

التنبؤ بالسلاسل الزمنية باستخدام الشبكات العصبية الاصطناعية -دراسة تطبيقية على الإيرادات
العامة في الجزائر -

Forecasting time series using artificial neural networks
- An applied study on public revenues in Algeria -

صالحى رياض الدين^{1*}، شعباني مجيد²

¹ مخبر تمويل التنمية في الاقتصاد الجزائري، جامعة بومرداس، ra.salhi@univ-boumerdes.dz

² مخبر مستقبل الاقتصاد الجزائري خارج المحروقات، جامعة بومرداس، m.chabani@univ-boumerdes.dz

تاريخ النشر: 2023/12/ 01

تاريخ القبول: 2023/11/ 06

تاريخ الاستلام: 2023/08/ 21

ملخص: هدفت هذه الدراسة الى عرض تقنية من تقنيات الذكاء الاصطناعي والمتمثلة في الشبكات العصبية الاصطناعية من خلال عرض مكوناتها وشكلها الرياضي مع شرح طريقة عملها في التنبؤ بسلاسل الزمنية والتي تعتبر تقنية جيدة في التعامل مع سلاسل زمنية غير خطية بحيث لا تؤخذ بعين الاعتبار الخصائص الاحصائية لسلسلة على غرار الطرق الاحصائية التقليدية

في الجانب التطبيقي قمنا بالتنبؤ بالسلسلة الزمنية للإيرادات العامة في الجزائر تتكون من 31 مشاهدة سنوية ممتدة من سنة 1990 إلى غاية 2020 والتنبؤ بقيمتها لثلاث سنوات مستقبلية باستخدام شبكة عصبية متعددة الطبقات وبالاعتماد على برمجية بايثون، تم الاعتماد على طريقة الانحدار الخطي كمثل رئيسي للطرق الإحصائية التقليدية في التنبؤ للمقارنة وقد اسفرت النتائج عن تفوق نموذج الشبكات العصبية الاصطناعية عن طريق الانحدار الخطي من خلال عدة معايير قياس جودة التنبؤ.

كلمات مفتاحية: شبكات عصبية اصطناعية، سلاسل زمنية، تنبؤ.

تصنيف JEL : C22، C45، C53

Abstract: Through this study, we aim to present one of the techniques of artificial intelligence represented by artificial neural networks and to explain its method of work in predicting time series, which is considered more efficient than traditional statistical methods.

On the applied side, we used a multi-layered neural network to predict a time series of public revenues consisting of 31 annual observations extending from 1990 to 2020 for Algeria, and compared the accuracy of its prediction by the linear regression method, which proved its superiority through several criteria for measuring the quality of prediction.

Keywords: Artificial Neurrone Network; Times Series; forecasting.

Jel Classification Codes : C53, C45,C22.

1. مقدمة :

ان الشبكات العصبية الاصطناعية هي عبارة عن خوارزمية من خوارزميات الذكاء الاصطناعي والتي تحاكي عمل الدماغ البشري في تحليل الظواهر والسلوكيات وازداد الاهتمام بهذه الخوارزمية مؤخرا نظرا لاتساع مجالات استخدامها وصولا لعملية التنبؤ بالسلاسل الزمنية و التي عرفت تفوقا في هذا المجال على باقي الطرق الاحصائية التقليدية

في النهاية، يمكن للتنبؤ بالسلاسل الزمنية باستخدام الشبكات العصبية الاصطناعية أن يكون أداة قوية للتنبؤ بالإيرادات العامة للجزائر وتحسين عملية اتخاذ القرارات الاقتصادية. ومع ذلك، يجب أن يتم النظر في التحديات والمخاطر المحتملة وتحديد مدى دقة النموذج ومدى ملاءمته للظروف الاقتصادية الحالية.

الفرضيات: من خلال الإشكالية المطروحة يمكن صياغة فرضية البحث التالية:

تعتبر نماذج الشبكات العصبية أكفأ وأكثر دقة في التنبؤ بسلسلة الزمنية للإيرادات العامة في الجزائر مقارنة بطرق تنبؤ بسلاسل الزمنية التقليدية.

حدود البحث: لتحقيق من فرضية البحث تم الاعتماد على سلسلة زمنية سنوية لإيرادات العامة في الجزائر من 1990 الى غاية 2020 والتي كان مصدرها الديوان الوطني للإحصائيات ONS .

المنهج المتبع: تم اعتماد منهجين في هذه الدراسة لغرض الاطلاع على مختلف جوانب البحث وتحليل أبعاده. أولاً، تم استخدام المنهج الوصفي لعرض الإطار النظري وترسيخ المفاهيم المرتبطة بالموضوع. هذا المنهج يساعد في تفصيل وصف دقيق للمفاهيم المرتبطة وتبسيطها لفهم أفضل. ثم، تم استخدام المنهج الكمي في الجزء التطبيقي من الدراسة. باستخدام المنهج الكمي، تم جمع وتحليل البيانات الكمية المرتبطة بالموضوع بمنهجية دقيقة وقياسية. وتم استخدام الأدوات الإحصائية والتحليلية لفهم العلاقات والنتائج واستخلاص الاستنتاجات من البيانات المحصلة. هذا التحليل المزدوج يسمح للباحثين بالحصول على نظرة

شاملة ومتكاملة حول الموضوع، حيث يساعد المنهج الوصفي في فهم النظرية والمفاهيم بشكل أفضل، بينما يسمح المنهج الكمي بتحليل البيانات والوصول إلى النتائج الكمية المدعومة بالأدلة. تمثل هذه الجمعية بين المناهج المختلفة نُهجًا شاملاً يساعد على تعمق فهم الموضوع وتأكيد النتائج.

أهمية الدراسة: تكمن أهمية الدراسة في تبيان كفاءة الشبكات العصبية الاصطناعية في التنبؤ بالسلاسل الزمنية مقارنة بطرق الاحصائية التقليدية التي تستند على مجموعة من الخصائص الصعبة تحقيق بالإضافة الى اهمية التنبؤ بالمتغير المدروس والمتمثل في الإيرادات العامة كونه أداة قوية في تحريك الاقتصاد الوطني.

اهداف الدراسة: تهدف من خلال هذه الدراسة إلى تحقيق العناصر التالية:

- تبيان مدى أهمية اللجوء الى تقنيات الذكاء الاصطناعي في التحليل الاقتصادي الحديث
- عرض خوارزمية الشبكات العصبية الاصطناعية وكيفية التنبؤ بها
- برهان تفوق الشبكات العصبية في التنبؤ بالسلاسل الزمنية على الطرق الاحصائية التقليدية من خلال مقارنتها مع التنبؤ بواسطة الأنحدار الخطي
- إيجاد أفضل نموذج للتنبؤ والذي يعطي أقل قيمة خطأ

2. السلاسل الزمنية:

السلسلة الزمنية هي متتابعة من القيم المشاهدة لظاهرة عشوائية مرتبة مع الزمن، و عادة ما تكون المشاهدات غير مستقلة و هذه الخاصية تساعدنا في التوصل الى تنبؤات موثوق منها، يتم استغلال الدليل السفلي للإشارة الى الترتيب الزمني للمشاهدة، بمعنى أن (y_t) تمثل المشاهدة رقم (t) كما (y_{t-1}) ان تمثل المشاهدة السابقة لها و (y_{t+1}) تمثل المشاهدة التالية لها (عادل بغزة ، علي العكروف ، 2022 ، صفحة453)

1.2. السلسلة الزمنية رياضيا

السلسلة الزمنية هي تسلسل حقيقي محدود $(n \in N)$ (y_t) $1 \leq t \leq n$ حيث $(t \in T)$ يمثل فهرس وحدة زمنية (يمكن ان تكون الشهر او السنة و ما الى ذلك)، و (n) عبارة عن طول السلسلة، أن متغير الزمن المستقل (t) والقيم المناظرة له المتغير التابع (y) وإن كل قيمة في الزمن (t) يقابلها قيم للمتغير التابع (x) فإن (x) دالة في الزمن (t) أي $y = f(t)$

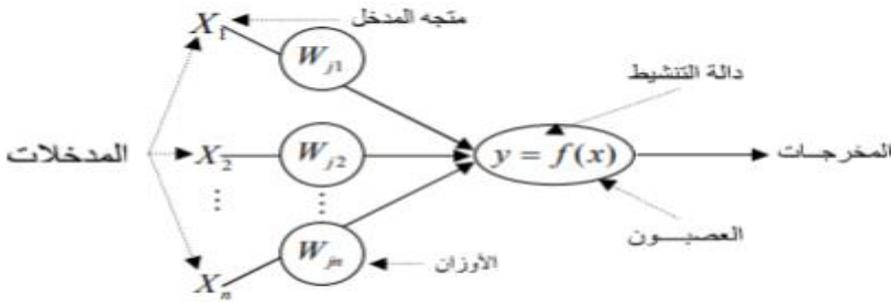
3. الشبكات العصبية الاصطناعية

الشبكات العصبية الاصطناعية هي نماذج حوسبة مستوحاة من الدماغ البشري، وتعتبر جزءاً من مجال الذكاء الاصطناعي. تستخدم هذه الشبكات لمعالجة البيانات والتعلم منها واكتشاف الأنماط واتخاذ

القرارات الذكية. تتكون الشبكات العصبية الاصطناعية من طبقات متعددة من الوحدات الحسابية المعروفة بالعقد، وتعتمد على عمليات الحساب الدقيقة لتحقيق الأهداف المطلوبة.

يمكن تعريف الشبكات العصبية الاصطناعية على أنها نظام معلومات يحاول أداء مهام الشبكة العصبية البيولوجية (الدماغ) المتكونة من مليارات الخلايا العصبية المرتبطة مع بعضها عبر والوصلات و التي يتلخص عملها في قيام الخلية بتجميع الإشارات من الخلايا المجاورة لها ، ثم تقوم هي الأخرى بإرسال إشاراتها إلى خلايا عصبية أخرى مجاورة لها في حين يقوم العصبون الصناعي بتجميع الدخول المرسل من العصبونات الأخرى ثم يطبق عليها دالة الفعالية و التي تنتج خرج العصبون الصناعي و ترسله للخلايا الأخرى(عبد الله علي المسلاتي ، أحمد عبد القادر جحا ، 2019 ، صفحة 381)

الشكل 1: مكونات الشبكة العصبية الاصطناعية



المصدر: رعاد عماد صليو ، ظافر رمضان قطر ، 2019 ، صفحة 59

1.3. مكونات النموذج الرياضي للشبكة العصبية

يتكون نموذج الشبكة العصبية الاصطناعية من عناصر اساسية هي (عمر صابر قاسم، إسراء رستم

محمد، 2013، صفحة 186):

- إشارات الادخال $\{x_1, x_2, \dots, x_n\}$: وهي عبارة عن بيانات حول المتغيرات المراد دراستها
- الأوزان $\{w_1, w_2, \dots, w_n\}$: وهي القيم المستخدمة لوزن كل واحد من متغيرات الادخال والتي تمكن من تحديد اهميتها المتعلقة بوظيفة كل عصبون
- المجموع $(\sum_{i=0}^n x_i w_i)$: يجمع جميع اشارات المدخلات المرجحة بالأوزان لإنتاج جهد التنشيط
- عتبة التنشيط (b_i) : هو متغير يستخدم لتحديد العتبة المناسبة للجهد الذي يجب ان ينتجه المجموع الخطي

- جهد التنشيط (u): وهو الفرق بين جهد التنشيط الخطي وعتبة التنشيط، فإذا كانت هذه القيمة موجبة أي إذا كان، عندها ينتج العصبون جهدا مثيرا
- دالة التنشيط (f): وتحدد مخرجات الخلية العصبية ضمن مجال القيم المحدد
- إشارة الاخراج (y): تتمثل في القيمة النهائية التي ينتجها، والتي يمكن استخدامها أيضا كمدخلات لخلايا عصبية أخرى

العلاقتان التاليتين تعتبران عن مخرجات الخلايا العصبية الاصطناعية التي اقترحه *pitts et McCulouch*

$$u = \sum_{i=1}^n w_i x_i - b_i$$

$$y = f(u)$$

2.3. دالة التنشيط

دالة التنشيط أو دالة التحويل هي الدالة المسؤولة عن تحديد قيم الخارجة y_1, \dots, y_p التي تمثل المتغيرات التابعة من الخلية عن طريق تحويل القيم الداخلة x_1, \dots, x_p التي تمثل المتغيرات المستقلة، و α, β تمثل معالم النموذج. وقد تأخذ شكل خطي او في غالب الأحيان تكون في شكل دالة غير خطية وتكون قابلة للتفاضل في مجال تعريفها تأخذ الصيغة الموالية $y = f(x_1, \dots, x_p; \beta)$. وهناك انواع مختلفة من دوال التنشيط منها المستمرة و القابلة للتفاضل على كافة مجال تعريفها و منها الدوال المتقطعة و التي تقبل التفاضل جزئيا فقط بحيث سنقوم باستعراض الأكثر استخداما و المتمثلة في دالة الخطوة و دالة سيغمويد و دالة الإشارة و الدالة الخطية (فلة بالله، 2022، صفحة 91):

- دالة الخطوة *step function*

$$\forall x \in \mathcal{R}, \quad y = f(x) = \begin{cases} 1 & \text{si } x \geq 0 \\ 0 & \text{si } x < 0 \end{cases}$$

- الدالة الخطية *linear function*

$$\forall x \in \mathcal{R}, \quad y = f(x) = x$$

- دالة الإشارة *signe function*

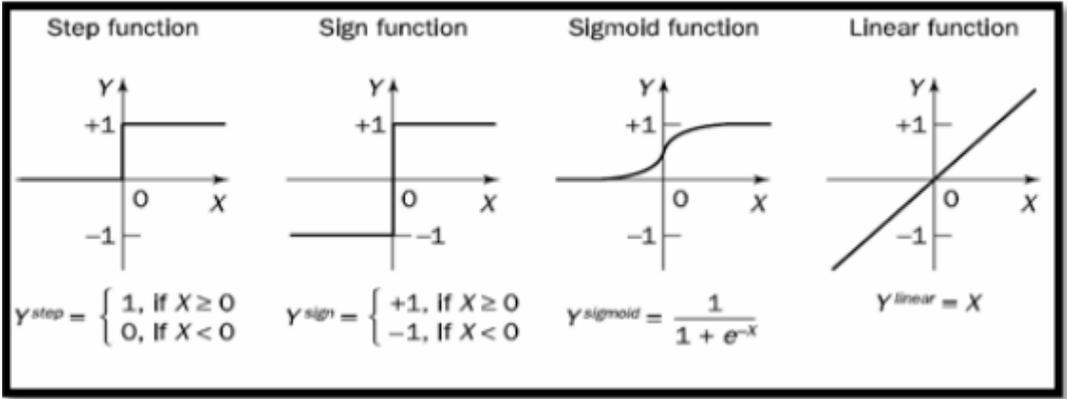
$$\forall x \in \mathcal{R}, \quad y = f(x) = \begin{cases} +1 & \text{si } x \geq 0 \\ -1 & \text{si } x < 0 \end{cases}$$

• دالة السيغمويد sigmoid function

$$\forall x \in \mathcal{R}, \quad y = f(x) = \frac{1}{1 + \exp^{-\beta x}} \in [-1.1]$$

ويمكن تلخيص الدوال السابقة وتمثيلاتها البيانية من خلال الشكل الموالي:

الشكل 2: انواع دوال التنشيط المستخدمة في الشبكات العصبية الاصطناعية



المصدر: عمر قاسم، إسراء رستم، 2013، صفحة 187

3.3. انحدار الشبكة العصبية الاصطناعية و معماريتها

تتكون الشبكة العصبية من طبقات متتالية تمثل في طبقة مدخلات ومجموعة من طبقات خفية وطبقة المخرجات عبارة عن مجموعة من الخلايا العصبية، تقوم طبقة المدخلات بقراءة إشارات المدخلات بحيث يوجد عصبون j لكل وحدة ادخال x_j وطبقة الإخراج تعبر عن استجابة النظام عن طريق دالة التحويل $g(x)$ من أجل قيم في \mathcal{R}^m والفضاء m يمثل قيم احتمالات الانتماء الى فئة المخرجات وتأخذ دالة الانحدار في شبكة عصبية تحتوي على q طبقة مخفية على الشكل الموالي :

$$y = f(x; \alpha, \beta) = \beta_0 + \beta'z$$

مع العلم أن

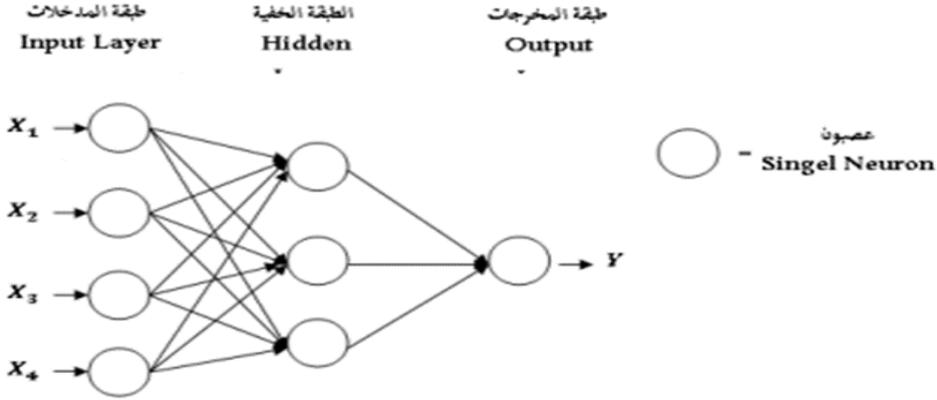
$$z_k = f(\alpha_{k0} + \alpha'_{kx}) \quad \forall k = 1 \dots \dots \dots q$$

بحيث أن

$g(\alpha_{k0} + \alpha'_{kx})$ تمثل دالة التحويل او التنشيط المستخدمة.

و باختصار تحتوي كل شبكة عصبية على ثلاث طبقات متمثلة في طبقة المدخلات و طبقات خفية و طبقة المخرجات، ويمكن تمثيلها في الشكل الموالي:

الشكل 3: معمارية الشبكة العصبية الاصطناعية



المصدر: بن نور فريد، نايت مرزوق محمد العربي، 2019، صفحة 73

4.3. أنواع الشبكات العصبية الاصطناعية

هناك نوعين من الشبكات العصبية يتمثلان في (إبراهيم احمد إبراهيم سيد أحمد، رجاء مصطفى صالح الأمين، مجدي عبد الاله محمد عباس، 2021، صفحة 87):

1.4.3. شبكات التغذية الأمامية *Feed Forward Neural Networks*

هي أحد أبسط وأكثر النماذج شيوعاً في مجال التعلم العميق. يُطلق عليها أيضاً اسم الشبكات العصبية التفاضلية وتعتبر من الشبكات ذات التوجه الواحد، أي أن الإشارة تنتقل فيها في اتجاه واحد فقط، من الطبقات الأولى إلى الطبقات الأخيرة. لا يوجد فيها دور للرجوع للخلف أو الاعتماد على الحالة السابقة.

2.4.3. الشبكات العصبية المتكررة *Recurrent Neural Networks (RNN)*

الشبكات العصبية التكرارية (RNN_s) هي نوع من الشبكات العصبية الاصطناعية التي تمتلك تدفقاً ثنائي الاتجاه، أي أنها تتصل بحيث يكون هناك تدفق للإشارة في الاتجاهين: الاتجاه الأمامي والاتجاه الخلفي. تعتبر هذه الخاصية مهمة لمعالجة البيانات المتسلسلة في الاتجاهين، وتمكن الشبكة من فهم السياق الزمني والتفاعل بين البيانات في كلا الاتجاهين

5.3. تعليم الشبكة العصبية

1.5.3. التعليم الاشرافي *supervised learning*

يُعتبر هذا الأسلوب هو الأكثر شيوعاً في تدريب الشبكات العصبية، حيث يتم جمع عينة من البيانات تحتوي على قيم للمتغيرات المدخلة وقيم للمتغيرات المخرجة. بعد ذلك، تقوم الشبكة بمقارنة التوقعات المحسوبة للمتغيرات المخرجة مع القيم الفعلية لتلك المتغيرات. واستناداً إلى الاختلاف بين التوقعات والقيم الفعلية، تقوم الشبكة بتعديل أوزانها بهدف تقليل الأخطاء في النتائج. ثم يتم تكرار عملية التدريب مراراً وتكراراً حتى يتم الوصول إلى نتائج مُقبولة (جمال أحمد الشوافي، عبد الوهاب سيد حجاج. 2013 صفحة 580)

2.5.3. التعلم غير الاشرافي *unsupervised learning*

تشابه هذه الطريقة مع طريقة التعليم الإشرافي، ومع ذلك، هناك اختلافات أساسية في عملية التدريب. ففي هذه الطريقة، لا تحتوي العينات المستخدمة في التدريب على أي قيم للمتغيرات الخارجية. بدلاً من ذلك، تتألف البيانات المدخلة من عدة مجموعات. ويتم تدريب الشبكة في هذه الحالة على اكتشاف المميزات الغير ظاهرة في مجموعة البيانات المستخدمة في التدريب. ثم يتم استخدام تلك المميزات لتقسيم بيانات المدخلات إلى مجموعات مختلفة، ولكن متقاربة داخل كل مجموعة. هذا يُمكن الشبكة من فهم العلاقات والأنماط المخفية بين البيانات وتحقيق أداء أفضل في المهام المعقدة (جمال أحمد الشوافي، عبد الوهاب سيد حجاج. 2013 صفحة 581)

6.3. طرق تعليم الشبكات العصبية

1.6.3. طريقة التعليم ذات الانتشار الخلفي *back – propagation*

تم اكتشاف هذه الطريقة من قبل بول ج. و ربرس حوال سنة 1974 و تعتبر هذه الطريقة أو الخوارزمية من أشهر طرق تعليم الشبكات العصبية متعددة الطبقات، و هي من الطرق التي تعتمد على الأمثلة أو الانماط أي التعليم بإشراف بحيث تهدف إلى التقليل من مربعات الأخطاء للخروج المحسوب بواسطة الشبكة بشكل تدريجي و يتم ذلك عن طريق تعديل الأوزان في كل دورة من دورات التدريب و تلتخص آلية عمل هذه الخوارزمية في ثلاث خطوات هي (عبد الله علي المسلاطي، أحمد عبد القادر جحا، 2019، صفحة 382)

- مرحلة التغذية الأمامية

• مرحلة الانتشار الخلفي

• مرحلة تحديث الأوزان

رياضيا لنفترض أن الوحدات j هي وحدات الإخراج وأن الوحدات i هي الوحدات في الطبقة التي تسبقها، يتم حساب الخرج عن طريق خطوتين هما:

$$x_j = \sum_i y_i w_{ij} \quad (1)$$

$$y_j = \frac{1}{1 + e^{-x_j}} \quad (2)$$

بحيث مجموع الخرج في الدالة الأولى هو x_j ، y_i هو i الوحدة النشطة في الطبقة السابقة و w_{ij} يمثل وزن الوصلة بين الوحدات i و j ، ثم تقوم الوحدة بحساب الخرج لها باستخدام دالة التنشيط التي في الغالب ما تكون دالة سيغمويد الممثلة في الدالة رقم (2)

و بمجرد حساب خرج جميع الوحدات، تقوم الشبكة بحساب مربعات الأخطاء بواسطة الدالة التالية

$$Q(\alpha, \beta) = \frac{1}{2} \sum_{i=1}^n Q_i = \frac{1}{2} \sum_{i=1}^n [y_j - f(x; \alpha, \beta)]^2$$

بوضع : $Q(\alpha, \beta) = E$ و $f(x; \alpha, \beta) = d_j$ للتبسيط

$$E = \frac{1}{2} \sum (y_j - d_j)^2 \quad (3)$$

بحيث y_j يمثل خرج الوحدة في الطبقة j باستخدام الدالة (1) ثم (2) و d_j يمثل الخرج الحقيقي المطلوب من الشبكة ان تعلمه وتمر عملية الانتشار الخلفي بأربع مراحل يمكن وصفها رياضيا كالتالي :

حساب معدل تغير الخطأ EA عند تغير الخرج الفعلي والذي هو الفرق بين الخرج الفعلي للشبكة من

(2) والخرج المطلوب وهو عبارة عن مشتق دالة الأخطاء بالنسبة ل y_j

$$EA = \frac{\partial E}{\partial y_j} = y_j - d_j \quad (4)$$

حساب معدل تغير الخطأ EI والذي يمثل ضرب الناتج من المعادلة (4) في مشتق خرج الوحدة، وهي

مشتق المعادلة (2)

$$EI_j = \frac{\partial E}{\partial x_j} = \frac{\partial E}{\partial y_j} \frac{dy_j}{dx_j} = EA_j y_j (1 - y_j) \quad (5)$$

حساب سرعة تغير الخطأ عند تغير الأوزان على الوصلات المتصلة بوحدات الإخراج عن طريق ضرب

الناتج من المعادلة (5) في مستوى نشاط الوحدة التي يخرج منها الاتصال في الصيغة (2)

$$E w_{ij} = \frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial x_j} \frac{\partial x_j}{\partial w_{ij}} = E I_i y_i \quad (6)$$

حساب معدل تغير الخطأ اعتماداً على تغيير نشاط الوحدة في الطبقة السابقة، وهذه العملية الممثلة في المعادلة (7) تسمح بتطبيق الانتشار الخلفي على الشبكات متعددة الطبقات

$$E A_i = \frac{\partial E}{\partial y_i} = \sum_j \frac{\partial E}{\partial x_j} \frac{\partial x_j}{\partial y_i} = \sum_j E I_j w_{ij} \quad (7)$$

وعن طريق استخدام المعادلتين (2) و(4) يمكن تطبيق هذا الإجراء على باقي الطبقات في الشبكة العصبية

2.6.3. خوارزمية النزول المتدرج *gradient descent*

خوارزمية النزول المتدرج هي عبارة عن خوارزمية تحسينية تستخدم بهدف تقليل من دالة الأخطاء وإيجاد قيمة المعلمات التي تجعل هذه الدالة اقل ما يمكن، أو بمعنى آخر إيجاد أقرب قيم للمخرجات التنبؤ بها من القيم الحقيقية، تعتبر هذه الخوارزمية التكرارية مناسبة لتحديد الأوزان لكل خلية عصبية عن طريق حساب المعاملات كالتالي (antoine caubriere , 2021 , page 30) :

$$\beta_k^{(r+1)} = \beta_k^{(r)} - \tau \sum_{i=1}^n \frac{\partial E}{\partial \beta_k^{(r)}}$$

$$\alpha_{kp}^{(r+1)} = \alpha_{kp}^{(r)} - \tau \sum_{i=1}^n \frac{\partial E}{\partial \alpha_{kp}^{(r)}}$$

بحيث τ يمثل معدل التعلم و يمكن التحكم فيه أو تحديده من قبل المستخدم أو حتى تغييره أثناء التنفيذ عن كريق بعض الأساليب التجريبية، تكون ها المعامل كبير في بداية عملية التدريب و يقوم بالانخفاض ليؤدي الى اقتراب المخرجات المحسوبة من المخرجات الحقيقية و تقليل نسبة الخطأ، كما تم تكييف العديد من طرق التحسين الأخرى لتعليم الشبكات العصبية منها طرق التدرج مم الدرجة الثانية باستخدام التقريب

4. الشبكات العصبية متعددة الطبقات

تُعد الشبكة متعددة الطبقات واختصاراً (*MLP*) من بين أكثر الشبكات العصبية شهرةً واستخداماً. تستند معماريتها إلى خوارزمية الانتشار الخلفي (*Back – propagation*) كأسلوب لتصحيح الأخطاء والتعلم. تتميز هذه الشبكة بوجود طبقات مخفية (*Hidden layers*) في الوسط، ويكمن السبب وراء وجود هذه الطبقات في القدرة على حل المشكلات غير الخطية (*nonlinear problems*) التي لا يمكن لشبكات الانتشار الأمامي التعامل معها. إن عدد

الطبقات المخفية في الشبكة متعددة الطبقات قد يكون لا نهائيًا، حسب تعقيد المشكلة التي تحاول الشبكة حلها. وتعتمد هذه الشبكات على نمط التعلم بالإشراف، حيث تزود الشبكة بالبيانات المستهدفة لتقوم بنمذجتها وتعلمها من خلال عملية التدريب والتعلم. تستخدم خوارزمية الانتشار الخلفي لتصحيح الأخطاء بشكل متكرر حتى تصل الشبكة إلى أدنى نسبة خطأ ممكنة. (سالم صلال الحسناوي، ليث حلیم مالک الحجيمي، 2022، صفحة 81)

وتمثل الصيغة التالية عملية الانتشار الأمامي للشبكات العصبية متعددة الطبقات:

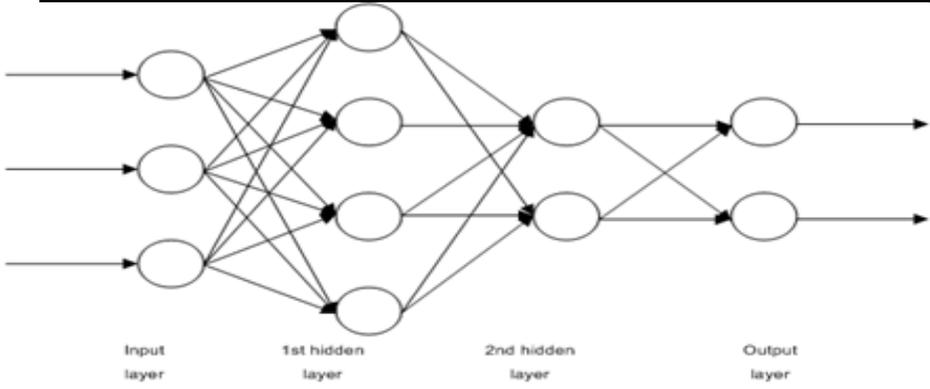
$$a_k^2 = f^2 \left(\sum_{j=1}^{s^1} w_{jlk}^2 f \left(\sum_{i=1}^R w_{ij}^1 p_i + b_j^1 \right) + b_k^2 \right)$$

$$\forall k = 1 \dots \dots \dots s^2$$

بحيث يمثل:

- s^1 عدد الوحدات المخفية
- s^2 عدد وحدات الاخراج
- R عدد وحدات المدخلات
- w_{jk} الأوزان بين الطبقة المخفية وطبقة المخرجات
- w_{ij} الأوزان بين المدخلات والطبقة المخفية
- f تمثل دالة التحويل او دالة التنشيط
- b_i التحيز

الشكل 4: معمارية الشبكات العصبية متعددة الطبقات



المصدر: سالم صلال الحسنوي، ليث حليم مالك الجحيمي ، 2022 ، صفحة 81

5. نتائج الدراسة ومناقشتها

1.5. بيانات الدراسة:

تمثلت بيانات الدراسة في سلسلة زمنية سنوية للإيرادات العامة للجزائر للفترة الممتدة من سنة 1990 إلى غاية سنة 2020 بمجموع 31 مشاهدة، إذ تم استخدام المشاهدات من سنة 1990 إلى غاية 2000 في عملية تدريب الشبكة، وأبقيت المشاهدات الأخير الممتدة من 2000 إلى غاية 2020 لأغراض المقارنة مع التنبؤات التي تم الحصول عليها، و قد تم الحصول على بيانات الدراسة من موقع الديوان الوطني للإحصائيات ONS

2.5. تقسيم البيانات

إن أول خطوة للقيام بالتنبؤ بواسطة الشبكات العصبية هو تقسيم البيانات إلى ثلاث مجموعات، وذلك من أجل تدريب الشبكة العصبية، وتتمثل هذه المجموعات في مجموعة التدريب ومجموعة اختبار ومجموعة تأكيد، وتتم عملية توزيع البيانات بشكل عشوائي

الجدول 1: توزيع المجموعات المستخدمة في الشبكة العصبية لسلسلة الإيرادات العامة

المجموعة	نسب المشاهدات	عدد المشاهدات
مجموعة التدريب	67.74 %	21
مجموعة التأكيد	19.35 %	6
مجموعة الاختبار	12.90 %	4

31	%100	المجموع
----	------	---------

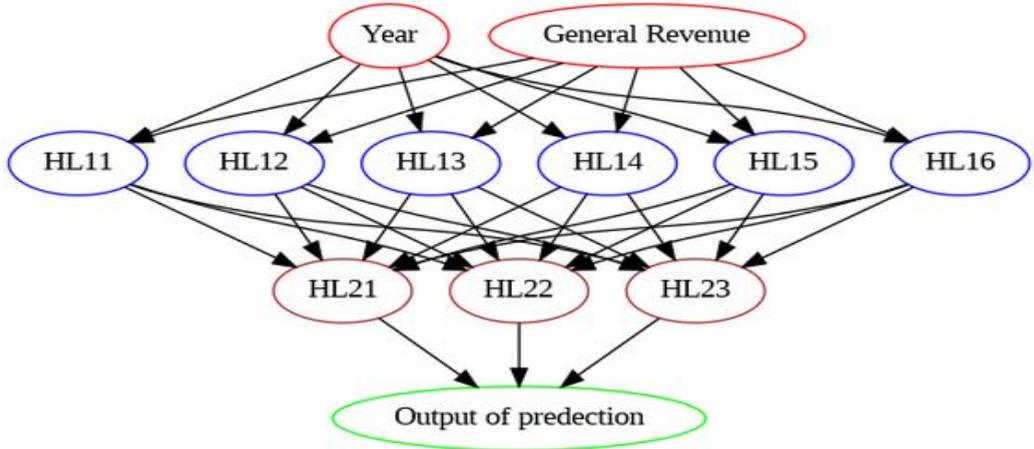
المصدر: من اعداد الباحثين بالاعتماد على مخرجات Python

من خلال الجدول السابق، يتضح أنه من إجمالي 31 مشاهدة مكونة لعينة الدراسة، تم استخدام 21 منها في مجموعة التدريب، 6 مشاهدة في مجموعة التأكيد و 4 منها في مجموعة الاختبار، و يجدر الإشارة إلى أن هذا النوع من التوزيع (70%، 15%، 15%)، هو أكثر التوزيعات استخداما في الشبكات العصبية

3.5. إختيار نوع الشبكة العصبية

للقيام بالتنبؤ بهذه السلسلة الزمنية قمنا بتحديد شبكة عصبية متعددة الطبقات ذات تغذية امامية تحتوي على طبقتين مخفيتين كما تم تطبيق خوارزمية الانتشار الخلفي في عملية تدريب الشبكة و اعتمدنا على دالة تحويل سيغمويد في تحديد معاملات الأوزان بالإضافة الى دالة الخطوة و التي اعطت نفس النتائج و الشكل الموالي يوضح هندسة الشبكة المعتمدة في الدراسة:

الشكل 5: هندسة الشبكة المعتمدة في الدراسة



المصدر: من اعداد الباحثين بالاعتماد على مخرجات Python

4.5. التنبؤ بالسلسلة الزمنية

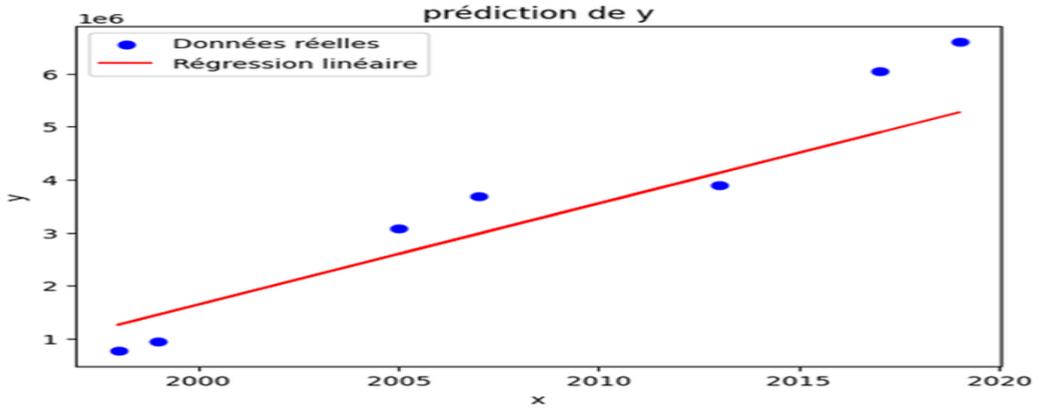
لغرض معرفة مدى ملائمة نموذج الشبكات العصبية في التنبؤ بالسلسلة الزمنية في حالتها العادية من دون إجراء اي تحويلات عليها سنقوم بتنبؤ بها اولاً بواسطة الانحدار الخطي ومن ثم سنقوم بإجراء التنبؤ بواسطة

الشبكات العصبية للقيام بالمقارنة فكانت نتائج التنبؤ بواسطة الانحدار الخطي البسيط لثلاث سنوات تالية كما يلي:

```
Mean Squared Error: 628987924785.8986
Predicted y for 2021: [5650519.9616192]
Predicted y for 2022: [5841359.37950337]
Predicted y for 2023: [6032198.7973876]
```

من خلال عملية التنبؤ بسلسلة الايرادات العامة بواسطة الانحدار الخطي باستخدام برنامج بايثون توصلت النتائج الى ان الايرادات العامة المتنبؤ بها لسنة 2021 كانت 5650519.9616192 اما بالنسبة لسنة 2022 فكانت قيمتها 5841359.37950337 و لسنة 2023 فكانت 6032198.7973876، أما بالنسبة لمربعات الاخطاء MSE فقد بلغت قيمتها 628987924785.8986 و الشكل الموالي يوضح مقارنة بين القيم المتنبؤ بها مع القيم الحقيقية

الشكل 6 : مقارنة القيم المتنبؤ بها بواسطة الانحدار الخطي مع القيم الحقيقية

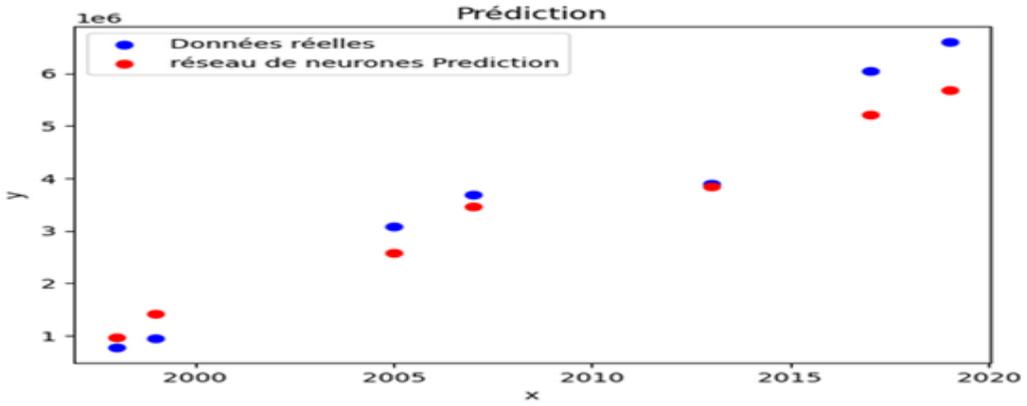


المصدر: من اعداد الباحثين بالاعتماد على مخرجات Python

اما نتائج التنبؤ باستخدام الشبكات العصبية لثلاث سنوات تالية لسلسلة الدراسة كانت كما يلي:

```
Mean Squared Error: 300422019370.78503
Predicted y for 2021: [5391763.45]
Predicted y for 2022: [5391763.45]
Predicted y for 2023: [5391763.45]
```

و من خلال عملية التنبؤ بسلسلة الإيرادات العامة بواسطة الشبكات العصبية الاصطناعية و باستخدام نفس البرنامج توصلت النتائج الى ان الإيرادات العامة المتنبؤ بها لسنوات 2021 و 2022 و 2023 كانت متطابقة و تساوت في 5391763.45 و بالنسبة لمربعات الأخطاء MSE فقد بلغت 300422019370.78503 و الشكل الموالي يوضح مقارنة بين القيم المتنبؤ بها و القيم الحقيقية الشكل 7: مقارنة القيم المتنبؤ بها بواسطة الشبكات العصبية الاصطناعية مع القيم الحقيقية



المصدر: من اعداد الباحثين بالاعتماد على مخرجات Python

5.5. مقارنة نتائج التنبؤ بين الانحدار الخطي والشبكات العصبية

سنقوم بتلخيص نتائج التنبؤ بين الانحدار الخطي و الشبكات العصبية الاصطناعية من خلال الجدول الموالي و للمفاضلة بين نتائج الطريقتين نعلم على مجموعة من المعايير المتمثلة في مربع متوسط الأخطاء MSE، متوسط نسبة الخطأ المطلق MAPE، مجموع الأخطاء المربعة SSE، متوسط الأخطاء المطلقة MAD و يتم حسابها وفق الصيغ التالية:

$$MSE = \sum_{t=1}^n \frac{(e_t)^2}{N} \quad MAPE = \frac{1}{N} \sum \left| \frac{e_t}{y_t} \right| \quad SSE = \sum (e_t)^2 \quad MAD = \frac{\sum |e_t|}{N}$$

الجدول 2: مقارنة نتائج التنبؤ بين الانحدار الخطي و الشبكات العصبية

طريقة التقييم	الانحدار الخطي	الشبكات العصبية
MSE	628987924785.8986	300422019370.78503

MAPE	40.32595742569	22.3256987412
SSE	745896	456982
MAD	20159.6587	12365.8531

المصدر: من اعداد الباحثين بالاعتماد على مخرجات Python

يتضح من خلال الجدول اعلاه أن جميع طرق التقييم المستعملة في قياس دقة التنبؤ بينت أن نموذج الشبكات العصبية هو الأفضل و الأكثر دقة في التنبؤ بالسلسلة محل الدراسة مقارنة مع طريقة الانحدار الخطي، فحسب قيمة متوسط نسبة الخطأ في حالة الانحدار الخطي كانت اكبر بكثير من نظيرتها في حالة الشبكات العصبية الاصطناعية بالإضافة الى مجموع مربعات الأخطاء MSE، و قيمة متوسط نسبة الخطأ المطلق MAPE و التي تشير الى تقييم النموذج من حيث دقة التنبؤات و اللذي يمثل الفرق بين النسبة الكلية و نسبة الخطأ في النموذج، فقد اسفرت دقة التنبؤ في نموذج الشبكات العصبية الى 77.68% (22.32-100) على عكس نموذج الانحدار الخطي الذي بلغت دقة تنبؤه فقط 59.68 (40.32-100) و ما يدل على تفوق نموذج الشبكات العصبية في عملية التنبؤ بهذه السلسلة.

6. خاتمة:

لقد عرفت خوارزميات الذكاء الاصطناعي المعتمدة على تعليم الالة تطورا هاما في اخر السنوات في عملية التحليل و التنبؤ بالظواهر العلمية و الاقتصادية ملائمتها لطبيعة هذه الظواهر و من بين اهم هذه الخوارزميات و اكثرها انتشارا في المجال الاقتصادي هي خوارزمية الشبكات العصبية الاصطناعية حيث تم تسليط الضوء في هذا المقال على الجانب الرياضي لهذه الخوارزمية و طريقة عملها و تبيان دورها في التنبؤ بالسلاسل الزمنية كطريقة حديثة و أكثر فعالية عن الطرق الاحصائية التقليدية و اثبات ذلك من خلال دراسة تطبيقية على سلسلة الايرادات العامة للجزائر من خلال تنبؤ بها بواسطة الانحدار الخطي و الشبكات العصبية و مقارنة نتائج التي اسفرت على تفوق الشبكات العصبية الاصطناعية على الانحدار الخطي و من بين أهم النتائج المتوصل اليها:

- تمثل خوارزميات الشبكات العصبية إحدى الأساليب الحديثة التي تتمتع بقدره استثنائية على التنبؤ وتقديم نتائج متميزة. تجدر الإشارة إلى ضرورة استخدام هذا الأسلوب في تحليل السلاسل الزمنية، نظراً لقدرتها الفريدة على تعيين نوعية وعدد المدخلات وتحديد عدد الطبقات المخفية في الشبكة.

التنبؤ بالسلاسل الزمنية باستخدام الشبكات العصبية الاصطناعية -دراسة تطبيقية على الإيرادات العامة-

- تعمل الشبكات العصبية الاصطناعية على التنبؤ بالسلاسل الزمنية بدون الحاجة إلى شروط صارمة ودقيقة ، بالإضافة لقدرتها الاستثنائية على فهم وتفسير سلوك السلاسل الزمنية غير الخطية
- تم الاعتماد على شبكة عصبية متعددة الطبقات كما تم استخدام دالة سيغمويد كدالة تحفيز وتم استخدام خوارزمية الانتشار العكسي لتدريب الشبكة
- من خلال مقارنة نتائج التنبؤ باستخدام الشبكة العصبية و نموذج احصائي تقليدي المتمثل في الانحدار الخطي تم التوصل الى تفوق خوارزمية الشبكات العصبية من خلال مقارنة مختلف معايير جودة التنبؤ و المتمثلة في $MSE, MAPE, SSE, MAD$
- ان الشبكة العصبية المستخدمة في الدراسة تعتبر جيدة بحيث اعطت تنبؤات دقيقة وقريبة جدا من الواقع

الاقتراحات والتوصيات

- ✓ الاعتماد على خوارزميات الذكاء الاصطناعي في التنبؤ بالمتغيرات الاقتصادية وتوظيفها في الواقع الاقتصادي أكثر
- ✓ إجراء دراسات لتحليل والتنبؤ بالسلاسل الزمنية متعددة المتغيرات
- ✓ كون معظم متغيرات الاقتصاد لا تخضع للخطية والتوزيع الطبيعي فإننا ننصح بنماذج الشبكات العصبية كونها أكثر ملاءمة للتعامل معها

7. قائمة المراجع:

- عمر قاسم، إسرائ رستم ، دراسة رياضية تحليلية لخوارزميات الشبكة العصبية الاصطناعية في ملاءمة نموذج للتشخيص الطبي ، مجلة الرافدين لعلوم الحاسوب و الرياضيات، المجلد 10 ، العدد 1 ، 2013
- عادل بغزة ، علي العكروف ، استخدام نموذج السلاسل الزمنية و البرمجيات الحديثة للتنبؤ بعدد سكان الجزائر آفاق 2040 ، مجلة أبعاد ، المجلد 9 ، العدد 02 ، 2020
- عبد الله علي المسلاقي، أحمد عبد القادر جحا ، استخدام الشبكات العصبية للتنبؤ في السلاسل الزمنية باستخدام طريقة التدريب ذات الانتشار الخلفي ، المؤتمر الدولي للعلوم التقنية ، 4-6 مارس 2019 ، جامعة مصراتة ، ليبيا

- جمال أحمد الشوادفي، عبد الوهاب السيد حجاج، الذكاء الاصطناعي وتحليل السلاسل الزمنية. المجلة العلمية لقطاع كليات التجارة - جامعة الأزهر , العدد 10 ، 2013
- إبراهيم احمد إبراهيم سيد أحمد، رجاء مصطفى صالح الأمين، مجدي عبد الاله محمد عباس، استخدام نماذج الشبكات العصبية الاصطناعية في تحليل الانحدار لدراسة العوامل المؤثرة على التضخم في السودان في الفترة من (2018-2021)، مجلة العلوم الانسانية والطبيعية، المجلد 2 ، العدد 6 ، 2021
- فلة بالله ، التنبؤ بالتعثر المالي باستخدام الشبكات العصبية الاصطناعية والمنطق الضبابي - دراسة تطبيقية على عينة من المؤسسات الاقتصادية الجزائرية، أطروحة دكتوراه ، الجزائر جامعة ادرار ، 2022
- رعاد عماد صليو، ظافر رمضان قطر، مقارنة أداء التنبؤ بين بعض الشبكات العصبية الاصطناعية و منهجية (بوكس و جينكينز) مع التطبيق ، المجلة العراقية للعلوم الاحصائية، المجلد 16 ، العدد 28 ، 2019
- بن نور فريد، نايت مرزوق محمد العربي ، استخدام نماذج الذكاء الاصطناعي للتنبؤ باحتياطات الصرف الأجنبي في الجزائر - نموذج الشبكات العصبية الاصطناعية ANN ، مجلة اقتصاديات شمال إفريقيا ، المجلد 15 ، العدد 20 ، 2019
- سالم صلال الحسنواوي، ليث حلیم مالک الحجيمي، التنبؤ بأسعار الإغلاق للأسهم باستخدام الشبكات العصبية لعينة من المصارف الإسلامية العراقية، مجلة بيت المشورة، العدد 18، 2022
- antoine caubriere , Du signal au concept : réseaux de neurones profonds appliqués à la compréhension de la parole, these doctorat , france le mans université , 2022

8. ملاحق:

code python :

```
import pandas as pd
import numpy as np
import tensorflow as tf
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import StandardScaler
# Lire le fichier Excel
file_path = 'article.xlsx'
df = pd.read_excel(file_path)
# Extraire les deux premières colonnes
data = df.iloc[:, :2].values
print(data)
# Diviser les données en variables d'entrée (X) et de sortie Y
X = data[:, 0].reshape(-1, 1)
Y = data[:, 1]
# Normalisation des données
scaler = StandardScaler()
X = scaler.fit_transform(X)
# Division des données en ensembles d'entraînement et de test
X_train, X_test, Y_train, Y_test = train_test_split(X, Y,
```

```
test_size=0.2, random_state=15) # Création du modèle de réseau de neurones model =
tf.keras.Sequential([ tf.keras.layers.Dense(64, activation='relu', input_shape=(1,)),
tf.keras.layers.Dense(64, activation='relu'), tf.keras.layers.Dense(1) ]) # Compilation du
modèle model. Compile(optimizer='adam', loss='mean_squared_error') #
Entraînement du modèle model.fit(X_train, Y_train, epochs=100, batch_size=32,
verbose=1) # Évaluation du modèle sur l'ensemble de test loss =
model.evaluate(X_test, Y_test) print("Test Loss:", loss) # Prédiction sur de
nouvelles valeurs de x new_x = np.array([[2019], [2020]]) new_x_scaled =
scaler.transform(new_x) predictions = model.predict(new_x_scaled)
print("Predictions for new values of x:", predictions) import matplotlib.pyplot as
plt # Prédiction sur l'ensemble de test Y_pred = model.predict(X_test) # Dessiner
le graphique plt.figure(figsize=(8, 6)) plt.scatter(X_test, Y_test, color='blue',
label='Vraies valeurs') plt.scatter(X_test, Y_pred, color='red', label='Prédictions')
plt.title("Vraies valeurs vs Prédictions") plt.xlabel("Valeurs de x")
plt.ylabel("Valeurs de y") plt.legend() plt.show()
```