

أثر الذكاء الاصطناعي في التنبؤ بالمصروفات الحكومية المستقبلية دراسة تطبيقية في دوائر محافظة نينوى

د. شاديا صوايا²
Chadidasawaya@usek.edu.lb

نصر محمد عيدان¹
Nasralmamary81@gmail.com

المستخلص: يهدف البحث إلى دراسة تأثير الذكاء الاصطناعي في التنبؤ بالمصروفات الحكومية المستقبلية في العراق وقد شملت الدراسة 11 مديرية في محافظة نينوى، الاستراتيجية الخاصة بالبحث هي دراسة حالة من الأرشف للبيانات المتوفرة للسنوات السابقة لدوائر محافظة نينوى، حيث تم استخدام خوارزمية الذكاء الاصطناعي المتمثلة بشبكة Perceptron للتنبؤ بقيم المصروفات للسنوات اللاحقة، توصل البحث إلى مجموعة من الاستنتاجات أهمها: يؤدي استخدام الذكاء الاصطناعي في ترشيد وتحسين الانفاق في الوحدات الحكومية في العراق وأوصى الباحث بضرورة تشجيع الوحدات الحكومية على تخصيص غطاء مالي لتنفيذ تقنيات الذكاء الاصطناعي بما في ذلك تحديث الأنظمة والبرامج والأجهزة المستخدمة.

الكلمات المفتاحية: الذكاء الاصطناعي-المصروفات الحكومية -التنبؤ بالمصروفات الحكومية
1- مقدمة:

تطورت التكنولوجيا بشكل كبير خلال العقود الأخيرة، وأصبح للذكاء الاصطناعي تأثير كبير في مجال إدارة الموارد المالية. فقد أدى استخدام الذكاء الاصطناعي في تحليل البيانات المالية السابقة وتوقع المصروفات المستقبلية، إلى تحقيق نتائج مذهلة في تحسين أداء الوحدات الحكومية في إدارة الموارد المالية. إن التنبؤ بالمصروفات باستخدام الذكاء الاصطناعي يعتبر أداة قوية للمساعدة في اتخاذ القرارات المالية الذكية وتحقيق الترشيد في الإنفاق. فبفضل قدرة الذكاء الاصطناعي على تحليل البيانات الضخمة والتعامل معها بشكل سريع ودقيق، يمكن للوحدات الحكومية أن تحصل على توقعات دقيقة للمصروفات المستقبلية وتخطيط استراتيجي مبني على أسس قوية. علاوة على ذلك، يمكن للذكاء الاصطناعي أن يقدم تحليلات متعمقة للبيانات المالية السابقة، مما يساعد في تحديد الأنماط والاتجاهات والعوامل التي تؤثر في المصروفات. وبناءً على هذه النتائج، يمكن للوحدات الحكومية اتخاذ إجراءات تصحيحية مبكرة وتحديد الأولويات في تخصيص المالي. ومن الجوانب الإيجابية الأخرى لاستخدام الذكاء الاصطناعي في تنبؤ المصروفات، أنه يقلل من الاعتماد على التقديرات اليدوية والتكهنات غير المؤكدة. حيث يعتمد التنبؤ التقليدي على تجربة وخبرة الفرد، وهو قد يكون معرضاً للأخطاء والتحيزات. بينما يعتمد الذكاء الاصطناعي على البيانات الواقعية والإحصائيات الموضوعية، مما يزيد من دقة التوقعات ويقلل من الأخطاء البشرية. باختصار، يعد تنبؤ المصروفات باستخدام الذكاء الاصطناعي تطوراً هاماً في مجال إدارة الموارد المالية. إن توقع المصروفات المستقبلية

¹ باحث: الجامعة الأمريكية للعلوم والتكنولوجيا – بيروت – لبنان

² د. الجامعة اللبنانية – بيروت – لبنان

بدقة وتحليل البيانات المالية السابقة يساهمان في تحسين الأداء المالي وترشيد الإنفاق، مما يساعد الوحدات الحكومية على اتخاذ قرارات مالية ذكية وفعالة.

المبحث الأول: منهجية البحث

1. مشكلة البحث:

تعاني الحكومات في العديد من الدول من تحديات مالية كبيرة وضغوط متزايدة على الموارد المالية المتاحة، مما يتطلب منها تحسين إدارة الإنفاق الحكومي وتحقيق الكفاءة المالية والإنفاق المستدام. وعلى الرغم من وجود العديد من الأساليب التقليدية للمحاسبة الإدارية، إلا أنها قد تكون غير كافية لتحقيق الأهداف المالية والاستراتيجية المطلوبة، مما يستدعي اللجوء إلى استخدام أساليب محاسبية إدارية حديثة وفعالة. ومن هنا تنشأ مشكلة البحث في عجز الأساليب المحاسبية الإدارية التقليدية عن تأدية دوراً فعالاً في ترشيد الإنفاق الحكومي وتحسين الأداء المالي للوحدات الحكومية، وي طرح ذلك سؤال عن الحاجة لاستخدام الذكاء الاصطناعي كأحد الأساليب المحاسبية الحديثة في التنبؤ بالمصروفات الحكومية مستقبلاً بهدف تحسين الأداء المالي للحكومة العراقية. ومن هنا برزت إشكالية بحثنا هذا التي نقول:

ما هو تأثير الذكاء الاصطناعي في التنبؤ بالمصروفات الحكومية المستقبلية؟

2. أهمية البحث:

- (1) تتمثل أهمية البحث في عدة جوانب فعلى المستوى الأكاديمي يمكن أن يساعد البحث في تطوير المعرفة حول كيفية استخدام الذكاء الاصطناعي في التنبؤ بالمصروفات الحكومية، كما يمكن استخدام النتائج والتوصيات التي يتم الوصول إليها في تحسين ممارسات المحاسبة الإدارية في المؤسسات الحكومية.
- (2) وعلى المستوى العملي يمكن أن يساهم البحث في تحسين كفاءة إدارة الموارد المالية وتحسين أداء الوحدات الحكومية عن طريق تحسين الإنفاق الحكومي وتحقيق الترشيد في الإنفاق. وبالتالي يمكن تخفيض تكاليف الإنفاق الحكومي وتوفير المزيد من الموارد المالية للاستثمار في مشاريع أخرى.
- (3) أخيراً، فإن هذا البحث يمكن أن يساعد في تطوير سياسات وإجراءات حكومية أكثر فاعلية في إدارة الموارد المالية وتحقيق الترشيد في الإنفاق. وهذا يمكن أن يؤدي إلى تحسين الثقة في الحكومة وتحسين مستوى الخدمات التي تقدمها الوحدات الحكومية للمواطنين.

3. أهداف البحث:

هدف هذا البحث هو دراسة تأثير استخدام الذكاء الاصطناعي في تنبؤ المصروفات الحكومية المستقبلية. وتشمل الأهداف الفرعية للبحث:


- تحليل تأثير استخدام الذكاء الاصطناعي في توقع المصروفات الحكومية المستقبلية. يهدف البحث لفهم كيف يمكن للذكاء الاصطناعي أن يساهم في تحسين الدقة والفعالية في توقع المصروفات الحكومية.
- قياس كفاءة ودقة نماذج الذكاء الاصطناعي في التنبؤ بالمصروفات الحكومية. يستهدف البحث اختبار أداء النماذج القائمة على الذكاء الاصطناعي وتحليل نسبة الخطأ والدقة في تنبؤ المصروفات.
- تقديم توصيات حول استخدام الذكاء الاصطناعي في توقع المصروفات الحكومية المستقبلية. يهدف البحث إلى تطوير نصائح وتوجيهات عملية للجهات الحكومية لتحسين استخدام الذكاء الاصطناعي في توقع المصروفات الحكومية واتخاذ قرارات مصيرية.
- تحسين تخطيط الموارد للحكومات من خلال استخدام توقعات المصروفات. يستهدف البحث إدخال تحسينات في عمليات التخطيط المالي والموارد الحكومية من خلال تحسين الدقة والموثوقية في توقع المصروفات الحكومية.

4. مخطط البحث الفرضي:

يوضح الشكل رقم (1) مخطط البحث الفرضي والذي يحتوي على المتغيرين الرئيسيين وهما:

1- المتغير المستقل (X) الذكاء الاصطناعي

2- المتغير التابع (Y) التنبؤ بالمصروفات الحكومية



الشكل (1) مخطط البحث الفرضي
المصدر: إعداد الباحث

5. فرضيات البحث:

الفرضية الرئيسية للبحث: يؤدي استخدام تقنيات الذكاء الاصطناعي الى تحسين جودة أساليب المحاسبة الإدارية ومن ثم تحسين الانفاق في الوحدات الحكومية

6. منهج البحث:

اعتمد البحث الحالي على المنهج الوصفي التحليلي والمنهج الاستنباطي وذلك من خلال مراجعة الأدبيات واستنباط الفرضيات وجمع البيانات وتحليلها ليتم في النهاية اختبار الفرضيات وتفسير نتائجها

7. حدود البحث:

- 1- الحدود المكانية: الوحدات الحكومية في محافظة نينوى.
- 2- الحدود الزمانية: تمتد فترة البحث بين شهري نيسان وأيلول عام 2023.

8. أداة البحث:

دراسة حالة من الأرشيف للبيانات المتوفرة للسنوات السابقة لدوائر محافظة نينوى.

المبحث الثاني: الإطار النظري

- الذكاء الاصطناعي (AI):

هو أحد مجالات علوم الكمبيوتر التي تركز على إنشاء آلات ذكية تعمل وتفكر وتتفاعل مثل البشر. حيث يتم تطبيق هذا المصطلح بشكل متكرر على مشروع تطوير الأنظمة التي تتمتع بالعمليات الفكرية المميزة للبشر، مثل القدرة على التفكير، والتعلم من التجارب السابقة. (السلمان، 2022، ص51) منذ تطوير الكمبيوتر الرقمي في أربعينيات القرن العشرين، ثبت أنه يمكن برمجة أجهزة الكمبيوتر لتنفيذ مهام معقدة للغاية والتعامل مع البيانات الضخمة وعلى الرغم من التقدم المستمر في سرعة معالجة الكمبيوتر وسعة الذاكرة، لا توجد حتى الآن برامج يمكنها أن تضاهي المرونة البشرية الكاملة في مجالات أوسع أو في المهام التي تتطلب الكثير من المعرفة اليومية. ومن ناحية أخرى، وصلت بعض البرامج إلى مستويات أداء الخبراء والمهنيين من البشر في أداء مهام محددة معينة، بحيث يوجد الذكاء

الاصطناعي بهذا المعنى المحدود في تطبيقات متنوعة مثل التشخيص الطبي، ومحركات البحث الحاسوبية، والتعرف على الصوت أو الكتابة اليدوية، والتنبؤ وتمييز الأشياء. (Castrounis, 2017, p43)


- التنبؤ بالمصروفات باستخدام الذكاء الاصطناعي:

هو عملية استخدام خوارزميات، تقنيات وأدوات الذكاء الاصطناعي لتحليل البيانات المالية السابقة وتوقع المصروفات المستقبلية لمؤسسة أو منظمة. هذا النوع من التنبؤ يمكن أن يكون أداة قوية لتحسين إدارة الموارد المالية واتخاذ قرارات مالية أكثر ذكاءً، ويمكن تطوير نماذج تنبؤية باستخدام الذكاء الاصطناعي تعتمد على البيانات السابقة ومتغيرات أخرى مثل الظروف الاقتصادية والعوامل الخارجية. هذه النماذج يمكن أن تستخدم لتوقع المصروفات المستقبلية بناءً على السيناريوهات المحتملة. في المجمل، التنبؤ بالمصروفات باستخدام الذكاء الاصطناعي يكون أداة قيمة لتحسين إدارة الموارد المالية وتعزيز القرارات المالية في المؤسسات أو المنظمات، مما يساهم في تحقيق الاستدامة المالية والنجاح الأعمق. (البزاز، عاصي، 2017، ص547)

- الشبكات العصبية


الشبكات العصبية والتي يرمز لها بالرمز Artificial Neural Network (ANN) هي مجموعة فرعية من التعلم الآلي تهدف إلى محاكاة بنية ووظيفة الدماغ البيولوجي. تُعرف الشبكات العصبية أيضًا باسم الشبكات العصبية الاصطناعية (ANNs)، وتتكون من عقد مترابطة، أو خلايا عصبية اصطناعية، منظمة في طبقات ذات اتصالات مرجحة تنقل البيانات وتعالجها. (العبدان، البطاط، 2020، ص64) تشكل الشبكات العصبية ذات الطبقات المتعددة أساس خوارزميات التعلم العميق، تم تصميم الشبكات العصبية لتعلم الأنماط والعلاقات من بيانات التدريب، والتكيف والتحسين المستمر، وتطبق هذا التعلم لاتخاذ التنبؤات أو القرارات. إن قدرتهم على استخلاص معلومات ذات معنى من البيانات المعقدة لحل المشكلات تميزهم عن الخوارزميات التقليدية. ومن أهم مميزات هذه الشبكات العصبية (السويدي، 2019، ص52)

- القدرة على العمل بمعلومات او معرفة غير كاملة
 - إمكانية العمل حتى بعد فشل بعض العقد وتعرض الشبكة لبعض الضرر
 - تخزين المعلومات على الشبكة كاملة وليس قاعدة بيانات
 - القدرة على عمل أكثر من وظيفة بنفس الوقت (المعالجة المتوازية)
- تتكون الشبكة العصبية الأساسية من خلايا عصبية مترابطة في ثلاث طبقات وكما هو موضح بالشكل (2):
- **طبقة الإدخال:** تدخل المعلومات إلى الشبكة العصبية من طبقة الإدخال؛ تقوم عقد الإدخال بعد ذلك بمعالجة البيانات وتحليلها وتمريرها إلى الطبقة التالية.
 - **الطبقة المخفية:** تأخذ الطبقات المخفية مدخلاتها من طبقة الإدخال أو الطبقات المخفية الأخرى، وتقوم بتحليل المخرجات من الطبقة السابقة، ومعالجتها، وتمريرها إلى الطبقة التالية.
 - **طبقة الإخراج:** تنتج طبقة الإخراج النتيجة النهائية ويمكن أن تحتوي على عقد مفردة أو متعددة.



الشكل (2) هيكلية طبقات الشبكات العصبية
المصدر: إعداد الباحث بالاعتماد على (Yanbo Huang, 2023,p2010)

- شبكة **Neural Network Multilayer Perceptro n** (فرحات، سادات، 2018، ص25)
هي نوع من **الشبكات العصبية** التي تستخدم على نطاق واسع في التعلم الآلي والذكاء الاصطناعي، وهي شبكة عصبية متجهة إلى الأمام، مما يعني أن المعلومات تتدفق في اتجاه واحد من طبقة الإدخال إلى طبقة الإخراج. تتكون بنية ال MLP من ثلاث طبقات أو أكثر: طبقة الإدخال Input layer، طبقة مخفية واحدة أو أكثر Hidden layer، وطبقة الإخراج Output layer. تقوم بتغذية طبقة الإدخال ببيانات الإدخال الخاصة بنا ونحصل على النتائج من طبقة الإخراج. يمكننا زيادة عدد الطبقة المخفية بقدر ما نشاء، لجعل النموذج أكثر دقة وتعقيدا وفقاً للمهمة التي نريد إنجازها. تتكون كل طبقة من مجموعة من العقد أو العصبونات المتصلة بالعقد الموجودة في الطبقات المجاورة. يتم ترجيح الروابط بين العقد في شبكة MLP وكما هو موضح بالشكل (3)



الشكل (3) هيكلية شبكة Perceptron
المصدر: إعداد الباحث

- حيث نلاحظ من الشكل أعلاه ان العصبون يتألف من:
- إشارة المدخلات: $X_1, X_2, \dots, X_n$
- الأوزان: $W_1, W_2, \dots, W_n$ والذي يعبر عن شدة الترابط بين العنصر القبل والبعد.
- عنصر المعالجة (دالة التنشيط): Y والذي يشمل قسمين:
- الجامع: والذي يقوم بجمع الإشارات في المدخل الموزون.

- تابع التفعيل: وهنا التابع يحد من مخرج العصبون لذا يسمى بتابع التخميد
- المخرجات: x_j
- المكونات الأساسية لشبكة **Multilayer Perceptron** (الشتوي، جيلان، 2016، ص175)
 1. طبقة الإدخال (Input Layer): تتكون طبقة الإدخال من خلية عصبية واحدة أو أكثر، والتي تستقبل إشارات الإدخال من العالم الخارجي أو من طبقات أخرى من الشبكة العصبية.
 2. الأوزان (Weights): ترتبط كل خلية عصبية مدخلة بوزن يمثل قوة الاتصال بين خلية الإدخال و خلية الإخراج.
 3. التحيز (Bias): تتم إضافة مصطلح التحيز إلى طبقة الإدخال لتزويد الشبكة بمرونة إضافية في نمذجة الأنماط المعقدة في بيانات الإدخال.
 4. وظيفة التنشيط (Activation Function): تحدد وظيفة التنشيط مخرجات الشبكة بناءً على مجموع اوزان للمدخلات ومصطلح التحيز.
 5. الإخراج (Output): إخراج الشبكة هو قيمة ثنائية واحدة، إما 0 أو 1، والتي تشير إلى الفئة أو الفئة التي تنتمي إليها بيانات الإدخال.
 6. خوارزمية التدريب (Training Algorithm): يتم تدريب الشبكة عادةً باستخدام خوارزمية التعلم الخاضعة للإشراف مثل خوارزمية التعلم الإدراكي أو الانتشار العكسي وخلال عملية التدريب، يتم تعديل الأوزان بغية لتقليل الخطأ بين المخرجات المتوقعة والمخرجات الحقيقية لمجموعة معينة من أمثلة التدريب. ويتم تعليم هذه الأوزان أثناء عملية التدريب. الهدف من تدريب الشبكة هو ضبط الأوزان بطريقة تمكن النموذج من التنبؤ بدقة ببيانات الإخراج لمدخل معين. ومعادلة تحديث الازوزان هي كالتالي:

الوزن = weight = الوزن السابق + معدل التعلم * learning rate * (القيمة المتوقعة - القيمة التي تم ايجادها predicted) * قيمة المدخل x

 7. الصيغة الرياضية للعصبون

تمثل العمليات الرياضية بالمعادلة الآتية:


$$y_k = f\left(\sum w_{jk} x_j + BK\right)$$

حيث أن:

إشارة المدخل $(x_1, x_2, \dots, x_j)$

الاوزان للعصبون k $(w_1, w_2, \dots, w_j)$

تابع عملية الجمع: $(\sum w_{jk} x_j + b_k)$ حيث ان (b_k) تمثل الانحياز الذي يمكن عده على انه احد الاوزان (w_0) ومدخله $(x_0=1)$ ليكون النموذج بالشكل (4)



الشكل (4) : الخوارزمية الرياضية للعصبون الصناعي
المصدر: إعداد الباحث بالاعتماد على Jamal M. Nazzal, 2008, 548

- كيف تعمل شبكة Multilayer Perceptron

تعمل هذه الشبكة من خلال عدد من الدوال وكما هو موضح ادناه:

1. دالة Multilayer Perceptron: هي دالة تحدد مدخلاتها والتي يشار إليها بالرمز "x"، والتي يتم ضربها بمعامل الوزن الذي تم تعلمه لإنشاء قيمة الإخراج "f(x)". وكما هو موضح بالمعادلة التالية:

$$f(x) = \begin{cases} 1 & \text{if } w \cdot x + b > 0 \\ 0 & \text{otherwise} \end{cases}$$

حيث ان:

"w" = متجه الأوزان ذات القيمة الحقيقية

"b" = انحياز (عنصر يضبط الحدود بعيداً عن الأصل دون أي اعتماد على قيمة الإدخال)

"x" = متجه قيم المدخلات

2. دالة مدخلات شبكة Multilayer Perceptron: يتم التعامل مع مدخلات هذا النوع من الشبكات العصبية من خلال المعادلة التالية


$$w_0 + w_1x_1 + w_2x_2 + \dots + w_nx_n$$

حيث ان:

"w" = يمثل الوزن

"x" = متجه قيمة الادخال

3. دالة التنشيط في شبكة Multilayer Perceptron: تطبق وظيفة التنشيط قاعدة الخطوة (تحويل الإخراج الرقمي إلى 1+ أو 1-) للتحقق مما إذا كان ناتج وظيفة الترجيح أكبر من الصفر أم لا.



الشكل (5): دالة التنشيط في شبكة Multilayer Perceptron

المصدر: إعداد الباحث

4. دالة مخرجات شبكة Multilayer Perceptron: يعتمد مخرجات الشبكة على المعادلة التالية

$$o(\vec{x}) = \text{sgn}(\vec{w} \cdot \vec{x})$$

$$\text{sgn}(y) = \begin{cases} 1 & \text{if } y > 0 \\ -1 & \text{otherwise} \end{cases}$$

حيث يشير الإخراج (+1) إلى تنشيط الخلية العصبية، بينما يشير الإخراج (-1) إلى أن الخلية العصبية لم يتم تحفيزها. في قاعدة تعلم الشبكة تتم مقارنة المخرجات المتوقعة بالمخرجات المعروفة. إذا لم يكن متطابقاً، فسيتم نشر الخطأ للخلف للسماح بإجراء تعديل الوزن. (Hadi Memarian, Siva Kumar Balasundram, 2012,p877)

- مميزات وعيوب شبكة Multilayer Perceptron

أ. مميزات الشبكة

1. يمكن لنموذج الشبكة متعدد الطبقات أن يحل المشكلات المعقدة غير الخطية.
2. إنه يعمل بشكل جيد مع كل من بيانات الإدخال الصغيرة والكبيرة.
3. يساعدنا في الحصول على تنبؤات سريعة بعد التدريب.
4. يساعدنا في الحصول على نفس نسبة الدقة مع البيانات الكبيرة والصغيرة.

ب. سلبيات الشبكة

1. في نموذج الشبكة متعدد الطبقات، تستغرق الحسابات وقتاً طويلاً.
 2. يعتمد أداء النموذج على جودة التدريب. (Geva, Roei, Jonathan, Omer, 2021,p5490)
- (Hadi, Siva, 2012,880)

المبحث الثالث: تحليل نتائج البحث واختبار فرضياته

أولاً: تنفيذ الشبكة العصبية (Multilayer Perceptron) للتنبؤ بالمصاريف المستقبلية

شبكة الإدراك الحسي للتنبؤ (Multilayer Perceptron) بالمصروفات تعتمد على استخدام الذكاء الاصطناعي وتقنيات معالجة البيانات لفهم وتحليل البيانات المالية السابقة واستخدام هذا الفهم لتوقع المصروفات المستقبلية بدقة أكبر. هذا يعني أنها تستفيد من المعلومات المالية والبيانات السابقة للمؤسسة لفهم كيفية تغيرت المصروفات مع مرور الزمن وكيفية تأثير العوامل المختلفة عليها. من خلال تحليل هذه البيانات المالية السابقة واستخدام تقنيات التعلم الآلي والتنبؤ الاصطناعي، يمكن للشبكة تطوير نماذج تنبؤية دقيقة. هذه النماذج تأخذ في الاعتبار العوامل المختلفة التي تؤثر على المصروفات مثل التغيرات في السوق، والظروف الاقتصادية، والتغيرات في استراتيجية الأعمال. ببساطة، شبكة الإدراك الحسي للتنبؤ بالمصروفات تعمل على توظيف الذكاء الاصطناعي لفهم البيانات المالية السابقة والاتجاهات والأنماط المالية، ومن ثم تطبيق هذا الفهم لتوقع كيفية تطور المصروفات في المستقبل. هذا يساعد المؤسسات على اتخاذ قرارات مالية أفضل وتخصيص الموارد بشكل أكثر فعالية استناداً إلى توقعات دقيقة للمصروفات المستقبلية.

أ. جدول التدريب والاختبار

عند تطوير نموذج لشبكة عصبية، يتعين عليك تقسيم بياناتك إلى مجموعتين رئيسيتين:

1. مجموعة التدريب (Training Set):
 - هذه المجموعة تتضمن جزء من البيانات.
 - تُستخدم هذه المجموعة لتدريب الشبكة العصبية على مهمتها الرئيسية.
 - خلال عملية التدريب، تقوم بتقديم البيانات إلى الشبكة وتعديل أوزانها تلقائياً لجعلها تتعلم من البيانات.
2. مجموعة الاختبار (Test Set):
 - هذه المجموعة تحتوي على جزء آخر من البيانات اختيرت من أجل عملية الاختبار.
 - تُستخدم هذه المجموعة لاختبار أداء الشبكة بعد أن تم تدريبها على مجموعة التدريب.
 - تساعد في تقييم قدرة الشبكة على التعامل مع بيانات جديدة لم تراها خلال عملية التدريب.

ومن ملاحظة الجدول (1) نجد بأنه قد تم تقسيم البيانات الى (60%) كبيانات اختبرت لعملية التدريب وهي النسبة الأكثر بغية ضبط اوزان تدريب الشبكة والجزء الآخر كان بنسبة (40%) والذي استخدم لاختبار مندى فعالية الشبكة في التنبؤ بالمصاريف اللاحقة وهذا التقسيم يساعد في تقييم أداء النموذج على بيانات جديدة بشكل مستقل.

جدول (1) نسب الاختبار والتدريب

	N	Percent
Sample Training	3	60.0%
Testing	2	40.0%
Valid	5	100.0%
Excluded	0	
Total	5	

المصدر: إعداد الباحث

ب. معلومات الشبكة العصبية:

ضم الجدول (2) ثلاثة أجزاء من المعلومات التي تشير الى تفاصيل تكوين هذه الشبكة حيث ضم الجزء معلومات متكاملة عن طبقة الادخال والتي تعتبر أولى طبقات الشبكة العصبية الصناعية. تكون هذه الطبقة مسؤولة عن استقبال المدخلات من البيانات وتميرها إلى باقي الطبقات في الشبكة. حيث ضمت هذه الطبقة أربع متغيرات والتي تمثل البيانات التي تريد تحليلها أو تصنيفها. يشير الجدول إلى وجود أربعة مدخلات مختلفة (Covariates) هي (تعويضات الموظفين، المستلزمات الخدمية، المستلزمات السلعية، الصيانة) وقد أشار المتغير (Number of unit's) الى هذا العدد. في حين تكونت الطبقة المخفية من طبقة واحدة ضمت عصبونيتين كل عصبون يقوم بمعالجة المدخلات القادمة من طبقة الادخال بناء على الاوزان التي حددت بعدها يتم حساب الإخراج بناء على استخدام وظيفة نشاط (Activation Function) بفرض وجود سلسلة زمنية تحتوي على القيم $(x_1, x_2, \dots, x_n)$ وللتنبؤ بالقيم المستقبلية للمتغير بايجاد القيم (x_{n+1}, x_{n+2}) حيث ان السلسلة محددة أي وجود عدد حقيقي (p) اللذين يسمى بالبعد المطور بحيث تكون $(t > p)$ حيث ان :

$$X(t) = f(x_{t-1}, x_{t-2}, \dots, x_{t-p}) \dots \dots (1)$$

ومن ثم يتم حساب دالة التنشيط من خلال اعتماد المعادلة (2).

$$F(x) = \tanh(x) = \frac{(e^x - e^{-x})}{(e^x + e^{-x})} \dots \dots \dots (2)$$

حيث يمثل المتغير (x) الإشارة القادمة من الطبقة السابقة.

والجزء الأخير من هذا الجدول ضمن معلومات طبقة الإخراج فبعد تدريب الشبكة العصبية وضبط أوزانها بواسطة مجموعة التدريب، يمكن استخدام الطبقة الأخيرة للتنبؤ بالنتائج عند تقديم بيانات جديدة. هذا الجزء من العملية يمثل الخطوة النهائية في استخدام الشبكة العصبية.


جدول (2) معلومات الشبكة

Input Layer	Covariates	1	تعويضات الموظفين
		2	المستلزمات الخدمية
		3	المستلزمات السلعية
		4	الصيانة
Hidden Layer(s)	Number of Units ^a	4	
	Rescaling Method for Covariates	Standardized	
	Number of Hidden Layers	1	
	Number of Units in Hidden Layer 1 ^a	2	
Output Layer	Activation Function	Hyperbolic tangent	
	Dependent Variables	1	الكلبي
	Number of Units	1	
	Rescaling Method for Scale Dependents	Standardized	
	Activation Function	Identity	
	Error Function	Sum of Squares	

المصدر: إعداد الباحث

ت. نموذج الشبكة العصبية

يمثل الشكل (6) النموذج النهائي لتنفيذ الشبكة العصبية والية هيكلتها حيث كما هو موضح بالشكل تالفة طبقة الادخال من أربع مدخلات أساسية لتقدير القيمة التقريبية للتنبيه بالمصاريف اللاحقة في حين ضمت الطبقة المخفية على طبقة واحدة تكونت وحدتين للمعالجة وهما (H1:2) و (H1:1) وأخيرا طبقة الإخراج التي كانت مخرجاتها هي قيمة التنبؤ بالمصاريف المستقبلية. في حين إشارة المتغير (Synaptic Weight) الى قيمة الاوزان التي استخدمت في ضبط الشبكة وتدريبها فيما لو كانت أكبر ام أصغر من القيمة الصفرية.



الشكل (6) نموذج الشبكة

المصدر: إعداد الباحث

ثانياً: نسبة الخطأ في التنبؤ

نسبة الخطأ في التنبؤ (Prediction Error Rate) تستخدم لتقييم وقياس أداء النموذج الموضح بالجدول (3) ومدى دقة التنبؤات التي قدمها النموذج في مقارنة مع القيم الفعلية التي تم إدخالها للسنوات السابقة لمعرفة مدى انحراف التنبؤات عن القيم الفعلية، حيث تراوحت نسب الخطأ بين (0.015) و(0.001) وهي قيم صغيرة جداً كدليل على دقة النموذج في الحصول على مقدار عالي من التنبؤ بالمصاريف المستقبلية وكما هو موضح بالجدول (3).

جدول (3) نسب الخطأ

Training	Sum of Squares Error	.015
	Relative Error	.010
	Stopping Rule Used	1 consecutive step (s) with no decrease in error ^a
	Training Time	0:00:00.00
Testing	Sum of Squares Error	.001
	Relative Error	. ^b

المصدر: إعداد الباحث

ثالثاً: مناقشة نتائج تنفيذ الشبكة العصبية

بعد تنفيذ الشبكة العصبية **Multilayer Perceptron** على البيانات المتوفرة للسنوات السابقة والمبينة بالجدول (4)

جدول (4) بيانات السنوات السابقة

السنة	تعويضات الموظفين	المستلزمات الخدمية	المستلزمات السلعية	الصيانة	الكلية
2019	564423315	17351000	3312400	25034600	610121315
2020	568021555	8960000	1350000	25000000	603331555
2021	643146849	22187750	15909500	16431450	697675549
2022	652035558	17681250	1730000	17000000	688446808
2023					

المصدر: إعداد الباحث

من ملاحظة الجدول أعلاه نجد ان قيم بند تعويضات الموظفين للسنوات (2019-2020-2021-2022) كانت على التوالي (564423315- 568021555 – 643146849 - 652035558) وكانت القيم لبند المستلزمات الخدمية (17351000-8960000-22187750-17681250) للأعوام نفسها فيما كانت القيم لبند المستلزمات السلعية والصيانة كالتالي (3312400-1350000-15909500-1730000) (25034600-25000000-16431450-17000000) اما بالنسبة لعمود الكلية والذي شمل المصروفات النهائية لكل سنة والتي كانت كالتالي (610121315-603331555-697675549-688446808) بالنسبة للسنوات (2019-2020-2021-2022). وبعد تنفيذ النموذج المقترح المستند على استخدام الشبكات العصبية (**Multilayer Perceptron**) للتنبؤ بالمصروفات الخاصة بالسنة 2023 من خلال الاعتماد على مصروفات السنوات السابقة كانت النتيجة كما مبينة بالجدول (5).

جدول (5) التنبؤ بمصروفات السنة 2023


السنة	تعويضات الموظفين المتنبأ بها	المستلزمات الخدمية المتنبأ بها	المستلزمات السلعية المتنبأ بها	الصيانة المتنبأ بها	الكلية المتنبأ بها
2023	691397325	20099625	8028550	12698425	732223925

المصدر: إعداد الباحث

حيث نلاحظ من الجدول أعلاه ان الرصيد الكلي بلغ (732223925) والذي يمثل القيمة النهائية للمصروفات التي تنبأت بها الشبكة العصبية وعند مقارنة هذا القيمة مع قيم المصروفات الكلية للسنوات السابقة نجد هنالك تقارب ومنطقية في القيمة التي ظهرت كنتاج تنفيذ وهذا يُشير إلى أن الشبكة العصبية قامت بتنبؤ قيمة المصروفات بدقة عالية وخلال فترة زمنية قليلة جدا من خلال المقارنة بين القيمة التنبؤية والبيانات السابقة للمصروفات.

. والشكل (7) يمثل المخطط البياني للمصروفات الكلية للسنوات (2019-2020-2021-2022-2023)

الشكل (7) المصروفات الكلية



المصدر: إعداد الباحث

الشكل (7) يعكس الزيادة في المصروفات الكلية مع مرور السنوات، حيث يظهر منحنى النمو ان المصروفات كانت في مستوى معين في السنة الأولى، ثم ارتفعت تدريجياً في السنوات التالية. هذا يشير إلى زيادة المصروفات بمرور الوقت ويمكن أن يعكس نمو النشاط أو الاستثمار في المشروع أو المؤسسة التي تتعلق بهذه البيانات.

يمثل الجدول التالي الرصيد النهائي لموازنة عام (2022) وحسب التنبؤات المبينة على التوالي وقد تم اعتماد العام 2022 كمؤشر رئيسي للتحقق من دقة النتائج المحققة باستخدام تقنيات الذكاء الاصطناعي، وذلك عبر مقارنتها بالنتائج التي تم الحصول عليها باستخدام الأساليب التقليدية لنفس العام.

الجدول (6) الرصيد النهائي لموازنة عام 2022

الانحراف المعياري للأسلوب التقليدي	الانحراف المعياري للذكاء الاصطناعي	الأسلوب التقليدي	استخدام الذكاء الاصطناعي	الفعلي	
0.002162321	0.001072919	655,025,667	653,025,667	652,035,558	تعويضات الموظفين
0.004069117	0.010590996	348,548,022	346,548,022	341,396,033	المخصصات
0.075492483	0.046155166	21,003,000	18,874,300	17,681,250	المستلزمات الخدمية
0.719483374	0.137137319	6,454,400	2,101,548	1,730,000	المستلزمات السلعية
0.098297011	0.069260156	21,552,200	18,750,875	17,000,000	الصيانة
0.008979861	0.00646404	1,052,583,289	1,039,300,412	1,029,842,841	الكلي

المصدر: إعداد الباحث


تم الاعتماد على قيمة الانحراف المعياري لقياس مدى دقة النتائج في كلا الحالتين فهو مقياس إحصائي يستخدم لتقدير تشتت البيانات في مجموعة معينة. يقيس الانحراف المعياري درجة التباين أو التشتت حول القيمة المتوسطة. عندما يكون الانحراف المعياري صغيراً، يشير ذلك إلى أن البيانات قريبة من المتوسط، مما يعكس تجانسها. بينما عندما يكون الانحراف المعياري كبيراً، يشير ذلك إلى وجود تشتت كبير في البيانات.

يتم حساب الانحراف المعياري عبر تطبيق صيغة رياضية كما موضح بالمعادلة التالية، حيث يتم قسم مجموع مربعات الانحرافات عن المتوسط على عدد البيانات، ثم يتم استخراج الجذر التربيعي للنتائج. يعزز الانحراف المعياري فهم

الانتشار الإحصائي للبيانات ويُستخدم في مجالات متنوعة مثل البحث العلمي والتحليل المالي. يمكن استخدامه لتقييم الثبات أو التغير في العمليات والأحداث، مما يساعد في اتخاذ القرارات الأكثر دقة وفعالية.

$$\sigma = \sqrt{\frac{\sum_{i=1}^N (X_i - \mu)^2}{N}}$$

- حيث أن: σ هو الانحراف المعياري.
 - N هو عدد العناصر في مجموعة البيانات.
 - X_i هي قيمة كل عنصر في مجموعة البيانات.
 - μ هو المتوسط الحسابي لمجموعة البيانات.
- وبعد تطبيق دالة (**STDEVA**) التي تستخدم لحساب متوسط انحراف قيم البيانات عن القيمة المتوسطة لمجموعة بيانات، والتي تم تطبيقها على القيم الحقيقية للعام 2022 حسب تنبؤيات (تعويضات الموظفين، المخصصات، المستلزمات الخدمية، المستلزمات السلعية، الصيانة، الكلي) والتي بلغت على التوالي (1,029,842,841 - 17,000,000 1,730,000 - 17,681,250 - 341,396,033 - 652,035,558) بالمقارنة مع من تم التوصل اليه من قيمة اجمالية متنبأ بها لنفس التنبؤيات والتي بلغت (653,025,667 - 346,548,022 - 18,874,300 - 2,101,548 - 18,750,875 - 1,039,300,412) ناتجة عن استخدام الذكاء الاصطناعي باعتماد البيانات المالية لموازنة عام 2021، حيث بلغت قيمة الانحراف المعياري لهذه التنبؤيات (0.001072919 - 0.010590996 - 0.046155166 - 0.137137319 - 0.069260156 - 0.00646404) في حين كانت قيمة الانحراف المعياري للقيمة الحقيقية للعام 2022 حسب (تعويضات الموظفين، المخصصات، المستلزمات الخدمية، المستلزمات السلعية، الصيانة، الكلي) والتي بلغت على التوالي (1,029,842,841 - 17,000,000 1,730,000 - 17,681,250 - 341,396,033 - 652,035,558) بالمقارنة مع من تم التوصل اليه من قيمة اجمالية باعتماد الأسلوب التقليدي لنفس التنبؤيات (655,025,667 - 348,548,022 - 21,003,000 - 6,454,400 - 21,552,200 - 1,052,583,289) هو (0.002162321 - 0.004069117 - 0.075492483 - 0.719483374 - 0.098297011 - 0.008979861) ويدل هذا المؤشر لقيم الانحراف المعياري التي تم التوصل اليها لكلا الحالتين ان اعتماد أسلوب الذكاء الاصطناعي أفضل من خلال تحقيق دقة عالية في التنبؤ بالقيم المستقبلية. والشكل (8) يمثل المخطط البياني للقيم الحقيقية والقيم التي تم التنبؤ بها بطرقتي الذكاء الاصطناعي والأسلوب التقليدي وقيم التقارب لكلا الطريقتين من البيانات الحقيقية.



الشكل (8) مخطط بياني للقيم الحقيقية والقيم المتنبئة

المصدر: إعداد الباحث

وبالتحليل السابق نبرهن صحة فرضية البحث الرئيسية أي أن استخدام الذكاء الاصطناعي يؤدي عند تحديد الأنشطة القيمة والمفيدة بالتأكد في ترشيد انفاق وكذلك عند اعداد تقديرات الانفاق باستخدام أدوات الذكاء الاصطناعي فسوف يؤدي ذلك الى تحسين الانفاق في الوحدات الحكومية.

الخلاصة:

يمكن الاعتماد على التنبؤ بالمصروفات بواسطة الذكاء الاصطناعي كأداة قيمة لتعزيز القرارات المالية في الوحدات الحكومية، مما يساهم في تحقيق الاستدامة المالية والنجاح الأعمق. تطوير نماذج تنبؤية تستند إلى الذكاء الاصطناعي يعزز فهمنا للظروف الاقتصادية والعوامل الخارجية التي تؤثر على المصروفات، وبالتالي يساهم في تحسين الأداء المالي وترشيد النفقات المالية وتحقيق الأهداف المؤسسية.

المبحث الرابع: الاستنتاجات والتوصيات

أولاً: الاستنتاجات

1. تحسين الدقة في التنبؤ: يساعد الذكاء الاصطناعي في تحليل البيانات الضخمة وتطبيق نماذج وتقنيات تعلم الآلة. فعند تدريب نظام الذكاء الاصطناعي على بيانات المصروفات الحكومية السابقة، قد يتمكن من استنتاج أنماط وعلاقات سابقة لم تكن واضحة أو من الصعب تحليلها بواسطة الإنسان. وبالتالي يمكن أن يحقق دقة أكبر في تنبؤ المصروفات المستقبلية.

2. توفير الوقت والجهد: بدلاً من الاعتماد على التحليل اليدوي للبيانات، ينفذ الذكاء الاصطناعي عملية التنبؤ بشكل أسرع وأكثر فعالية. وهذا يعني توفير الوقت والجهد للمحللين والموظفين الذين يعملون على إعداد ومراجعة الميزانيات الحكومية.

3. تحسين اتخاذ القرار: يقدم الذكاء الاصطناعي توصيات مبنية على تحليل البيانات والنماذج الاحتمالية. وهذا يمكن أن يساعد صناع القرار في اتخاذ قرارات أكثر ذكاءً وأكثر استناداً إلى البيانات.

4. تقليل الخطأ البشري: يساهم الذكاء الاصطناعي في تقليل الخطأ البشري في التنبؤ بالمصروفات الحكومية. فمن خلال الاعتماد على أنظمة ذكاء اصطناعي قوية، يتم استبعاد العوامل الشخصية والعواطف التي قد تؤثر على قرارات التنبؤ.

5. تحسين إدارة الموارد: يساعد الذكاء الاصطناعي أن يساعد في تحسين إدارة الموارد المالية للحكومة عن طريق التنبؤ بالمصروفات وتوجيه الاستثمارات بشكل أفضل. وهذا يمكن أن يؤدي إلى تحسين الكفاءة المالية وتقليل الإهدار.

ثانياً: التوصيات

1. استخدام الذكاء الاصطناعي كتقنية حديثة تعمل في تطوير وتحسين أساليب المحاسبة الإدارية الحديثة ولاسيما اعداد الموازنات مما يؤدي تحقيق اهداف الوحدات الحكومية في ترشيد الانفاق الحكومي.
2. اعتماد البرنامج الذي اعتمده الباحث في اعداد الموازنات في محافظة نينوى اذ ثبت كونه أكثر دقة وأسرع في اعداد الموازنات.
3. توجيه الوحدات الحكومية على ضرورة استخدام الذكاء الاصطناعي في تحسين وتطوير أساليب المحاسبة الإدارية المطبقة لديها ولاسيما اعداد الموازنات لتحقيق اهداف تلك الأساليب
4. تشجيع الوحدات الحكومية على تخصيص غطاء مالي لتنفيذ تقنيات الذكاء الاصطناعي بما في ذلك تحديث الانظمة والبرامج والاجهزة المستخدمة.
5. تعزيز التعلم والتدريب للعاملين في اعداد الموازنات على استخدام الذكاء الاصطناعي والتكنولوجيا الحديثة من خلال تحفيزهم للاشتراك بدورات التعليم المستمر والمشاركة بالورش التدريبية.

المبحث الخامس: المصادر

أولاً: المصادر العربية:

1. السلمان، قصي محمد (2022). تطبيقات الذكاء الاصطناعي في مجالات متعددة: دراسة استطلاعية. مجلة جامعة البحرين للعلوم التطبيقية، 1(1)، 45-60
2. اليزاز، خليفة، وعاصي، عمر قاسم. (2017). الذكاء الاصطناعي وتطبيقاته. دار الشروق 5 (5): 546-552
3. العبدان، نادية، والبطاط، سهيل. (٢٠٢٠). "تحليل الأنماط بواسطة الشبكات العصبية ودورها في تعزيز الذكاء الاصطناعي". مجلة علوم الحاسوب والمعلوماتية، ٢٤(١)، ٦٠-٧٣.
4. السويدي، فهد. (٢٠١٩). "الشبكات العصبية ودورها في الذكاء الاصطناعي". مجلة الذكاء الاصطناعي والروبوتات، ٥(٣)، ٥٩-٧٠.
5. فرحات، علي، وسادات، حسين. (٢٠١٨). "تطبيق الشبكات العصبية في الذكاء الاصطناعي". دورية الهندسة الكهربائية والإلكترونية، ٤٥(١٢)، ٢٠-٣٣.
6. الثتوي، أسامة، وجبلان، تمام. (٢٠١٦). "تعزيز الذكاء الاصطناعي باستخدام الشبكات العصبية". مجلة الكويت للعلوم الحاسوبية والمعلوماتية، ٢(٢)، ١٧١-١٨٥.

ثانياً: المصادر الأجنبية

7. Castrounis, A. (2017). Artificial Intelligence, Deep Learning, and Neural Networks, Explained. [online] Kdnuggets.com. Available at: <http://www.kdnuggets.com/2016/10/artificial-intelligence-deep-learning-neuralnetworks-explained.html> [Accessed 28 Sep. 2017]
8. Yanbo Huang, 2023, "Advances in Artificial Neural Networks – Methodological Development and Application", algorithms, ISSN 1999-4893,

9. Jamal M. Nazzal, 2008, " Multilayer Perceptron Neural Network (MLPs) For Analyzing the Properties of Jordan Oil Shale ", World Applied Sciences Journal 5 (5): 546-552,
10. Hadi Memarian, Siva Kumar Balasundram, 2012, Comparison between Multi-Layer Perceptron and Radial Basis Function Networks for Sediment Load Estimation in a Tropical Watershed, Journal of Water Resource and Protection, pp870-876
11. Geva, Mor; Schuster, Roei; Berant, Jonathan; Levy, Omer (2021). "Transformer Feed-Forward Layers Are Key-Value Memories". Proceedings of the 2021 Conference on Empirical Methods in Natural Language Processing. pp. 5484–5495

The impact of artificial intelligence on predicting future government expenditures

An applied study in the departments of Nineveh Governorate

¹ Nasr Mohammad Edan
NasrAlmamary81@gmail.com

² Dr. Chadia Sawaya
Chadidasawaya@usek.edu.lb

Abstract : The research aims to study the impact of artificial intelligence on predicting future government expenditures in Iraq. The study covered 11 directorates in Ninawa province, and the research strategy was a case study of archive data for previous years of Ninawa province departments. The study used the artificial intelligence algorithm represented by the Perceptron network to predict the values of expenditures for future years. The research concluded that the use of artificial intelligence leads to rationalizing and improving spending in government units in Iraq. The researcher recommended encouraging government units to allocate financial resources to implement artificial intelligence technologies, including updating systems, programs, and devices used.

Keywords: artificial intelligence, government expenditures, prediction of government expenditures

¹ Researcher: American University of Science & Technology – Beirut – Lebanon

² Dr. Chadia Sawaya – Lebanese University – Beirut – Lebanon