ النَّموذجِ التنبُّؤي الذي تمَّ بناؤه باستخدامِ الشَّبكاتِ العصبيَّةِ الاصطناعيَّة وفعاليتهِ في التنبُّؤ ببعضِ المتغيِّراتِ النَّفسيَّة بالمقارنةِ بأسلوبِ تحليلِ الانحدار المتعدِّد لدى عيِّنة من طالباتِ جامعةِ القصيم بلغتْ (٣٥٩) طالبةً، وتمثَّلتْ أدواتُ البحثِ في: قائمةِ التَّكيُّف الأكاديمي بوصفهِ مُتغيِّرًا تابعًا، واستبانةِ الصَّلابةِ النَّفسيَّة، ومقياسِ فعاليَّةِ الذات بوصفهما مُتغيِّرين مُستقلِّين، وقدْ خلُصتْ نتائجُ البحثِ إلى كفاءةِ نموذجِ التنبُّؤ الذي تم إنشاؤه باستخدامِ الشَّبكاتِ العصبيَّةِ الاصطناعيَّة حيث تمَّ استخدامُ مجموعِ مربَّعاتِ الخطأ للحكمِ على جودةِ التنبُّؤ بين مجموعةِ بياناتِ التَّدريب وتحسُّنهِ حيث بلغَ المؤشِّرُ (٩٢,١٣٩) وبين مجموعةِ الاختبار حيث بلغ المؤشِّرُ (٣٤,٠٤٢)، ويظهرُ بوضوح انخفاضُ نسبةِ الخطأ للتنبُّؤ ما بين مجموعتي التَّدريبِ والاختبار؛ ممَّا يدلُّ على رصانةِ النَّموذج المستخدم ووصولهِ لأفضلِ أداء تنبؤي. وللحكمِ على فعاليَّةِ النَّموذج تمَّ عملُ مقارنة بين أسلوبِ الشَّبكاتِ العصبيَّةِ الاصطناعيَّة في التنبُّؤ وأسلوبِ تحليل الانحدار المتعدِّد لمتغيِّراتِ الدِّراسة وأظهرتْ النَّتائجُ التي اعتمدتْ على مؤشِّرات جودةِ النَّموذج التنبُّؤي وملائمته انخفاضًا في قيمِ كلِّ مؤشِّراتِ الحكم (جذر متوسِّط مربَّع الخطأ – متوسِّط القيمة المطلقة للخطأ – المتوسِّط النِّسبي للخطأ المطلق – جذر المتوسِّط النِّسبي لمربَّع الخطأ) وزيادة في النِّسبة المفسِّرة للتباينِ للمتغيِّر المتنبأ به التي تمَّ حسابُها عن طريقِ معامل التحديد (R^2)، ووصلتْ الشَّبكة لمعدَّلٍ مرتفعٍ وعالٍ من الدِّقة، وأعطتْ نموذجًا رصينًا يصلحُ للتنبُّؤ بالقيمِ المستقبليَّة لاستخدامهِ طريقةَ التَّحقُّقِ المتقاطع.

الكلمات المفتاحية: الشَّبكات العصبيَّة الاصطناعيَّة؛ الصلابة النَّفسيَّة؛ فعاليَّة الذات؛ التَّكيُّف الأكاديمي؛ تحليل الانحدار المتعدد.

Comparison of Artificial Neural Networks and Multiple Regression Analysis in Prediction of Some Psychological Variables among University Female Students

Dr. Nisreen Mohamed Saeed Zarea
Psychology Assistant Professor - Faculty of Education – Qassim University

Abstract:

This study aimed to reveal the efficiency and effectiveness of the predictive model built using artificial neural networks in predicting psychological variables among female students from Qassim University comparing to multiple regression analysis with sample size reached ٣٥٩ students. The study tools were academic adaptation inventory as a dependent variable, the psychological hardness questionnaire and the self-efficacy scale as independent variables. Results assured the efficiency of the prediction model that was created using ANN, where the sum of the square errors was used to judge the quality and improvement of prediction between the training data set, where the indicator reached ٩٢,١٣٩, and the test set, where the indicator reached ٣٤,٠٤٢, and it clearly shows a decrease in the error rate for prediction between the two groups, which indicates the validity of the used model and its best predictive performance. In order to judge the effectiveness of the model, a comparison was made between artificial neural networks (ANN) and multiple linear regression (MLR). The results showed that there was a decrease in the values of all judgment indicators (root mean square error RMSE - mean absolute error MAE - Mean Absolute Percentage Error MAPE - Root Mean Square Percentage Error RMSPE) and an increase in the explanatory ratio of variance for the predicted variable calculated by means of the coefficient of determination $R^{٢}$, and the network reached a high accuracy rate and gave a solid model that is suitable for predicting future values using the cross-validation method.

Keywords: Artificial Neural Networks; Psychological Hardness; Academic Adaptation; Self-Efficacy; Multiple Linear Regression.

المُقدِّمةُ:

اهتمَّ علمُ النَّفس تاريخيًا بشرحِ الآليّاتِ السببيَّة (Causal Mechanisms) التي تؤدِّي إلى السُّلوك البشري، حيثُ تمَّ اعتمادُ التَّجاربِ العشوائيَّة، ومراقبةِ السُّلوك، وردودِ الأفعالِ للمجتمع؛ لتكونَ المعيارَ الرئيسَ للبحثِ النَّفسي، وأدَّى ذلك إلى تركيزٍ شبه كامل لعلم النَّفس على تفسيرِ مُسبِّباتِ السُّلوك، ممَّا أثرى المجالَ ببرامجَ بحثيَّة توفِّرُ نظريات مُعقَّدة للميكانزمات النَّفسيَّة، ولكنَّ لديها قدرةً قليلةً على التنبُّؤ بالسُّلوكيَّاتِ المستقبليَّة بأي طريقةٍ ملموسة.

ومؤخَّرًا أصبحتْ الأبحاثُ الحديثةُ في مجالاتِ العلومِ المختلفة، تتناولُ عدَّةَ متغيِّرات كميَّة أو نوعيَّة، وأدتْ معالجةُ هذه البياناتِ المتعدِّدة إلى ظهورِ فرعٍ جديدٍ في الإحصاء ينتجُ عنه بياناتٌ مُتعدِّدة تحتاجُ إلى أساليب إحصائية أكثر تعقيدًا، ومنذُ ظهورِ مفهومِ الذَّكاء الاصطناعي ارتبطَ بعلمِ النَّفس ارتباطًا وثيقًا، فقدْ أجرى علماءُ النَّفس وباحثو الذَّكاءِ الاصطناعي كثيرًا من الأبحاثِ التَّعاونيَّة. حيث أُنجزتْ عديدٌ من الأبحاثِ المشتركةِ بين العلماءِ في التَّخصُّصَين، واستخدموا تقنياتِ التَّعلمِ العميق لمحاكاةِ قُدراتِ الملاحةِ المكانيَّة بنجاحٍ من الدماغ البشري؛ ممَّا أتاحَ للباحثين آفاقًا جديدة لتطبيقِ تكنولوجيا الذَّكاءِ الاصطناعي في أبحاثِ علمِ النَّفس.

ومن ناحيةٍ أخرى يمكنُ أنْ تساعدَ المبادئُ والتِّقنياتُ من مجالِ التَّعلُّمِ الآلي والذَّكاءِ الاصطناعي علمَ النَّفس في أنْ يصبحَ علمًا أكثر تنبؤًا يركِّزُ على أسئلةِ البحثِ التنبُّؤية. حيثُ إنَّ التركيزَ المتزايد على التنبُّؤ بدلاً من التَّفسير، يمكنُ أنْ يقودَ في النهاية إلى فهمٍ أكبر للسلوك (Yarkoni & Westfall, ٢٠١٧)

وفي الوقت الحاضر، يتمُّ تطبيقُ تكنولوجيا الذَّكاءِ الاصطناعي بشكلٍ جيد في البحثِ في مجالِ القياس النَّفسي. حيث تمَّ تطبيقُ الحوسبةِ التَّطوريَّة التَّفاعليَّة IEC (Interactive Evolutionary Computation) للقياسِ النَّفسي وتقييم مرضى الفصام للمساعدةِ في التَّحقُّقِ من أنَّ النِّطاقَ الديناميكي للتَّعبيرِ العاطفي الذي يشعرُ به مرضى الفصام أعلى من الأشخاصِ الأصحاء (Takagi, ٢٠٠١).

ويُعدُّ هذا البحثُ أحدَ البحوثِ الرائدة للخوارزميَّاتِ المطبَّقةِ في مجالِ القياسِ النَّفسي. وقبل ذلك، اعتقدَ الأطبَّاءُ النَّفسيون والمعالجون النَّفسيون أنَّ مرضى الفصام يعانون من مشاكل في التَّعبيرِ العاطفي، ولكن بسببِ الافتقارِ إلى الأساليب الكميَّة لقياسِ قدرتِهم على التَّعبير العاطفي، لم يمكن استخدامُها أساسًا تشخيصيًا. وتوفِّرُ الحوسبةُ التَّطوريَّة التَّفاعليَّة طريقةَ القياسِ الكمي التي تجعلُ من الممكنِ قياسَ نطاقِ الإدراكِ العاطفي. وفي وقتٍ لاحق تمَّ استخدامُ تقنياتِ الذَّكاء الاصطناعي لدراسة القلقِ الاجتماعي المرتفع والمنخفض لدى طلَّابِ الجامعات، حيث قام الباحثون بقياسِ الفَرقِ في نطاقِ الإدراكِ الديناميكي ومقارنته للتَّعرُّفِ إلى عواطفِ الوجه بنجاح (Huang et al., ٢٠١٣). وتُظهرُ هذه الدِّراساتُ أنَّ تقنياتِ الذَّكاء الاصطناعي، باعتبارها خوارزميَّة ذكيَّة، مناسبةٌ لقياسِ الصحةِ العقليَّة.

وقدْ تمَّ استخدامُ تقنيةِ تعرُّفِ تعبيراتِ الوجه المتاحة بتقنياتِ الذَّكاءِ الاصطناعي في أبحاثِ التنبُّؤ بعوامل الشخصية النَّفسيَّة. حيث كانت طريقةُ تحديدِ أنواع الشَّخصيات هي الاستباناتُ بشكلٍ أساسي، وكانت هذه الطريقةُ تستغرقُ كثيرًا من الجهدِ والوقتِ، وتعاني من عدمِ دقَّةِ القياس. وتمَّ استحداثُ نظامٍ جديدٍ يُمكِّنه تحديدُ خصائصِ الشَّخصية للشَّخصِ بُناءً على تعبيراتِ الوجهِ التي تمَّ الحصولُ عليها من خلالِ ترميزِ حركةِ الوجه (Gavrilescu & Vizireanu, ٢٠١٧) .

ومن أهمِّ التِّقنياتِ في مجالِ الذَّكاءِ الاصطناعي، تقنيةُ الشَّبكاتِ العصبيَّة الاصطناعيَّة. وقد استخدمتْ تقنيةُ الشَّبكة العصبيَّة لتطويرِ نظامِ تشخيصِ الاضطراباتِ النَّفسيَّة للأطفالِ مثل اضطرابِ فرطِ الحركةِ، ونقصِ الانتباه، واضطراباتِ السُّلوكِ والاضطراباتِ العقليَّة، حيثُ تشبه عمليةُ معالجةِ الإدراكِ الاجتماعي البشري عمليَّةَ معالجةِ المعلومات الخاصة بالشَّبكة العصبيَّة الاصطناعيَّة؛ لذلك أنشأ عديدٌ من الباحثين نماذجَ تنبؤ للشَّبكةِ العصبيَّةِ الاصطناعيَّة وبخصائصِها الخاصة لبعضِ المتغيِّرات النَّفسيَّة في عمليَّةِ الإدراكِ الاجتماعي. بالإضافة إلى ذلك، تمَّ استخدامُ تقنيةِ الشَّبكة العصبيَّة الاصطناعيَّة بشكلٍ أفضل في التنبُّؤ بالصحةِ العقلية، حيثُ تمَّ استخدامُ تقنيةِ الشَّبكة العصبيَّة الاصطناعيَّة للتنبؤ بالاكتئابِ في اضطراباتِ المزاج السريرية (Serretti & Smeraldi, ٢٠٠٤).

اهتمَّ الباحثون في التَّربيةِ وعلمِ النَّفس بمفهومِ التَّكيُّف الأكاديمي؛ لارتباطهِ بكثيرٍ من العواملِ المؤثِّرة في حياةِ الفرد، وتمَّ استخدامُ مفهومِ التَّكيُّفِ على نطاقٍ واسعٍ منذ داروين Darwin ، وهو مفهومٌ مُعقَّد ويصعبُ تحديدُه ، ويميلُ إلى أنْ يصبحَ مفهومًا شاملاً، فهو عمليَّةٌ نَّفسيَّةٌ للاعتيادِ والتَّعامُل مع المشكلاتِ والتَّحدياتِ ومتطلَّباتِ الحياةِ اليوميَّة والتَّعاملِ معها وإدارتِها ويُعدُّ تكيُّفُ الطلَّابِ الأكاديمي مع بيئةِ الجامعة عاملًا مهمًا في توقُّعِ النَّتائج وهو أمرٌ بالغُ الأهميَّةِ لإنجازاتِهم المستقبليَّة.

ومن ناحيةٍ أخرى، تظهرُ الحاجةُ إلى شعورٍ قوي بالفاعليَّة الذَّاتيَّة للمثابرةِ على الواجباتِ والتَّحديات والتَّكيُّفِ مع البيئةِ الأكاديمية، فعندما يواجهُ المرءَ النَّجاح والفشل، سيختار الأفرادُ الذين يتمتَّعون بمزيدٍ من الفاعليَّةِ الذَّاتية مهامًا صعبة ومهمَّة ويلتزمون بشدة بواجباتهم، حيثُ يشعرُ الأفرادُ ذوو الفاعليَّة الذاتيَّة المتدنيَّة باليأسِ وخيبةِ الأمل من المشاكلِ والعقبات، وبالتالي يصعبُ تكيُّفهم مع أعضاءِ المجتمع الآخرين. وقد حظي هذا المفهومُ باهتمامِ العلماءِ والباحثين، وبخاصةٍ في علمِ النَّفس وفروعه المختلفة، حيثُ ارتبطَ بمفاهيم مختلفة، بما في ذلك مفهومُ الصلابةِ النَّفسيَّة.

إنَّ القدرةَ على النَّظرِ إلى العقباتِ على أنَّها نمطُ حياةٍ عادي، والاهتمامُ الحقيقي والفضولُ بشأنِ المهمَّة وضبطِ النَّفس يمكنُ أنْ تجعلَ الشَّخصَ أكثر تركيزًا على العمل. والصلابةُ النَّفسيَّة هي جانبٌ من جوانبِ الشَّخصيَّة التي تؤثِّرُ على الطريقةِ التي ينظرُ بها الأفراد، ويتصرَّفون في المواقفِ العصيبة، حيث يميلُ الأشخاصُ الذين يتمتَّعون بصلابةٍ نفسيَّةٍ عالية إلى رؤيةِ العالمِ على أنَّه مثيرٌ للاهتمام وذو مغزى، ويشاركون بنشاطٍ في الأنشطةِ المختلفةِ من

حولهم، حيثُ التَّحدي والالتزام والتَّحكُّم هي المكوِّنات الثَّلاث لعمليَّةِ التَّقييم المعرفي التي يُطلقُ عليها اسمُ الصلابةِ النَّفسيَّة (Kobasa, ١٩٧٩). وقد كشف (Orr & Westman, ١٩٩٠) أنَّ الصلابةَ النَّفسيَّة مرتبطةٌ بشكلٍ كبيرٍ بقدرةِ الفردِ على التَّكيُّف.

مُشْكِلةُ البحث:

من الأهدافِ الأساسيَّة لعلمِ النَّفس عمل تنبُّؤات حول كيفيةِ تفكيرِ الفرد وكيفيةِ تصرُّفهِ، حيث يُعدُّ التنبُّؤ النَّاجحُ بالسُّلوك أحدَ أفضلِ الطُّرقِ لفهمِ الأسبابِ الكامنة وراءَ الأفعال. ويسمحُ التوقُّعُ أيضًا لعلماءِ النَّفس بعملِ تخميناتٍ حول السُّلوكِ البشري دون فهمٍ بالضرورةِ للآليَّاتِ الكامنةِ وراءَ الظَّواهرِ المختلفة.

ويمكنُ التنبُّؤ باستخدامِ عديدٍ من الِتّقنيات، بما في ذلك مجموعةٌ متنوِّعة من الأساليب الإحصائية مثل (الانحدارِ الخطي والانحدارِ اللوجستي، والتَّحليلِ التمييزي). وتمثِّلُ الشَّبكاتُ العصبيَّةُ الاصطناعيَّة تقنيةً جديدةً ظهرت بديلًا مُحتملًا لتحليلِ الانحدار، والطُرقِ الإحصائيَّةِ الكلاسيكية الأخرى(Guerriere & Detsky, ١٩٩١).

وتتميَّزُ الشَّبكاتُ العصبيَّةُ الاصطناعيَّة بأنَّها ليست مقيدةً بعلاقةٍ رياضيةٍ محدَّدةٍ مُسبَّقًا بين المتغيِّراتِ التابعةِ والمتغيِّراتِ المستقلة، ولديها القدرةُ على نمذجةِ أي علاقةٍ غير خطية مُعقَّدة، ويمكنُ تطويرُ النَّماذج من قِبَلِ المستخدمين الذين يكون لديهم حدٌّ أدنى من المعرفةِ النَّظرية (Tu, ١٩٩٦).

تشيرُ بعضُ الدِّراساتِ إلى أنَّها قدْ تقدِّمُ أداءً تنبؤيًا أفضلَ بكثيرٍ من الطُرقِ الإحصائيَّة التقليدية لمشاكل مُعيَّنة، وبالتالي قدْ تمثِّلُ الشَّبكاتُ العصبيَّة بديلاً جذابًا للانحدار بوصفه أسلوبَ نمذجةٍ إحصائية في ظلِّ ظروفٍ معيَّنة (Pourshahriar, ٢٠١٢; St-Pierre, ٢٠١٦)

وقدْ أثارتْ الخلافاتُ الأخيرةُ حول مستوى قابليةِ تكرارِ البحوثِ السُّلوكية التي تمَّ تحليلُها باستخدامِ الاستدلالِ الإحصائي اهتمامًا بتطويرِ تقنياتٍ أكثرَ كفاءةً لتحليلِ نتائج المقاييس النَّفسيَّة، حيثُ توصَّل (Orrù et al., ٢٠٢٠) إلى أنَّ استكمالَ سيرِ العملِ التحليلي لنتائجِ المقاييس النَّفسيَّة، مع التَّحليلِ القائمِ على التَّعلمِ الآلي سيؤدِّي إلى زيادةِ الدقة وتقليلِ مشكلات قابلية التكرار، بالمقارنةِ مع الاستدلال الإحصائي، وأنَّ التَّحليلَ القائمَ على تقنياتِ تعلُّمِ الآلة (Machine Learning) للبياناتِ التَّجريبية هو نموذجٌ محايدٌ ويركِّزُ بشكلٍ أساسي على التنبُّؤ بدلاً من الاستدلال.

وبالنَّظرِ إلى الدورِ المحوري للتَّكيُّفِ الأكاديمي لنجاح الطلاب، فمن المهمِّ النَّظر بتمعُّن حول كيفيةِ تأثيرِ عديدٍ من العواملِ النَّفسيَّةِ والسُّلوكيةِ كفعاليَّةِ الذَّات، والصلابةِ النَّفسيَّة على التَّكيُّف الأكاديمي، ومدى قابليَّةِ التنبُّؤ بالتَّكيُّفِ الأكاديمي من خلالها. ونظرًا لاستخدامِ الشَّبكاتِ العصبيَّةِ الاصطناعيَّة أسلوبًا إحصائيًا للتنبُّؤ على نطاقٍ واسعٍ في مختلفِ مجالاتِ العلوم وكونه أسلوبًا واعدًا يحتاج مزيدًا من الدراسة، ولندرةِ استخدامهِ في العلومِ النَّفسيَّة وبخاصةٍ في البيئة العربية، برزتْ أهميَّةُ هذه الدراسة وتبلورتْ مشكلتُها في التَّساؤلِ التالي:

ما فاعليَّةِ وكفاءةِ التنبُّؤ بالمتغيِّرات النَّفسيَّة عن طريقِ استخدامِ الشَّبكاتِ العصبيَّةِ الاصطناعيَّة بالمقارنةِ بأسلوبِ تحليلِ الانحدارِ المتعدد؟

ويتفرعُ منه الأسئلةُ الفرعيةُ التَّالية:

١. ما كفاءةُ نموذجِ التنبُّؤ بالتَّكيُّف الأكاديمي من خلالِ الصلابة النَّفسيَّة وفاعليَّةِ الذات باستخدامِ الشَّبكات العصبيَّة الاصطناعيَّة؟

٢. ما فاعليَّةُ الشَّبكاتِ العصبيَّة الاصطناعيَّة في التنبُّؤ بالمقارنةِ بأساليب التنبُّؤ الكلاسيكية كأسلوبِ تحليل الانحدار المتعدِّد؟

أهدافُ البحث:

يهدفُ البحثُ الحالي استخدامَ أسلوبِ الشَّبكاتِ العصبيَّةِ الاصطناعيَّة باعتبارها وسيلةً متطورةً وأكثرَ دقة للتنبُّؤ بالمتغيِّراتِ النَّفسيَّة، والتَّحقُّقِ من كفاءةِ استخدامِ النَّموذجِ الذي تم بناؤه في التنبُّؤ بالتَّكيُّفِ الأكاديمي من خلال فاعليَّةِ الذَّات، والصلابةِ النَّفسيَّة لطالباتِ الجامعة. معَ التَّأكُّدِ من فاعليَّةِ استخدامِ الشَّبكات العصبيَّة الاصطناعيَّة للتنبؤ بالمقارنةِ بأساليب التنبُّؤ التقليدية وتحديدًا أسلوب تحليلِ الانحدار المتعدِّد.

أهميَّةُ البحث:

الأهميَّةُ النَّظرية:

تكمنُ أهميَّةُ البحثِ الحالي فيما ستسفرُ عنه معرفةُ العلاقةِ بين متغيِّراتِه، ممَّا قدْ يسهمُ في زيادةِ الفهم والوعي بتأثيرِ كلٍ منهما في الآخر، ومن ثمَّ توجيهُ نظرِ القائمين على العمليَّةِ التَّربويَّة إلى استثمارِها في تحسينِ التَّكيُّفِ الأكاديمي للطلبة وزيادةِ كفاءتِهم وفاعليتِهم ونجاحِهم في حياتِهم الأكاديميَّة.

وتنبعُ أهميةُ البحثِ الحالي أيضًا من الاتجاهِ الحديثِ في علمِ النَّفس للتركيزِ على التنبُّؤ بوصفهِ محاولةً لفهمِ السُّلوك البشري من الاتجاه إلى التفسير، وعليه كانت الحاجةُ إلى تسليطِ الضوءِ على الشَّبكاتِ العصبيَّةِ الاصطناعيَّة بوصفه أسلوبًا إحصائيًا متطورًا، ومن ثم جذب انتباه الباحثين والمهنيين إلى أهميتها.

الأهميَّةُ التَّطبيقيَّة:

طرحُ أسلوبٍ إحصائي جديدٍ على البيئةِ العربيَّةِ، والباحثين بمجالِ علمِ النَّفس، والتَّحقُّقُ من فاعليَّةِ استخدامِ الشَّبكاتِ العصبيَّةِ الاصطناعيَّة وكفاءتِها بوصفها بديلًا أكثرَ دقةً للتنبُّؤ بالمتغيِّرات النَّفسيَّة؛ ممَّا يتيحُ الفرصةَ للباحثين باستخدامهِ في التنبُّؤ بالمتغيِّرات النَّفسيَّة، والحصول على نتائج أكثر فاعليَّة.

مُصطلحاتُ البحثِ:

٣. **التنبُّؤ (prediction)**: هو محاولةُ استشرافِ ما سيحدثُ في حالةٍ مُعيَّنة، على أساسِ البياناتِ السابقِ الحصولِ عليها، بحيثُ يُعطِي التنبُّؤ النَّظريُ النَّتائجَ المتوقَّعة لتجربةٍ ما، أو لملاحظاتٍ مُحكَّمةٍ وفقًا للمنطقِ والمعايير المقبولة لنظريةٍ ما (VandenBos & Gary, ٢٠٠٧).

٤. **الشَّبكاتُ العصبيَّةُ الاصطناعيَّة (Artificial Neural Networks)**: هي مجموعةٌ مترابطةٌ من الخلايا العصبيَّة الاصطناعيَّة التي تستخدمُ نموذجًا رياضيًا أو نموذجًا حسابيًا لمعالجةِ البيانات، وتتخذُ من العقلِ البشري نموذجًا على كيفيَّةِ عملِ الخلايا العصبيَّة ونقاطِ الاشتباكِ العصبي في الدماغ البشري، حيثُ تربطُ الشَّبكة العصبيَّة الخلايا العصبيَّة لتشكيلِ شبكةٍ من العُقد، وتُعدُّ الشَّبكاتُ العصبيَّةُ الاصطناعيَّةُ نظامًا يتكيَّفُ مع طبيعةِ البياناتِ بحيثُ تُغيِّرُ هيكَلها بُناءً على معلومات خارجيَّة أو داخليَّة تتدفَّقُ عبر الشَّبكة. ومن الناحية العملية، تعدُّ الشَّبكاتُ العصبيَّة أدواتٍ لنمذجةِ البيانات الإحصائية غير الخطية. يمكنُ استخدامُها لنمذجةِ العلاقاتِ المعقَّدة بين المدخلاتِ والمخرجاتِ أو للعثورِ على الأنماطِ في البيانات (VandenBos & Gary, ٢٠٠٧).

مُتغيِّراتُ البحثِ:

- **الصلابةُ النَّفسيَّة (Psychological Hardiness)**

هي سمةٌ شخصية مرتبطةٌ بقدرةِ الشخص على إدارةِ أحداثِ الحياة المجهِدة والاستجابةِ لها من خلالِ استراتيجياتِ المواجهة التي تحوِّلُ الظروفَ المؤسِفةَ المحتمَلةَ إلى فُرصٍ للتَّعلم، وهي تشتملُ على: الالتزام، والتَّحكُّم، والتَّحدي، وتُؤثِّرُ على الطريقةِ التي ينظرُ بها المرءُ إلى نفسهِ ويتفاعلُ مع العالمِ من حولِه، حيثُ يتميَّزُ الفردُ ذو الصلابةِ النَّفسيَّة العالية بالميلِ للانخراطِ بعمق والحاجةِ إلى السيطرة، والرغبةِ في التَّعلمِ من أحداثِ الحياةِ بغض النَّظرِ عن النَّتائج (Maddi, ٢٠٠٤).

- **فعاليَّةُ الذات (Self-Efficacy)**

وهو مفهومٌ اقترحه عالمُ النَّفس ألبرت باندورا، ويشيرُ إلى إيمانِ الفردِ بقدرتهِ على تنفيذِ السُّلوكيات اللازمة لإنتاجِ إنجازات أداءٍ مُحدَّدة. تؤثِّرُ الفعاليَّةُ الذاتيَّةُ على كل مجالٍ من مجالاتِ المساعي البشرية، وذلك من خلالِ تحديدِ المعتقداتِ التي يحملُها الشَّخصُ فيما يتعلَّقُ بقدرتهِ على التأثيرِ في المواقف، وتؤثِّرُ فعاليَّةُ الذاتِ بقوة على كلٍ من القوةِ التي يمتلكُها الفردُ بالفعل لمواجهةِ التَّحدياتِ بكفاءة، والخياراتِ التي من المرجَّحِ أن يتَّخذَها الفردُ (Bandura, ١٩٧٧)

وهذه التأثيراتُ تكونُ واضحةً ومقنعةً بشكلٍ خاص فيما يتعلَّقُ بسلوكيَّاتِ التعليم، ويعزِّزُ الشُّعورُ القوي بالفعاليَّةِ الذاتية الإنجازاتِ البشرية والرفاهيةِ الشخصية، حيثُ ينظرُ الشَّخصُ ذو الفعاليَّةِ الذاتيَّةِ العالية إلى

التَّحدياتِ على أنَّها أشياء من المفترضِ إتقانُها بدلًا من كونِها تمثِّلُ تهديدات يجبُ تجنُّبها. وهم قادرون على التَّعافي من الفشلِ بشكلٍ أسرع، ومن المرجَّحِ أنْ ينسبوا الفشل إلى نقصِ الجهد. ويتعاملون مع المواقفِ المهدِّدة بالاعتقادِ بأنَّهم يستطيعون السيطرةَ عليها (Bandura, ٢٠١٠).

- **التَّكيُّفُ الأكاديمي (Academic Adaptation)**

يشيرُ المصطلحُ غالبًا إلى السُّلوكِ الذي يمكِّنُ الفردَ من التَّكيُّفِ مع البيئةِ بفعاليَّة والعمل على النحو الأمثلِ في مُختلفِ المجالات، كالتَّعامُلِ مع الضغوطاتِ اليومية، والتَّعديلاتِ التي يجريها الفردُ طبقًا لمطالبِ المجتمع وقيوده وأعرافه، بما في ذلك القدرةُ على التعايشِ والعملِ بانسجامٍ مع الآخرين، والمشاركةُ في التَّفاعلاتِ والعلاقاتِ الاجتماعية(Adaptation – APA Dictionary of Psychology, n.d.).

حدودُ البحثِ:

الحدودُ البشريَّة: طالباتُ جامعةِ القصيم.

الحدودُ الزمانية: العامُ الدراسي (١٤٤٠ – ١٤٤١ هـ).

الحدودُ المكانية: جامعةُ القصيم.

الحدودُ الموضوعية: اقتصر هذا البحثُ على:

- أدواتِه المتمثِّلةِ في: مقياسِ التَّكيُّفِ الأكاديمي، ومقياسِ فاعليَّةِ الذات، ومقياسِ الصلابةِ النَّفسيَّة.
- استخدامِ أسلوبِ تحليل الانحدار المتعدِّد، وأسلوبِ الشَّبكاتِ العصبيَّةِ الاصطناعيَّة في التنبُّؤ بالبياناتِ والمقارنة بينهما.

الإطارُ النَّظري والدِّراساتُ السَّابقة

يُعدُّ التنبُّؤ جزءًا من الاستدلالِ الإحصائي، ويمكنُ إجراؤه ضمنَ أيٍ من الأساليب المتعدِّدةِ للاستدلال، وتشملُ الأساليبُ الإحصائيةُ المستخدَمة للتنبُّؤ: تحليلَ الانحدارِ وفئاتِه الفرعيةِ المتعدِّدة كالانحدارِ الخطي Linear Regression، والنَّماذج الخطيّة المعمَّمة Generalized Linear Models ومنها: الانحدارُ اللوجيستي، وانحدارُ بواسون، والانحدارُ المحتمَل.

٥. تحليلُ الانحدار:

تحليلُ الانحدارِ في النَّمذجةِ الإحصائية هو مجموعةٌ من العمليَّاتِ الإحصائيَّة لتقديرِ العلاقاتِ بين متغيِّرٍ تابع (غالبًا ما يُسمَّى: متغيِّرُ النتيجةِ أو الاستجابة) ومُتغيِّرٍ واحدٍ أو أكثر من المتغيِّراتِ المستقلة (غالبًا ما تُسمَّى بالمتنبئاتِ أو المتغيِّراتِ التَّفسيريَّة). وفي حالةِ استخدامِ تحليلِ الانحدارِ للتنبُّؤ، يتمُّ جمعُ البياناتِ عن المتغيِّرِ الذي سيتمُّ التنبُّؤ بنتائجهِ، ويكونُ الشَّكلُ الأكثر شيوعًا لتحليلِ الانحدار هو "الانحدارُ الخطي" وغالبًا ما تُمثَّلُ فيه

العلاقةُ بين المتغيِّراتِ بدالةٍ خطيَّة يتمُّ افتراضُها للعلاقةِ السببيَّةِ بينهم، ويتمُّ تقديرُ بارامترات هذه الدالة من البياناتِ المجمَّعة، أي يتمُّ اختيارُها لتلائمَ بطريقةٍ ما الدالةَ الخطية، وتعدُّ هذه الخطوة هي خطوةُ تقديرِ القيم (Fox, ٢٠١٦).

وبالنسبةِ لخطوةِ التنبُّؤ، فقيمُ المتغيِّراتِ التَّفسيريَّة التي تُعدُّ ذاتَ صلةٍ بالقيمِ المستقبليَّة للمتغيِّر التابع هي مُدخلاتُ المعلَمَاتِ للدالةِ الخطيةِ المستخدَمة لتوليدِ تنبؤاتِ درجاتِ المتغيِّرِ التابع، حيثُ يتمُّ إيجادُ الخطِّ الأكثرَ ملاءمةً للبياناتِ وفقًا لمعيارٍ رياضي محدَّد. فعلى سبيلِ المثال، تحسبُ طريقةُ المربَّعاتِ الصغرى الخطَّ الفريدَ الذي يُقلِّلُ من مجموعِ الفروقِ التربيعيَّة بين البياناتِ الحقيقيةِ وهذا الخط (Cook & Weisberg, ١٩٨٢).

ويسمحُ هذا للباحثِ تحت اشتراطاتٍ رياضيةٍ مُحدَّدة كما في حالةِ الانحدارِ الخطي، بتقديرِ التوقُّعِ الشَّرطي Conditional Expectation(أو القيمة المتوسِّطة للمجتمعِ) للمتغيِّرِ التَّابعِ عندما تأخذُ المتغيِّراتُ المستقلةُ مجموعةً مُعيَّنةً من القيم. وتستخدمُ أشكالُ الانحدارِ الأقلَّ شيوعًا إجراءاتٍ مختلفةٍ قليلاً لتقديرِ بارامترات بديلة لموقعِ القيمِ كأسلوبِ الانحدارِ الكمِّي، أو يتمُّ تقديرُ التوقُّعِ الشَّرطي عبر مجموعةٍ أوسعَ من النَّماذجِ غير الخطية مثل أساليب الانحدار اللا بارامتري (Chernick & Friis, ٢٠٠٣).

ويتمُّ تمثيلُ العلاقةِ الرئيسةِ بين المتغيِّراتِ في تحليلِ الانحدارِ بمعادلةِ الانحدار. وتحتوي معادلةُ الانحدارِ على بارامترات الانحدار، ويتمُّ تقديرُ قيمِها باستخدامِ البيانات، وتقيسُ البارامتراتُ المقدَّرةُ العلاقةَ بين المتغيِّرِ التَّابعِ والمتغيِّراتِ المستقلة. وعند استخدامِ نموذجِ الانحدار، تتمُّ نمذجةُ المتغيِّر التَّابعِ باعتباره متغيِّرًا ذا توزيعٍ عشوائي؛ إمَّا بسببِ عدمِ اليقينِ فيما يتعلَّق بقيمتهِ، أو بسببِ التَّغيُّرِ الكامنِ فيه. ويُفترضُ أنْ تكونَ البياناتُ عيِّنةً من التَّوزيعِ الاحتمالي، الذي يُفترَضُ عادةً أنَّه يتْبعُ التَّوزيعَ الطبيعي.

ويمكنُ أيضًا استخدامُ تحليلِ الانحدارِ لاستنتاجِ العلاقاتِ السببيَّةِ بين المتغيِّراتِ المستقلةِ والتَّابعة، وحيثُ إنَّ الانحداراتِ في حدِّ ذاتِها تكشفُ فقط العلاقاتِ بين متغيِّرٍ تابعٍ ومجموعةٍ من المتغيِّراتِ المستقلة في مجموعةِ بيانات ثابتة؛ لذلك يجبُ على الباحثِ عند استخدامِ الانحداراتِ للتنبُّؤ، أو لاستنتاجِ العلاقاتِ السببيَّة، أنْ يبرِّر بعناية سببَ امتلاكِ العلاقاتِ القائمةِ بين المتغيِّراتِ لقوةٍ تنبؤية بالسياقاتِ الجديدة، أو لماذا يكونُ للعلاقةِ بين متغيِّرين تفسيرٌ سببي، في حين يتميَّزُ التنبُّؤ عن طريقِ الشَّبكاتِ العصبيَّةِ الاصطناعيَّة بعدمِ الحاجةِ إلى وجودِ مبرِّرات وتفسيرات للعلاقةِ بين المتغيِّرين (Freedman, ٢٠٠٩).

يعتمدُ تحليلُ الانحدارِ على افتراضاتٍ مُعيَّنةٍ حيثُ يجبُ أنْ تكونَ المتنبِّئاتُ مُستقلةً خطيًا، أي يجبُ ألَّا يكونَ من الممكنِ التعبيرَ عن أي متنبئ بوصفه مجموعةً خطيَّة من الآخرين. كما يجبُ أنْ يتبعَ الخطأُ التَّوزيعَ الطبيعي، وأنْ تكونَ الأخطاءُ مستقلة. وأنْ يكونَ تباينُ الخطأ ثابتًا. وأنْ تكونَ العيِّنةُ ممثِّلةً للمجتمع. وأنْ تكونَ لتوزيعِ قيمِ المتغيِّرِ التَّابعِ تغيُّراتٌ متساويةٌ تقريبًا (افتراض المثلية) (Berk, ٢٠٠٤) .

وفي كثيرٍ من الأحيان فإنَّه عندَ بناءِ نموذجِ انحدار، توجد صعوبةٌ لتقديرِ المعاملِ لكل مُتغيِّر مستقل، ولا يمكنُ شرحُ سببِ حدوثه، لاحتمالِ وجودِ علاقةٍ خطيَّةٍ متداخلةٍ في نموذج الانحدار (Collinearity)، حيثُ تحدثُ العلاقةُ الخطيَّةُ المتداخلة لأنَّ المتغيِّراتِ المستقلةِ المستخدمةِ لبناءِ نموذج انحدار مرتبطةٌ ببعضِها البعض. وهذا يمثِّلُ مشكلةً لأنَّه يجبُ أنْ يكونَ المتغيِّرُ مُستقِلاً، ولا ينبغي أنْ يكونَ له أيُ ارتباطٍ مع المتغيِّراتِ المستقلةِ الأخرى، وفي حالةِ وجودِ علاقةٍ خطيَّة متداخلة بين المتغيِّراتِ المستقلة، يتمُّ انتهاكُ إحدى النِّقاطِ الرئيسةِ لتحليلِ الانحدار، حيثُ من المفترضِ أنْ يتمَّ عزلُ تأثيرِ كُلِّ متغيِّرٍ مستقل على المتغيِّرِ التَّابعِ حتَّى يمكنَ تفسيرُ تقديرِ المعاملِ على أنَّه متوسِّط التغيير في المتغيِّر التَّابعِ لكل وحدةِ تغييرٍ في المتغيِّرِ المستقل مع الحفاظِ على المتغيِّراتِ المستقلةِ الأخرى ثابتةً (Winastwan, ٢٠٢١) .

وتبرز أهميَّةُ الشَّبكاتِ العصبيَّةِ الاصطناعيَّةِ في التَّغلبِ على صعوبةِ تحقُّقِ اشتراطاتِ تطبيقِ تحليلِ الانحدار في الدِّراساتِ النَّفسيَّة.

٦. الشَّبكاتُ العصبيَّةُ الاصطناعيَّة:

إنَّ أفضلَ طريقة لفهمِ كيفيةِ عملِ الشَّبكة العصبيَّةِ الاصطناعيَّة هي فهمُ كيفيَّةِ عملِ الشَّبكة العصبيَّةِ الطبيعية داخل الدماغ ورسمُ التوازي بينهما، فالخلايا العصبيَّة هي المكوِّنُ الأساسي للدماغِ البشري، وهي مسؤولة عن التَّعلُّمِ والاحتفاظِ بالمعرفة والمعلوماتِ كما نعرفُها. ويمكن اعتبارُها وحدةَ المعالجةِ في الدماغ، حيثُ يتمُّ التَّعاملُ مع البياناتِ الحسيَّةِ باعتبارِها مُدخلات تتمُّ مُعالجتُها، حيث تشكِّلُ البياناتُ النَّاتجةُ من هذه العملية مُدخلاتٍ جديدةٍ تستخدُمها الخلايا العصبيَّةُ الأخرى. وهكذا تستمرُّ معالجةُ المعلوماتِ وتمريرُها بين الخلايا العصبيَّة حتى يتمَّ الوصولُ إلى نتيجةٍ حاسمة. وترتبطُ الشَّبكة العصبيَّةُ الأساسية في الدماغ عن طريقِ نقاطِ الاشتباكِ العصبي (synapses). وهي نقاطٌ يمكنُ تصوُّرُها على أنَّها العقدُ النِّهائيةُ للجسرِ الذي يربطُ بين اثنين من الخلايا العصبيَّة؛ لذا فإنَّ المشبكَ هو نقطةُ التقاءِ اثنين من الخلايا العصبيَّة. وتُعدُّ نقاطُ الاشتباكِ العصبي جزءًا مهمًا من هذا النظام لأنَّ قوةَ التَّشابُك العصبي سَتُحدِّدُ عُمقَ الفهمِ والاحتفاظِ بالمعلومات (Urban & Gates, ٢٠٢١) .

وتتمُّ معالجةُ جميعِ البياناتِ الحسية التي يجمعُها الدماغُ في الوقت الفعلي من خلالِ هذه الشَّبكاتِ العصبيَّة. ومع مُعالجتِها بواسطةِ الخلايا العصبيَّة الأوَّلية، يصبحُ الشَّكلُ المعالَجُ للإشارةِ الكهربائيةِ القادمةِ من خليَّةٍ عصبية واحدة هو المدخلاتُ لخلايا عصبيةٍ أخرى. ومعالجةُ المعلوماتِ الدقيقةِ في كلِّ طبقةٍ من الخلايا العصبيَّة هو ما يجعلُ هذه الشَّبكة فعَّالة، ومن خلالِ تكرارِ هذا الموضوع لمعالجةِ البياناتِ عبر الشَّبكة العصبيَّة، تستطيعُ الشَّبكاتُ العصبيَّةُ الاصطناعيَّة إنتاجَ مخرجاتٍ متفوقة.(Wu & Feng, ٢٠١٨)

أمَّا في الشَّبكاتِ العصبيَّةِ الاصطناعيَّة، فقد تمَّ تصميمُ كلِّ شيء لتكرارِ هذه العملية. فجميعُ البياناتِ التي يتمُّ إدخالُها "X" في النظام لها وزن "W" لتوليدِ إشارةٍ عصبية موزونة. ويماثِلُ هذا دورَ قوةِ الإشارةِ التَّشابكيَّةِ في

الدماغ. ويتمُّ إرفاقُ متغيِّرِ التَّحيُّزِ للتَّحكُّمِ في نتائجِ المخرجاتِ من الدالةِ المستخدَمة، ويتمُّ تعيينُ الأوزان لإشاراتِ المدخلاتِ جميعًا حيثُ إنَّ الأوزانَ ضروريةٌ للشبكاتِ العصبيَّة الاصطناعيَّة؛ لأنَّها تسمحُ للشَّبكاتِ بالتَّعلم، وتحدِّدُ الأوزانُ إشاراتِ المدخلاتِ غير المهمة، أي الإشارات التي يتمُّ تمريرُها أو لا.

شكل ١

الإطارُ النَّموذجي للشَّبكةِ العصبيَّة الاصطناعيَّة

وتتمُّ معالجةُ كل هذه البيانات في الدالةِ الرياضية المستخدَمة وينتهي الأمرُ بمخرَجٍ واحد (Output)، وهذا هو الشَّكلُ الذي ستبدو عليه الشَّبكة العصبيَّةُ ذات الطبقةِ الواحدة، حيثُ تدورُ فكرةُ الشَّبكة العصبيَّة الاصطناعيَّة حول ربطِ عدة مجموعات من هذه الخلايا العصبيَّة الاصطناعيَّة للحصولِ على نواتج أكثر فاعلية. وهذا هو السببُ في أنَّ إطارَ المفاهيمِ النَّموذجي للشَّبكةِ العصبيَّة الاصطناعيَّة يشبهُ إلى حدٍ كبير ما هو مُوضَّح بشكل (١). وتُستخدمُ هذه الآليةُ لفكِ تشفيرِ مجموعاتِ البياناتِ الكبيرة، ويميلُ المخرَجُ النهائي عمومًا إلى أنْ يكونَ عبارة عن علاقةٍ سببيَّة مُنشأة بين المتغيِّراتِ التي تمَّ استخدامُها باعتبارها مدخلات، وفي هذه الحالةِ يمكنُ استخدامُها أيضًا للتنبُّؤ (Lecun et al., ٢٠١٥) .

وبُناءً على ما سبق يمكنُ تعريفُ الشَّبكاتِ العصبيَّةِ الاصطناعيَّة على أنَّها شبكةٌ تمَّ تصميمُها على غرارِ الدماغ البشري من خلالِ إنشاءِ نظامٍ عصبي اصطناعي عبر خوارزميَّة حاسوبيَّة، تتعرَّفُ إلى الأنماطِ، وتتعلَّمُ من البيانات الحسية، وتُفسِّرُها وتُصنِّفُها. وتمتلك معظمُ المتغيِّراتِ التي تمَّت دراستُها في الحياةِ الواقعية علاقةً غير خطية، وهذا ما يميِّزُ الشَّبكاتِ العصبيَّة الاصطناعيَّة في دراسةِ العلاقاتِ بين المتغيِّرات، حيثُ إنَّ إحدى الخصائصِ المركزية المشتركة عبر جميع الشَّبكات العصبيَّة الاصطناعيَّة هي مفهومُ اللاخطيَّة.

تعملُ الشَّبكاتُ العصبيَّةُ الاصطناعيَّة وتتعلَّمُ عن طريقِ دالةٍ رياضية يُطلَقُ عليها مصطلحُ "دالةَ التَّنشيط (activation function). حيثُ تقومُ دالةُ التَّنشيطُ بالمعالجةِ الأوَّليةِ للبياناتِ لتحديدِ ما إذا كان سيتمُّ تنشيطُ الخلايا العصبيَّة لتعملَ أم لا وتستخدمُ دالةَ التنشيطِ المبادئَ الرياضية الأساسية لتحديدِ ما إذا كانت المعلوماتُ ستتمُّ معالجتُها أم لا، وفي حالِ لم يتمَّ تنشيطُ الخليةِ العصبيَّةِ فستكونُ نواتجُها هي هي مُدخلاتُها، أي لا شيء يحدثُ للبيانات، وهذه المعالجةُ الأوَّليَّة أمرٌ بالغُ الأهمية في الشَّبكة العصبيَّةِ وإلا فسيضطرُ النظامُ إلى معالجةِ كثيرٍ

من المعلوماتِ التي ليس لها تأثيرٌ على المخرجات. وأكثرُ أشكالِ دوال التنشيط شيوعًا هي دالةُ "الخطوة الثنائية"، و"الدالةُ اللوجستية"، ودالةُ "المماس (الظل) الزائدية"، ودالةُ "الوحدات الخطية المصحَّحة" (Hinton, ١٩٩٢).

- **دالةُ الخطوةِ الثُّنائية (Binary step function)** تقوم هذه الدالةُ بتنشيطِ الخلايا العصبيَّةِ على أساسِ العتبة، بحيثُ إذا كانت الدالةُ لها نتيجة نهائية أعلى أو أقل من القيمةِ المعيارية، يتمُّ تنشيطُ الخليةِ العصبيَّة.
- **الدالةُ اللوجستية (Logistic function)**: ويُطلَقُ عليها أيضًا دالةُ السيجمويد (Sigmoid function)، وهذه الدالة لها نتيجةٌ رياضية في شكلِ منحنى "S"، وتُسْتخدَمُ عندما تكونُ الاحتمالاتُ هي المعاييرُ الرئيسة لتحديدِ ما إذا كان يجبُ تنشيطُ الخلايا العصبيَّة؛ ولذلك يمكنُ في أي نقطةٍ حسابُ ميلِ هذا المنحنى، حيثُ يكونُ الميلُ هو قيمةُ المماسِ الذي يلامِسُ المنحنى عند النَّقطةِ المحدَّدة التي تبدأ فيها اللاخطيةُ بين المتغيِّرات. وتقعُ قيمةُ هذه الدالة بين (٠) و (١)، ويتمُّ حسابُ الميلِ باستخدامِ دالةٍ تفاضليَّة. ويتمُّ استخدامُ هذا المفهوم عندما لا تكونُ للمتغيِّرين علاقةٌ خطية. والمشكلةُ مع الدالةِ اللوجستية هي أنَّها لا تصلحُ لمعالجةِ البياناتِ ذات القيمِ السالبة.
- **دالةُ الظلِّ الزائدية (Hyperbolic tangent function)**: وهي دالةٌ مماثلةٌ للدوالِ المثلثيَّة (أو الدائرية)، لكنَّها مُعرَّفةٌ بواسطةِ القطعِ الزائدِ بدلًا من الدائرة، وهي مشابهةٌ تمامًا للدالةِ اللوجستية باستثناء أنَّ قيمَها تقع بين (−١ و +١). لذلك تختفي مشكلةُ القيمةِ السالبة التي لا تتمُّ معالجتُها في الشَّبكة العصبيَّة.
- **دالةُ الوحداتِ الخطيَّة المصحَّحة ReLu (Rectified linear units)**: تقعُ قيمُ هذه الدالة بين (٠) وما لانهاية الموجبة (+∞)، وتعملُ هذه الدالةُ بطريقةٍ بسيطة، إذا كان الإدخالُ مُوجبًا، فسوف تعطي الدالةُ قيمةَ "X". بالنسبة لجميعِ المدخلاتِ الأخرى، ستكون القيمةُ "٠". ويمكنُ استخدامُ دالةٍ أخرى مُشتقَّةً من هذه الدالة ويُطلَقُ عليها (Leaky ReLu) وهي تعالج القيمَ بين المالانهاية السَّالبة والمالانهاية الموجبة. ويتمُّ استخدامُها عندما تكونُ العلاقةُ بين المتغيِّراتِ التي تتمُ معالجتُها ضعيفةً، وقد تتعرَّضُ إلى أنْ يتمَّ حذفُها تمامًا بواسطةِ دالةِ التنشيط، ويتمُّ تحديدُ مُعاملِ الانحدارِ لهذه الدالة قبل مرحلةِ تدريبِ الشَّبكة.

وبالرجوعِ إلى تركيبِ شبكةِ الإدراكِ الحسي والشَّبكة العصبيَّة نجدُ أنَّ الفرقَ الرئيسي هو وجودُ الطبقةِ الخفية، حيث توجد طبقةٌ خفيةٌ بين طبقتي الإدخالِ والإخراجِ في الشَّبكة العصبيَّة، وتتمثَّلُ مُهمَّةُ الطبقةِ الخفية في تحسينِ المعالجةِ والقضاءِ على المتغيِّراتِ التي لن يكونَ لها تأثيرٌ قوي على المخرجاتِ، فعندما يكونُ التغييرُ في قيمةِ مُتغيِّرِ المدخلاتِ ذا تأثيرٍ ملحوظ على متغيِّرِ المخرجاتِ للشَّبكةِ العصبيَّة، فستُظْهِرُ الطبقةُ الخفية تلك العلاقة، بحيث تسهِّلُ الطبقةُ الخفية من عملِ الشَّبكة العصبيَّة الاصطناعيَّة لتعطي إشارات أقوى للطبقةِ التَّاليةِ من المعالجة (Ritter et al., ٢٠١٧).

ومن ناحيةٍ أخرى ولمعرفةِ الطريقةِ الفعليَّةِ حولَ كيفيَّةِ تعلُّمِ الشَّبكاتِ العصبيَّةِ الاصطناعيَّة، يجبُ معرفةُ ماهيةِ التعلُّم أولًا التعلُّم ببساطة هو إنشاءُ علاقةٍ سببيَّة بين شيئين (أنشطة، أو عمليات، أو متغيِّرات). فمثلًا عند تعلُّمِ مهارةٍ بدنية جديدة يتمُّ إنشاءُ علاقةٍ سببيَّة بين الفعلِ البدني المطلوب بطريقةٍ مُعيَّنة وبين جعلِ العضلاتِ تنمو، ومن السهلِ تحديدُ متى يتحرك مُتغيِّران في الاتجاه نفسهِ (بمعنى أخر يكونُ من السَّهلِ تحديدُ ارتباطِهما)، ولكن من الصعبِ أنْ نقولَ بيقينٍ مطلق أيُّ المتغيِّرين يسبِّبُ الحركةَ في المتغيِّرِ الأخر (السَّببيَّة).

وفي الغالب يتمُّ إثباتُ ذلك عن طريقِ الحدسِ البشري، لكن بالنسبةِ للشَّبكات الاصطناعيَّة لكي تتفهَّمَ وتضاهي الحدسَ البشري يتمُّ استخدامُ دالةٍ رياضية تُسمَّى دالةُ التكلفة (Cost function) وهي دالةٌ تحدِّدُ مدى جودةِ أداءِ نموذجِ التعلُّمِ الآلي لمجموعةٍ معيَّنةٍ من البيانات. ويمكنُ إنشاءُ دوال التكلفة بمجموعةٍ متنوِّعة من الأساليب حسب الحالة، ولتقديرِ مدى ضعفِ أداءِ النماذج، يتمُّ استخدامُ دوالِ التكلفة. حيثُ تعدُّ مقياسًا للخطأ بين القيمة التي يتوقعها النَّموذج وبين القيمةِ الفعلية. وتُعرَّفُ رياضيًا أنَّها الفرقُ التربيعي بين القيمةِ الفعلية لمجموعةِ البيانات، وقيمةِ الإخراجِ لمجموعةِ البيانات، مع مُراعاةِ درجةِ الخطأ. ونقومُ بتربيعها لأنَّه في بعضِ الأحيان يمكنُ أن يكونَ الفرقُ سالبًا (Aggarwal & Singh, ٢٠١٩).

ولكي تتعلَّمَ الشَّبكةُ العصبيَّة، تتمُّ مقارنةُ القيمةِ المتوقَّعة التي تمَّ إنشاؤها بواسطةِ دالةِ التنشيط بالقيمةِ الفعلية، التي يتمُّ تقديمُها بوصفِها متغيِّر اختبار، ويتمُّ تقسيمُ جزءٍ من مجموعة البيانات بحيث تقتصرُ هذه البيانات على عمليةِ اختبارِ نفسها بها، ويستمرُّ النَّموذجُ في التَّحقُّقِ من نفسه مُقابلَ القيمةِ الفعلية، ويقومُ بإجراءِ تعديلاتٍ مع كل قيمةٍ صحيحةٍ أو غير صحيحة عن طريق حسابِ دالة التكلفة.

ومع كل دورةٍ من المدخلاتِ لمعالجةِ المخرجاتِ باستخدامِ دالةِ التكلفة، تتمثَّلُ المهمةُ الأساسيَّة للباحثِ، ومهمةُ الشَّبكات العصبيَّة الاصطناعيَّة في تقليلِ دالةِ التكلفة إلى أدنى قيمةٍ ممكنة، ويمكنُ تحقيقُ ذلك من خلال ضبطِ الأوزانِ في الشَّبكة. وتُسمَّى عمليةُ الانتقالِ من المدخلاتِ إلى المخرجاتِ بالانتشارِ الأمامي (Forward Propagation). وتُسمَّى عمليةُ استخدامِ بياناتِ المخرجاتِ لتقليلِ دالةِ التكلفة عن طريق ضبطِ الوزن بترتيبٍ عكسي من آخرِ طبقةٍ مخفية إلى طبقةِ المدخلات بالانتشارِ العكسي(Back Propagation) (Buscema, ١٩٩٨).

٧. معاييرُ الحكمِ على جودةِ التنبُّؤ لتوفيق البيانات لنموذجِ التنبُّؤ.

تمَّ تحديدُ عددٍ من المعايير لقياسِ قدرةِ نموذجِ التنبُّؤ وملاءَمتهُ للبيانات ومن أهمِّها:

- **جذر متوسِّط مربَّع الخطأ Root Mean Square Error (RMSE)**

يقيسُ مقدارَ الخطأ في النَّماذج الإحصائية، حيث يقيِّمُ جذرُ متوسِّطِ مربَّع الخطأ الفرقَ بين القيمِ المشاهدة والمتوقَّعة (معادلة ١)، وعندما لا يوجد خطأ في النَّموذج، فإن RMSE يساوي صفرًا. ومع زيادةِ خطأ النَّموذج

تزدادُ قيمتُه. وكلما اقتربتْ نقاطُ البياناتِ من خط الانحدار، فإنَّ النَّموذج يكونُ به خطأ أقل، ممَّا يقلِّلُ من جذرِ مُتوسِّطِ مربَّع الخطأ، وعليه فالنَّموذج ذو الخطأ الأقل ينتجُ تنبؤاتٍ أكثرَ دِقَّة. وبالإضافةِ إلى ذلك فإنَّ تأثيرَ كل خطأ على RMSE يتناسبُ مع مربَّعِ حجم الخطأ؛ وبالتَّالي فإنَّ الأخطاءَ الكبيرة لها تأثيرٌ كبيرٌ بشكلٍ غير متناسب على جذرِ متوسِّط مربَّع الخطأ. وبالتَّالي، فإنَّ هذا المؤشِّر حساسٌ للقيمِ المتطرفة بعكسِ متوسِّطِ مربَّعِ الخطأ(MSE) الذي يتعاملُ مع الأخطاءِ الكبيرةِ النَّاتجة عن القيمِ المتطرِّفة والأخطاء الصغيرة بالطريقةِ نفسها ولا يُفرِّقُ بينهما، ويكونُ على نفسِ مقياسِ البيانات التي يتمُّ قياسُها وبالتالي يعطي رؤيةً قاصرةً للنَّماذجِ ذات المقاييسِ المختلفة (Barnston, ١٩٩٢) .

$$RMSE = \sqrt{\frac{\sum_{i-١}^{n}(\hat{y}_i - y_i)^٢}{n}} \qquad (١)$$

حيث $\hat{y}_i$ هي القيمةُ المتوقَّعة، y_i هي القيمةُ المشاهدَة، n هو عددُ البيانات

ولتسهيلِ المقارنةِ بين مجموعاتِ البيانات أو النماذج ذات المقاييسِ المختلفة تمَّ تقديمُ مؤشِّر جذرِ متوسِّط مربَّع الخطأ المعياري (NRMSE) حيث تتمُّ المعايرةُ بالقسمةِ على الفرقِ بين أكبر قيمة وأصغر قيمة للبيانات المقاسة كما هو مبين بمعادلة (٢)

$$NRMSE = \frac{RMSE}{y_{max} - y_{min}} \qquad (٢)$$

وغالبًا ما يتمُّ التَّعبيرُ عن هذا المؤشِّر بوصفهِ نسبةً مئوية، حيثُ تشيرُ القيمُ الأقل للمؤشِّر إلى تباينٍ أقل للبواقي.

- **متوسِّطُ القيمةِ المطلَقةِ للخطأ Mean Absolute Error (MAE)**

هو مقياسٌ للقيمةِ المطلَقة للفرقِ بين أخطاءِ المشاهداتِ المزدوجة التي تعبِّرُ عن الظاهرةِ نفسِها، أي بين القيمِ المشاهدة مقابل القيمِ المتوقَّعة مقسومةً على عددِ المشاهدَات، وبالتَّالي هو المتوسِّطُ الحسابي للقيمِ المطلقة للأخطاء كما هو مُوضَّح بالمعادلة (٣)

$$MAE = \frac{\sum_{i-١}^{n}|\hat{y}_i - y_i|}{n} \qquad (٣)$$

يسهمُ كلُّ خطأ في المؤشِّرِ بما يتناسبُ مع القيمةِ المطلقةِ للخطأ. وهذا على عكسِ جذرِ متوسِّط مربَّع الخطأ الذي يتضمَّن مربَّعَ الفروق، بحيثُ تؤدِّي بعضُ الأخطاءِ الكبيرة إلى زيادةِ جذرِ متوسِّط مربع الخطأ RMSE إلى درجة أكبر من مؤشر متوسِّط القيمةِ المطلَقة للخطأ MAE، ويَستخدِمُ مُتوسِّطُ القيمةِ المطلَقة للخطأ مقياسَ البياناتِ نفسها التي يتمُّ قياسُها ويُعرفُ هذا بمؤشِّرِ دقةِ التنبُّؤ المعتمد على المقياس، وبالتَّالي لا يمكن استخدامهُ لإجراء مقارنات بين البياناتِ ذات المقاييس المختلفة.

- **المتوسِّطُ النِّسبي للخطأ المطلق Mean Absolute Percentage Error (MAPE)**

هو الخطأ المطلق الذي تمَّت معايرتهُ على البيانات، ممَّا يسمحُ بمقارنةِ الخطأ عبر البيانات بمقاييس مختلفة، حيثُ تتمُّ معايرتُه على القيمةِ الفعلية، ويتمُّ حسابهُ لكل نقطة بيانات، ثمَّ يتمُّ حسابُ متوسِّطه كما بمعادلة (٤).

$$MAPE = \frac{١٠٠٪}{n}\sum_{i=١}^{n}\frac{\hat{y}_i - y_i}{y_i} \qquad (٤)$$

يتمُّ حسابُ المتوسِّط النسبي للخطأ المطلق عبر كل نقطة بيانات ومتوسِّطها، وبالتَّالي يلتقطُ مزيدًا من الأخطاء والقيم المتطرفة، ولحسابِ المتوسِّط النسبي للخطأ المطلق MAPE يجبُ استبعادُ نقاط البيانات ذات القيمةِ الفعلية "صفر" لتجنب القسمةِ على الخطأ الصفري.

يتعاملُ المتوسِّطُ النسبي للخطأ المطلَق بحدة أكبر مع الأخطاءِ السالبة، بمعني أنَّه بالنسبةِ لنفس قيمة الخطأ، يكون الخطأ أعلى عندما تكونُ الدرجةُ المتوقَّعة أقل من الدرجةِ المشاهدة منه عند حدوثِ العكس (De Myttenaere et al., ٢٠١٦).

- **معاملُ التحديد Coefficient of Determination($R^٢$)**

يقومُ معاملُ التَّحديدِ $R^٢$ بتقييمِ تشتُّتِ نقاطِ البيانات حول خطِ الانحدارِ المناسب، تمثِّلُ قيمُ معاملِ التحديد الأعلى اختلافاتٍ أصغر بين البياناتِ المشاهدَة والقيمِ المناسبة للنموذج. لا يشيرُ معاملُ التحديدِ وحده إلى ما إذا كان نموذجُ الانحدار يوفِّر ملاءمةً مناسبةً لبياناتك، يمكنُ أن يكونَ للنموذجِ الجيد قيمة $R^٢$ منخفضة.

ومن ناحيةٍ أخرى يمكنُ أن يكونَ للنموذجِ المتحيِّزِ قيمة $R^٢$ عالية. تحتوي بعضُ مجالاتِ الدراسةِ بطبيعتِها قدرًا أكبر من التَّباين غيرِ القابل للتفسير. وفي هذه المجالات لابدَّ أنْ تكونَ قيمُ $R^٢$ أقل. فعلى سبيل المثال فإنَّ المجالاتِ التي تحاولُ تفسيرَ السُّلوكِ البشري بشكلٍ عام لها قيم $R^٢$ أقل من (٥٠٪). حيث يصعبُ التنبُّؤ بسلوكِ الأفراد.

وبالإضافةِ إلى ذلك إذا كانتْ قيمةُ مُعاملِ التحديدِ منخفضةً لكنَّ المتغيِّراتِ المستقلة ذات دلالةٍ إحصائية، يكونُ بالإمكانِ استخلاصُ استنتاجاتٍ مهمَّة حول العلاقاتِ بين المتغيِّرات. وتستمرُ المعاملاتُ ذاتُ الدلالةِ الإحصائية في تمثيلِ متوسِّطِ التَّغييرِ في المتغيِّر التَّابع بالنَّظرِ إلى تحوُّلِ وحدةٍ واحدة في المتغيِّرِ المستقل (Frost, ٢٠١٩).

ولاختبارِ فعاليَّةِ الشَّبكات العصبيَّة الاصطناعيَّة وكفاءتِها في التنبُّؤ بالمتغيِّرات النَّفسيَّة، تمَّ استخدامُ عددٍ من المتغيِّراتِ النَّفسيَّة في هذه الدراسة (الصلابة النَّفسيَّة – فعالية الذات) ودراسةُ كفاءةِ تنبؤهما بالتَّكيُّفِ الأكاديمي لطالباتِ الجامعة.

الدِّراساتُ السَّابقة:

يتمُّ استخدامُ الشَّبكاتِ العصبيَّةِ الاصطناعيَّة (ANNs) بشكلٍ متزايدٍ في مختلفِ التَّخصُّصاتِ خارج علومِ الكمبيوتر مثل القياسات الببليومترية، واللغويات، والطب. ومع ذلك، فإنَّ استيعابَها في مجتمعِ العلومِ الاجتماعيَّة كان بطيئًا نسبيًا؛ لأنَّ هذه النماذج غير الخطية يصعبُ للغايةِ تفسيرُها، ولا يمكنُ استخدامُها لاختبارِ الفرضيات، وفي السنواتِ القليلةِ الماضية، كانتْ إحدى التقنياتِ الأكثرَ استخدامًا في حلِّ عديدٍ من المشكلاتِ المعقَّدة في المجال الطبي هي الشَّبكاتُ العصبيَّةُ الاصطناعيَّة (ANN)، باستخدامِ بياناتِ الإدخالِ من مجموعةٍ من الاختباراتِ السيكومترية للتنبُّؤ ببعض الاضطراباتِ النَّفسيَّة، حيث خلصتْ نتائجُ عديدٍ من الدِّراساتِ إلى فاعليَّةِ الشَّبكاتِ العصبيَّة للتنبُّؤ، وتبيَّن أنَّها يمكنُ أن تكونَ طريقةً واعدةً لتحديدِ أنماطِ المشاكلِ النَّفسيَّة بدرجةٍ عاليةٍ من الدقة. (Duarte, ٢٠٢٠; Hu, ٢٠١٠; Kheirollahpour et al., ٢٠٢٠; Serretti & Smeraldi, ٢٠٠٤b; Tey et al., ٢٠٢١)

-وفي دراسة (Pukelis & Stančiauskas, ٢٠١٩) تمَّت مناقشةُ إمكانيةِ الاستفادةِ من استخدامِ الشَّبكات العصبيَّة الاصطناعيَّة في عددٍ من الطرقِ في مجتمعِ العلومِ الاجتماعية، حيث سيُمَكِّنُ استخدامُ الشَّبكاتِ العصبيَّةِ الاصطناعيَّة فرقًا صغيرةً من الباحثين من معالجةِ كمياتٍ أكبر من البيانات، وتنفيذِ مشاريعَ أكثرَ طموحًا. وطرحتْ الدِّراسةُ إمكانيَّةَ الاستفادةِ من تعقيدِ مهامِ ما قبل المعالجة، التي يمكنُ لشبكاتِ ANN القيامَ بها، وهذا يعني أنَّه يمكنُ للباحثين الحصولَ على بياناتٍ غنيةٍ ومعقَّدةٍ مرتبطةٍ عادةً بالبحث النوعي على نطاقٍ واسع؛ ممَّا يسمحُ بدمجِ الأفضل من كلٍ من الأساليب النوعيةِ والكميَّة.

-وفي هذا السياق قام (Jat et al., ٢٠١٨) بدراسةٍ حول قدراتِ التقنياتِ الإحصائية، والشَّبكاتِ العصبيَّةِ الاصطناعيَّة المستخدمة في أنواعٍ مختلفةٍ من التطبيقات، حيثُ تجمعُ التَّحليلاتُ التنبُّؤية بين تقنياتٍ مثل: النمذجةِ التنبُّؤية، والتعلُّم الآلي لتحليلِ البياناتِ السابقة للتنبُّؤ بالاتجاهاتِ المستقبليَّة، لكنَّ الشَّبكاتِ العصبيَّة تختلفُ عن الأدواتِ التنبُّؤية العادية، فالنَّموذجُ الأكثرُ استخدامًا – الانحدار الخطي – هو في الواقع طريقةٌ بسيطةٌ جدًا للتَّعامُلِ مع الأشياءِ مقارنةً بالشَّبكةِ العصبيَّة، حيث تعملُ الشَّبكاتُ العصبيَّةُ بشكلٍ أفضل في التَّحليلاتِ التنبُّؤية بسببِ الطبقاتِ المخفية، في حين تَستخدِمُ نماذجُ الانحدارِ الخطي عُقدَ الإدخالِ والإخراجِ فقط لعمل تنبُّؤات، في حين تستخدمُ الشَّبكةُ العصبيَّةُ أيضًا الطبقةَ المخفيةَ لجعلِ التنبُّؤات أكثرَ دقة هذا لأنَّها تتعلَّمُ بالطريقةِ نفسِها التي يتعلَّمُ بها الإنسان.

-وتوصل (Koutsomanis, ٢٠١٤) من خلالِ دراستهِ إلى أنَّه يمكنُ للشَّبكاتِ العصبيَّةِ الاصطناعيَّة التنبُّؤ بالسُّلوك البشري في ظل ظروفٍ منهجيةٍ معيَّنة وكان متوسِّطُ دقةِ التنبُّؤ يصل إلى حوالي ٠,٩١.

-واقترحت دراسةُ (Anirudh Bhardwaj et al., ٢٠١٧) طريقةً للاستفادةِ من الإمكاناتِ الكاملة للتقييماتِ السيكومترية لمهامِ التَّصنيفِ النَّفسي، باستخدامِ مفاهيم التعلُّمِ الآلي مثل الشَّبكاتِ العصبيَّة، وتمَّ استخدامُ هذه الخوارزميات المقترَحة للتنبُّؤ بدرجةِ التوافقِ النَّفسي للمرشَّحين المستقبليين للعمل ومديرِهم المباشر، وكان الهدفُ من التنبُّؤاتِ هو المساعدةُ في عمليةِ تشكيلِ المجموعاتِ ذات التَّوافقِ النَّفسي المثلى لتحقيقِ أقصى قدرٍ من الإنتاجيَّة.

وبالرغم من أن النَّظريةَ النَّفسيَّة تقرُّ بوجودِ أنظمةٍ معقَّدة، وبأهميةِ التَّأثيراتِ غير الخطية، فقد تمَّ استخدامُ النَّماذج الإحصائية الخطية بطريقةٍ مُطَّردةٍ لفحصِ العلاقاتِ بين المتغيِّرات، ولا يبدو أنَّ الطَّريقةَ التي يتمُّ بها تحليلُ هذه العلاقات تعكسُ طريقةَ التَّصوُّرِ النَّظري لها، وفي هذا السياق ناقشت دراسةُ (Karanika-Murray & Cox, ٢٠١٠) فعاليَّةَ تطبيقِ الشَّبكاتِ العصبيَّةِ الاصطناعيَّة لنمذجةِ العلاقاتِ بين خصائصِ العملِ وصحةِ الموظَّف، من خلالِ مُقارنتِها بمنهجٍ خطي إحصائي تقليدي (الانحدار الخطي المتعدد) على عيِّنةٍ من (١٠٠٣)أفراد. وأشارت مقارناتُ مقاييسِ الأداءِ إلى وجودِ اختلافاتٍ في ملاءمةِ النماذج، حيثُ تفوقتْ الشَّبكاتُ العصبيَّةُ على نماذجِ الانحدارِ الخطي، وكشفتْ المقارناتُ أنَّ المتغيِّراتِ المنبئةِ في النهجين اختلفتْ في أهميتِها النسبية للتنبُّؤ بالنَّتائج، ويُعزى التَّحسُّنُ إلى قدرةِ الشَّبكاتِ العصبيَّةِ على نمذجةِ العلاقات غير الخطية المعقَّدة، كونها غير مقيَّدة بافتراضاتِ الخطيَّة، حيثُ يمكنُها تقديمُ تقريبٍ أفضلَ لهذه الظَّواهر النَّفسيَّة والاجتماعيَّة.

وللوصولِ إلى أكبر استفادةٍ من التقنياتِ الحديثةِ للذكاءِ الاصطناعي وتطبيقاتِ التعلُّمِ العميق، ركَّزَ (Gavrilescu & Vizireanu, ٢٠١٧, ٢٠١٨, ٢٠١٩) عملهم على استخدامِ الشَّبكاتِ العصبيَّةِ الاصطناعيَّة لبناءِ أو ّ ّل بنيةٍ في أدبيَّاتِ علم النَّفس تهدفُ إلى التنبُّؤ بالسِّمات الشَّخصيةِ الخمسةِ الكبرى للفرد، من خلال تحليلِ الكتابةِ اليدوية دون اتصالٍ بالإنترنت وتعطي الطريقةُ المقترَحةُ أعلى دقة مقارنةً بأحدث الأساليب الأخرى، ويتمُّ حسابُ النَّتائج في (٩٠) ثانية حدًا أقصى، ممَّا يجعلُ هذا النهجَ أسرعَ من الاستبانةِ أو المقابلاتِ النَّفسيَّةِ المستخدمةِ حاليًا؛ لتحديدِ سماتِ الشَّخصية الخمسةِ الكبرى.

وتُظهرُ الدراسةُ أيضًا أنَّ هناك علاقاتٍ بين ميزاتِ الكتابةِ اليدويةِ المحدَّدة، والتنبُّؤ بدقةٍ عالية لسماتٍ شخصيةٍ معيَّنة، ويمكنُ استغلالُ ذلك بشكلٍ أكبر لتحسينِ دقةِ التنبُّؤ للبنيةِ المقترَحة. وتمَّ اقتراحُ بنيةٍ أخرى هدفتْ إلى التنبُّؤ بمستوياتِ مقياسِ القلقِ والاكتئاب من خلالِ تحليلِ تعابير الوجه بالاعتمادِ على خواصِّ الشَّبكات العصبيَّة الاصطناعيَّة، وفي دراستهم الأخيرة تمَّ اقتراحُ بنيةٍ جديدة من ثلاثِ طبقات باستخدامِ الشَّبكاتِ العصبيَّة للتنبؤ بالعواملِ السِّتةِ عشر للشَّخصيةِ (١٦PF) عن طريقِ ملامحِ الوجه، وقد حقَّقتْ طريقةُ الشَّبكاتِ العصبيَّة الاصطناعيَّة للتنبُّؤ دقةً وحساسيةً وخصوصيةً أعلى بنسبةٍ ملحوظة مُقارنةً بأحدث الطرق الأخرى.

وفي السَّنواتِ القليلةِ الماضية، بدأ ازديادُ اهتمامِ الباحثين النَّفسيين بالذَّكاءِ الاصطناعي وتعلُّمِ الآلة، فكانتْ هناك عدَّةُ محاولات لاستخدامِ تلك التِّقنيات في التنبُّؤِ ببعضٍ من المتغيِّراتِ النَّفسيَّة.

-مثل دراسة (Song et al., ٢٠١٨) التي اهتمَّتْ بالتنبُّؤ بالمرونةِ النَّفسيَّةِ لكبارِ السن باستخدامِ الشَّبكات العصبيَّة الاصطناعيَّة.

-ودراسة (Gray et al., ٢٠١٤) التي استعرضتْ العواملَ التي يمكنُ استخدامُها للتنبُّؤ بالأداءِ الأكاديمي باستخدامِ تقنياتِ استخراجِ البيانات (Data Mining)، وركَّزتْ على العوامل السيكومترية للقدرةِ والشَّخصيةِ والتَّحفيزِ واستراتيجياتِ التَّعلُّم.

-كما ناقشتْ دراسةُ (Hu, ٢٠١٠) استخدامَ الشَّبكاتِ العصبيَّةِ الاصطناعيَّةِ للتَّعرُّف إلى أنماطِ الأداءِ السُّلوكي الاجتماعي، وتطرقتْ دراسةُ (Grządzielewska, ٢٠٢١) إلى تقنياتِ تعلُّمِ الآلة للتنبُّؤ بالاحتراقِ النَّفسي للعاملين باعتبارها مجالًا جديدًا لم يتم تناولُهُ في مجالِ العلومِ النَّفسيَّة والسُّلوكية، وتوصَّلت إلى خوارزميّات جديدة تساعد في مُراقبةِ الاحتراقِ النَّفسي والحد منه وتحسين ظروف العمل.

وقدْ تعدَّدتْ الدِّراساتُ التي اهتمَّت بدراسةِ التَّكيُّفِ الأكاديمي لطلبةِ الجامعات، والعلاقاتِ بينه وبين عديدٍ من المتغيِّراتِ النَّفسيَّة وبخاصةٍ فعاليَّةِ الذات والصلابة النَّفسيَّة للطلاب، وخلُصتْ هذه الدِّراساتُ إلى وجودعلاقاتٍ ارتباطيَّةٍ مباشرة وغير مباشرة بين مُتغيِّراتِ الدراسة (Cheng et al., ٢٠١٩; Crowley et al., ٢٠٠٣; Lee, ١٩٩١; Mihaela Rus et al., ٢٠٢٠; Qorbanpoor Lafmejani et al., ٢٠١٩)

٨. تعقيبٌ على الدِّراساتِ السَّابقة:

أصبحتْ البياناتُ الضخمةُ مُعقَّدةً للغاية، وديناميكية للغاية، بحيثُ لا يمكنُ معالجتُها وتخزينُها وتحليلُها وإدارتُها باستخدامِ أدواتِ البيانات التقليدية. وتُعدُّ الأساليبُ الإحصائية المختلفةُ أدواتٍ مهمَّةٍ لتحليلِ البيانات، ولكن يلزمُ لتطبيقِها توفُّرُ اشتراطاتٍ معيَّنة؛ لذلك تظهرُ الحاجةُ لاستكشافِ تقنيةٍ ذكيةٍ لتحليلِ كميةٍ كبيرةٍ من البيانات بكفاءة. وتُعدُّ الشَّبكةُ العصبيَّةُ الاصطناعيَّة (ANN) أحدَ الأساليب المهمَّة المستخدَمة في التَّعلُّمِ الآلي، حيثُ تُستخدَمُ لتحليلِ البياناتِ باستخدام الخوارزميَّات التي تسمحُ بالتعلم، وتستندُ في تطبيقِها إلى البياناتِ وحدها مقارنةً بمجموعةٍ من الافتراضات والاشتراطات اللازم توافرها في الأساليبِ الإحصائية التقليدية، وأكَّدتْ عديدٌ من الدِّراساتِ السَّابقة أهميَّةَ استخدامِ الشَّبكاتِ العصبيَّةِ الاصطناعيَّة وفاعليتها في التنبُّؤ، مع الحاجةِ إلى مزيدٍ من الدِّراسات المتخصِّصة لمعرفةِ مدى كفاءتِها والاستفادةِ القصوى من إمكاناتِها في التنبُّؤِ بالمتغيِّرات النَّفسيَّة.

الطَّريقةُ والإجراءات

منهجُ البحثِ:

تمَّ استخدامُ المنهجِ الوصفي التحليلي عن طريقِ تحليلِ البيانات، وإدخالِ المتغيِّراتِ المؤثِّرة وتنبؤاتِها ومعالجتِها للحصولِ على أفضلِ النَّتائج، ثمَّ المفاضلةُ بين طرقِ التنبُّؤ باستخدامِ مجموعةٍ من المعايير الإحصائية.

مجتمعُ البحثِ:

تكوَّنَ مجتمعُ البحثِ من جميعِ طالباتِ جامعةِ القصيم للعام الدراسي (١٤٤٠هـ-١٤٤١هـ) في كُليَّاتِ (العلومِ والآداب، والشريعةِ والدِّراساتِ الإسلامية، والعلومِ، والتَّربية، والزِّراعة والطب البيطري، والتَّصاميم والاقتصاد المنزلي).

عيِّنةُ البحثِ:

اخْتِيْرت عيِّنةُ البحثِ باستخدامِ الطريقةِ العشوائيةِ الطبقية، حيثُ تكوَّنتْ عيِّنةُ البحثِ من (٣٥٩) طالبةً من سبعِ كُليَّات من المستوياتِ الدِّراسيَّةِ كافةً، وكانتْ الأعدادُ والنِّسبُ المئوية لعيِّنةِ البحثِ وفق المستوياتِ المختلفة، كما يوضِّحُها جدولُ (١)

جدول ١

العددُ والنِّسبُ المئوية لعيِّنةِ البحثِ وفقَ المستوياتِ الدراسية

المستوى	العدد	النسبة المئوية
الأول	٣٥	١٠٪
الثاني	١٢	٣٪
الثالث	٥٣	١٥٪
الرابع	٢١	٦٪
الخامس	١٩	٥٪
السادس	٦٨	١٩٪
السابع	٤٤	١٢٪
الثامن	٩٨	٢٧٪
دراسات عليا	٩	٣٪

أدواتُ البحثِ:

اعتمدَ البحثُ الحالي على عددٍ من المقاييسِ النَّفسيَّة بيانُها كالتَّالي: استبانةُ الصَّلابةِ النَّفسيَّة (مخيمر، ٢٠٠٢)، ومقياسُ الفاعليةِ الذَّاتيةِ للفرد (العدل, ٢٠٠١)، وقائمةُ التَّكيُّفِ الأكاديمي لهنري بورو الذي ترجمه أبوطالب وقنَّنه (عبد المطلب، ٢٠١٠).

- **قائمةُ التَّكيُّفِ الأكاديمي:**

– هدفُ القائمةِ ووصفُها:

تتكوَّنُ القائمةُ من (٥٦) عبارةً مُصاغةً في (١١) عبارةً موجبةً و(٤٥) عبارةً سالبة، وموزَّعة على ستةِ أبعادٍ فرعيَّة هي:

١- التَّكيُّفُ مع المناهجِ: ويقيسُ هذا البعدُ مدى رضا الطالبِ عن دراستهِ في الجامعة وقناعتهِ بالتَّخصُّصِ الذي التحقَ به ومدى استمتاعهِ بالمسافاتِ التي يدرسُها وإحساسُه بأهميتِها. وتمثِّلُ هذا البعدَ الفقراتُ من (١-٧)،

٢- نضجُ الأهدافِ ومُستوى الطموح: ويقيسُ هذا البعدُ إدراكَ الطالبِ لمدى ارتباطِ البحوثِ الجامعيَّةِ بخططِ الطالب المستقبليَّة وتمثِّلُ هذا البعدَ الفِقْراتُ (٨-١١).

٣- الفاعليَّةُ الشَّخصيَّة، ويقيسُ هذا البعدُ مدى فاعليةِ الطَّالبِ في التَّخطيطِ لنشاطاته اليومية وتنفيذِها ومدى استخدامهِ للوقتِ بفاعليَّة وتمثِّلُ هذا البعدَ الفِقْراتُ (١٢-٢٣).

٤- المهاراتُ والعاداتُ الدراسيَّة: ويقيسُ هذا البعدُ استخدامَ الطالبِ للعاداتِ الدراسيَّةِ الجيدة مثل: التَّلخيصِ، وأخذِ الملاحظات، واستعمالِ المكتبة، وإبرازِ النقاط الهامة، وتمثِّلُ هذا البعدَ الفِقْراتُ (٢٤-٣٦).

٥- الصحةُ النَّفسيَّة: ويقيسُ هذا البعدُ مدى ثقةِ الطالبِ بنفسه، وبقدراته على مواجهةِ المشكلاتِ، ومدى معاناتهِ من القلقِ وأحلامِ اليقظةِ والشعورِ بالغربة، وتمثِّلُ هذا البعدَ الفِقْراتُ من (٣٧-٤٧).

٦- العلاقاتُ الشَّخصيَّة، ويقيسُ هذا البعدُ قدرةَ الطالبِ على التَّعامُلِ مع المدرسين والزملاء، ومدى تعاونهِ وتفاعلهِ معهم، وتمثِّلُ هذا البعدَ الفِقْراتُ من (٤٨-٥٦).

الخصائصُ السيكومتريَّة للقائمة:

تمَّ التَّحقُّقُ من الخصائصِ السيكو مترية للقائمةِ الأصليةِ لهنري بورو باستخدامِ طريقةِ التَّجزئةِ النَّصفيَّة، وكان معاملُ ثباتِ القائمةِ (٠,٩)، وعن طريقِ إعادةِ الاختبار لتعطي معامل ثبات (٠,٩٢)، وتمَّ التَّحقُّقُ من الصدقِ الظَّاهري وصدقِ المحكَّمين للنسخةِ العربيةِ المقنَّنة، وتمَّ التَّأكُّدُ من الاتساقِ الداخلي لعباراتِ القائمةِ على أبعادها الست، والتَّحقُّقُ من الثَّباتِ باستخدام ألفا كرونباخ وكان معاملُ الثَّباتِ للقائمة (٠,٩٢).

- **صدقُ القائمة:**

تمَّ التَّحقُّقُ من صدقِ قائمةِ التَّكيُّفِ الأكاديمي في البحثِ الحالي من خلال التَّحقُّقِ من الصِّدقِ العاملي بإجراءِ التَّحليلِ العاملي التوكيدي على الارتباطات البينية بين درجاتِ أفرادِ العيِّنة على أبعادِ المقياسِ باستخدامِ برنامج JASP ٠,١٦، وقد أسفرتْ النَّتائجُ عن مُطابقةِ النَّموذج للبياناتِ مُطابقةً مقبولةً إلى حدٍ كبير كما يوضِّحُها جدول (٢).

جدول ٢

مؤشِّراتُ حسنُ المطابقةِ لنموذجِ التَّحليلِ العاملي التوكيدي لقائمةِ التَّكيُّفِ الأكاديمي

المؤشِّر	القيمة
Comparative Fit Index (CFI) مؤشِّرُ المطابقةِ المقارن	٠,٩٣٧
Root mean square error of approximation (RMSEA) جذر متوسِّط مربَّع الخطأ التقاربي	٠,٠٧٧
Standardized root mean square residual (SRMR) جذر متوسِّطات مربَّعات البواقي المعيارية	٠,٠٩٣
Goodness of fit index (GFI) مؤشِّر حسن المطابقة	٠,٩٣٥
Tucker-Lewis Index (TLI) مؤشِّر توكر–لويس	٠,٩٣٣
Bentler-Bonett Non-normed Fit Index (NNFI) مؤشِّر المطابقة غير المعياري	٠,٩٣٣
Bentler-Bonett Normed Fit Index (NFI) مؤشِّر المطابقة المعياري	٠,٩١٠
Relative Noncentrality Index (RNI) المؤشِّرُ اللامركزي النسبي	٠,٩٣٧

يتَّضحُ من جدول (٢) أنَّ النَّموذج المفترضَ لقائمةِ التَّكيُّفِ الأكاديمي يطابقُ بدرجةٍ كبيرةٍ بيانات العيِّنة، حيثُ كانتْ قيمُ مؤشِّرات المطابقةِ جميعًا تشيرُ إلى مُطابقةٍ مقبولةٍ وقريبةٍ من حدِّها الأقصى، وكذلك مؤشِّرُ جذرِ متوسِّط مربَّع خطأ التقريب RMSEA كان أقل من ٠,٠٨، ومؤشِّر جذر متوسِّط مربَّع البواقي SRMR أقل من ٠,١، وهو ما يؤكِّدُ الصدقَ البنائي وجاءتْ تشبُّعاتُ عباراتِ القائمةِ جميعًا أكبر من ٠,٣، وجاءتْ جميعُ قيمِ "z" دالة عند مستوى ٠,٠١، ما عدا عبارة واحدة كان تشبُّعُها أقل من ٠,٣ وقيمة "z" لها غير دالة وتمَّ حذفُها من القائمة، وهو ما يؤكِّدُ صدقَ النَّموذجِ المفترض، وأنَّ عباراتِ القائمةِ تتشبَّع على ستةِ أبعاد تمثِّلُ أبعادَ التَّكيُّفِ الأكاديمي.

- **ثباتُ القائمة:**

للتأكُّدِ من ثباتِ القائمةِ وأبعادِها الفرعيَّة تمَّ استخدامُ مُعاملِ ثباتِ أوميجا الكلية (ω_t) الذي يصلحُ لهذا النوعِ من أدواتِ القياس نظرًا لطبيعةِ بيانات القائمة، وكان معاملُ ثباتِ القائمةِ ككل (٠,٩٣٤)، وجاءت معاملاتُ ثباتِ أبعادها الفرعية (٠,٧٢٤، ٠,٤٦٥، ٠,٨٣٠، ٠,٨١٧، ٠,٨٣٥، ٠,٧٦٨) على التوالي، وهي معاملاتُ ثباتٍ مقبولة، ممَّا يؤكِّدُ ثباتَ درجاتِ القائمةِ ككل وثباتِ أبعادها الفرعية.

ويتَّضحُ ممَّا سبقَ تمتُّعُ قائمةِ التَّكيُّفِ الأكاديمي بخصائص سيكومترية جيدة تسمحُ باستخدامِها في البحث الحالي.

- **استبانةُ الصلابةِ النَّفسيَّة**

- **هدفُ الاستبانةِ ووصفُها:**

تهدفُ الاستبانةُ إلى التقديرِ الكمِّي لصلابةِ الفردِ النَّفسيَّة، ويتكونُ المقياسُ من (٤٨) بندًا تقريريًا مُوزَّعة على ثلاثة أبعاد هي: الالتزامُ ويمثِّلهُ (١٦) بندًا، التَّحكُّمُ ويمثِّلهُ (١٦) بندًا، (التَّحدي) ويمثله ١٦ بندًا، وتُصحَّحُ إجاباتُ المفحوصين ضمن أربعةِ بدائل، وارتفاعُ الدرجةِ تعني ارتفاعَ الصلابةِ النَّفسيَّة.

الخصائصُ السيكومترية للاستبانة:

تمَّ التَّحقُّقُ من الخصائصِ السيكومترية للاستبانةِ الأصلية في البيئةِ المصرية، حيثُ تمَّ التَّحقُّقُ من الصدقِ التَّلازمي مع مقياس بيك، ومقياس قوة الأنا، وكانتْ النَّتائجُ (٠,٦٣ و ٠,٧٥) على الترتيب، وتمَّ حسابُ الثَّباتِ باستخدامِ معامل ألفا كرونباخ حيث أعطى القيمة (٠,٧٥) ، وتراوحتْ قيمُ الاتساقِ الداخلي للعبارات بين (٠,٢٢ و ٠,٧٤).

- **صدق الاستبانة:**

تمَّ التَّحقُّقُ من صدقِ استبانةِ الصلابةِ النَّفسيَّة في البحث الحالي من خلالِ التَّحقُّقِ من الصدقِ العاملي بإجراءِ التَّحليلِ العاملي التوكيدي على الارتباطاتِ البينيةِ بين درجاتِ أفراد العيِّنةِ على أبعادِ الاستبانة، وقد أسفرتْ النَّتائجُ عن مُطابقةِ النَّموذج للبياناتِ مطابقةً مقبولةً إلى حدٍ كبيرٍ، فقدْ جاءتْ مؤشِّراتُ حسنِ المطابقةِ كما يوضِّحُها جدول (٣).

جدول ٣

مؤشِّراتُ حسنُ المطابقةِ لنموذجِ التَّحليلِ العاملي التَّوكيدي لاستبانة الصلابة النَّفسيَّة

المؤشِّر	القيمة
Comparative Fit Index (CFI) مؤشِّر المطابقة المقارن	٠,٩٤٤
Root mean square error of approximation (RMSEA) جذر متوسِّط مربَّع الخطأ التقاربي	٠,٠٦٥
Standardized root mean square residual (SRMR) جذر متوسِّطات مربَّعات البواقي المعيارية	٠,٠٨٤
Goodness of fit index (GFI) مؤشِّر حسن المطابقة	٠,٩٤٣
Tucker-Lewis Index (TLI) مؤشِّر توكر–لويس	٠,٩٤١
Bentler-Bonett Non-normed Fit Index (NNFI)	٠,٩٤١

المؤشِّر	القيمة
مؤشِّر المطابقة غير المعياري Bentler-Bonett Normed Fit Index (NFI)	٠,٩١٠
مؤشِّر المطابقة المعياري Relative Noncentrality Index (RNI)	٠,٩٤٤
المؤشِّر اللامركزي النسبي	

يتَّضِحُ من جدول (٣) أنَّ النَّموذجَ المفترضَ لاستبانةِ الصلابةِ النَّفسيَّة يطابقُ بدرجةٍ كبيرةٍ بيانات العيِّنةِ، حيثُ كانتْ قيمُ مؤشِّراتِ المطابقةِ جميعًا قيمٌ مرتفعةٌ وقريبةٌ من حدِّها الأقصى (واحد صحيح)، وكذلك مؤشِّرُ جذرِ متوسِّط مربَّع خطأ التقريب RMSEA كان أقل من (٠,٠٨)، ومؤشِّر جذر متوسِّط مربَّع البواقي (SRMR) أقل من (٠,١) وهو ما يؤكِّدُ الصدق البنائي؛ وجاءتْ تشبُّعاتُ مهامِ المقياس جميعها أكبر من (٠,٣)، وجاءتْ جميعُ قيمِ "z" دالة عند مستوى (٠,٠١) وهو ما يؤكِّدُ صدقَ النَّموذجِ المفترض، وأن عبارات الاستبانة تتشبَّعُ على أبعادِ الصلابةِ النَّفسيَّة.

- **ثباتُ الاستبانة:**

للتأكُّدِ من ثباتِ المقياسِ وأبعادِهِ الفرعية تمَّ استخدامُ معاملِ ثباتِ أوميجا الذي يصلحُ لهذا النوعِ من أدواتِ القياسِ نظرًا لطبيعةِ بياناتِ الاستبانة، وكان معاملُ ثباتِ الاستبانة ككل (٠,٩٢٣) وجاءتْ معاملاتُ ثباتِ أبعاده الفرعية (٠,٨٠٨)، (٠,٨٠٣)، (٠,٨١٨)، على التَّوالي، وهي معاملاتُ ثباتٍ مقبولة، ممَّا يؤكِّدُ ثباتَ درجاتِ الاستبانةِ ككل وثباتِ أبعادِها الفرعية. ويتَّضحُ ممَّا سبقَ تمتُّعُ استبانةِ الصلابةِ النَّفسيَّة بخصائص سيكومترية جيدة تسمحُ باستخدامِها في الدراسةِ الحالية.

- **مقياسُ دافعيَّةِ الذَّات:**

- هدفُ المقياسِ ووصفُه: يحتوي المقياسُ على (٥٠) عبارةً تُعبِّرُ جميعُها عن فاعليَّةِ الفردِ في التنبُّؤ بمسارِ سلوكِهِ بصفةٍ عامَّة وأمامَ كلِّ عبارة أربعةُ اختيارات، تحدِّدُ درجةَ فاعليةِ الذاتِ لدى الفردِ وهي: نادرًا، أحيانًا، غالبًا، دائمًا، والعباراتُ مصاغةٌ في (٢٦) عبارةً موجبة و(٢٤) عبارةً سالبة.

الخصائصُ السيكومترية للمقياس:

تمَّ التَّحقُّقُ من الخصائصِ السيكومترية للمقياسِ الأصلي، حيثُ تمَّ حسابُ الصدقِ عن طريق صدقِ المحكَّمين وباستخدامِ صدقِ المحك بحسابِ معاملِ الارتباطِ بين درجاتِ الطلاب في المقياس، ودرجاتِهم في مقياسِ سكوارتز، وجاء معاملُ الارتباطِ مساويًا (٠,٦٤) وهو مؤشرٌ لصدقِ المقياس، وتمَّ حسابُ مُعاملِ الثَّبات بطريقةِ مُعاملِ ألفا وكان (٠,٧٧)، وطريقة التجزئةِ النصفية وبلغ (٠,٨٣)K ومعادلة جتمان وبلغ (٠,٧٩)، كذلك تمَّ حسابُ التَّجانسِ الداخلي للمقياس.

- **صدقُ المقياس:**

تمَّ التَّحقُّقُ من صدقِ مقياسِ فاعليةِ الذات في البحثِ الحالي من خلالِ التَّحقُّقِ من الصدقِ العاملي، بإجراءِ التَّحليلِ العاملي التَّوكيدي على الارتباطاتِ البينية بين درجاتِ أفرادِ العيِّنةِ على أبعادِ المقياس، وقد أسفرتْ النَّتائجُ عن وجودِ بعض تشبُّعاتِ عباراتِ المقياسِ أقل من (٠,٣)، وكانتْ قيمُ "Z" لها غيرَ دالة عند مستوى (٠,٠١)، وبالتَّالي تمَّ حذفُها من المقياس وعليه أصبحتْ بنودُ المقياسِ (٢٤) بندًا، وكانتْ مطابقةُ النَّموذجِ للبياناتِ بعد الحذفِ مطابقةً مقبولةً إلى حدٍ كبير، فقد جاءتْ مؤشِّراتُ حسنِ المطابقةِ كما يوضِّحُها جدولُ (٤).

جدول ٤

مؤشِّراتُ حسنِ المطابقةِ لنموذجِ التَّحليلِ العاملي التوكيدي لاستبانة الصلابة النَّفسيَّة

المؤشِّر	القيمة
Comparative Fit Index (CFI) مؤشِّر المطابقة المقارن	٠,٩٤١
Root mean square error of approximation (RMSEA) جذر متوسِّط مربَّع الخطأ التقاربي	٠,٠٨٠
Standardized root mean square residual (SRMR) جذر متوسِّطات مربَّعات البواقي المعيارية	٠,١٠٠
Goodness of fit index (GFI) مؤشِّر حسن المطابقة	٠,٩٢٨
Tucker-Lewis Index (TLI) مؤشِّر توكر–لويس	٠,٩٣٦
Bentler-Bonett Non-normed Fit Index (NNFI) مؤشِّر المطابقة غير المعياري	٠,٩٣٦
Bentler -Bonett Normed Fit Index (NFI) مؤشِّر المطابقة المعياري	٠,٩٠٠
Relative Non centrality Index (RNI) المؤشِّر اللامركزي النسبي	٠,٩٤١

يتَّضِحُ من جدول (٤) أنَّ النَّموذجَ المفترضَ لمقياسِ فاعليةِ الذات يطابقُ بدرجةٍ مقبولةٍ بيانات العيِّنة، وهو ما يؤكِّدُ الصدقَ البنائي؛ وجاءتْ تشبُّعاتُ عباراتِ المقياس جميعها بعد حذفِ العباراتِ غيرِ المطابقة، أكبر من (٠,٣)، وجاءتْ جميعُ قيمِ "z" دالة عند مستوى (٠,٠١) وهو ما يؤكِّدُ صدقَ النَّموذج المفترَض، وأنَّ عباراتِ المقياسِ تتشبَّعُ على بعدٍ واحدٍ يمثِّلُ دافعيَّةَ الفردِ الذاتية.

- **ثباتُ المقياس:** للتَّأكُّدِ من ثباتِ المقياسِ وأبعادِهِ الفرعية تمَّ استخدامُ معاملِ ثباتِ أوميجا، وكان معاملُ ثباتِ المقياس (٠,٨٨٣)، ممَّا يؤكِّدُ ثباتَ درجاتِ المقياس. ويتَّضحُ ممَّا سبقَ تمتُّعُ مقياسِ دافعيةِ الذَّاتِ بخصائص سيكومترية جيدة تسمحُ باستخدامِهِ في البحث.

بناءُ نموذجِ التنبُّؤ باستخدامِ الشَّبكاتِ العصبيَّةِ الاصطناعيَّة (ANN)

- مُدْخلاتُ الشَّبكة:

لقياسِ فاعليةِ الشَّبكاتِ العصبيَّةِ الاصطناعيَّة في التنبُّؤِ بالمتغيِّرات النَّفسيَّة تمَّ بناءُ نموذج باستخدامِ المتغيِّراتِ المستقلة محل البحثِ، وتتمثَّل في: فاعليةِ الفردِ الذاتية، وأبعادِ الصلابةِ النَّفسيَّة الثَّلاث (الالتزام، والتَّحكُّم، والتَّحدي)؛ وذلك للتنبُّؤ بالمتغيِّرِ التَّابعِ المتمثِّلِ في "التَّكيُّفِ الأكاديمي"، حيث سيتمُّ تحديدُ الأوزانِ النسبيةِ لبيان أهميةِ المتغيِّرات المستقلةِ التي تفسِّرُ سلوكَ المتغيِّرِ التَّابع، وتمثَّلتْ خطواتُ البناءِ في معالجةِ البيانات التي تمَّ الحصولُ عليها من تطبيقِ المقاييسِ المستخدمةِ في البحث، ومن ثمَّ تكويدُها وإعدادُها للإدخال، وتمَّ استخدامُ برامج (SPSS ٢٣) وبرنامج (JASP ٠,١٦) وبرنامج (GMDH Shell ٣) لتصميمِ الشَّبكةِ العصبيَّةِ وتدريبِها، وعملِ التَّحليلاتِ الإحصائية، واستخراجِ معاييرَ تقييمِ كفاءة التنبُّؤ وفعاليته.

- نوعُ الشَّبكة:

تمَّ استخدامُ شبكةِ البثِ (الانتشار) العكسي للخطأ (Back Propagation) المتعدِّدَةِ الطبقات (Multilayer Perceptron) وهي شبكةٌ عصبيةٌ ذاتُ تغذيةٍ أماميَّة، أي يتمُّ تنشيطُ الخليةِ العصبيَّةِ في الطبقاتِ الأولى للحصولِ على الطبقاتِ التي تليها، حتى الوصول إلى طبقةِ المخرجات، ثمَّ يتمُّ تقييمِ جودةِ المخرجاتِ عن طريقِ دالةِ التكلفة (cost function) ومقارنتُها بالمخرجاتِ الحقيقية، ومن ثمَّ تقومُ الشَّبكةُ بنشرِ الخطأ في الاتجاه العكسي لتحديثِ أوزانِ التَّحيُّزِ للطبقاتِ المخفيةِ وقيمه، حيث نحاولُ بشكلٍ أساسي ضبطَ الشَّبكةِ العصبيَّةِ بأكملها، بحيث يتمُّ تحسينُ قيمةِ المخرجات. وبهذه الطريقةِ يتمُّ الحكمُ على الخوارزميَّة من حيث الأداء: هل هو سيئ أم جيد؟ وعلى أساسِ النتيجة: حيثُ يتمُّ باستمرار تحسينُ دالةِ التكلفة من خلالِ الملاحظاتِ الجديدة من مجموعةِ البياناتِ المدخلة.

- هيكلية (معمارية) الشَّبكة:

تتكوَّنُ الشَّبكةُ من ثلاثِ طبقات (المدخلات، والمخفية، والمخرجات) مُترابطةٍ فيما بينَها بروابط لها أوزان، وتكوَّنتْ الشَّبكةُ من خمسِ طبقاتٍ مخفية (٤ طبقات، وطبقة للتقاطعاتِ بينهم)، وتنقسمُ إلى (٣١) عقدةً (شكل ٢).

شكل ٢

معمارية الشَّبكة العصبيَّة الاصطناعيَّة للتنبؤ بالتَّكيُّف الأكاديمي

تكونُ المفاضلةُ بينهم بواسطةِ متوسِّط مربَّع الخطأ MSE، فبعدِ الحصولِ على المخرَجِ الأوَّل يتمُّ ضربُ عملياتِ التنشيط (a_i) في الأوزان (w_i) للحصولِ على خليةٍ عصبيةٍ جديدة في الطبقةِ التَّالية، وذلك بدءًا من الأوزانِ والتنشيطاتِ الأولى وبضربِ المعادلةِ السَّابقةِ في دالةِ التنشيطِ المستخدمةِ في الشَّبكة (tanH) وإضافةِ أو طرحِ التحيز (b) من مُضاعفةِ عمليات التنشيط والأوزان، حيث تكونُ مهمَّةُ التحيزِ هي تحديدُ القيمةِ التي تبدأ فيها قيمةُ الخلايا العصبيَّة الجديدة في أنْ تكونَ ذات مغزى حسب المعادلة (٥)

$$\tanH\,(w_1a_1 + w_2a_2 + \ldots + w_na_n + b) = \text{new neuron} \qquad (٥)$$

ولتحديثِ الشَّبكةِ، نحسبُ ما يسمَّى بالتَّدرجاتِ (gradients)، وهي عبارة عن تحديثاتٍ صغيرةٍ للأوزانِ الفرديةِ في كل طبقة، ويتمُّ حسابُ هذه التَّدرُجاتِ عن طريقِ الانتشارِ العكسي (Back Propagation) لتقليلِ الميل، حيث تبدأُ عمليةُ التَّحديثِ من طبقةِ المخرجاتِ، بحيثُ يتمُّ تحديثُ الأوزانِ والتَّحيزاتِ للحصولِ على مقاربةٍ من القيم المطلوبة لتحقيقِ دوال التنشيط؛ مما يعني أنَّه يمكنُ بشكلٍ غير مباشر تعديلُ كل جزءٍ من الشَّبكةِ العصبيَّة، للحصولِ على المخرجاتِ المطلوبة.

- **تدريبُ الشَّبكة:**

تمَّ تقسيمُ البياناتِ المتاحةِ إلى مجموعةِ بيانات التَّدريب بنسبةِ (٦٤%) لتدريبِ الشَّبكةِ العصبيَّةِ وتعلُّمِها بواقعِ (٢٣٠) استجابةً، ومجموعةِ بياناتِ التَّحقُّقِ (Validation Dataset) بنسبة (١٦%) للتَّحقُّقِ من كفاءةِ تنبُّؤ الشَّبكةِ بعد التَّدريب بواقعِ (٥٨) استجابةً، ومجموعةِ بياناتِ الاختبار بنسبةِ (٢٠%) لاختبارِ كفاءةِ الشَّبكةِ ومهارتِها في التنبُّؤ بواقعِ (٧١) استجابةً واستبعدتْ الشَّبكةُ (١٠) استجابات لها قيمُ عوامل لا توجدُ بعينةِ

التَّدريب، وتمَّ اعتمادُ دالةِ الظل الزائدية (TanH) لتدريبِ الشَّبكة، وتمَّ وضعُ معيار لإنهاءِ التَّدريب وهو عدمُ ملاحظةِ أي تغيير في متوسِّط مربعِ الخطأ MSE (الجداول ٥، ٦).

جدول ٥

ملخَّصُ العمليات على بياناتِ الشَّبكة.

		N	Percent
مجموعة بيانات	التَّدريب	٢٣٠	٦٤,٠٪
	التحقق	٥٨	١٦٪
	الاختبار	٦١	٢٠٪
الصالحValid		٣٤٩	١٠٠,٠٪
المستبعدExcluded		١٠	
المجموعTotal		٣٥٩	

جدول ٦

معلومات الشَّبكة Network Information

طبقةُ الإدخال	المتغيِّرات	١	فاعليةُ الذات
		٢	الالتزام
		٣	التَّحكُّم
		٤	التَّحدي
		٥	الصلابة النَّفسيَّة
الطبقاتُ المخفيَّة	عددُ الطبقاتِ المخفية Number of Hidden Layers		٥
	Number of Units in Hidden Layer ١[a] عددُ الوحداتِ بالطبقةِ المخفية		٣١
	دالة التنشيط Activation Function		Hyperbolic tangent
طبقةُ المخرجات	Dependent Variables	١	التَّكيُّف الأكاديمي
	عدد الوحدات Number of Units		١
	Rescaling Method for Scale Dependents		Standardized
	دالة التنشيط Activation Function		Identity
	دالة حساب الخطأ Error Function		مجموع المربعات Sum of Squares

نتائجُ البحث

للحكمِ على كفاءةِ الشَّبكاتِ العصبيَّةِ الاصطناعيَّة في التنبُّؤ بالمتغيِّرات النَّفسيَّة محل الدراسة، تمَّ تنفيذُ نموذج التنبُّؤ الذي تمَّ بناؤه وفقًا لأسلوبِ الشَّبكاتِ العصبيَّة الاصطناعيَّة، وتلخَّصت بياناتُ جودةِ النَّموذجِ ومؤشراته في جدول (٧).

جدول ٧

مُلخَّص مؤشِّراتِ كفاءةِ نموذج التنبُّؤ باستخدامِ الشَّبكاتِ العصبيَّة الاصطناعيَّة

التَّدريب	مجموع مربعات الخطأ	٩٢,١٣٩
	الخطأ النسبي	.٧١٢
	قاعدة التوقف المستخدمة	خطوتان متتاليتان بدون نقص في مقدار الخطأ
	Stopping Rule Used	١ consecutive step(s) with no decrease in error[a]
	Training Time زمن التَّدريب	٠:٠٠:٠٠,٠٦
الاختبار	Sum of Squares Error مجموع مربعات الخطأ	٣٤,٠٤٢
	Relative Error الخطأ النسبي	.٨٣٨

Dependent Variable: التَّكيُّف الأكاديمي

a. Error computations are based on the testing sample.

بالنَّظرِ في الجدولِ نجدُ أنَّه تمَّ استخدامُ مجموعِ مربَّعاتِ الخطأ للحكمِ على جودةِ التنبُّؤ وتحسُّنهِ بين مجموعةِ بياناتِ التَّدريب حيثُ بلغَ (٩٢,١٣٩) وبين مجموعةِ الاختبارِ حيث بلغَ المؤشِّرُ (٣٤,٠٤٢) حيث يظهرُ بوضوح تدنِّي نسبةِ الخطأ للتنبُّؤ ما بين مجموعتي التَّدريب والاختبار، ممَّا يدلُّ على رصانةِ النَّموذج المستخدَم ووصوله لأفضل أداء تنبؤي.

وللحُكمِ الجيدِ على جودةِ النموذجِ التنبُّؤي يجبُ أنْ تكونَ الأخطاءُ مستقلةً وتتبعُ التَّوزيعَ الطبيعي، وبالنَّظرِ إلى شكلِ (٣) الذي يمثِّلُ البواقي على المحورِ الصادي والمتغيِّر المستقل على المحور السيني، ويظهرُ الجزءُ الأخيرُ من الشكل البيانات الجديدة التي تمَّ التنبُّؤ بها باستخدامِ النَّموذجِ نفسهِ، يتَّضِحُ من الشكلِ أنَّ معظمَ البواقي تتوزَّعُ بطريقةٍ عشوائية حولَ نقطةِ الأصل، وبطريقةٍ متماثلة أي تتبعُ التَّوزيعَ الطبيعي (شكل ٤)، ممَّا يعني أنَّ النَّموذجَ التنبُّؤي قام باحتواءِ جميعِ المعلوماتِ التنبُّؤية ممَّا يدلُّ على جودةِ الشَّبكات العصبيَّة الاصطناعيَّة وكفاءتها في التنبُّؤ بالمتغيِّرات النَّفسيَّة محل الدراسة.

شكل ٣

توزيع البواقي لنموذج التنبُّؤ باستخدام الشَّبكات العصبيَّة الاصطناعيَّة

شكل ٤

التوزيع التكراري لقيم البواقي لنموذج التنبُّؤ باستخدام الشَّبكات العصبيَّة الاصطناعيَّة

٩. فعاليَّةُ الشَّبكةِ العصبيَّةِ الاصطناعيَّة في التنبُّؤ بالمتغيِّرات النَّفسيَّة:

وللتَّحقُّقِ من فعاليَّةِ استخدامِ الشَّبكاتِ العصبيَّة الاصطناعيَّة وأفضليتها في التنبُّؤ تمَّت مقارنةُ نموذجين للتنبؤ أولهما بالاعتمادِ على نموذجِ الانحدارِ التقليدي الأكثرَ استخدامًا في الدِّراساتِ النَّفسيَّة، والأخرُ الذي تمَّ بناؤه باستخدامِ الشَّبكات العصبيَّة

- **نموذجُ التنبُّؤ باستخدامِ أسلوبِ الانحدارِ الخطي المتعدِّد.**

يُعدُّ تحليلُ الانحدارِ المتعدِّد من أكثر الأساليب الإحصائية استخدامًا، حيثُ يهتمُّ بتقديرِ العلاقةِ بين المتغيِّر التَّابع وعدة متغيِّراتٍ أخري هي المتغيِّراتُ المستقلة، وبالرجوعِ للمُتغيِّراتِ الخاصةِ بالدراسةِ نجدُ متغيِّرَ التَّكيُّفِ الدراسي مُتغيرًا تابعًا، والصَّلابةَ النَّفسيَّةَ بأبعادِها الثلاثة، وفاعليَّةَ الذَّاتِ مُتغيِّراتٍ مستقلة، ولتقديرِ النَّموذجِ التنبُّؤي تمَّ إدخالُ البياناتِ الخاصة بالمتغيِّراتِ ومعالجتِها إحصائيًا باستخدامِ برنامج (SPSS ٢٣) وبرنامج (JASP ٠,١٦)

للحصولِ على مؤشِّرات الحكمِ على جودةِ النَّموذج، وكانتْ النَّتائجُ كالتالي:

جدول ٨

مُلخَّصُ نتائج المقاييس الأساسية لنموذجِ الانحدار المتعدد

Model النَّموذج	R	R Square معامل التحديد	Adjusted R Square	R Square Change	Change Statistics اختبار المعنوية F Change	df١	df٢	Sig. F Change	Durbin-Watson
١	.٤٤١[a]	.١٩٤	.١٨٥	.١٩٤	٢١,٣٤١	٤	٣٥٤	.٠٠٠	١,٩٩٣

a. Predictors: (Constant), Hard_Total, Efficacy_Total, HARD١, HARD٣, HARD٢

المنبئات: الصلابة النَّفسيَّة، فعالية الذات، الالتزام، التحدي، التحكم

b. Dependent Variable: Adapt_Total

المتغير التابع: التَّكيُّف الأكاديمي

يتَّضحُ من جدول (٨) أنَّ مُعاملَ التَّحديد كان (٠,١٩٤) وكانتْ قيمةُ (ف) دالة إحصائيًّا؛ ممَّا يدلُّ على إسهامِ المتغيِّرات المستقلة، وتأثيرها في المتغيِّرِ التَّابع، حيث بلغتْ نسبةُ الإسهامِ (١٩,٤ %)، ممَّا دلَّ على جودةِ النَّموذج الإحصائي للتنبُّؤ بالتَّكيُّف الأكاديمي.

- **مقارنةُ نموذجي التنبُّؤِ باستخدامِ أسلوبِ الانحدارِ المتعدِّد وأسلوبِ الشَّبكاتِ العصبيَّةِ الاصطناعيَّة.**

للتَّأكُّدِ من فعاليَّةِ استخدامِ الشَّبكاتِ العصبيَّةِ الاصطناعيَّة في التنبُّؤ بالمتغيِّراتِ النَّفسيَّة تمَّ استخدامُ مقاييسِ جودةِ ملاءمةُ النَّموذج ومقارنتُها بمثيلتِها لنموذجِ الانحدارِ المتعدِّد كما يظهرُ بالجدولِ التَّالي (جدول ٩)

جدول ٩

مقارنة لمؤشرات الجودة للنماذج المستخدمة للتنبؤ بالتَّكيُّف الأكاديمي

مؤشر جودة التنبُّؤ	نموذج الانحدار المتعدد	نموذج الشَّبكات العصبيَّة الاصطناعيَّة
جذر متوسط مربع الخطأ Root Mean Square Error (RMSE)	٢٠,٩٧٧٢	١٩,٨٩١٨
متوسط القيمة المطلقة للخطأ Mean Absolute Error (MAE)	١٦,٥٠٦٣	١٥,٨٥
المتوسط النسبي للخطأ المطلق Mean Absolute Percentage Error (MAPE)	١٧,٨٦٩٦٪	١٦,٥٧٣٦٪
جذر المتوسط النسبي لمربع الخطأ Root Mean Square Percentage Error (RMSPE)	٢٩,٦٩٥٧٪	٢٥,١٢٣٩٪
معامل التحديد Coefficient of Determination (R^2)	٠,١٩٤	٠,٢٦٤٤٨٢

من الجدولِ السابقِ يتَّضحُ أنَّ المعاييرَ المستخدمة للحكمِ على أفضليةِ النَّموذج أثبتتْ تفوقَ نموذج الشَّبكاتِ العصبيَّةِ الاصطناعيَّةِ حيثُ كانتْ كلُّ قيمِ حساب الخطأ أقل من نظيرتِها الخاصة بنموذجِ الانحدارِ المتعدِّد، وبالنَّظرِ إلى البواقي، وتوزيعها الطبيعي، وعشوائية بياناتها، أكَّدتْ فاعليَّةَ الشَّبكاتِ العصبيَّةِ الاصطناعيَّة في التنبُّؤ بالتَّكيُّفِ الأكاديمي من خلالِ الصلابةِ النَّفسيَّة، وفاعليةِ الذات حيثُ ارتفعَ معاملُ التَّحديدِ من (٠,١٩٤) للانحدارِ المتعدِّد إلى (٠,٢٦٤) للشَّبكاتِ العصبيَّة أي أنَّ الصلابةَ النَّفسيَّة وفاعليَّةَ الذات تفسِّرُ (٢٦,٤%) من التباينِ الحاصلِ في التَّكيُّف الأكاديمي.

وقدَّمتْ الشَّبكاتُ العصبيَّةُ الاصطناعيَّة أيضًا الأهميَّةَ النِّسبيَّةَ للمتغيِّراتِ المستقلة كما هو مُوضَّح بالجدولِ التَّالي (جدول ١٠)

جدول ١٠

الأهمية النسبية للمتغيرات المستقلة

المتغير المستقل	الأهمية النسبية
فاعلية الذات	٦٤,١٪
الالتزام	١٠٠,٠٪
التحكم	٥٨,٩٪
التحدي	٨١,٧٪
الصلابة النَّفسيَّة	٧٧,٦٪

يظهرُ من الجدولِ السَّابقِ أنَّ بُعدَ الالتزامِ من أبعادِ الصَّلابةِ النَّفسيَّة كان الأكثرَ تأثيرًا في التنبُّؤ بالتَّكيُّفِ الأكاديمي بنسبة (١٠٠ %)، ويليه بعدُ التَّحدي بنسبة (٨١,٧%)، في حين كان بُعدُ التَّحكُّمِ هو الأقلُّ تأثيرًا في القدرةِ على التنبُّؤ بالتَّكيُّف الأكاديمي بنسبة (٥٨,٩ %)، وجاءتْ فاعليَّةُ الذاتِ بأهميَّةٍ نسبيَّةٍ قليلةٍ نوعًا ما (٦٤,١ %)، في حين جاءتْ الصلابةُ النَّفسيَّة ككل بأهميةٍ نسبية (٧٧,٦ %).

الاستنتاجاتُ:

أظهرَ البحثُ كفاءةَ الشَّبكاتِ العصبيَّةِ الاصطناعيَّة وفعاليتَها في التنبُّؤ بالتَّكيُّفِ الأكاديمي لطالباتِ جامعةِ القصيم من خلالِ معرفةِ أدائهن على مقياسي: الصلابة النَّفسيَّة، وفاعلية الذات، حيثُ تمَّ الحكمُ على كفاءةِ نموذجِ التنبُّؤ بالنَّظرِ إلى تحسُّنِ مقدارِ التنبُّؤ ما بين مجموعتي التَّدريب والاختبار، وذلك عن طريقِ التدنِّي الملاحَظ في مُؤشِّرِ الخطأ، والنَّظرِ إلى عشوائية البواقي وتوزيعِها المنتظم حول خط الأصل، حيثُ وصلتْ الشَّبكةُ لمعدلٍ مرتفعٍ وعالٍ من الدقة، وأعطتْ نموذجًا رصينًا يصلح للتنبُّؤ بالقيمِ المستقبليَّة لاستخدامِهِ طريقة التَّحقُّقِ المتقاطع (Cross-Validation) حيثُ تقومُ الشَّبكةُ بتقسيمِ جميعِ بيانات التَّدريب عشوائيًا إلى مجموعاتٍ فرعية متميزة K، ونقومُ بتدريبِ الشَّبكة باستخدامِ مجموعات K – ١ الفرعية، واختبار الشَّبكة على المجموعةِ الفرعيةِ المتبقية،

ثم يتمُّ تكرارُ عمليةِ التَّدريب والاختبار لكل خيار من خيارات K الممكنة للمجموعة الفرعية التي تمَّ حذفُها من التَّدريب. ويعطي متوسِّطُ الأداءِ على المجموعاتِ الفرعية المحذوفة K التقديرَ لإمكانيةِ التعميم.

واستُخْدِمَتْ معاييرُ الحكمِ على جودةِ التنبُّؤ للنموذج بالمقارنةِ بأسلوبِ الانحدار المتعدِّد التقليدي، وجاءتْ النَّتائجُ لتؤكِّد فعاليَّة نموذجِ التنبُّؤ باستخدامِ الشَّبكاتِ العصبيَّةِ الاصطناعيَّةِ حيث كان هناك انخفاضٌ في قيمِ كلِّ مؤشِّراتِ الحكم (جذر متوسِّط مربع الخطأ – متوسِّط القيمة المطلقة للخطأ – المتوسِّط النسبي للخطأ المطلق – جذر المتوسِّط النسبي لمربَّع الخطأ) وزيادة في النِّسبةِ المفسرةِ للتباين للمتغيِّرِ المتنبأ به التي تمَّ حسابُها عن طريقِ معاملِ التحديد R^2 وهو ما أكَّدته دراسات (Duarte, ٢٠٢٠; Grządzielewska, ٢٠٢١; Pukelis & Stančiauskas, ٢٠١٩; Song et al., ٢٠١٨; Urban & Gates, ٢٠٢١)

التَّوصيات:

بالرغمِ من وجودِ المفاهيم النظرية اللاخطية في العلاقاتِ بين المتغيِّراتِ النَّفسيَّة، فإنَّ افتراضَ الخطية لا يزالُ يهيمنُ على المجالِ البحثي للمتغيِّراتِ النَّفسيَّة. إنَّ تبنِّي نموذج أقرب إلى عملِ الأنظمةِ في العالم الحقيقي، بحيث لا يقيدُ البيانات المعقَّدة وغير الخطيةِ المحتملةِ في تمثيلاتٍ خطيَّة من شأنه أن يفيدَ المجالَ، حيثُ يجبُ علينا استكشافَ التَّطوراتِ الجديدةِ واستخدامها حيثما كان ذلك مُناسبًا. يتطلَّبُ التنبُّؤ بالمتغيِّرات النَّفسيَّة بشأن أفضل نهجٍ تحليلي ودراسةٍ متأنيَّة، ويجبُ أنْ تحدِّده احتياجاتُ البحثِ وسياقِهِ بالاعتمادِ على نماذجَ دقيقة تعكسُ طبيعةِ البيانات.

يمثِّلُ هذا البحثُ خطوةً أوليَّة نحو تمكينِ علماءِ النَّفس في البيئةِ العربيةِ من الاستفادةِ من أدبيَّاتِ التَّعلُّم الآلي والشَّبكاتِ العصبيَّةِ الاصطناعيَّةِ بالطريقةِ نفسها التي استخلصوها تاريخيًا من أدبيَّاتِ الإحصاء، حيثُ يحتاجُ علماءُ النَّفس إلى استخدامِ استراتيجياتِ التَّعلُّمِ العميقِ للإجابة عن أسئلةِ البحثِ، التي تركِّزُ على التنبُّؤ بديلًا عن التَّفسيرِ الذي يقودُنا بدورِهِ إلى فهمٍ أكبر للمتغيِّراتِ النَّفسيَّة، ويجبُ على علماءِ علمِ النَّفس والباحثين الأخذَ في الاعتبار أنَّ نماذجَ التَّعلمَ العميقَ التي تتعلَّمُ تلقائيًا العلاقات المعقَّدة بين المتغيِّراتِ المستقلِّةِ والتَّابعة ليستْ بترخيصٍ لتغذيةِ بياناتِ الباحثين في خوارزميَّةٍ مع الأملِ في الحصولِ على النَّتائج المرجوة. وبدلًا من ذلك، يتطلَّبُ البحثُ النَّفسي الصحيحُ الانتباهَ إلى تحديدِ فرضياتِ البحثِ بصورةٍ دقيقة، وترجمةِ التركيباتِ النظريةِ المجرَّدةِ إلى قياساتٍ ذاتَ مغزى يمكنُ ملاحظتَها؛ وتصميمِ الدِّراساتِ وجمعِ البيانات بشكلٍ أخلاقي. واختيارِ تقنياتِ النمذجةِ الإحصائية الكلاسيكية أو الحديثةِ المناسبة، حيث يمثِّلُ التَّعلُّمُ الآلي والتَّعلُّمُ العميقُ والشَّبكات العصبيَّة جنبًا إلى جنب مع ممارساتِ البحثِ الممتازة خطوةً أساسيَّةً نحو مساعدةِ علماءِ النَّفس على التنبُّؤ بدقةٍ وموثوقيةٍ بالسُّلوكيات والإدراك والعواطف البشرية.

المقترَحات:

١. التوسُّعُ في استخدامِ الشَّبكاتِ العصبيَّة الاصطناعيَّة في التنبُّؤ بالمتغيِّرات النَّفسيَّة.
٢. إجراءُ أبحاثٍ لقياسِ كفاءةِ النماذجِ الأخرى للشبكاتِ العصبيَّةِ الاصطناعيَّة وفعاليتِها.
٣. الاستفادةُ من إمكانيَّاتِ الشَّبكاتِ العصبيَّةِ الاصطناعيَّة في تصنيفِ البياناتِ وعملِ العناقيدِ البيانيةِ بكفاءة.
٤. اجراءُ أبحاثٍ مُدَعَّمة للتوجُّه الحديثِ لعلمِ النَّفس نحو زيادةِ التركيزِ على التنبُّؤ بدلًا من التفسير للعلاقاتِ بين المتغيِّراتِ النَّفسيَّة.
٥. مقارنةُ النماذج المتعدِّدة للتَّعلُّمِ الآلي والتَّعلُّمِ العميق للوصولِ إلى أفضل النَّماذج للتنبُّؤ بالمتغيِّرات النَّفسيَّة.

المراجع

أولًا: المراجعُ العربية:

العدل، عادل .(٢٠٠١) .تحليل المســار للعلاقة بين مكونات القدرة على حل المشــكلات الاجتماعية وكل من فعالية الذات والاتجاه نحو المخاطرة .مجلة كلية التربية -جامعة عين شمس، ٢٥(١)، ١٢١-١٧٨.

عبد المطلب، ســارة .(٢٠١٠) .التَّكيُّف الأكاديمي لدى طلاب جامعة الخرطوم وعلاقته بأســاليب المعاملة الوالدية كما يدركها الأبناء [رسالة ماجستير غير منشورة]. جامعة الخرطوم

مخيمر، عماد .(٢٠٠٢) .استبيان الصلابة النَّفسيَّة .مكتبه النهضة المصرية .

Abdul Muttalib, S. (٢٠١٠). Academic Adaptation of University of Khartoum Students and its Relationship to Parental Treatment Methods as Perceived by Children. Master's Thesis - University of Khartoum.

Adaptation-APA Dictionary of Psychology. (n.d.). Retrieved December ٢٨, ٢٠٢١, from https://dictionary.apa.org/adaptation

Aggarwal, G., & Singh, L. (٢٠١٩). Classification of intellectual disability using LPC, LPCC, and WLPCC parameterization techniques. International Journal of Computers and Applications, ٤١(٦), ٤٧٠–٤٧٩. https://doi.org/١٠,١٠٨٠/١٢٠٦٢١٢X.٢٠١٨,١٤٧٥٣٣٠

Al-adl, A. (٢٠٠١). Path analysis of the relationship between components of social problem-solving ability and both self-efficacy and risk-taking. Journal of the College of Education - Ain Shams University, ٢٥ (١), ١٢١-١٧٨.

Anirudh Bhardwaj, C., Mishra, M., & Hemalatha, S. (٢٠١٧). An Automated Compatibility Prediction Engine using DISC Theory Based Classification and Neural Networks. ArXiv E-Prints, arXiv:١٧٠٩,٠٠٥٣٩.

Bandura, A. (١٩٧٧). Bandura١٩٧٧PR. Psychological Review, ٨٤(٢), ١٩١–٢١٥.

Bandura, A. (٢٠١٠). Self-Efficacy. The Corsini Encyclopedia of Psychology. https://doi.org/١٠,١٠٠٢/٩٧٨٠٤٧٠٤٧٩٢١٦.CORPSY٠٨٣٦

Barnston, A. G. (١٩٩٢). Correspondence among the correlation, RMSE, and Heidke Forcast Verification Measures; Refinement of the Heidke Score. Notes and Correspondence, Climate Analysis Center, ٧, ٦٩٩–٧٠٩.

Berk, R. (٢٠٠٤). Regression Analysis: A Constructive Critique. SAGE Publications, Inc. https://doi.org/١٠,٤١٣٥/٩٧٨١٤٨٣٣٤٨٨٣٤

Buscema, M. (١٩٩٨). Back propagation neural networks. Substance Use and Misuse, ٣٣(٢), ٢٣٣–٢٧٠. https://doi.org/١٠,٣١٠٩/١٠٨٢٦٠٨٩٨٠٩١١٥٨٦٣

Cheng, Y. H., Tsai, C. C., & Liang, J. C. (٢٠١٩). Academic hardiness and academic self-efficacy in graduate studies. Higher Education Research and Development, ٣٨(٥), ٩٠٧–٩٢١. https://doi.org/١٠,١٠٨٠/٠٧٢٩٤٣٦٠,٢٠١٩,١٦١٢٨٥٨

Chernick, M. R., & Friis, R. H. (٢٠٠٣). Correlation, Linear Regression, and Logistic Regression. In Introductory Biostatistics for the Health Sciences. https://doi.org/١٠,١٠٠٢/٠٤٧١٤٥٨٧١٦.ch١٢

Cook, R. D., & Weisberg, S. (١٩٨٢). Criticism and Influence Analysis in Regression. Sociological Methodology, ١٣, ٣١٣–٣٦١. https://doi.org/١٠,٢٣٠٧/٢٧٠٧٢٤

Crowley, B. J., Hayslip, B., & Hobdy, J. (٢٠٠٣). Psychological Hardiness and Adjustment to Life Events in Adulthood. Journal of Adult Development, ١٠(٤), ٢٣٧–٢٤٨. https://doi.org/١٠,١٠٢٣/A:١٠٢٦٠٠٧٥١٠١٣٤

De Myttenaere, A., Golden, B., Le Grand, B., & Rossi, F. (٢٠١٦). Mean absolute percentage error for regression models. Neurocomputing, ١٩٢, ٣٨–٤٨.

Duarte, V. D. J. (٢٠٢٠). Artificial Neural Network techniques to distinguish children with Fetal Alcohol Spectrum Disorder from psychometric data. Proceedings - International Conference of the Chilean Computer Science Society, SCCC, ٢٠٢٠-November. https://doi.org/١٠,١١٠٩/SCCC٥١٢٢٥,٢٠٢٠,٩٢٨١١٤٧

Fox, J. (٢٠١٦). Applied regression analysis & genealized linear models. In Sage.

Frost, J. (٢٠١٩). Regression Analysis: An Intuitive Guide For Using And Interpreting Linear Models (١st ed.). Jim Frost. statisticsbyjim.com

Freedman, D. (٢٠٠٩). Statistical models : theory and practice. Cambridge University Press.

Gavrilescu, M., & Vizireanu, N. (٢٠١٧). Predicting the Sixteen Personality Factors (١٦PF) of an individual by analyzing facial features. Eurasip Journal on Image and Video Processing, ٢٠١٧(١). https://doi.org/١٠,١١٨٦/s١٣٦٤٠-٠١٧-٠٢١١-٤

Gavrilescu, M., & Vizireanu, N. (٢٠١٨). Predicting the Big Five personality traits from handwriting. Eurasip Journal on Image and Video Processing, ٢٠١٨(١). https://doi.org/١٠,١١٨٦/s١٣٦٤٠-٠١٨-٠٢٩٧-٣

Gavrilescu, M., & Vizireanu, N. (٢٠١٩). Predicting depression, anxiety, and stress levels from videos using the facial action coding system. In Sensors (Switzerland) (Vol. ١٩, Issue ١٧). https://doi.org/١٠,٣٣٩٠/s١٩١٧٣٦٩٣

Gray, G., Mcguinness, C., Owende, P., & Carthy, A. (٢٠١٤). A Review of Psychometric Data Analysis and Applications. In Journal of Learning Analytics (Vol. ١, Issue ١).

Grządzielewska, M. (٢٠٢١). Using Machine Learning in Burnout Prediction: A Survey. In Child and Adolescent Social Work Journal (Vol. ٣٨, Issue ٢, pp. ١٧٥–١٨٠). Springer. https://doi.org/١٠,١٠٠٧/s١٠٥٦٠-٠٢٠-٠٠٧٣٣-w

Guerriere, M. R. J., & Detsky, A. S. (١٩٩١). Neural Networks: what Are They?.Pdf. Annals of Internal Medicine, ١١٥(١١), ٩٠٦–٩٠٧.

Hinton, G. E. (١٩٩٢). How Neural Networks Learn from Experience Networks of artificial neurons can learn to represent complicated information. Such neural networks may prOvide inSi g hts into the learnin g abilities of the human brain. SClENTIFIC AMERICAN.

Huang, X., Zhang, Y., Xu, A., Kawabayashi, H., & Chen, Y.-W. (٢٠١٣). Application of interactive evolutionary computation to emotional perception assessment of patients with social anxiety disorder. Information (Japan), ١٦, ٣٤٣–٣٥٢.

Hu, P. (٢٠١٠). Identification of Psychological Patterns Using Neural Identification of Psychological Patterns Using Neural Networks Approach. https://digitalcommons.unl.edu/elecengtheseshttps://digitalcommons.unl.edu /elecengtheses/١١

Jat, D. S., Dhaka, P., & Limbo, A. (٢٠١٨). Applications of statistical techniques and artificial neural networks: A review. Journal of Statistics and Management Systems, ٢١(٤), ٦٣٩–٦٤٥. https://doi.org/١٠,١٠٨٠/٠٩٧٢٠٥١٠,٢٠١٨,١٤٧٥٠٧٣

Karanika-Murray, M., & Cox, T. (٢٠١٠). The use of artificial neural networks and multiple linear regression in modelling work-health relationships: Translating theory

into analytical practice. European Journal of Work and Organizational Psychology, ١٩(٤), ٤٦١–٤٨٦. https://doi.org/١٠,١٠٨٠/١٣٥٩٤٣٢٠٩٠٢٩٩٥٩١٦

Kheirollahpour, M. M., Danaee, M. M., Merican, A. F. A. F., & Shariff, A. A. A. A. (٢٠٢٠). Prediction of the Influential Factors on Eating Behaviors: A Hybrid Model of Structural Equation Modelling-Artificial Neural Networks. Scientific World Journal, ٢٠٢٠. https://doi.org/١٠,١١٥٥/٢٠٢٠/٤١٩٤٢٩٣

Kobasa, S. C. (١٩٧٩). Stressful life events, personality, and health: An inquiry into hardiness. In Journal of Personality and Social Psychology (Vol. ٣٧, Issue ١, pp. ١–١١). American Psychological Association. https://doi.org/١٠,١٠٣٧/٠٠٢٢-٣٥١٤,٣٧,١,١

Koutsomanis, D. (٢٠١٤). Artificial intelligence for ethology: Neural networks in the prediction of human behavior. Proceedings - UKSim-AMSS ١٦th International Conference on Computer Modelling and Simulation, UKSim ٢٠١٤, ٣٢–٣٥. https://doi.org/١٠,١١٠٩/UKSim.٢٠١٤,١٠٦

Lecun, Y., Bengio, Y., & Hinton, G. (٢٠١٥). Deep learning. Nature, ٥٢١(٧٥٥٣), ٤٣٦–٤٤٤. https://doi.org/١٠,١٠٣٨/nature١٤٥٣٩

Lee, E. N. (١٩٩١). [The relationship between and hardiness and psychosocial adjustment of persons with colostomies]. Kanho Hakhoe Chi [The Journal of Nurses Academic Society], ٢١(٢), ٢١٨–٢٢٩. https://doi.org/١٠,٤٠٤٠/JNAS.١٩٩١,٢١,٢,٢١٨

Maddi, S. R. (٢٠٠٤). Hardiness: An Operationalization of Existential Courage. Journal of Humanistic Psychology, ٤٤(٣), ٢٧٩–٢٩٨. https://doi.org/١٠,١١٧٧/٠٠٢٢١٦٧٨٠٤٢٦٦١٠١

Mihaela Rus, Mihaela Luminita Sandu, Senouci Boumediene, Tănase Tasențe, & Djellouli Zineb. (٢٠٢٠). Self competence and psychological hardiness: self-efficacy as Moderator. Technium Social Sciences Journal, ١٣, ٢٣٥–٢٤٣. https://doi.org/١٠,٤٧٥٧٧/TSSJ.V١٣I١,١٩٣٦

Mukhaimer, I. (٢٠٠٢). Psychological hardiness questionnaire. The Egyptian Nahda Library.

Orr, E., & Westman, M. (١٩٩٠). Does hardiness moderate stress, and how? A review. In Learned resourcefulness: On coping skills, self-control, and adaptive behavior. (pp. ٦٤–٩٤). Springer Publishing Co.

Orrù, G., Monaro, M., Conversano, C., Gemignani, A., & Sartori, G. (٢٠٢٠). Machine learning in psychometrics and psychological research. Frontiers in Psychology, ١٠(January), ١–١٠. https://doi.org/١٠,٣٣٨٩/fpsyg.٢٠١٩,٠٢٩٧٠

Pourshahriar, H. (٢٠١٢). Correct vs. accurate prediction: A comparison between prediction power of artificial neural networks and logistic regression in psychological researches. Procedia - Social and Behavioral Sciences, ٣٢(٢٠١١), ٩٧–١٠٣. https://doi.org/١٠,١٠١٦/j.sbspro.٢٠١٢,٠١,٠١٧

Pukelis, L., & Stančiauskas, V. (٢٠١٩). The opportunities and limitations of using artificial neural networks in social science research. Politologija, ٩٤(٢), ٥٦–٨٠. https://doi.org/١٠,١٥٣٨٨/Polit.٢٠١٩,٩٤,٢

Qorbanpoor Lafmejani, A., Fayyaz, B., Rezaei, S., Ramzani, S., & Professor, A. (٢٠١٩). Structural Model of the Effects of Psychological Hardiness and Self-esteem on Students' Psychological Empowerment: Mediating Role of Academic Self-Concept. Quarterly Journal of Child Mental Health, ٦(٢), ١٦٨–١٧٩. https://doi.org/١٠,٢٩٢٥٢/JCMH.٦,٢,١٥

Ritter, S., Barrett, D. G. T., Santoro, A., & Botvinick, M. M. (٢٠١٧). Cognitive psychology for deep neural networks: A shape bias case study. ٣٤th International Conference on Machine Learning, ICML ٢٠١٧, ٦, ٤٥١٠–٤٥١٩.

Serretti, A., & Smeraldi, E. (٢٠٠٤a). Neural network analysis in pharmacogenetics of mood disorders. BMC Medical Genetics, ٥, ١–٦. https://doi.org/١٠,١١٨٦/١٤٧١-٢٣٥٠-٥-٢٧

Serretti, A., & Smeraldi, E. (٢٠٠٤b). Neural network analysis in pharmacogenetics of mood disorders. BMC Medical Genetics, ٥. https://doi.org/١٠,١١٨٦/١٤٧١-٢٣٥٠-٥-٢٧

Song, C., Ogata, Y., & He, J. (٢٠١٨). A study of the psychological resilience of the elderlybased on the Artificial Neural Network. ٢nd IEEE Advanced Information Management, Communicates, Electronic and Automation Control Conference (IMCEC), ٢١١٩–٢١٢٣.

St-Pierre, N. R. (٢٠١٦). Comparison of model predictions with measurements: A novel model-assessment method. Journal of Dairy Science, ٩٩(٦), ٤٩٠٧–٤٩٢٧. https://doi.org/١٠,٣١٦٨/jds.٢٠١٥-١٠٠٣٢

Takagi, H. (٢٠٠١). Interactive evolutionary computation: fusion of the capabilities of EC optimization and human evaluation. Proceedings of the IEEE, ٨٩(٩), ١٢٧٥–١٢٩٦. https://doi.org/١٠,١١٠٩/٥,٩٤٩٤٨٥

Tey, S. F., Liu, C. F., Chien, T. W., Hsu, C. W., Chan, K. C., Chen, C. J., Cheng, T. J., & Wu, W. S. (٢٠٢١). Predicting the ١٤-day hospital readmission of patients with pneumonia using artificial neural networks (Ann). International Journal of Environmental Research and Public Health, ١٨(١٠). https://doi.org/١٠,٣٣٩٠/ijerph١٨١٠٥١١٠

Tu, J. V. (١٩٩٦). Advantages and disadvantages of using artificial neural networks versus logistic regression for predicting medical outcomes. Journal of Clinical Epidemiology, ٤٩(١١), ١٢٢٥–١٢٣١. https://doi.org/١٠,١٠١٦/S٠٨٩٥-٤٣٥٦(٩٦)٠٠٠٠٢-٩

Urban, C. J., & Gates, K. M. (٢٠٢١). Deep learning: A primer for psychologists. Psychological Methods, ١–٤٧. https://doi.org/١٠,١٠٣٧/met٠٠٠٠٣٧٤

VandenBos, & Gary, R. (٢٠٠٧). APA Dictionary of Psychology. In G. R. VandenBos (Ed.), APA Dictionary of Psychology. (pp. xvi, ١٠٢٤–xvi, ١٠٢٤). American Psychological Association.

Winastwan, R. (٢٠٢١). Collinearity in regression model. https://towardsdatascience.com/collinearity-in-regression-model-٢٠ba١e٢٥٩caa

Wu, Y. chen, & Feng, J. wen. (٢٠١٨). Development and Application of Artificial Neural Network. Wireless Personal Communications, ١٠٢(٢), ١٦٤٥–١٦٥٦. https://doi.org/١٠,١٠٠٧/s١١٢٧٧-٠١٧-٥٢٢٤-x

Yarkoni, T., & Westfall, J. (٢٠١٧). Choosing prediction over explanation in psychology: Lessons from machine learning. Physiology & Behavior, ١٧٦(١), ١٠٠–١٠٦. https://doi.org/١٠,١١٧٧/١٧٤٥٦٩١٦١٧٦٩٣٣٩٣.