



**Tikrit Journal of Administrative
and Economics Sciences**
مجلة تكريت للعلوم الإدارية والاقتصادية

EISSN: 3006-9149

PISSN: 1813-1719



**The Use of Artificial Intelligence Applications (Artificial Neural
Networks) in Analyzing Factors Influencing Employee Satisfaction and
Their Impact on Work Sustainability**

**Mona Saleh Tawhariya^{*A}, Moudher Kh Abdal-Hameed^B
Shadi Ismail Al-Talbani^C**

^A College of Law and Political Science/University of Bordj Bou Arreridj-Algeria

^B College of Administration and Economics/Tikrit University

^C College of Management and Economics/Al-Azhar University - Gaza

Keywords:

Institutional work sustainability, employee satisfaction, artificial intelligence, neural networks, Kaggle web-site, operations research.

Article history:

Received 15 Dec. 2024

Accepted 10 Jan. 2025

Available online 25 Jun. 2025

©2023 College of Administration and Economy, Tikrit University. THIS IS AN OPEN ACCESS ARTICLE UNDER THE CC BY LICENSE

<http://creativecommons.org/licenses/by/4.0/>



***Corresponding author:**

Mona Saleh Tawhariya

College of Law and Political
Science/University of Bordj Bou Arreridj-
Algeria



Abstract: In a world characterized by sustainable technological advancement, the use of artificial intelligence applications, particularly modern operational research methods such as neural networks, stands out as a key tool for improving modeling and forecasting. This study presents a modern approach to examining the issue of employee satisfaction and its impact on work sustainability within organizations. The aim of this research is to explore the potential of employing one of these applications to measure and analyze employee satisfaction indicators, assess its role in improving the work environment, enhance institutional performance, and gauge its impact on workforce sustainability within organizations. The study seeks to understand the factors influencing employee satisfaction, such as the work environment, incentive policies, and peer interaction, and their role in strengthening employees' desire to stay and continue working. To achieve its objective, the study employs a neural network model to analyze data related to employee behavior and satisfaction levels, offering in-depth insights that enable predictions about potential trends in workforce sustainability based on their behavior, such as remaining in or leaving their jobs. The research adopts an analytical and experimental approach to answer the study's questions by analyzing datasets from organizations published on the Kaggle platform, utilizing neural networks as one of the AI techniques. The results are encouraging and can serve as a roadmap for ensuring work sustainability within organizations. The researchers concluded with valuable recommendations to support institutional work sustainability.

استخدام تطبيقات الذكاء الاصطناعي (الشبكات العصبية الاصطناعية) في تحليل العوامل المؤثرة على رضا العاملين وانعكاساتها على استدامة العمل

منى صالح طواهرية	مظهر خالد عبد الحميد	شادي اسماعيل التلبناني
كلية الحقوق والعلوم السياسية	كلية الإدارة والاقتصاد	كلية الإدارة والاقتصاد
جامعة برج بوعريش-الجزائر	جامعة تكريت-العراق	جامعة الأزهر – غزة

المستخلص

في عالم اتسم بالتطور التكنولوجي المستمر، يعد استخدام تطبيقات الذكاء الاصطناعي، خاصة ما يتعلق بأحد أساليب بحوث العمليات الحديثة كـ (الشبكات العصبية) كأبرز أدوات التي تستخدم لتحسين النمذجة والتوقعات، مدخلا حديثا لدراسة إشكالية رضا العاملين، وأثره على استدامة العمل في المؤسسات. جاءت هذه الدراسة للوقوف على امكانية توظيف أحد تلك التطبيقات بهدف استكشاف استخدام أدوات الذكاء الاصطناعي في قياس وتحليل مؤشرات رضا العاملين، ومدى مساهمتها في تحسين بيئة العمل وتعزيز الأداء المؤسسي، وقياس تأثيره على استدامة عمل القوى العاملة داخل المؤسسات، بما يمكن من فهم العوامل المؤثرة على رضاهم، مثل بيئة العمل، وسياسات التحفيز، والتفاعل بين الزملاء، ودورها في تعزيز رغبتهم في البقاء واستمرارهم في العمل. لتحقيق هدف الدراسة تم توظيف أحد نماذج الشبكات العصبية لتحليل البيانات المتعلقة بسلوك العاملين ومستويات رضاهم، لتقديم رؤى معمقة حول ذلك، بما يمكننا من التنبؤ بالاتجاهات المحتملة لاستدامة العمل بناءً على سلوكهم، كـ (استمرارهم في العمل أو تركه). اعتمد البحث على أسلوب تحليلي وتجريبي، للتوصل للإجابة عن أسئلة الدراسة بعد تحليل مجموعة البيانات المحصل عليها لمؤسسات منشوره على موقع كاجل، باستخدام (الشبكات العصبية) كأحد تقنيات الذكاء الاصطناعي، وتم التوصل إلى نتائج مشجعة يمكن عدها كخارطة طريق لاستدامة العمل في المؤسسات، وخرج الباحثون بتوصيات قيمة تدعم استدامة العمل المؤسسي.

الكلمات المفتاحية: استدامة العمل المؤسسي، رضا العاملين، الذكاء الاصطناعي، الشبكات العصبية، موقع كاجل، بحوث العمليات.

المقدمة

أخذت ملامح المجتمعات الحديثة تتغير مع فجر الألفية الثالثة، بعد أن أدى التطور التكنولوجي والمعلوماتي، إلى ايجاد عالم مختلف بوتيرة لم يسبق لها مثيل، فقد ساهمت الثورة الصناعية الرابعة التي دعمها التحول الرقمي في حدوث تقارب ابداعي بين مجموعة كبيرة من التكنولوجيات جمعت بين تسريع الأتمتة، اختصار الوقت في الابتكارات الحديثة، التقارب في الوجودين الفعلي والرقمي، التوصيلة في كل مكان، كـ رغبة في محاكاة الذكاء الإنساني، فنتج عنها ما يعرف بالذكاء الاصطناعي. وتستخدم اليوم التكنولوجيات الرقمية، من قبيل تجميع البيانات والذكاء الاصطناعي، لنتبع المشكلات وتشخيصها في مختلف المجالات كالزراعة والصحة والبيئة، وحتى في إدارة الموارد البشرية بالمؤسسات التي تتوافر لديها بشكل متزايد الأدوات اللازمة حول مواردها البشرية واستغلالها في إدارة هذا المورد، حيث أصبحت تعتمد الشبكات العصبية الاصطناعية كإحدى أدوات الذكاء الاصطناعي في قياس وتحليل مؤشرات رضا العاملين، ومدى مساهمتها في تحسين بيئة العمل وتعزيز الأداء المؤسسي، وقياس تأثيره على استدامة عمل القوى العاملة داخل المؤسسات، وذلك من

خلال تحليل البيانات المتعلقة بسلوك العاملين ومستويات رضاهم، ومن ثمة التنبؤ بالاتجاهات المحتملة لاستدامة العمل بناءً على سلوكهم، كاستمرارهم في العمل أو تركه، وهو ما تسعى هذه الدراسة للكشف عنه من خلال اعتماد الشبكات العصبية الاصطناعية في قياس مدى رضا العاملين وأثره على استدامتهم في العمل أو تركه. كان هناك دافعا نبع من أهمية الموضوع في تشخيص استخدام تقنيات الذكاء الصناعي وخاصة استخدام الشبكات العصبية، وخاصة في موضوع الموارد البشرية، وبمساهمة علمية برزت استخدام التقنيات المتقدمة الحديثة كبعض اليات الذكاء الصناعي في هذا الجانب الحيوي من إدارة المنظمات.

الأدبيات السابقة: تعد الشبكات العصبية من تقنيات الذكاء الاصطناعي الحديثة التي تستخدم في تحليل البيانات الضخمة، وهي أسلوب لا معلمي يتجاوز بعض المعايير الإحصائية التقليدية، ولا يعتمد بشكل كبير على اختبار الفرضيات. لقد أثبتت الشبكات العصبية دورها البارز في التنبؤ، إذ استخدمها الباحثون في التنبؤ بمخرجات مشكلات متنوعة، مثل معدل دوران الموظفين في المؤسسات الكبيرة. على سبيل المثال، في دراسة ترأسها "كوين" ، تم مقارنة نموذج الانحدار اللوجستي بالشبكات العصبية في التنبؤ بدوران الموظفين، مما أسفر عن نتائج مشجعة وأدى إلى تقديم إرشادات حول قوة هذه الأساليب وتقييمها وتفسيرها (Quinn, et al., 2002: 67)، أما فريق (Wang) فاستخدم الشبكات العصبية بطريقة مبتكرة من خلال دمج مصنفات متعددة، مما خلق نهجا لشبكة اختيار ديناميكية وشبكة أخرى تعمل كمجمع نهائي. تم تأكيد فعالية هذا النهج باستخدام بيانات تم جمعها من نظام اتصالات كبير تديره برامج متقدمة في شركة لوسنت تكنولوجي. أظهرت النتائج أن الشبكة المدمجة تفوقت على أنظمة الدمج الكلاسيكية، وإن شبكة الاختيار الديناميكي حسنت بشكل ملحوظ أداء النظام المقترح مقارنة بالأساليب الأنفة الذكر (Wang, et al., 2005: 922)، كما وظف فريق (Mohanty) البحثي طريقة لمعالجة مجموعة البيانات، وركزوا في منهجيتهم على خوارزمية طريقة التنظيم الذاتي الاستدلالي لبناء علاقة الإدخال والإخراج لنظام كبير ومعقد باستخدام بنية الإدراك متعدد الطبقات الشبيهة بالشبكة العصبية متعددة الطبقات ذات التغذية الأمامية بهدف التأكد من موثوقية البرمجيات الحديثة. (Mohanty, et al., 2009: 15)، في حين استخدم عام 2013 الفريق البحثي لـ (Girela) بعض استخدامات تقنيات الذكاء الاصطناعي، وخاصة الشبكات العصبية الاصطناعية، في مختلف المجالات ومنها المجال الحياتي للتنبؤ بمعايير الخصوبة استناداً إلى العوامل البيئية التي يتعرض لها الفرد، ونمط الحياة التي يعيشها، وهذا يشير إلى الأهمية الكبيرة لموضوع الشبكات العصبية في حل المشاكل لمختلف الظواهر الحياتية (Girela et al., 2013: 101)

بينما في عام 2016 طبق (Bilal) أساليب التنقيب عن البيانات لاكتشاف الأنماط لتعزيز المعرفة، باستخدام الشبكات العصبية، فتم بناء النموذج بهدف التنبؤ بفقدان العملاء في صناعة البنوك باستخدام بيانات لأحد البنوك الإلكترونية الصغيرة لإنشاء نموذج لفقدان العملاء، بفرضية مفادها أن العملاء الأكثر ولاءً هم من يستخدم المزيد من الخدمات المصرفية، وعلى البنك أن يركز عليهم، وأن يتم تقديم خدماتهم وفقاً لاحتياجاتهم (Bilal, 2016: 117)، كما قام (Maire, 2016: 174) بتدريب شبكة عصبية تلافيفية بهدف التنبؤ بالعلاقات الثنائية بهدف تجزئة وتنظيم الشكل (و/أو) الخلفية للصور، فيما استخدم (Jhaver, 2019: 20) تقنية تحسين التدرج بهدف تطوير نظام للتنبؤ بدوران الموظفين، الغرض منه مساعدة المنظمات في الاحتفاظ بالموظفين القيمين ذوي الخبرات المكتسبة في العمل لديها.

وفي عام 2018 استخدم فريق (Pérez-Campdesuñeret) تحليل الشبكات العصبية بنهج مختلف في بعض الاطر العامة، فقاموا بتحديد المتغيرات الداخلية التي تؤثر على دوران الموظفين بتوظيف تحليل قواعد البيانات بهدف تقييم إمكانيات الشبكات العصبية في استكشاف التأثير المحتمل لدور المتغيرات الموضوعية المتاحة فيها. بحيث يتمكن متخذي القرار من معرفة هذه العلاقة الكامنة وتصميم استراتيجيات، تهدف إلى تقليل احتمالية الآثار السلبية المترتبة على تبادل الادوار (Pérez-Campdesuñeret, et al., 2018: 2)

أهمية الدراسة: أدى التحول الرقمي الهائل إلى إدخال تقنيات الذكاء الاصطناعي ضمن المؤسسات، فبعد أن كانت تعتمد الأدوات التقليدية في إدارة وتسيير وظائف إدارة الموارد البشرية للمؤسسة، أصبحت اليوم تستخدم أدوات الذكاء الاصطناعي ومنها الشبكات العصبية في تحليل البيانات المتعلقة بالقوى العاملة، على نحو يساهم في إيجاد بيئة عمل مرضية للعاملين تقلل من معدل تركهم للعمل.

أهداف الدراسة: تسعى الدراسة لتحقيق الأهداف الآتية:

- ❖ دراسة مدى تأثير مستويات الرضا الوظيفي على قرارات الموظفين بمغادرة وظائفهم.
- ❖ الربط بين متغيرات الدراسة وعوامل ترك العمل
- ❖ تطوير نموذج حديث يعتمد على الشبكات العصبية الاصطناعية لتحليل العلاقة بين مستويات الرضا الوظيفي ونوايا ترك العمل بالمنظمات.
- ❖ إثراء المكتبة العربية بمثل هذه الدراسات وحث الباحثين على التطرق لمثل هذه المشكلات وإيجاد حلول لها.

مشكلة الدراسة: تواجه المؤسسات تحديات متزايدة في الحفاظ على كوادرها الوظيفية بسبب ارتفاع معدلات ترك العمل، وهو ما يشكل تهديداً للاستقرار المؤسسي والإنتاجية. يعد في ذلك الرضا الوظيفي من أبرز العوامل المؤثرة على بقاء الموظفين، حيث يرتبط بمستوى الارتباط العاطفي والتنظيمي الذي يشعر به الموظف تجاه عمله، وهو ما دفعنا للبحث في الموضوع من خلال طرح السؤال الآتي: هل يؤثر رضا العاملين على ترك العمل بالمنظمات؟

فرضية الدراسة: لا تؤثر متغيرات الدراسة على ترك العمل

منهجية الدراسة: تعتمد الدراسة على المنهج التحليلي التجريبي المناسب لهذا الموضوع، وذلك من خلال استخدام الشبكات العصبية كأداة في تحليل بيانات (15000) موظفا يعملون في إحدى المؤسسات من موقع كاجل، ومن ثم قياس مدى رضا العاملين اعتمادا على عدة عوامل مثل الراتب، الترقيات، المبيعات وحوادث العمل، والتي مثلت متغيرات يمكن من خلالها التنبؤ باستمرارية الموظفين في العمل أو تركه.


سوف يتم دراسة الموضوع وفق السياق الآتي:

أولاً. الذكاء الاصطناعي في العصر الرقمي الحديث: يعد الذكاء الاصطناعي (Artificial Intelligence) من أهم مخرجات الثورة الصناعية الرابعة، حيث يشير إلى: "قدرة كمبيوتر أو روبوت مدعم بكمبيوتر على معالجة المعلومات والوصول إلى نتائج بطريقة مماثلة لعملية التفكير لدى البشر في التعلم واتخاذ القرارات وحل المشاكل، فهو بذلك محاكاة عمليات الذكاء البشري بواسطة الآلات والبرمجيات، وخاصة أنظمة الكمبيوتر". (Smith, Shum, 2018: 34)، ومن ثم فإن هدف أنظمة الذكاء الاصطناعي هو تطوير أنظمة قادرة على معالجة المشاكل المعقدة بطرق مشابهة للعمليات المنطقية والاستدلال عند البشر، إذ يعمل الذكاء الاصطناعي على عمل برامج


للحاسب الآلي قدرة على محاكاة السلوك الانساني المتمسم بالذكاء، فتكون قادرة على حل مشكلة أو اتخاذ قرار بناء على العمليات الاستدلالية التي غذي بها البرنامج.

تعد الشبكات العصبية (Artificial Neural Networks) تقنية ذكاء اصطناعي مستوحاة من عمل الدماغ البشري، تُستخدم لتحليل البيانات واستخلاص الأنماط والتنبؤ بالمستقبل. تعتمد على نماذج رياضية تساعد في اتخاذ القرارات، ويتم تدريبها باستخدام كميات كبيرة من البيانات، مما يمكنها من التعلم من الأخطاء وتحسين أدائها تدريجياً.

يحاكي نموذج الشبكة العصبية الدماغ البشري بأسلوب يتناول المعلومات لحل المشاكل المعقدة ذات الأبعاد العالية، بشكل عام يتركب هيكلها من خلايا عصبية متوالية على شكل طبقات متصلة عبر اوزان. الأخير ينقل المعلومات التي تقوم الخلايا بتصنيفها ونقلها لبناء النموذج التنبؤي كما يوضح الشكل رقم (1) نموذج يحاكي واقع الشبكات العصبية الاصطناعية بتشبيهاها بخلية الشبكة العصبية لكائن بشري (Krenker & Kos, 2011: 5).



شكل (1): أ-نموذج تصميم الخلايا العصبية، ب-نموذج تصميم الخلايا العصبية الاصطناعية
يتضمن نموذج الشبكة العصبية الأساسي ثلاث طبقات، طبقة الإدخال: تحتوي على عدد من الخلايا يتناسب مع عدد المتغيرات المستقلة (الخصائص) التي نرغب في معالجتها. ترتبط خلايا هذه الطبقة بخلايا الطبقة التالية عبر وصلات بأوزان تحدد تأثير كل مدخل، ولا توجد وصلات بين خلايا طبقة الإدخال نفسها. وطبقة مخفية مزودة بخلايا خفية متعددة يتم فيها معالجة البيانات (المعلومات) الواردة من طبقة الإدخال عن طريق وصلات (Nadwa. & Ezza, 2010: 7) (الأوزان) الموصوفة بشكل رقم (1-أ) تربط كل خلية منها بالخلايا طبقة الادخال تقوم بدور تدفق المعلومات، التي تضم دالة التنشيط: يكون دورها تحديد ما إذا كان ينبغي تنشيط الخلية العصبية بناءً على المدخلات الواصلة إليها من طبقة الادخال. وتنتج طبقة الإخراج نتائج كتصنيفات أو قيم مستمرة، حيث تقوم بضرب القيم الواردة من طبقة الإدخال بأوزان محددة، ثم يتم تجميعها لإنتاج رقم يُمرر إلى دالة رياضية غير خطية (تُعرف بدالة التنشيط)، التي تُرجع قيمة بين (0 و 1) (Zacharis, 2016: 19).



شكل (2): 1- هيكل الشبكة العصبية، ب-خلية (عقدة) التنشيط

المرحلة الاولى (التدريب): مرحلة التدريب هي الخطوة الأولى في عمل الشبكات العصبية الاصطناعية، وتهدف إلى تعليم النموذج كيفية التنبؤ أو تصنيف البيانات بدقة. تبدأ بإدخال بيانات التدريب، إذ تمر عبر طبقات الشبكة، ويتم حساب التنبؤات من الطبقة النهائية. بعدها تُستخدم دالة الخسارة لقياس الفرق بين التنبؤات والقيم الحقيقية، مما يساعد في تقييم دقة النموذج لتقليل الخطأ وتحسين الأداء، تُحدث الأوزان باستخدام خوارزميات مثل "التدرج المترافق (Gradient Descent)" عبر حساب مشتقات دالة الخسارة (Loss Function)، وهو ما يتيح للنموذج التكيف مع البيانات بشكل أفضل (Krenker & Kos, 2011: 21).

المرحلة الثانية (مرحلة الاختبار) في الشبكات العصبية: يتم تقييم أداء نموذج الشبكة العصبية بعد الانتهاء من التدريب، بهدف قياس قدرة النموذج على التعرف على الأنماط في بيانات جديدة. تبدأ هذه المرحلة بإدخال بيانات مجموعة الاختبار، التي لم تُستخدم في التدريب، ليتم تقييم النموذج من خلالها. بعد ذلك، يتم تمرير البيانات عبر الشبكة للحصول على التنبؤات، وتتم مقارنة هذه التنبؤات مع القيم الحقيقية باستخدام مقاييس متعددة مثل الدقة (Accuracy)، التي تمثل النسبة المئوية للتنبؤات الصحيحة، ومعدل الخطأ (Error Rate)، الذي يمثل النسبة المئوية للتنبؤات الخاطئة، ومؤشرات أخرى كـ (Precision، Recall، F1-score). في حين يتم حساب معادلة الدقة بالصيغة الآتية:

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}$$

حيث ان:

TP: عدد التنبؤات الصحيحة الإيجابية (True Positives).

TN: عدد التنبؤات الصحيحة السلبية (True Negatives).

FP: عدد التنبؤات الخاطئة إيجابية (False Positives).

FN: عدد التنبؤات الخاطئة سلبية (False Negatives) (Krenker & Kos, 2011: 25).

المرحلة الثالثة (الاحتفاظ): تهدف مرحلة الاحتفاظ بالنموذج إلى تسريع عملية التنبؤ النهائية وضمان عدم فقدان المعرفة المكتسبة خلال التدريب. يتم في هذه المرحلة حفظ النموذج المدرب لاستخدامه في المستقبل، إذ تُخزن الأوزان والمعلمات الأخرى لضمان إمكانية إعادة استخدام النموذج دون الحاجة لإعادة تدريبه، مما يوفر الوقت. تبدأ هذه المرحلة بحفظ النموذج في قاعدة بيانات تحتوي على

المعلومات والأوزان، ثم يتم استرجاع النموذج عند الحاجة، مما يتيح تحميله في أي وقت لإجراء التنبؤات. لمزيد من المعلومات انظر (Giovannangeli & Gaussier, 2007: 1028-1033)

ثانياً. الرضا الوظيفي كمدخل لاستدامة العمل

عرّف لوك وهين الرضا الوظيفي بأنه: " حالة عاطفية إيجابية ناتجة عن تحقيق قيم الوظيفة في بيئة العمل، إذ يعكس الرضا الوظيفي تقييم الفرد لوظيفته بناءً على ما تحققه من قيم تتوافق مع احتياجاته، ومن ثمة يمكن عد الرضا حالة عاطفية ناتجة عن المكافآت المرتبطة بالعمل" (Al -Suraihi et al., 2021: 03)، كما عرّف سبيكتور الرضا الوظيفي، بأنه: " الطريقة التي يشعر بها الأفراد تجاه وظائفهم وجوانبها المختلفة، ويعكس مدى إعجابهم أو عدم إعجابهم بعملهم. يمكن أن يظهر الرضا أو عدم الرضا الوظيفي في أي موقف عمل، إذ يمثل مزيجاً من المشاعر الإيجابية أو السلبية التي يحملها الموظفون تجاه عملهم. ويرتبط الرضا الوظيفي ارتباطاً وثيقاً بسلوك الموظف في مكان العمل، وهو يعتمد على مدى تطابق التوقعات مع الجوائز الحقيقية التي يحصل عليها العامل." (Biaison, 2020: 407)، فالرضا الوظيفي بذلك هو موقف الفرد وسلوكه تجاه وظيفته، إذ يعبر عن استجابة عاطفية لجوانب محددة من الوظيفة، وله علاقة مباشرة مع معدل ترك العمل، فعندما يصبح الموظف غير راضٍ عن وظيفته، يصبح تركه للعمل محتملاً. ذلك أن الرضا الوظيفي إنما هو شعور بالاستقرار العاطفي الناتج عن الوظيفة الحالية للموظف أو وظيفته. وبالمقابل يشير ترك العمل إلى ميل الموظف أو استعداده لترك منصبه الحالي داخل المؤسسة، حيث يعرفه تركسون بأنه: " قياس عدد الموظفين الذين يتركون منظمة معينة واستبدالهم. إذ يترك الموظف مكان عمله لمؤسسة أخرى لتولي مهمة جديدة (Mahdi, et al., 2012: 1250)، ويرتبط ترك الموظفين العمل بعدة عوامل، إذ يُعد الرضا الوظيفي العامل الأبرز في تحديد ما إذا كان الموظف سيظل في عمله أو يتركه. ومن هذه العوامل نذكر:

الرواتب: تعد من أهم العوامل المؤثرة، بحيث إذا كانت الأجور غير كافية أو لا تعكس قيمة العمل المبذول، يؤدي ذلك إلى عدم رضا الموظف، خاصة إذا شعر أنه لا يُكافأ بما يتناسب مع مجهوداته. ومن ثمة يبحث الموظف عن وظائف أخرى تقدم له راتباً أفضل (Stamolampros, et al., 2019: 30)

بيئة العمل: تؤدي بيئة العمل غير المريحة، سواء من حيث الأمان، المرافق، أو توافر الأدوات اللازمة للعمل إلى الشعور بعدم الراحة والإحباط. فظروف العمل السيئة مع وجود صراعات بين الزملاء يمكن أن تؤثر بشكل كبير على الرضا الوظيفي. إذ إن سوء التفاعل الاجتماعي داخل الفريق أو غياب الدعم من الزملاء قد يجعل الموظف يشعر بالانعزال أو بعدم الارتياح، مما يزيد من رغبته في مغادرة العمل والانتقال إلى مكان يوفر له بيئة أكثر دعماً وراحة. (Aleem and Khan, 2014: 126)


التقدير: يشعر الموظفون عندما لا يعترف أصحاب العمل بجهودهم بالإحباط وعدم التقدير مما يجعلهم أقل فاعلية ومشاركة في صنع القرار بالمنظمة، ومن ثمة تقليل مستوى إنتاجية الموظف وزيادة رغبته في ترك المؤسسة (Kosha, et al., 2024: 240)

فرص النمو الوظيفي: السعي لتحقيق النمو الوظيفي وزيادة الأجور يدفع الموظفين إلى مغادرة مؤسساتهم إذا لم تتوفر لهم فرص للتطور داخل المنظمة. فالشركات التي تفتقر إلى مسارات وظيفية محددة، حتى وإن كانت تقدم حزم أجور تنافسية، تكون معرضة لفقدان موظفيها، والبحث عن منظمات توفر فرصاً واضحة للنمو. وتحقيق الطموحات (Barnabas, 2018: 14).

تبعاً لما سبق، يرتبط الرضا الوظيفي بنوايا الموظفين في ترك العمل، إذ إن الموظفين الراضين عن وظائفهم يكونون أقل ميلاً للبحث عن فرص بديلة، بينما يميل الموظفون غير الراضين إلى استكشاف خيارات جديدة بحثاً عن عمل أكثر إشباعاً. وهذا يؤدي إلى تكاليف كبيرة للمنظمة، حيث تقدر تكاليف الاستبدال والتدريب بين 1.5 إلى 2.5 ضعف الراتب السنوي للموظف. كما أن توظيف وتدريب موظفين جدد قد يكلف الشركات حوالي 50% إلى 60% من راتب الموظف السنوي، مما يؤثر سلباً على الإنتاجية ويزيد من نفقات المنظمة (Kosha, et al., 2024: 245).

ثالثاً. تحليل متغيرات رضا العاملين باستخدام الشبكات العصبية (الجانب التطبيقي)

البيانات: تم الحصول على بيانات من موقع كأجل تشمل 15,000 موظفاً في إحدى المؤسسات، إذ تم تسجيل أنشطتهم لتقييم رضا الموظفين بناءً على عدة متغيرات مثل عدد المشاريع، ساعات العمل الشهرية، مدة العمل، حوادث العمل، الترقيات في آخر 5 سنوات، المبيعات، والرواتب. يوضح الجدول المرفق مع الشكل رقم (1) الإحصائيات الأولية، إذ تبين أن 11,428 موظفاً لم يغادروا العمل، بنسبة 76.8%، مما يشير إلى الرضا الوظيفي لدى معظم الموظفين. في المقابل، غادر 3,572 موظفاً، بنسبة 23.8%، مما يستدعي من المؤسسة دراسة العوامل المسببة لهذه النسبة واتخاذ الإجراءات المناسبة لتحسين الظروف واحتفاظ الموظفين.



شكل (3): توزيع عينة الدراسة

ليكمل الجدول رقم (1) في أدناه التصور المبدئي لخمس متغيرات تتعلق بالرضا والتقييم، إذ اتضح أن توجه القوى العاملة يميل إلى الاستقرار إلى حد ما للبقاء في المؤسسة، جدول (1): وصف أحصائي لخمس متغيرات تتعلق بالرضا والتقييم

	N	Minimum	Maximum	Mean	Std. Deviation	Skewness		Kurtosis	
	Statistic	Statistic	Statistic	Statistic	Statistic	Statistic	Std. Error	Statistic	Std. Error
مستوى الرضا	15000	.09	1.00	.6128	.24863	-.476-	.020	-.671-	.040
التقييم الأخير	15000	.36	1.00	.7161	.17117	-.027-	.020	-1.239-	.040
عدد المشاريع	15000	2	7	3.80	1.233	.338	.020	-.495-	.040
متوسط ساعات العمل الشهرية	15000	96	310	201.05	49.943	.053	.020	-1.135-	.040
مدة العمل في الشركة	15000	2	10	3.50	1.460	1.853	.020	4.773	.040
Valid N (listwise)	15000								

يعرض الجدول رقم (1) إحصاءات وصفية لمتغيرات عدة رئيسة متعلقة بالرضا الوظيفي، مثل عدد المشاريع، التقييم الأخير، متوسط ساعات العمل الشهري، ومدة العمل في الشركة. أظهرت النتائج تباينا متقاربا بين بيانات الرضا والتقييم مع تقارب في المتوسطات، مما يشير إلى رضا عام إيجابي، خاصة في متغير التقييم الأخير. كما تبين أن بعض المتغيرات مثل عدد المشاريع وساعات العمل ومدة الخدمة كانت منحرفة نحو القيم العليا، مما يعكس تأثيرا إيجابيا على بقاء العدد الأكبر من الموظفين في العمل. أما فيما يخص تشتت البيانات بين المتغيرات فيتطلب تحليلا ميدانيا معمقا لفهم الأسباب وراء هذه الفروقات بغية تقليصها. وقد لخص هذا الجدول نظرة شاملة حول جوانب بعض متغيرات الرضا في بيئة العمل المعنية، مما يساهم في تسهيل مهمة اتخاذ القرارات المستندة إلى البيانات الفعلية.

جدول (2): الارتباط لمتغيرات رئيسية تتعلق بمستوى الرضا الوظيفي

مدة العمل في الشركة	متوسط ساعات العمل الشهرية	عدد المشاريع	التقييم الأخير	مستوى الرضا	
				1	مستوى الرضا
			1	.105**	التقييم الأخير
		1	.349**	-.143**	عدد المشاريع
	1	.417**	.340**	-.020*	متوسط ساعات العمل الشهرية
1	.128**	.197**	.132**	-.101**	مدة العمل في الشركة

يستمر الجدول رقم (2) في اكمال التصور حول الرضا الوظيفي، فهو يعرض الارتباط بين متغيرات الكمية المتعلقة بمستوى الرضا، ويتضح أنها علاقة ارتباط موجبه مع التقييم الأخير وبغض النظر عن قوتها فهي معنويه جدا، وعلاقة عكسية معنوية أيضا مع كل من المتغيرات (عدد المشاريع ومتوسط ساعات العمل ومدة العمل بالشركة)، يتضح من ذلك، أن الأول بحاجة إلى تعزيز والثلاثة الأخير تحتاج الى معالجة في بعض الجوانب المتعلقة بأسلوب العمل في المؤسسة في إشارة إلى أنها بحاجة إلى تحسين غير كثير مما يعني أن المستويات في بعض جوانبها تحتاج إلى إعادة النظر في بعض ظروف العمل.


نتائج الشبكة العصبية (MLP): إن من أهم أهداف هذه الدراسة الكشف عن إمكانية استخدام الشبكة العصبية في مساعدة متخذي القرار في الاحتفاظ بالموظفين ومحاولة التنبؤ بشكل جيد بنتائج البقاء في العمل (ترك العمل أو عدم ترك العمل) للموظفين، من خلال تحليل البيانات التي تم الحصول عليها من العينة، ويمثل الجدول رقم (3) معلومات حول عينة البيانات المستخدمة لبناء نموذج (ANN).

جدول (3) تقسيم عينة البيانات في الشبكة العصبية

		N	Percent
Sample	Training	9167	61.1%
	Testing	3468	23.1%
	Holdout	2365	15.8%
Valid		15000	100.0%
Excluded		0	
Total		15000	

يوضح الجدول رقم (3) عدد بيانات كل عينة في الشبكة العصبية، بينما يبين الشكل رقم (1) هيكل الشبكة العصبية والمتغيرات المستقلة المتمثلة في (9) مدخلات تشمل مستوى الرضا، التقويم الأخير، عدد المشاريع، ساعات العمل الشهرية، مدة العمل في الشركة، حوادث العمل، ترقية في آخر 5 سنوات، المبيعات، والراتب. تم قياس هذه المتغيرات باستخدام الطريقة القياسية لجعلها ذات متوسط صفري وانحراف معياري واحد لتحسين أداء النموذج وضمان تساوي نطاقات المتغيرات. تم اختيار هيكل تلقائي من (8) خلايا عصبية في الطبقة المخفية، بينما كانت المخرجات تحتوي على (2) خلية لتمثيل البقاء في العمل من عدمه. استخدمت دالة التنشيط (دالة الظل الزائد) في الطبقة المخفية لمعالجة البيانات غير الخطية، ودالة (سوفت ماكس) في طبقة الخرج لتحويل المخرجات إلى احتمالات، مع دالة (الانتروبيا المتقاطعة) كدالة خطأ، لتعزيز دقة النموذج وكفاءته.

الشكل رقم (4) مخطط الشبكة العصبية للتنبؤ بالبقاء في العمل يظهر الشكل رقم (4) مخطط الشبكة الذي استخدمه برنامج SPSS للتنبؤ بنتائج البقاء من عدمه في العمل (ترك العمل = 0، عدم ترك العمل = 1) والـ (9) متغيرات المستقلة كعقد الإدخال التسعة والعقد المخفية الـ (8) وعقدتي الإخراج اللتين تمثلان فئات النتائج (ترك العمل = 0، عدم ترك العمل = 1).



جدول (4): ملخص النموذج

Training	Cross Entropy Error	1306.828
	Percent Incorrect Predictions	4.0%
	Stopping Rule Used	1 consecutive step(s) with no decrease in error ^a
	Training Time	0:00:00.34
Testing	Cross Entropy Error	536.084
	Percent Incorrect Predictions	4.1%
Holdout	Percent Incorrect Predictions	4.6%

a. Error computations are based on the **العمل ترك** Dependent Variable: testing sample

وضح الجدول رقم (4) نتائج أداء نموذج الشبكة العصبية بالنسبة لمتغير "ترك العمل" لعينة التدريب، الاختبار، وعينة الاحتفاظ. تشير القيمة (1306.828) لخطأ الانتروبيا المتقاطعة إلى أن النموذج قوي في التنبؤ بالنتائج، لكن النسبة المئوية للخطأ كانت أعلى في عينة الاحتفاظ مقارنة بعينات التدريب والاختبار، مما يعكس قدرة النموذج على التعميم بشكل جيد وتجنب الإفراط في التدريب. كما أظهرت النتائج أن النسبة المئوية للتنبؤات غير الصحيحة كانت منخفضة في التدريب (4.0%) والاختبار (4.1%)، بينما انخفضت إلى 1.6% في عينة الاحتفاظ. تم تنفيذ التعلم مع قاعدة توقف بخطوة واحدة (أي أننا حصلنا على نتائج جيدة دون الحاجة إلى إعادة تقسيم عينات التدريب والاختبار والاحتفاظ، وتوصل للنتائج بوقت قياس أقل من نصف ثانية)، مما أسفر عن وقت تدريب قصير جداً (0:00:00.34). رغم أن هناك فرقاً بسيطاً في دقة النموذج بين التدريب والاختبار، إلا أن الأداء كان جيداً نسبياً. تشير النتائج إلى فعالية النموذج في التعلم السريع، عموماً، كان النموذج ذو أداء فعال وجيد في التنبؤ بمتغير (ترك العمل)، ولكن قد يكون من الجيد استكشاف تحسينات إضافية للتقليل من خطأ الاختبار للحصول على نتائج أكثر دقة.

جدول (5): تقدير اوزان المعلمات

Predictor		Predicted								Output Layer	
		H(1:1)	H(1:2)	H(1:3)	H(1:4)	H(1:5)	H(1:6)	H(1:7)	H(1:8)	[left=0]	[left=1]
Input Layer	(Bias)	-.057-	-1.070-	.474	-.370-	3.001	-2.119-	.061	.439		
	satisfaction_level	.167	-1.328-	.785	.751	-.555-	.737	.899	.481		
	last_evaluation	-.214-	-1.053-	.949	-.494-	.769	.949	.296	.292		
	number_project	.020	.651	-.823-	.632	1.875	1.060	-.020-	-.004-		
	average_monthly_hours	.051	-.281-	.405	-.413-	-.041-	1.419	.913	.094		
	time_spend_company	-.195-	-1.628-	-.080-	-1.657-	1.223	-.454-	-2.959-	-.438-		
	Work_accident	1.168	.154	-.179-	.213	.018	-.043-	-.031-	.041		
	promotion_last_5years	.432	.002	.469	-.093-	-.139-	.040	1.240	-.197-		
	sales	-.180-	-.052-	-.120-	.230	-.093-	.058	-.067-	.074		
	salary	1.124	-.318-	.922	.374	.005	-.091-	.108	-.419-		
Hidden Layer 1	(Bias)									-.347-	-.305-
	H(1:1)									.542	-.064-
	H(1:2)									-1.145-	1.410
	H(1:3)									-1.042-	.699
	H(1:4)									.359	-.777-
	H(1:5)									1.234	-1.670-
	H(1:6)									-1.371-	1.575
	H(1:7)									1.160	-1.843-
	H(1:8)									-.013-	.388


تعكس النتائج في الجدول رقم (5) تأثير المتغيرات المستقلة على مخرجات نموذج الشبكة العصبية، مما يساعد في فهم العوامل التي تؤثر على قرار ترك العمل في المؤسسة. يعكس الجدول تأثير العوامل مثل (مستوى الرضا، عدد المشاريع، متوسط الساعات الشهرية، حوادث العمل، والراتب) بشكل إيجابي على الطبقات المخفية، مما يدل على دورها الكبير في تقليل احتمالية ترك العمل. من ناحية أخرى، يظهر الوزن السالب لمتغيرات مثل (التقييم الأخير، الخدمة في الشركة، والمبيعات) تأثيراً سلبياً، مما يشير إلى أنها تسهم في تقليل فرص ترك العمل. كما تظهر الطبقات المخفية تفاعلات معقدة للأوزان، مع تباين كبير في التأثيرات نتيجة لاختلاف الأوزان وأثر المتغيرات عبر الطبقات.

جدول (6): التصنيف

Sample	Observed	Predicted		
		ترك العمل	لم يترك العمل	Percent Correct
Training	ترك العمل	6878	150	97.9%
	لم يترك العمل	215	1924	89.9%
	Overall Percent	77.4%	22.6%	96.0%
Testing	ترك العمل	2556	58	97.8%
	لم يترك العمل	84	770	90.2%
	Overall Percent	76.1%	23.9%	95.9%


Sample	Observed	Predicted		
		ترك العمل	لم يترك العمل	Percent Correct
Holdout	ترك العمل	1745	42	97.6%
	لم يترك العمل	66	512	88.6%
	Overall Percent	76.6%	23.4%	95.4%
Dependent Variable: ترك العمل				

تشير نتائج الجدول رقم (6) إلى أن النموذج يمتلك قدرة جيدة على التنبؤ بـ(ترك العمل) بدقة مرتفعة في عينتي التدريب والاختبار. في عينة التدريب، حقق النموذج دقة تصنيف تصل إلى 97.9% للحالات التي تركت العمل و89.9% للحالات التي لم تترك العمل، مع دقة عامة بلغت 96%. في عينة الاختبار، كانت دقة التصنيف 97.8% للذين تركوا العمل و90.2% للذين لم يتركوا العمل، بمستوى دقة عام بلغ 95.9%. أما في عينة الاحتفاظ، كانت الدقة 97.6% للذين تركوا العمل و88.6% للذين لم يتركوا العمل، بمستوى دقة عام بلغ 95.4%. تشير هذه النتائج إلى أن النموذج يتمتع بقدرة كبيرة على التنبؤ الدقيق بحالة الموظف الذي سيترك، مما يسهل اتخاذ القرارات المناسبة لتحليل ظروف العمل المؤثرة.



شكل (5): نتائج التصنيف للتنبؤ بترك العمل مقارنةً بالواقع الفعلي

يوضح تحليل الشكل رقم (5) وجود فجوة كبيرة بين نتائج التصنيف للتنبؤ بترك العمل والواقع الفعلي. فيما يخص نسبة ترك العمل والواقع الفعلي، فالنموذج قد مال إلى المبالغة في تقدير نسبة ترك العمل بشكل واضح، إذ فشل النموذج في عكس العوامل الحقيقية المؤثرة في قرار ترك العمل، مما أدى إلى فارق كبير بين التنبؤ والواقع. بالمقابل، كانت النسبة الفعلية لترك العمل أقل بكثير من التوقعات، وهذا يبدو منطقياً لأن هناك عوامل أخرى عديدة قد تؤثر على قرار ترك العمل لم يتم تضمينها في النموذج التنبؤي، غير أن استطاع النموذج التمييز بين حالات ترك العمل وعدم تركه بشكل مقبول. ومن ثم، هناك حاجة ماسة لدراسة العوامل الأخرى المؤثرة على قرار ترك العمل بشكل أعمق وإدراجها في النموذج لتحسين دقة التنبؤات في الدراسات المستقبلية لاحقاً.




شكل (6): أداء التصنيف

يقدم منحنى ROC رؤية أكثر تحديداً للرسم البياني في سياق تحليل وتقييم أداء المتغيرات التنبؤية المختلفة. فيوضح الشكل رقم (6) منحنى ROC كأداة تحليلية تستخدم لتقييم أداء نموذج التصنيف أو التنبؤ بين متغيرين، والذي يمثل رسم بياني للحساسية مقابل الخصوصية، إذ يعرض العلاقة بين معدل (الإيجابيات الحقيقية) الحساسية ومعدل (الإيجابيات الكاذبة). التي تمثل (1- التحديد) المدى من قيم الحساسية للنموذج، إذ يوضح الخط المائل بزاوية 45^0 سيناريو التخمين العشوائي، وكلما ابتعد منحنى النموذج عن هذا الخط، كان التصنيف أكثر دقة. وقد أظهر منحنى ROC لمتغير "ترك العمل" بالخط الأزرق أداء أفضل من "عدم ترك العمل" الذي يظهر بالخط الأحمر، إذ حقق "ترك العمل" مستويات حساسية أعلى مع معدلات إيجابيات كاذبة أقل. تشير المنطقة تحت منحنى ROC (AUC) إلى مقياس لجودة النموذج التنبؤي، وكلما كانت AUC أعلى، كان أداء النموذج أفضل.

شكل (6): يوضح المساحة تحت منحنى ROC

		Area
ترك العمل	ترك العمل	.973
	لم يترك العمل	.973

يوضح الجدول رقم (6) المساحة تحت منحنى ROC. إن قيمتها تشير إلى أنه إذا تم اختيار موظف من فئة الذين تركوا العمل وآخر من فئة الذين لم يتركوا العمل عشوائياً، فهناك احتمال بنسبة (0.973) أن تكون الاحتمالية الزائفة التي ينتبأ بها النموذج للموظف الأول للانتماء إلى فئة ترك العمل أعلى من الاحتمالية الزائفة التي ينتبأ بها النموذج للموظف الثاني للانتماء إلى فئة ترك العمل.




شكل (7): المكاسب التراكمية

يمثل الشكل رقم (7) المكاسب التراكمية لمخرجات نموذج الشبكة العصبية المستخدم لتحليل ظاهرة عدم ترك العمل. يُمثل الرسم البياني الدالة التراكمية (CDF) التي توضح العلاقة بين النسبة المئوية للموظفين والمتغيرات المؤثرة في قرار البقاء في العمل. على سبيل المثال، تشير النقطة (20%، 82%) إلى أنه إذا قامت الشبكة العصبية بتقييم مجموعة بيانات وترتيب الحالات حسب احتمالية ترك العمل، فمن المتوقع أن تحتوي (20%) أو أقل من الحالات على (82%) من جميع حالات ترك العمل. يوضح منحنى المكاسب التراكمية فعالية النموذج، إذ كلما كان المنحنى بعيداً عن الخط الأساسي، زادت المكاسب وأدى ذلك إلى أداء أفضل. يساعد هذا الرسم على فهم التغيرات في معدل ترك العمل وتحديد العوامل الرئيسية المؤثرة في قرار الموظفين، مما يوفر معلومات قيمة لتصميم استراتيجيات إدارة الموارد البشرية في المؤسسة. إن مخططات الرفع ومخططات المكاسب تمثل أدوات بصرية تستخدم لتقييم أداء نماذج التصنيف في الشبكات العصبية. والتي تختلف بشكل عام عن مصفوفة الارتباك التي تقيم النماذج على المستوى الشامل للبيانات، فيكون دورها هو تقييم مخططات المكاسب، أو رفع أداء النموذج في أي جزء من بيانات العينة قيد الدراسة. في الشكل الأيمن، تستخدم مخططات الرفع جزءاً من مجموعة البيانات لتعطي رؤية صريحة للفائدة المتوخاة من استخدام نموذج مقارنة بعدم استخدامه. تُستخدم القيم من مخطط المكاسب لحساب عامل الرفع (أي الفائدة): الرفع عند (82%) لفئة عدم ترك العمل هو $(3.8 = 82\%/20\%)$.

جدول (9): الأهمية النسبية لمتغيرات الدراسة

Independent Variable Importance		
	Importance	Normalized Importance
مستوى الرضا	.168	100.0%
التقييم الأخير	.154	91.5%
تعدد المشاريع	.150	89.2%
متوسط ساعات العمل الشهرية	.158	94.3%
مدة العمل في الشركة	.152	90.5%
حوادث العمل	.040	23.9%
الترقبات في آخر 5 سنوات	.102	61.0%
المبيعات	.014	8.3%
salary	.063	37.5%



الشكل رقم (8) الأهمية النسبية لمتغيرات الدراسة

الشكل رقم (8) يوضح تأثير كل المتغيرات المستقلة التي أدخلت في نموذج الشبكة العصبية الاصطناعية وفيه تم ترتيب تلك المتغيرات حسب أهميتها النسبية والمعدلة. يرافقه الجدول رقم (9) الذي يُسهل تفسير الرسم البياني من حيث أهمية المتغيرات، بمعنى آخر أنهما معا يصفان مدى حساسية النموذج للتغيرات في كل متغير مدخل حسب أهمية التأثير الذي يمثل ذلك المتغير.

الاستنتاجات والتوصيات

أولاً. الاستنتاجات: جاء توظيف الشبكات العصبية الاصطناعية كهدف لتوقع التصنيف والتنبؤ بحالات ترك العمل بناء على مجموعة بيانات مؤسسة نشرت بياناتها على موقع كاجل، حيث تم التركيز على كيفية تأثير العوامل المختلفة مثل بيئة العمل، المكافآت والحوافز، الرواتب، والمسار الوظيفي على قرار الموظفين بالبقاء أو ترك العمل. أظهرت النتائج أن الشبكات العصبية تفوقت على الأساليب التقليدية في دقة التنبؤ، إذ بلغ معدل دقة التصنيف 98.3%. وقد بينت الدراسة أن مؤشرات الرضا الوظيفي ومتوسط ساعات العمل كانت من العوامل الأكثر تأثيراً على قرار الموظفين بالبقاء في العمل. على الرغم من الحاجة إلى تحسين النموذج من خلال تحسين حجم بيانات التدريب والاختبار والاحتفاظ، إلا أن النتائج تدعم فعالية الشبكات العصبية في التنبؤ بحالات ترك العمل. هذا يشير إلى أن الرضا الوظيفي ضروري للاحتفاظ بالموظفين، وتقليل معدلات ترك العمل، فهو مؤشر مهم ليس فقط لتقليل تكاليف ترك الموظفين العمل، أو التكلفة التي تتكبدها الشركة للتوظيف والتدريب، إنما الحاجة للاحتفاظ بالخبرات التي اكتسبها العاملين لسنوات عدة ومعرفتهم بأسرار المؤسسة التي يجب أن يتم الحفاظ عليها وعدم نقلها لمؤسسات أخرى من باب المنافسة، ومن ثم فإن استخدام الشبكات العصبية يساعد في اتخاذ قرارات استراتيجية لتحسين بيئة العمل والاحتفاظ بالموظفين ذوي الخبرة، مما يعزز استدامة العمل ويقلل من تأثيرات تسرب الموظفين.

ثانياً. التوصيات: خرج الباحثون من خلال ما تقدم من نتائج عبر تحليل البيانات باستخدام نموذج الدراسة بمجموعة من التوصيات من أهمها:

1. ينبغي تعزيز دقة النماذج التنبؤية من خلال تحسين نماذج الشبكات العصبية التي تدمج متغيرات سلوكية ونفسية أخرى كالتوازن بين العمل والحياة، الانضباط الانفعالي والانتماء التنظيمي، لمعالجة الفجوة بين التنبؤات والواقع، واعتماد تقنيات موازنة البيانات لتحسين تمثيل حالات ترك العمل نتيجة لمختلف الظروف .
2. الاهتمام بزيادة الرضا الوظيفي عبر تصميم سياسات مرنة للرواتب وفرص الترقية وكل ما يتعلق به من متغيرات أخرى بناءً على تحليل الشبكات العصبية للمتغيرات الأكثر تأثيراً كمستوى الرضا ومتوسط ساعات العمل مع ربط المكافآت بالأداء المؤسسي الفردي من خلال المتابعة المستمرة للإنجازات الحقيقية .
3. الاهتمام تحسين بيئة العمل باستمرار لمعالجة العوامل ذات الارتباط العكسي بالرضا كساعات العمل الطويلة وعدد المشاريع التي تؤثر بشكل مباشر على بيئة العمل، عبر توفير برامج دعم نفسي، وإعادة هندسة المهام، وتعزيز التواصل بين الفرق لتقليل الصراعات الداخلية التي تؤثر على الانجاز لدى الموظفين .
4. التوسع باستثمار الذكاء الاصطناعي من خلال تطوير أنظمة رقابة مبكرة في إدارة الموارد البشرية تعتمد على نماذج الشبكات العصبية بنماذجها المختلفة الأكثر تطوراً للكشف عن الموظفين المعرضين لخطر الترك، وتقديم تدخلات مخصصة كالتحفيز والتدريب أو التعديل الوظيفي وزيادة الاهتمام بنظام الترقية في مواقع العمل .
5. توسيع نطاق الدراسات المتعلقة بإجراء بحوث مماثلة في مختلف القطاعات كالصحة والتعليم ومقارنة تأثير الثقافة المؤسسية على الرضا، مع استخدام خوارزميات تعلم آلي هجينة ومتقدمة لزيادة موثوقية التنبؤات التي تساهم في حل مشاكل نظام العمل في تلك القطاعات.

المصادر

1. Al-Suraihi.W.A , Samikon.S.A, Al-Suraihi.A.A, and Ibrahim.I.(2021). Employee Turnover: Causes, Importance and Retention Strategies, European Journal of Business and Management Research, 6(03).
2. Al-Tilbany, S. I., & Abd-AlHameed, M. K. (2021). for Time Series Forecasting (MLP, ELM, SVM) Using Nonlinear Methods (Case Study). AL-Anbar University journal of Economic and Administration Sciences, 13(1).
3. Barnabas.S.S.(2018). Job Satisfaction And Employee Turnover In Organizations, International Journal Of Advanced Academic Research.4(11).
4. Biason.R.S.(2020). The effect of job satisfaction on employee retention, International Journal of Economics, Commerce and Management ,8(03).
5. Bilal Zorić, A. (2016). Predicting customer churn in banking industry using neural networks. Interdisciplinary Description of Complex Systems: INDECS, 14(2), 116-124.
6. Giovannangeli, C., & Gaussier, P. (2007, August). Human-robot interactions as a cognitive catalyst for the learning of behavioral attractors. In RO-MAN 2007-The 16th IEEE International Symposium on Robot and Human Interactive Communication (pp. 1028-1033). IEEE

7. Girela, J. L., Gil, D., Johnsson, M., Gomez-Torres, M. J., & De Juan, J. (2013). Semen parameters can be predicted from environmental factors and lifestyle using artificial intelligence methods. *Biology of reproduction*, 88(4), 99-1.
8. Jhaver, M., Gupta, Y., & Mishra, A. K. (2019, November). Employee turnover prediction system. In 2019 4th International Conference on Information Systems and Computer Networks (ISCON) (pp. 391-394). IEEE.
9. Khan.A.H, Aleem.M.(2014). Impact of job satisfaction on employee turnover:An empirical study of Autonomous Medical Institutions of Pakistan, *Journal of International Studies*, 7(01).
10. Kosha.A. K, Almadni.N. F, Rajkhan.D.M.(2024). Job Satisfaction and Employees' Turnover Intentions (An Empirical Study of Universities in Saudi Arabia), *International Journal of Research and Studies Publishing*, 15(56)
11. Krenker, A., Bešter, J., & Kos, A. (2011). Introduction to the artificial neural networks. *Artificial Neural Networks: Methodological Advances and Biomedical Applications*. InTech, 1-18.
12. Mahdi.A. F, Mohd Zin.M. Z, Mohd Nor.M. R, Sakat.A. A and Naim.A. S.(2012). The Relationship Between Job Satisfaction and Turnover Intention, *American Journal of Applied Sciences* 9 (9).
13. Maire, M., Narihira, T., & Yu, S. X. (2016). Affinity cnn: Learning pixel-centric pairwise relations for figure/ground embedding. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 174-182).
14. Mohanty, R., Ravi, V., & Petra, M. R. (2009). Software reliability prediction using group method of data handling. In *Rough Sets, Fuzzy Sets, Data Mining and Granular Computing: 12th International Conference, RSFDGrC 2009, Delhi, India, December 15-18, 2009. Proceedings 12* (pp. 344-351). Springer Berlin Heidelberg.
15. Mostafaeipour, A., Goli, A., & Qolipour, M. (2018). Prediction of air travel demand using a hybrid artificial neural network (ANN) with Bat and Firefly algorithms: a case study. *The journal of supercomputing*, 74(10), 5461-5484.
16. Nadwa Kh, R. & Ezza Ha. Z., (2010). Using Artificial Neural Networks in Multiple Linear Regression Analysis. *Rafidain Development Journal*, Vol. 32, No. 99, pp. 151-165
17. Pérez-Campdesuñer, R., De-Miguel-Guzman, M., Sánchez-Rodríguez, A., Garcia-Vidal, G., & Martínez-Vivar, R. (2018). Exploring neural networks in the analysis of variables that affect the employee turnover in the organization. *International Journal of Engineering Business Management*, 10, 1847979018772738.
18. Quinn, A., Rycraft, J. R., & Schoech, D. (2002). Building a model to predict caseworker and supervisor turnover using a neural network and logistic regression. *Journal of Technology in Human Services*, 19(4), 65-85
19. Smith.B , Shum.H.(2018). *The Future Computed Artificial Intelligence and its role in society*, U.S.A: Microsoft Corporation.
20. Stamolampros.P, Korfiatis.N, Chalvatzis.K, Dimitrios Bouhalis.D.(2019). Job Satisfaction and Employee Turnover Determinants in High Contact Services: Insights from Employees'Online Reviews, United Kingdom: University of Leeds.

21. Wang, Q., Zhu, J., & Yu, B. (2005). Combining classifiers in software quality prediction: A neural network approach. In *Advances in Neural Networks–ISNN 2005: Second International Symposium on Neural Networks, Chongqing, China, May 30-June 1, 2005, Proceedings, Part III 2* (pp. 921-926). Springer Berlin Heidelberg.
22. Yamada, T., Yang, Y., Valnegri, P., Juric, I., Abnoui, A., Markwalter, K. H., & Bonni, A. (2019). Sensory experience remodels genome architecture in neural circuit to drive motor learning. *Nature*, 569(7758), 708-713.
23. Zacharis, N. Z. (2016). Predicting student academic performance in blended learning using artificial neural networks. *International Journal of Artificial Intelligence and Applications*, 7(5), 17-29.