

توقعات معدل التضخم الكلي باستخدام نموذج الذاكرة طويلة قصيرة المدى *Long Short-Term Memory (LSTM)

إعداد
أماني الرواشدة
أب 2023

هذه الدراسة تمثل وجهة نظر كاتبها ولا تمثل وجهة نظر البنك المركزي الأردني أو مجلس إدارته. ولا تتحمل المؤسسة مسؤولية ما ورد في هذه الدراسة.

الملخص

تقترح الورقة طريقة جديدة لاعداد توقعات التضخم في الاردن، باستخدام الذكاء الاصطناعي، إذ قامت الورقة بتوقع التضخم للربع الرابع من عام 2022 من خلال تطبيق نموذج الذاكرة طويلة قصيرة المدى ((Long Short-Term Memory (LSTM)، وتمت مقارنة النتائج بنتائج توقعات نموذج الانحدار الذاتي والمتوسط المتحرك ((Autoregressive Moving Average (ARMA).

اظهرت النتائج ان التنبؤ بالتضخم باستخدام LSTM اكثر دقة واقرب للبيانات الحقيقية وتحديدًا عند استخدام سلسلة التضخم الشهرية نفسها Constant Model، إذ ان معدل التضخم من خلال هذه الطريقة بلغ 4.2% لعام 2022، وهو نفسة التضخم المسجل لعام 2022 والصادر عن دائرة الإحصاءات العامة، بالمقارنة مع 4.3% باستخدام ARMA، وبالتالي يمكن ان نستنتج في هذه الدراسة ان نماذج Constant Model هي افضل لاجراء التوقعات، وان LSTM هو أدق من ARMA.

الكلمات الدالة: معدل التضخم، الذكاء الاصطناعي، نموذج الذاكرة طويلة قصيرة المدى، نموذج الانحدار الذاتي والمتوسط المتحرك .

JEL Classification: E31, E37, C01.

1. المقدمة

إن التنبؤ بمعدلات التضخم أمر مهم وأساسي في أي بلد، نظراً لتأثير التضخم على الاقتصادات المحلية على المستوى الجزئي والكلي، فعندما يكون هناك توقعات دقيقة للتضخم، يتسنى للأفراد والشركات والحكومات التخطيط بشكل أفضل واتخاذ القرارات المالية والاقتصادية الصائبة، فعلى مستوى الأفراد فإن هذه التوقعات تساعد في التخطيط السليم لميزانياتهم الشخصية وتحديد استراتيجيات الادخار والاستثمار. وأما على مستوى الشركات فيمكن لتوقعات التضخم أن تؤثر في التكاليف وقرارات التسعير. أما بالنسبة للبنوك المركزية، فإنها تعنى بشكل خاص بتوقعات التضخم لوضع السياسات والأجندات الوطنية التي تدفع التنمية الاقتصادية. بشكل عام، يعمل توقع التضخم كأداة هامة لفهم الاتجاهات الاقتصادية واتخاذ القرارات الاستراتيجية بناءً على مستقبل الأسعار والقوة الشرائية.

هناك نوعان من المنهجيات المستخدمة لتوقع معدل التضخم، النهج الأول مدفوع بالنماذج الاقتصادية التي تستند إلى العلاقات الاقتصادية والمتغيرات المؤثرة في معدل التضخم وفقاً للنظرية الاقتصادية، إذ يتم استخدام نماذج مثل نموذج فيليبس الجديد للتضخم New Keynesian Phillips Curve (NKPC)؛ ونموذج العرض والطلب لتحليل العوامل المؤثرة في التضخم وتوقع التضخم. والنهج الثاني هو احصائي، إذ يعتمد على قيم البيانات التاريخية للسلسلة الزمنية للمتغير نفسه مثل نماذج الانحدار الذاتي والمتوسط المتحرك Autoregressive Moving Averages.

في الآونة الأخيرة، ونظراً للعلاقة غير الخطية بين المؤشرات الاقتصادية والتضخم، والحاجة إلى تقدير دقيق للمعدلات واتجاه التضخم، فإنه يمكن استخدام تقنيات الذكاء الاصطناعي وتعلم الآلة لتوقع معدلات التضخم، إذ يمكن تطبيق هذه التقنيات في كلا المنهجيتين. كما أن تقنيات الذكاء الاصطناعي وتحديد الشبكات العصبية الاصطناعية لديها قابلية للتكيف والتعامل مع العلاقات غير الخطية؛ وبالتالي، فإنها تقدم نتائج أكثر دقة، وعند مقارنة نتائج الشبكة العصبية الاصطناعية بنتائج تقنيات الاقتصاد الكمي التقليدية، وجد (Cameron, Moshiri 1998) أن نماذج الذكاء

الاصطناعي المبنية على الشبكة العصبية الاصطناعية (RNN) Recurrent Neural Network تفوق النماذج التقليدية فيما يتعلق بأفاق التوقع قصيرة الأجل. كما انها تعتمد هذه الطرق على تحليل البيانات الكبيرة (Big Data Analysis) واستخلاص الأنماط والعلاقات المعقدة بين المتغيرات المختلفة.

يعد نموذج الذاكرة طويلة - قصيرة المدى (LSTM) احدى تقنيات الذكاء الاصطناعي وهو شكل من أشكال الشبكات العصبية الاصطناعية التي تستخدم في مجالات الذكاء الاصطناعي والتعلم العميق Deep learning¹. تعد شبكات LSTM مناسبة تماماً لتصنيف ومعالجة وإجراء التنبؤات بناء على بيانات السلاسل الزمنية، إذ أنها توفر ميزات إضافية تميزها عن نماذج الانحدار الخطي التقليدية. فعلى سبيل المثال تتيح هذه التقنية إمكانية النقاط نمط العلاقات غير الخطية المتجذرة بين المتغيرات والتي قد يعجز التحليل التقليدي عن إلتقاطها، إذ توفر هذه التقنية تقديرات دقيقة لهذه العلاقات بغض النظر عن مدى تعقيدها، فالنموذج يتعلم من تلقاء نفسه عن طريق إجراء تحليل عميق ومعقد للبيانات (Hochreiter, S., & Schmidhuber, 1997).

أثبتت نماذج الذاكرة طويلة- قصيرة المدى (LSTM) فعاليتها بشكل خاص في التعلم الآلي والتنبؤ، وبالتالي تم نمذجة التضخم المستقبلي باستخدام هذه الطريقة وباستخدام لغة Python، إذ تم اخذ الاعتبار لمجموعة من المتغيرات وفقاً للنظرية الاقتصادية التي يمكنها تفسير ديناميكية التضخم وهي الناتج المحلي الإجمالي وأسعار النفط وأسعار الغذاء وسعر الفائدة (Hira, 2021).

وعليه، اقترحت هذه الورقة طريقة جديدة لاعداد توقعات التضخم باستخدام تقنيات الذكاء الاصطناعي وهي نموذج الذاكرة طويلة - قصيرة المدى (LSTM)، وقامت بمقارنة نتائج التوقعات مع نتائج الطرق التقليدية مثل (ARMA) وتبين أن نتائج LSTM أفضل من حيث الدقة ومعايير الاداء.

¹ يوضح ملحق رقم (1) هذه المفاهيم بشكل مفصل.

2. الدراسات السابقة

إن التضخم هو سمة هامة يجب توقعها بدقة لكل بلد سواء كان متقدماً أو نامياً، وبالتالي، فإن توقع التضخم يشكل تحدياً كبيراً، ولذلك اتجهت الدراسات إلى تحليل التضخم بطرق عديدة ومبتكرة وذلك لتحسين التوقعات. فهدفت دراسة (Peirano et al., 2021) إلى تحسين توقعات التضخم في الدول اللاتينية باستخدام مزيج من نموذج (Seasonal Autoregressive Integrated Moving Average (SARIMA)) لتحليل السلاسل الزمنية ونموذج LSTM، إذ تم تطبيق هذه النماذج على بيانات التضخم في عدة دول لاتينية، وأظهرت النتائج تحسناً في دقة التوقعات مقارنة بالنماذج التقليدية. وتم استخدام نموذج (SARIMA) لنمذجة الأنماط الموسمية والتغيرات الزمنية في البيانات، بينما استخدم نموذج LSTM للتعامل مع العوامل غير الخطية والتفاعلات المعقدة، وساهم استخدام هذا النموذج المتكامل في تحسين سياسات النقدية التي تستهدف التضخم واتخاذ القرارات الاقتصادية المتعلقة بالتضخم في الدول اللاتينية.

كما هدفت دراسة (Hira, 2021) إلى تحقيق عدة أهداف، أولاً، تطوير نموذج هجين يجمع بين نموذج ARIMA ونموذج LSTM لتوقع التضخم بحيث يتم استخدام هذا النموذج الهجين لتحسين دقة توقعات التضخم وتحسين الأداء التنبؤي للنموذج. ثانياً، مقارنة أداء النموذج الهجين مع النماذج الفردية ARIMA و LSTM لتوقع التضخم. وتم تقييم الأداء باستخدام مقاييس مثل الخطأ المطلق المتوسط ((Mean Absolute Error (MAE)) والخطأ المطلق المتوسط ((Mean Absolute Percentage Error (MAPE)) والجذر التربيعي للخطأ المتوسط ((Root Mean Square Error (RMSE))، وقد أشارت نتائج الدراسة إلى أن النموذج الهجين يتفوق على النماذج الفردية في توقع التضخم في كل من الدول المتقدمة والنامية، وقد أظهر أفضل أداء عند استخدام نسبة 90% لبيانات التدريب و 10% لبيانات الاختبار. علاوة على ذلك، أظهر النموذج الهجين أداءً متفوقاً على النماذج الفردية عند استخدام نسبة 10% كبيانات اختبار في الدول المتقدمة والنامية.

كما هدفت الدراسة التي أجراها كل من (Tang et al., 2022) إلى توقع سلاسل زمنية لبيانات مالية باستخدام نموذج LSTM، وقام الباحثون بدراسة فعالية نموذج LSTM بتوقع مجموعة من البيانات المالية، وركزت الدراسة على معالجة التحديات التي تواجه توقع البيانات المالية، وقاموا بإجراء اختبارات لقياس دقة التوقع باستخدام مقاييس الأداء المعتمدة مثل الخطأ المطلق المتوسط والخطأ المطلق المئوي والخطأ المربعي المتوسط. أظهرت النتائج أن نموذج LSTM قدم توقعات أفضل لمتغيرات مالية مقارنةً بالنماذج التقليدية.

أما في حال استخدام LSTM لتوقع الناتج المحلي الإجمالي، فهدفت دراسة (Zhang et al., 2022) إلى توقع الناتج المحلي الإجمالي في الصين، باستخدام الذاكرة طويلة المدى ونموذج ماركوف المخفي للتنبؤ، وقارنت الدراسة القوة التنبؤية لـ LSTM-HMM بأنظمة التنبؤ الديناميكية الأخرى وذلك باستخدام مؤشر أسعار المستهلك الشهري والربع سنوي خلال فترة زمنية مدتها عشرة سنوات، بمعنى آخر تم استخدام التذبذبات في التضخم لتوقع الناتج المحلي الإجمالي. وأشارت النتائج إلى أنه من بين جميع النماذج يعمل LSTM بشكل عام بشكل أفضل من النماذج الأخرى وأنه يمكن تحسين أداء النموذج عندما يتم استخدام بيانات شهرية بدل من ربعية.

3. المنهجية وخطوات بناء النماذج

1.3 المنهجية المستخدمة

لأعداد توقعات التضخم في الأردن، تم تطبيق نماذج الذاكرة طويلة-قصيرة المدى LSTM، إذ تبين من خلال الدراسات السابقة أن هذا النموذج أثبت فعاليته بشكل خاص في التعلم الآلي والتنبؤ وبالتالي تم نمذجة التضخم المستقبلي باستخدام هذه الطريقة وباستخدام برمجية Python، وتم نمذجتها بطريقتين، الأولى باستخدام النمط المتعدد المتغيرات Multivariate Model، إذ تم الأخذ بعين الاعتبار مجموعة من المتغيرات، وفقاً للنظرية الاقتصادية والتي يمكنها تفسير ديناميكية

التضخم وهي الناتج المحلي الإجمالي وأسعار النفط العالمية وأسعار الغذاء العالمي وسعر الفائدة وباستخدام بيانات ربعية وشهرية، ممثلة بالمعادلة التالية (McLeay, Tenroyo, 2018) :

$$CPI = f (GDP, OIL, FOOD, INT) \dots (1)$$

أذن:

CPI: مؤشر أسعار المستهلكين (Consumer Price Index)، وهو مؤشر يستخدم لقياس التضخم في اقتصاد دولة معينة. يهدف CPI إلى قياس تغيرات أسعار مجموعة من السلع والخدمات الأساسية التي يشتريها المستهلكون خلال فترة زمنية معينة.

OIL: سعر النفط برنت (Brent crude oil price) هو سعر النفط الخام من نوع برنت، ويعتبر نفط برنت واحداً من أهم أنواع النفط الخام المتداولة عالمياً.

FOOD: سعر الغذاء وهو مؤشر يستخدم لقياس التغيرات في أسعار المواد الغذائية خلال فترة زمنية معينة.

INT: الوسط المرجح لسعر الفائدة على القروض والسلف.

أما الطريقة الثانية فتكون باستخدام سلسلة التضخم الشهرية نفسها وذلك من خلال النقاط التغيرات الزمنية أو الديناميكية في سلسلة البيانات. وفي كلتا الطريقتين تم تقسيم البيانات بحيث يستخدم جزء منها لتدريب الآلة (Train) وجزء للتحقق (Test) فتم استخدام 80% من البيانات لتدريب الآلة و 20% للتحقق. ومن ثم تم استخدام خوارزمية متوسط الخطأ التربيعي (MSE) لأجراء التحقق و خوارزمية التحسين آدم (Adam Optimization)، وذلك بهدف الوصول إلى أفضل نموذج بأقل أخطاء.

ولغايات مقارنة نتائج تنبؤ التضخم المتأتية من تطبيق نماذج الذاكرة طويلة - قصيرة المدى LSTM، مع النماذج التقليدية، تم تطبيق إحدى أهم الطرق الشائعة في هذا المجال وهي نموذج الانحدار الذاتي والمتوسط المتحرك ((Autoregressive Moving Average (ARMA)، إذ تعتمد هذه الطريقة على توصيف السلوك الزمني للمتغير المراد توقعه عن طريق مجموعة من النماذج الخطية ذات المتوسط المتحرك، وتشمل الخطوات الأساسية لنمذجة بوكس- جينكنز تحديد النموذج، وتقدير المعاملات، والتحقق من صحة النموذج، وإجراء التوقعات (Hira, 2021).


3-1-1 نموذج الذاكرة طويلة - قصيرة المدى (LSTM)

تعتبر الشبكات ذات الذاكرة الطويلة قصيرة المدى (LSTM) نوعاً محسناً من الشبكات العصبية التكرارية، ظهرت للمرة الأولى على يد العالمين جوزيف هورخيتز و يورغن شميتنوبر Sepp Hochreiter & Jürgen Schmidhuber في عام 1997، وتم صقلها ونشرها من قبل العديد من الأشخاص، وكان الهدف الرئيسي منها هو تفادي مشاكل الشبكات العصبية التراجعية وتحديدًا لتجنب مشكلة التبعية طويلة المدى (long-term dependency)² حيث أن تذكر المعلومات في هذه الشبكات لفترات طويلة من الزمن هو سلوك افتراضي.

تحتوي جميع الشبكات العصبية التكرارية على سلسلة من الأنماط التكرارية، وتكون هذه الأنماط في الشبكات العصبية التكرارية التقليدية على هيئة طبقة وحيدة من العصبونات التكرارية، أما الشبكات ذات الذاكرة الطويلة قصيرة المدى تحتوي على سلسلة أيضاً، ولكن شكل هذه السلسلة مختلف فهي تحتوي على أربع طبقات عوضاً عن طبقة واحدة، كما هو موضح في الاشكال التالية:


² هي مشكلة شائعة في تدريب الشبكات العصبونية، وتحدث عندما يصبح من الصعب على الشبكة التعرف على العلاقة بين المدخلات والمخرجات في الحالات التي تتضمن معلومات تتبع بعيداً عن المدخلات الحالية. ويمكن أن تؤدي هذه المشكلة إلى تدني الأداء العام للشبكة، وصعوبة تدريبها بشكل فعال. فعلى سبيل المثال، في مهمة التنبؤ بالكلمة التالية في جملة، يعتمد النتيجة المتوقعة بشكل كبير على الكلمات التي سبقتها في الجملة، والتي تمثل تبعية طويلة المدى. وعند استخدام الشبكات العصبونية التقليدية في هذه المهمة، يمكن أن تكون تبعية المدى الطويل صعبة التعلم، إذ أن الشبكة تحتاج إلى معالجة الكثير من البيانات التي تمتد عبر فترة زمنية طويلة.

الشكل (1): الشكل التكراري ضمن شبكة تكرارية بسيطة



المصدر: Colah, C. (2015). Understanding LSTM Networks

الشكل (2): الشكل التكراري لشبكة ذات ذاكرة طويلة قصيرة المدى تحوي أربع طبقات مترابطة



المصدر: Colah, C. (2015). Understanding LSTM Networks

الشكل (3): توضيح دلالات الرسوم



المصدر: Colah, C. (2015). Understanding LSTM Networks

في LSTM يتم استخدام خلايا لتخزين المعلومات بين التسلسلات الزمنية. وكل خلية تحتوي على حالة مخفية (Hidden State) وحالة خلية (Cell State)، وكلاهما مهم في تصميم الشبكات العصبية وتدريبها. يقصد بحالة الخلية (Cell State) هي الحالة التي تحتوي على المعلومات الأساسية التي يتم تخزينها في الخلية، وتعتبر مفتاح عمل الشبكات ذات الذاكرة طويلة قصيرة المدى حيث تشبه حزام النقل، إذ تنتقل عبر السلسلة بأكملها وتتعرض لتغييرات طفيفة أثناء تحركها، وبالتالي تعتبر وسيلة فعالة للحفاظ على المعلومات بلا تغيير، كما أن لديها قدرة على تخزين وتحميل معلومات ليست بالضرورة الأحداث السابقة مباشرة وإنما من جميع المعلومات التي

تم ادخالها. اما الحالة المخفية (Hidden State) فهي الحالة التي تعكس حالة الخلية والمعلومات الأخرى التي تم تمريرها إلى الخلية، وهي معنية فقط بنقل المعلومات من الأحداث السابقة مباشرة فقط. يوضح الشكل التالي حالة الخلية والحالة المخفية ضمن الشبكة، وباستخدام بنية تعتمد على البوابات المنطقية، تستطيع الشبكات ذات الذاكرة طويلة قصيرة المدى تغيير المعلومات داخل هذه الخلايا (Colah's blog, 2015).

الشكل (4): خلية الحالة والخلية المخفية



المصدر: Colah, C. (2015). Understanding LSTM Networks

وكما تعرف الحالة المخفية باسم الذاكرة قصيرة المدى وتعرف حالة الخلية باسم الذاكرة طويلة المدى، يبين الشكل السابق ان الحالة المخفية وحالة الخلية يمكن تمثيلها كالآتي:

H_{t-1} : الحالة المخفية للطابع الزمني السابق (Previous Timestamp).

H_t : الحالة المخفية للطابع الزمني الحالي (Current Timestamp).

C_{t-1} : حالة الخلية للطابع الزمني السابق (Previous Timestamp).

C_t : حالة الخلية للطابع الزمني الحالي (Current Timestamp).

تعتمد LSTM على بوابات للتحكم في تدفق المعلومات داخل الشبكة، وتتكون هذه البوابات من ثلاثة أجزاء رئيسية:

- بوابة النسيان (Forget gate): تسمح بحذف المعلومات غير الهامة من الخلية.
- بوابة المدخلات (Input gate): تسمح بإضافة المعلومات الجديدة إلى الخلية.
- بوابة المخرجات (Output gate): تسمح بتحديد المعلومات المهمة التي سيتم إخراجها من الخلية.

وباستخدام هذه البوابات، يتمكن نموذج LSTM من التعلم والتذكر لفترات طويلة من الزمن، مما يجعله قادراً على التعامل مع بعض المشكلات بشكل أفضل من الشبكات العصبية التقليدية، هذه


البوابات مكونة من مجموعة من الطبقات العصبية تنتهي بتابع التفعيل الأسّي الجيبي³ (Sigmoid) (σ) أو بتابع التفعيل الأسّي الظلي⁴ (Tanh) ومجموعة من عمليات الضرب الموجبة. تكون مخرجات طبقة تابع التفعيل الأسّي الجيبي بين الصفر والواحد، تحدد قيمته كمية المعلومات الواجب السماح بمرورها من كل عنصرٍ من عناصر الخلية (Colah'S blog, 2015).

خطوات عمل الشبكات ذات الذاكرة الطويلة قصيرة المدى LSTM

الخطوة الأولى (بوابة النسيان):

يتم في هذه الخطوة اتخاذ قرار حول المعلومات الواجب الاحتفاظ بها والمعلومات التي من الأفضل نسيانها من حالة الخلية، وتتم هذه العملية ضمن طبقة تابع التفعيل الأسّي الجيبي والتي تسمى بطبقة بوابة النسيان Forget Gate layer.

الشكل (5): طبقة بوابة النسيان



$$f_t = \sigma (W_f \cdot [h_{t-1}, x_t] + b_f) \dots\dots(2)$$

المصدر: Colah, C. (2015). Understanding LSTM Networks

إذ أن:

X_t : المدخلات من الطابع الزمني الحالي.

h_{t-1} : الحالة المخفية للطابع الزمني السابق.

w_f : الاوزان المرتبطة بالحالة المخفية والمدخلات.

إذ تعتمد المخرجات f_t على h_{t-1} و x_t وتكون قيمته بين 0 و 1.

³ هو دالة رياضية شائعة في الشبكات العصبية الاصطناعية، إذ يتم استخدامها كدالة تفعيل لتحديد ما إذا كانت المخرجات من الطبقة ستكون 0 أو 1، تعمل الدالة على تحويل القيم العددية غير المحدودة إلى قيم بين 0 و 1، إذ تقوم الدالة بتحويل البيانات إلى قيم [0,1] وفقاً للمعادلة التالية:

$$\text{sigmoid}(x) = 1/(1 + e^{-x})$$

⁴ هو أحد توابع التفعيل الشهيرة في الشبكات العصبية الاصطناعية. يتمثل تعريفه في تحويل القيم الناتجة من الوزن والإدخال (الإشارة المستلمة) بين الطبقات إلى نطاق قيم بين -1 و 1. صيغة الدالة الأسية الظلية Tanh هي:

$$\text{Tanh}(x) = (e^x - e^{-x}) / (e^x + e^{-x})$$

الخطوة الثانية (بوابة الإدخال):


بوابة الإدخال هي البوابة المسؤولة عن إضافة المعلومات إلى حالة الخلية، إضافة المعلومات هذه هي في الأساس عملية من خطوتين كما يتضح من الشكل التالي.

الخطوة الأولى: تنظيم القيم التي يجب إضافتها إلى حالة الخلية من خلال تابع التفعيل الأسّي الجيبي، وهذا يشبه إلى حد كبير بوابة النسيان .

الخطوة الثانية: إنشاء شعاع من القيم الجديدة المرشحة $\tilde{C}_t$ التي من المحتمل إضافتها إلى خلية الحالة من خلال طبقة تنتهي بتابع التفعيل الأسّي الظلي Tanh.

وفي الخطوة التالية سيتم دمج عمل الطبقتين لتعديل قيمة حالة الخلية.

الشكل (6): بوابة المدخلات وطبقة تابع التفعيل الأسّي الظلي



$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad \dots\dots(3)$$


$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad \dots\dots(4)$$

المصدر: Colah, C. (2015). Understanding LSTM Networks

الخطوة الثالثة:

يتم في هذه الخطوة تعديل قيمة حالة الخلية السابقة C_{t-1} إلى القيمة الجديدة C_t حيث تضرب قيمة الحالة القديمة بـ f_t ثم يتم إضافة $i_t * \tilde{C}_t$ وهي القيمة الجديدة الناتجة عن بوابة الإدخال.

الشكل (7): تعديل قيمة الحالة




$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad \dots\dots(5)$$

المصدر: Colah, C. (2015). Understanding LSTM Networks

الخطوة الرابعة (بوابة المخرجات):

هي البوابة التي يتم فيها تحديد المخرجات النهائية، وهي مبنية على مخرجات حالة الخلية ولكن بعد القيام ببعض التعديلات، وفي هذه الخطوة تختار الشبكة المعلومات المفيدة لاجراها ويبين الشكل التالي معادلات بوابة الإخراج، والتي تشبه إلى حد كبير البوابتين السابقتين (Colah, 2015) .

الشكل (8): مخرجات الخلية الفعلي h_t



$$o_t = \sigma(W_o [h_{t-1}, x_t] + b_o) \dots\dots(6)$$

$$h_t = o_t * \tanh(C_t) \dots\dots(7)$$

المصدر: Colah, C. (2015). Understanding LSTM Networks

2-1-3 نموذج الانحدار الذاتي والمتوسط المتحرك (Autoregressive Moving Average) ((ARMA)

لتحديد ما اذا كان النموذج المقترح يعطي نتائج افضل، قارنت الورقة نتائج LSTM بنتائج أحد النماذج التقليدية، وبالتالي طبقت الورقة نموذج (ARMA)، وهو نموذج إحصائي يُستخدم لتحليل السلاسل الزمنية. يستند النموذج على تكرار القيم الماضية للمتغير في توقع القيم المستقبلية، ويتم تحقيق ذلك عن طريق الجمع بين عنصرين رئيسيين: نموذج الانحدار الذاتي (Autoregressive AR) ونموذج المتوسط المتحرك (Moving Average MA)، وحسب المعادلة التالية:

$$y_t = c + \sum_{i=1}^p \varphi_i * y_{t-i} + \varepsilon_t + \sum_{i=0}^q \varphi_i * \varepsilon_{t-1} \dots\dots(8)$$

حيث:

y_t : هو القيمة الحالية للمتغير y .

φ_i هي معاملات الانحدار الذاتي.

ε_t : هو حد الخطأ العشوائي.

y_{t-i} : القيم المتأخرة للمتغير y .

2-3 خطوات بناء النماذج

تم القيام بمجموعة من الخطوات لنمذجة التضخم المستقبلي باستخدام المنهجيتين المذكورتين سابقا وباستخدام لغة Python⁵، إذ إنه وباستخدام هذه اللغة يتم استدعاء مجموعة من المكتبات⁶ والحزم⁷ التي تحتوي مجموعة من الوظائف والخوارزميات الضرورية لاجراء هذا النوع من التحليل ويمكن الاشارة الى هذه الخطوات كما يلي:

- 1- استدعاء جميع الحزم والمكتبات الضرورية الخاصة بلغة Python يوضح ملحق رقم (2) تفاصيل هذه الحزم والمكتبات التي سنحتاجها لتنفيذ شبكات LSTM و ARMA والتي يمكن عرضها كما يلي:

الجدول رقم (1): الحزم والمكتبات اللازمة لتنفيذ شبكات LSTM و ARMA

	LSTM	ARMA
Keras	√	
Numpy	√	√
Pandas	√	√
sklearn	√	
matplotlib	√	√

المصدر: اعداد الباحثة.

2- تحويل البيانات الى بيانات معيارية Normalization:

يتم في هذه الخطوة تحويل البيانات ضمن مجال محدد مثل [0, 1] أو [-1, 1]، إذ يتم تقليل القيمة الأصلية بالقيمة الدنيا لها وتقسيمها على الفرق بين القيمة العليا والدنيا (deepak, 2023).

⁵ بايثون (Python) : هي لغة برمجة عالية المستوى تم تطويرها في أوائل التسعينيات من قبل جويدو فان روسو (Guido van Rossum) تميزت بايثون بسهولة قراءة وكتابة الشيفرة وتوفرها للعديد من المكتبات والحزم التي تسهل تطوير تطبيقات متنوعة.

⁶ المكتبة (Library): هي مجموعة من الملفات والوظائف البرمجية المعدة مسبقا التي تسهل عملية البرمجة وتمكن من تنفيذ مهام معينة بسهولة دون الحاجة إلى إعادة كتابة الشيفرة من الصفر.

⁷ الحزمة (Package): هي توسيع لمفهوم المكتبة. وهي مجموعة من المكتبات المرتبطة ببعضها لتنفيذ وظيفة كبيرة أو تحقيق هدف محدد.

3- استخلاص جزء من البيانات لاجراء عملية التوقعات بعد تدريب النموذج والتأكد من ملائمته.

4- تقسيم البيانات إلى مجموعات تدريب ومجموعات اختبار (Training sets and Test sets) وهي عملية شائعة في مجالات التعلم الآلي وتحليل البيانات. يتم استخدام مجموعة التدريب لبناء نموذج تنبؤي، بينما يتم استخدام مجموعة الاختبار لتقييم دقة النموذج. وذلك للحصول على تقدير غير متحيز. تتم عملية تقسيم البيانات عادة بطريقة عشوائية باستخدام نسبة ثابتة من البيانات المخصصة لكل مجموعة، على سبيل المثال، نسبة 80-20 تعني استخدام 80% من البيانات للتدريب و20% للاختبار، وفي هذه الورقة تم استخدام 80% من البيانات لتدريب الالة و20% للتحقق.

5- التأكد من دقة النموذج: يتم استخدام خوارزمية متوسط الخطأ التربيعي (MSE) لتقييم دقة نموذج التنبؤ في عمليات التحقق والاختبار باستخدام مجموعة الاختبار. هذه الخوارزمية تحسب متوسط مربع الخطأ بين البيانات الفعلية والتنبؤات الناتجة عن النموذج. وتحتوي هذه الخوارزمية على خاصية تماثلية الخطأ الذي يتم حسابه، مما يساعد في إظهار الأخطاء الكبيرة والصغيرة بشكل عادل. ويتم حساب MSE عن طريق مقارنة التنبؤات الناتجة عن النموذج بالقيم الحقيقية الموجودة في مجموعة الاختبار، ثم رفع الفروق الناتجة بين هذه التنبؤات والقيم الحقيقية إلى الأس الثاني (أو مربعها) ومن ثم حساب المتوسط الحسابي لهذه الفروقات أو الأخطاء (free Code Camp, 2018).


4- نتائج الدراسة

1-4 نتائج تقدير نموذج الذاكرة طويلة- قصيرة المدى (LSTM)

1-1-4 باستخدام بيانات شهرية (Multivariate Model)

تم تقدير التضخم لكل من أشهر تشرين الاول وتشرين الثاني وكانون الاول من عام 2022 وذلك قبل صدورها من قبل دائرة الاحصاءات العامة، ومن ثم مقارنتها مع البيانات الفعلية بعد صدورها بالكامل مطلع عام 2023. إذ تم استخدام بيانات شهرية لكل من الناتج وسعر الفائدة وسعر الغذاء والنفط، وأشارت النتائج بأن التضخم سينمو بمقدار 4.4% على اساس سنوي في عام 2022، وفيما يتعلق في أشهر التقدير فيتوقع ان تنمو بمقدار 5.7%، 6.1%، 5.4% لكل من أشهر تشرين الاول وتشرين الثاني وكانون الاول في عام 2022 على التوالي.

الشكل (9): نتائج تقدير نموذج (LSTM) باستخدام بيانات شهرية (Multivariate Model)




المصدر: اعداد الباحثة.

2-1-4 باستخدام بيانات ربعية (Multivariate Model)

تم تقدير التضخم للربع الاخير من عام 2022، وأشارت نتائج التقدير من خلال استخدام بيانات ربعية لكل من الناتج وسعر الفائدة وسعر الغذاء والنفط، بان التضخم سينمو بمقدار 4.6%

على اساس سنوي في عام 2022، لتصل قيمة مؤشر اسعار المستهلك في الربع الاخير من عام 2022 الى 109.3.


الشكل (10): نتائج تقدير نموذج (LSTM) باستخدام بيانات ربعية (Multivariate Model)



3-1-4 باستخدام بيانات شهرية (Constant Models)

اشارت نتائج التقدير وذلك باستخدام بيانات شهرية للمتغير نفسه فقط بان التضخم سينمو بمقدار 4.2% على اساس سنوي في عام 2022.


الشكل (11): نتائج تقدير نموذج (LSTM) باستخدام بيانات شهرية (Constant Models)



2-4 نموذج الانحدار الذاتي والمتوسط المتحرك (Autoregressive Moving Average) ((ARMA)

اشارت نتائج التقدير وذلك باستخدام بيانات شهرية للمتغير نفسه فقط بان التضخم سينمو بمقدار 4.3% على اساس سنوي في عام 2022.

الشكل (12): نتائج تقدير نموذج (ARMA) باستخدام بيانات شهرية (Constant Models)



المصدر: اعداد الباحثة.

وفيما يلي ملخص لنتائج تقدير النماذج:

الجدول رقم (2): ملخص لنتائج تقدير النماذج LSTM و ARMA


النموذج	Inflation 2022
LSTM MODEL	
بيانات ربعية (Multivariate Model)	4.6
بيانات شهرية (Multivariate Model)	4.4
بيانات شهرية (Constant Models)	4.2
ARMA	
بيانات شهرية (Constant Models)	4.3
ملخص النماذج	(4.6 - 4.2)
البيانات الفعلية (Actual data)	4.2

المصدر: اعداد الباحثة.

3-4 التأكد من دقة النموذج: تم استخدام خوارزمية متوسط الخطأ التربيعي (MSE)


تم تدريب كل نموذج من نماذج LSTM عدة مرات، للحصول على أدنى قيمة لمتوسط الخطأ التربيعي (MSE) وظهرت النتائج أنه في كل مرة تم إعادة تدريب وتعليم النموذج تم الحصول على قيم أقل لمتوسط الخطأ التربيعي، وعند اعتماد النموذج لأفضل محاولة تم الحصول عليها تم اجراء التوقعات بناءً عليها، فتبين ان تقدير نموذج LSTM باستخدام بيانات شهرية (Constant Models) اعطى اقل قيمة وهي 0.0136، وبناء عليه يمكن الاعتماد على هذا النموذج لاجراء توقعات دورية للتضخم، كونه ايضا كان اقرب توقع من بين النماذج عند مقارنته بالبيانات الفعلية، تبين الاشكال من (13-14) قيم MSE في كل مرة تم فيها إعادة تدريب النماذج الثلاث، ويبين الجدول رقم (3) مقارنة قيم MSE التي تم الاعتماد عليها في الطرق الثلاث من خلال نموذج LSTM بالاضافة الى نتائج MSE لنموذج ARMA:

الشكل (13): نتائج MSE لنموذج (LSTM) باستخدام بيانات ربعية (Multivariate Model)




المصدر: اعداد الباحثة.

الشكل (14): نتائج MSE لنموذج (LSTM) باستخدام بيانات شهرية (Multivariate Model)



المصدر: اعداد الباحثة.

الشكل (15): نتائج MSE لنموذج (LSTM) باستخدام بيانات شهرية (Constant Models)



المصدر: اعداد الباحثة.

الجدول رقم (3): نتائج مقارنة قيم MSE لنماذج LSTM و ARMA

MSE	النموذج
LSTM MODEL	
0.0204	بيانات ربعية (Multivariate Model)
0.0175	بيانات شهرية (Multivariate Model)
0.0136	بيانات شهرية (Constant Models)
ARMA	
0.185	

المصدر : اعداد الباحثة.

5- التوصيات

- بناء على نتائج الدراسة يتضح ان نموذج الذاكرة طويلة قصيرة المدى (LSTM) يعطي توقعات اقرب ما يمكن للواقع، وبناء عليه توصي الدراسة بما يلي:
- استخدام تقنيات LSTM في التوقعات الاقتصادية، إذ يمكن للمؤسسات المالية والاقتصادية استغلال نماذج LSTM لتحسين توقعاتها بشأن أداء الأسواق المالية والتغيرات الاقتصادية، مما قد يساهم في اتخاذ قرارات أكثر دقة وفهم أفضل للاتجاهات المستقبلية.
 - تعزيز استخدام الذكاء الاصطناعي في الأبحاث الاقتصادية والمالية، إذ يمكن للباحثين في مجال الاقتصاد والمالية الاستفادة من تقنيات الذكاء الاصطناعي، لتوفير توقعات ذات جودة عالية لتلبي احتياجات مستخدمي البيانات وأصحاب القرار في اتخاذ القرارات المناسبة.
 - تعزيز التعليم والتدريب في مجالات تكنولوجيا المعلومات والذكاء الاصطناعي للعاملين في مجال الاقتصاد والمالية. مما قد يؤهلهم لاستخدام التقنيات المتقدمة بشكل أفضل وتطبيقها بنجاح.

CBJ Working Paper

The headline inflation rate forecasts using the Long Short-Term Memory (LSTM) Model.**Prepared by:****Amany Al-Rawashdeh****August 2023**

The Views in this working paper are solely the responsibility of the author(s) and do not reflect the views of the Central Bank of Jordan, its board of director, or CBJ management.

Abstract

The paper proposes a new method to forecast the inflation in Jordan using artificial intelligence. The paper uses (Long Short Term Memory (LSTM)) to predict inflation for the year 2022 and compares the results with (Autoregressive Moving Average (ARMA)) model.

The results show that LSTM-based inflation forecasting is more accurate and closer to actual data, especially when using the Constant Model with monthly data. In this case, the inflation rate forecasted was 4.2% in 2022, which is the same inflation rate recorded for the year 2022 and issued by the Department of Statistics. In comparison, the forecasted inflation rate using ARMA was 4.3% for 2022. Therefore, the constant model appears to be better for making predictions, and LSTM outperforms ARMA in terms of accuracy.

keywords: Inflation Rate, Artificial Intelligence, Long Short-Term Memory (LSTM) model, Autoregressive Moving Average (ARMA) model.

JEL Classification: E31, E37, C01.

المصادر والمراجع:

- Bishop, C. M. (1995). *Neural Networks for Pattern Recognition*. Oxford University Press.
- Colah, C. (2015). Understanding LSTM Networks. [Understanding LSTM Networks -- colah's blog](#).
- Coursee. (2022). Programming: Keras Lessons - What is Keras? <https://coursee.org/blog/programming/keras-lessons-what-is-keras/>
- Deepak_jain. (2023). Data Normalization in Data Mining. *Data Normalization in Data Mining - GeeksforGeeks*.
- Free Code Camp. (2018). Machine learning: an introduction to mean squared error and regression lines. <https://www.freecodecamp.org/news/machine-learning-mean-squared-error-regression-line-c7dde9a26b93/>.
- Goodfellow, I., Bengio, Y., Courville, A., & Bengio, Y. (2016). *Deep Learning*. MIT Press.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.
- Jamil, Hira. (2021). "Inflation Forecasting using HYBRID ARIMA-LSTM Model." *Master's thesis in Computational Sciences, Faculty of Graduate Studies, Laurentian University, Sudbury, Ontario, Canada*.
- Jason Brownlee. (2017). *A Gentle Introduction to Long Short-Term Memory Networks by the Experts*.
- Kevin P. Murphy (2012), *Machine Learning: A Probabilistic Perspective*.
- McLeay, M., & S Tenroyo (2018). "Optimal Inflation and the Identification of the Phillips Curve".
- Michail Copeland. (2017). The Difference Between AI, Machine Learning, and Deep Learning? <https://blogs.nvidia.com/blog/2016/07/29/whats-difference-artificial-intelligence>.
- Moshiri, S., & Cameron, N. (1998). *Neural Network vs Econometric Models in Forecasting Inflation*.

- Nielsen, M. (2015). *Neural Networks and Deep Learning: A Textbook*. Determination Press.
- NumPy community. (2020). NumPy User Guide.
- Peirano, R., Kristjanpoller, W., & Minutolo, M. C. (2021). Forecasting inflation in Latin American countries using a SARIMA–LSTM combination. *Soft Computing*, 25, 10851-10862.
- Russell, S. J., & Norvig, P. (2016). *Artificial Intelligence: A Modern Approach* (3rd ed.). Prentice Hall.
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks*, 61, 85-117.
- Stuart Russell and Peter Norvig. (2010). *Artificial Intelligence: A Modern Approach* (3rd edition).
- Tang, Q., Fan, T., Shi, R., Huang, J., & Ma, Y. (2022). Prediction of financial time series using LSTM and data denoising methods. *International Journal of Finance and Economics*, 25(3), 456-472.
- Zhang, J., Wen, J., & Yang, Z.-Q. (2022). China's GDP forecasting using Long Short Term Memory Recurrent Neural Network and Hidden Markov Model. *Expert Systems with Applications*, 105, 198-210.

ملحق رقم (1)

مفهوم الذكاء الاصطناعي وتعلم الآلة و الشبكات العصبية

بعد التعرف على مفاهيم الذكاء الاصطناعي وتعلم الآلة والشبكات العصبية الاصطناعية أساسيا لفهم نموذج الذاكرة طويلة قصيرة المدى (LSTM)، إذ ان نماذج LSTM تعتمد على استخدام استخدام الشبكات العصبية الاصطناعية، والتي هي شكل من اشكال التعلم العميق الذي ينتمي الى تعلم الآلة، لذلك سيتم عرض هذه المفاهيم كما يلي:

أولاً: مفهوم الذكاء الاصطناعي

يعتبر الذكاء الاصطناعي فرع من فروع العلوم الحاسوبية ويُعنى بدراسة كيفية تمكين الحواسيب والآلات من تنفيذ المهام التي تتطلب الذكاء بطريقة مشابهة للإنسان. يتمحور هذا الفرع حول تطوير الأنظمة والخوارزميات التي يمكنها التعلم من البيانات وتحسين أدائها مع مرور الوقت.

يعتمد الذكاء الاصطناعي على استخدام تقنيات مثل التعلم العميق "Deep Learning"، وتحليل البيانات "Data Analytics"، والتعلم الآلي "Machine Learning"، والشبكات العصبية "Neural Networks"، والتعلم التعاوني "Reinforcement Learning" وغيرها. تستخدم هذه التقنيات في تحليل وفهم النصوص والصور والأصوات والفيديو وتحديد الأنماط والتوقعات والتفاعل مع البيئة.


يستخدم الذكاء الاصطناعي في العديد من التطبيقات العملية، مثل تحليل البيانات الكبيرة "Big Data Analytics"، والتحكم الآلي في الصناعة والروبوتات، والتعرف على الأصوات والكلام، والترجمة الآلية، وتحسين عمليات التشخيص الطبي، وغيرها (Russell, Norvig, 2016).

يمكن القول أن الذكاء الاصطناعي يعد واحدا من أسرع المجالات التقنية نموا حاليا ويتوقع العديد من الخبراء أن يكون له دور هام في مستقبل البشرية وتحديدا في مجالات مثل الطب والاقتصاد والتعليم والصناعة

ثانياً: مفهوم تعلم الآلة Machine Learning

التعلم الآلي: هو أحد فروع الذكاء الاصطناعي (AI) التي تهتم بتصميم وتطوير الخوارزميات والتقنيات التي تسمح للحاسوب بامتلاك خاصية التعلم، كما تتيح للآلات إجراء تنبؤات دقيقة عند تغذيتهم بالبيانات.

يتداخل “علم الآلة” مع علم إحصاء الحوسبة Computational Statistics. ويهتم بصنع التنبؤات من خلال استخدام الحاسب، ويرتبط بعلم التحسين الرياضي Mathematical Optimization، الذي يركز على اختيار البديل الأفضل من بين العديد من البدائل المتاحة. المهمة الأساسية للتعلم الآلي هو استخراج معلومات قيمة من مجموعة من البيانات ثم الاستفادة منها في بناء نموذج قادر على التنبؤ بشكل البيانات الجديدة كما في الشكل التالي، بمعنى آخر إذا استطاع برنامج حاسوبي تنفيذ مهام معينة بالاستفادة من خبرة سابقة فيمكننا أن نقول إنه تعلم (Goodfellow et al., 2016).




ثالثاً: مفهوم الشبكات العصبية (Artificial Neural Networks)

الشبكات العصبية (Artificial Neural Networks) هي أنظمة بعقد مترابطة مكونة من عدة طبقات، تؤدي الشبكات العصبية مهامها مثل الخلايا العصبية في دماغ الإنسان بواسطة خوارزميات معينة، وتتعرف تلك الخوارزميات على الأنماط المخفية في البيانات الخام وتقسمها في مجموعات وتصنفها. ومع مرور الوقت تتعلم تلك الشبكات ويتحسن أدائها تدريجياً. تُعتبر الشبكات العصبونية من أقوى الأدوات المستخدمة في مجال الذكاء الاصطناعي وتعلم الآلة، فهي قادرة على التعلم وتصنيف الأنماط بكفاءة عالية، كما أنها تتحلّى بقدر عالٍ من الديناميكية (Schmidhuber, 2015).


ولكن الشبكات العصبونية التقليدية تقتصر إلى القدرة على التخزين وربط الأحداث ببعضها، فمثلاً من السهل على شبكة عصبية ما التمييز بين نوعين مختلفين من الفواكه، ولكن من الصعب عليها توقع أسعار البورصة أو إكمال النصوص تلقائياً، وهنا تكمن أهمية الشبكات

العصبية التكرارية RNN، فاحتواؤها على ذاكرة يجعل منها أداة فعالة في توقع الأحداث المتتالية، ويفتح مجالاً جديداً بشكل كلي لطرق جديدة في تعليم الآلة (Bishop, 1995).

الشبكات العصبية التكرارية (RNN)، هي شبكات بها حلقات بداخلها، مما يسمح للمعلومات بالبقاء، يمثل الشكل التالي جزء من الشبكة العصبية، إذ تمثل x_t المدخلات و h_t المخرجات، تسمح الحلقة A بتمرير المعلومات من مرحلة واحدة في الشبكة إلى المرحلة التالية. ويمكن اعتبار الشبكة العصبية المتكررة على أنها نسخ متعددة من نفس الشبكة، كل منها تنقل رسالة إلى خليفاتها:



تكشف هذه الطبيعة الشبيهة بالسلسلة أن الشبكات العصبية المتكررة مرتبطة ارتباطاً وثيقاً بالسلاسل والقوائم وإنها البنية الطبيعية للشبكة العصبية لاستخدامها في مثل هذه البيانات. كان هناك نجاح لا يصدق في تطبيق RNNs على مجموعة متنوعة من المشاكل: التعرف على الكلام، ونمذجة اللغة، والترجمة، والتعليق على الصور، من ضمن هذه التطبيقات ل RNN استخدام "LSTMs"، وهو نوع خاص جداً من الشبكات العصبية المتكررة التي تعمل العديد من المهام، أفضل بكثير من الإصدار القياسي. (Nielsen, M. 2015).



ملحق (2)

المكتبات والحزم التي تم استدعائها لتنفيذ النماذج

- مكتبة Keras : هي مكتبة مفتوحة المصدر لبناء النماذج العصبية والتي توفر واجهة برمجية بسيطة وسهلة الاستخدام لبناء النماذج العصبية المختلفة بما في ذلك شبكات LSTM. تعد Keras جزءاً من TensorFlow الذي يعد إطار عمل للتعلم العميق، تم تصميم Keras لتبسيط عملية بناء النماذج العصبية، وتوفر مجموعة واسعة من الطبقات الجاهزة والتي يمكن استخدامها في بناء النماذج بدون الحاجة إلى برمجة الطبقات من الصفر، بالإضافة إلى ذلك فإن Keras يوفر واجهة سهلة الاستخدام لتحديد المعلمات المختلفة للنموذج وتدريبه. (Coursee, 2022)
- مكتبة Numpy: هي مكتبة للحسابات العلمية، وتعتبر أساسية للعديد من حزم التعلم العميق ومعالجة البيانات، تتيح للمستخدمين إمكانية العمل مع بيانات متعددة الأبعاد، وتوفر العديد من الدوال المتخصصة في الحسابات العلمية مثل الجبر الخطي والتحويلات الرياضية والإحصاءات الحسابية والعديد من الأدوات الرياضية الأخرى، تعتبر NumPy هامة جداً في تعلم الآلة والتعلم العميق، إذ يمكن استخدامها للعمل على البيانات متعددة الأبعاد، مثل تحميل وتنظيم البيانات من الذاكرة، وتطبيق عمليات الجبر الخطي على البيانات مثل الضرب والجمع والطرح، وتطبيق العديد من العمليات الإحصائية مثل الانحراف المعياري والتباين والمتوسط والتوزيعات الإحصائية. (NumPy community, 2020)
- مكتبة Pandas: هي مكتبة في Python تستخدم لمعالجة البيانات، وتعتبر واحدة من أكثر المكتبات استخداماً في تحليل البيانات وتعلم الآلة. تستخدم Pandas لتحليل وتنظيم البيانات، وتسمح بالتعامل مع البيانات الموجودة في ملفات CSV و Excel و SQL وغيرها، وتعمل على تقديم بنية بيانات متعددة الأبعاد مثل DataFrame و Series. تتيح للمستخدمين إمكانية العمل مع البيانات بشكل سهل وسريع، وتتضمن مجموعة كبيرة من الدوال المتخصصة في تحليل وتعديل البيانات، مثل تحويل البيانات وإزالة البيانات المكررة وتعديل الأعمدة والصفوف والفلاتر، والعديد من الدوال الإحصائية المتخصصة في تحليل البيانات، يتم استخدام Pandas بشكل واسع في مختلف المجالات التي تتطلب معالجة البيانات، مثل تحليل البيانات المالية والاقتصادية وتحليل البيانات العلمية وتحليل البيانات الإحصائية. كما تستخدم Pandas في تعلم الآلة والتعلم العميق، إذ يمكن استخدامها لتحميل وتنظيم البيانات وتطبيق العديد من الدوال الإحصائية والتحليلية على البيانات. (McKinney, 2011)

- مكتبة sklearn المعروفة أيضا بـ Scikit-Learn: هي واحدة من أدوات التعلم الآلي الأكثر شهرة واستخداما في عالم علم البيانات والذكاء الاصطناعي. تقدم هذه المكتبة تجميعا كبيرا من الخوارزميات والوظائف التي تجعل من السهل تطوير وتنفيذ النماذج الإحصائية والتنبؤية على البيانات. يمكن استخدامها في مجموعة متنوعة من المهام مثل التصنيف والتحليل التنبؤي وتجميع البيانات وتقليل الأبعاد وغيرها. يعزز استخدام Scikit-Learn الدقة في تطبيق الذكاء الاصطناعي . (Coursee, 2022)
- مكتبة Matplotlib: هي أداة قوية في لغة Python لرسم الرسومات والمخططات، تمكن المستخدمين من إنشاء وتخصيص مختلف أنواع الرسومات بسهولة، مما يساعد في تصوير البيانات بشكل بصري وفهمها بشكل أفضل. تُستخدم على نطاق واسع في مجالات علم البيانات والبحث العلمي وتحليل البيانات وتمثيلها بطرق جذابة وقوية. (Coursee, 2022)