

دراسة تقنيات التنبؤ بالسلاسل الزمنية

المشرف العلمي: أ.د. كمال السلوم *

إعداد طالبة الماجستير: م. نرمين أحمد الخضر **

الملخص

التنبؤ بالسلاسل الزمنية يعني التنبؤ بالقيمة المستقبلية على مدى فترة من الزمن. ويستلزم تطوير نماذج بناءً على البيانات السابقة وتطبيقها لإبداء الملاحظات وتوجيه القرارات الاستراتيجية المستقبلية. تتضمن العديد من مشكلات التنبؤ عنصراً زمنياً، وبالتالي تتطلب استقراء بيانات السلاسل الزمنية، ونظراً لما له من أهمية كبيرة فتتعدد طرائق التنبؤ بالسلاسل الزمنية فمنها الطرائق الاحصائية التقليدية ومنها التعلم العميق حيث تم في هذا البحث التنبؤ بعدد المكالمات الواردة الى مقسم المحطة باستخدام السلاسل الزمنية فمن اجل ذلك تم استخدام مزيج من الخوارزميات الاحصائية التقليدية و التعلم العميق وهي Exponential Auto Regressive Integrated Moving Average و prophet و Smoothing Recurrent Neural Network و prophet و من ثم المقارنة بين النتائج التي تم الحصول عليها من قبل كل خوارزمية على حدى وذلك باستخدام معيار Mean Squared Error كما تم اجراء تجارب مستقلة لمعرفة تأثير عمق الشبكات العصبونية التكرارية RNN على التنبؤ بعدد المكالمات الواردة الى مقسم المحطة وقد اثبتت النتائج ان خوارزمية ARIMA قد كانت الأفضل وذلك بمقدار خطأ MSE قدره 33346.7 متفوقاً بذلك على جميع الخوارزميات المستخدمة ضمن هذا البحث بما فيها شبكة RNN-LSTM.

الكلمات المفتاحية: السلاسل الزمنية، القطاعات الخدمية، مقسم المحطة، ARIMA,

RNN, Prophet, ES

Study of time series forecasting techniques

Abstract

Time series forecasting means predicting future value over a period of time. It entails developing models based on previous data and applying them to make observations and guide future strategic decisions. Many forecasting problems include a time element, and therefore require extrapolation of time series data. Given its great importance, time series forecasting methods have varied, including traditional statistical methods, including deep learning. In this research, the number of incoming calls to the station exchange was predicted using time series, in order to A combination of traditional statistical algorithms and deep learning was used, namely Auto Regressive Integrated Moving Average, Exponential Smoothing, Recurrent Neural Network, and Profet, and then comparing the results obtained by each algorithm separately, using the Mean Squared Error standard. Experiments were also conducted. Independently, to determine the effect of the depth of recursive neural networks (RNN) on predicting the number of incoming calls to the station exchange. The results proved that the ARIMA algorithm was the best, with an MSE error of 33346.7, superior to all algorithms used in this research, including the RNN-LSTM network.

Keywords: time series, service sectors, station divider, ARIMA, RNN, Prophet, ES

1. المقدمة

تشهد نسبة الخدمات في الاقتصاد العالمي نمواً سريعاً خلال القرن العشرين. فعلى سبيل المثال، استأثر قطاع الخدمات في الولايات المتحدة أكثر من نصف الناتج المحلي الإجمالي في عام 1929 م، والثلاثين في سنة 1978 م، وأكثر من ثلاثة أرباع في عام 1993 م. في أوائل القرن الحادي والعشرون، صناعة الخدمات تمثل أكثر من ثلاثة أخماس الناتج المحلي الإجمالي العالمي، ويوظف هذا المجال أكثر من ثلث القوى العاملة في جميع أنحاء العالم.[1]

قطاعات الخدمات تشمل الخدمات المصرفية والاتصالات وتجارة الجملة والتجزئة، وجميع الخدمات المدنية مثل الهندسة، برمجة الحاسوب، الطاقة الكهربائية والمائية، الاتصالات، الطب، والنشاطات الاقتصادية غير الربحية كخدمة العملاء.

تعد هيمنة الاقتصاد على الخدمات من سمات الدول المتقدمة. وهنا تبرز الحاجة الماسة إلى أدوات تنبؤ دقيقة وفعالة، خصوصاً في القطاعات الخدمية التي تشكل جزءاً كبيراً من الاقتصاد العالمي. تعتبر السلاسل الزمنية أداة حاسمة في هذا السياق، حيث تسمح بتحليل البيانات الزمنية واستخلاص الأنماط التي تتبعها المؤشرات الاقتصادية والاجتماعية على مر الزمان. هذه الأنماط، عندما يتم تفسيرها بدقة، تقدم رؤى قيمة للتنبؤ بالتوجهات المستقبلية واتخاذ القرارات الاستراتيجية.

من خلال استخدام تقنيات التنبؤ بالسلاسل الزمنية، يمكن للمؤسسات الخدمية تحسين قدرتها على التخطيط للطلب، إدارة المخزون، وتقديم خدمات أفضل للعملاء. علاوة على ذلك، يسهم استخدام هذه التقنيات في تقليل التكاليف وزيادة الكفاءة، مما يعزز من قدرة هذه المؤسسات على التنافس في سوق متغير ومليء بالتحديات.

2. مشكلة البحث

تعد مشكلة التنبؤ بالسلاسل الزمنية من أبرز المشاكل التي اثارت اهتمام الباحثين وخاصة في مجال القطاعات الخدمية لما لها من وضع خاص ومازال البحث عن مصنفات قادرة على التنبؤ بالسلاسل الزمنية في القطاعات الخدمية بأفضل شكل ممكن جار الى حد الآن.

3. هدف البحث

يهدف البحث بشكل رئيسي الى التنبؤ بالسلاسل الزمنية للقطاعات الخدمية في الجمهورية العربية السورية حيث تم اختيار قسم المحطة كحالة دراسة للتنبؤ بعدد المكالمات الواردة الى القسم ودراسة احتياج المقسم لمعدات اضافية وذلك باعتماد مزيج من خوارزميات التنبؤ بالسلاسل الزمنية سواء الطرق التقليدية أو باستخدام شبكة RNN-LSTM واجراء مقارنة لمعرفة الخوارزمية الأفضل اداء.

4. مقسم الهاتف

مقسم الهاتف هو نظام للاتصالات يُستخدم في شبكة الهاتف العامة المبدلة أو في المؤسسات الكبيرة. يتم من خلاله توصيل خطوط المشتركين بالهواتف أو الدوائر الافتراضية للأنظمة الرقمية لإنشاء مكالمات هاتفية بين المشتركين. تاريخياً، كانت مقاسم الهاتف تُدار يدوياً بواسطة مُشغلين يستخدمون لوحات التبديل؛ ومع ذلك، فإن المقاسم الحديثة مؤتمتة وتعمل إلكترونياً.

الوظيفة الأساسية لمقسم الهاتف هي إدارة توجيه المكالمات الهاتفية في المنطقة المحلية التي يخدمها. يضمن توصيل المكالمات من مشترك إلى آخر مباشرة، ويتم تمرير المكالمات إلى مناطق أخرى إلى مقسم آخر. يستخدم المقسم طريقة من تكنولوجيا معالجة الإشارات لتوجيه المكالمات، والتي يتم تسهيلها من خلال استخدام نقاط التبديل وقواعد البيانات التي تدير منطق توصيل المكالمات.

كما يوفر مقسم الهاتف خدمات مثل تحويل المكالمات، البريد الصوتي، انتظار المكالمات، والمؤتمرات، إلى جانب ميزات أخرى يمكن برمجتها في المقسم [3] [2].

5. السلاسل الزمنية

السلسلة الزمنية هي تسلسل لنقاط البيانات المسجلة على فترات زمنية، تمثل سلوك الظواهر المختلفة كما تتغير بمرور الوقت. يكون هذا النوع من البيانات مفيداً بشكل

خاص في مجالات مثل الاقتصاد، والتمويل، ودراسات البيئة، والهندسة، حيث تكون الأنماط على مر الزمن حاسمة للتنبؤ وتحليل الاتجاهات واتخاذ القرارات.

5.1 مكونات السلسلة الزمنية

تحتوي السلسلة الزمنية النموذجية على أربعة مكونات رئيسية:

1. الاتجاه (Trend): يمثل هذا التقدم طويل الأمد للسلسلة. يمكن أن تكون الاتجاهات تصاعدية، أو تنازلية، أو حتى أفقية/ثابتة، مما يعكس الزيادات المنهجية، أو الانخفاضات، أو الاستقرار في البيانات بمرور الوقت.
2. الموسمية (Seasonality): هذه هي الأنماط التي تتكرر بانتظام، مثل اليومية، والأسبوعية، والشهرية، أو الفصلية. الموسمية تعكس التأثيرات التي تحدث في أوقات محددة ويمكن أن تكون مهمة جداً للأعمال التي تتأثر بالعوامل الموسمية.
3. الدورات (Cycles): هذه هي التقلبات التي تحدث على مدى فترات أطول من التأثيرات الموسمية. على عكس الموسمية، هذه الدورات ليست ذات فترات ثابتة ويمكن أن تختلف في المدة، غالباً ما تتأثر بدورات الأعمال أو الظروف الاقتصادية. تعبر عن تغيرات تطرأ بسبب الظروف والتي تتكرر بشكل دوري. يمكن أن تكون هذه الدورة عدة سنوات.

4. العشوائية أو الضوضاء (Irregularity) : هذا المكون هو التباين العشوائي في

السلسلة، غالبًا ما يكون ناتجًا عن أحداث غير متوقعة أو عشوائية. الضوضاء

هي مكون من السلسلة الزمنية الذي عادةً ما يكون غير قابل للتنبؤ ولا يمكن

وصفه بشكل منهجي.

5.2 أنواع السلسلة الزمنية

يمكن تصنيف بيانات السلسلة الزمنية بناءً على استقرارها، الموسمية، وما إذا كان يمكن

تفكيكها بطريقة جمعية أو ضربية:

1. سلاسل زمنية ثابتة (Stationary): تلك التي تظل خصائصها مثل الوسط

والتباين ثابتة على مر الزمن .

2. سلاسل زمنية غير ثابتة (Non-stationary): تلك التي تتغير خصائصها مع


الزمن [4][5].

5.3 مثال عن السلاسل الزمنية

أرباح شركة جونسون آند جونسون الأميركية ربع السنوية للسهم الواحد، 84 ربعاً، من

عام 1960 إلى عام 1980 التي قدمها البروفيسور بول غريفين (الاتصالات الشخصية)

من كلية الدراسات العليا للإدارة، جامعة كاليفورنيا، ديفيس كما هو موضح في الشكل 1.



شكل 1 أرباح شركة جونسون آند جونسون الأميركية ربع السنوية للسهم الواحد، 84 ربعاً، من عام 1960 إلى عام 1980 [7]

6. خوارزميات التنبؤ بالسلاسل الزمنية

تقسم خوارزميات التنبؤ بالسلاسل الزمنية الى مجموعة كبيرة وقد تم اختيار اربع خوارزميات التي تخدم هدف البحث.

6.1 نموذج ARIMA

نموذج ARIMA ، وهو اختصار لـ النموذج التكاملي المتوسط المتحرك ذاتي الارتباط (Auto Regressive Integrated Moving Average) وهو أحد النماذج الإحصائية المستخدمة في تحليل وتنبؤ السلاسل الزمنية. يعتبر نموذج ARIMA مفيداً خصوصاً للبيانات التي تظهر اتجاهات غير موسمية أو موسمية والتي قد تكون غير ثابتة مع مرور الوقت.

. ويتم تعريف نموذج ARIMA عادةً على أنه $ARIMA(p, d, q)$ ، حيث:

- p هو عدد ملاحظات التأخر المضمنة في النموذج $AR(p)$
- d هو عدد المرات التي اختلفت فيها الملاحظات الأولية (درجة الاختلاف) $I(d)$
- q هو حجم نافذة المتوسط المتحرك $MA(q)$

كيفية عمل نموذج: ARIMA

لتطبيق نموذج ARIMA ، يتم اتباع الخطوات التالية:

1. التحقق من ثبات السلسلة الزمنية: إذا لم تكن السلسلة ثابتة، يتم أخذ الفروقات لجعلها كذلك.

2. تحديد المعاملات d, p, q : يتم تحديد هذه المعاملات عن طريق التحليل الإحصائي للسلسلة الزمنية (مثل رسومات الارتباط الذاتي والارتباط الذاتي الجزئي).

3. تركيب النموذج وتقديره: بمجرد تحديد المعاملات، يتم تركيب النموذج واستخدام البيانات التاريخية لتقدير المعاملات.

4. التحقق من صحة النموذج: يتم التحقق من صحة النموذج عن طريق تقنيات

مثل مخطط الأخطاء وتحليل القيم المتبقية.

5. التنبؤ: يمكن استخدام النموذج للتنبؤ بقيم المستقبلية [6].

Prophet 6.2

نموذج Prophet هو أداة قوية للتنبؤ بالسلاسل الزمنية تم تطويرها بواسطة فريق علم البيانات الأساسي في فيسبوك. صُمم النموذج ليتعامل مع أنواع الشوائب في البيانات التي غالبًا ما تكون موجودة في بيانات العالم الواقعي، مثل القيم المفقودة والنقاط الشاذة الكبيرة وتحولات الموسمية الدرامية، مما يجعله متعدد الاستخدامات ويمكن تطبيقه في سياقات مختلفة بما في ذلك الأعمال والاقتصاد.

تعمل Prophet عن طريق تحليل بيانات السلاسل الزمنية إلى عدة مكونات، مثل الاتجاه والموسمية والعطلات ثم تركيب نموذج لكل مكون. يمكن هذا النهج Prophet من الحصول على الفروق الدقيقة في بياناتك بدقة وإنتاج تنبؤات موثوقة. تعتبر Prophet مثالية للشركات التي لديها أنماط طلب غير منتظمة أو القيم المتطرفة المتكررة أو الشركات التي تتأثر بالأحداث الخاصة مثل العطلات أو العروض الترويجية.

نموذج Prophet مفيد بشكل خاص عند التعامل مع مجموعات بيانات تقتقر إلى الملاحظات أو تحتوي على نتائج كبيرة. كما أنه قوي في التكيف مع التحولات في الاتجاه، ويعامل المعلومات الجديدة بشكل جيد.

6.3 التنعيم الأسّي (Exponential Smoothing)

هو تقنية لتنعيم بيانات سلسلة الزمن باستخدام دالة نافذة أسية. بينما في نماذج المتوسط المتحرك البسيط يتم وزن الملاحظات الماضية بشكل متساوٍ، يقوم التنعيم الأسّي بتعيين أوزان تتناقص أسياً مع مرور الوقت. إنها طريقة يسهل تعلمها وتطبيقها لإنتاج بيانات سلسلة، خاصةً عند التعامل مع بيانات تحتوي على الكثير من الضوضاء أو التقلبات، وغالباً ما يستخدم بسبب قدرته على دمج بيانات الماضي مع التقليل التدريجي من التأكيد على الملاحظات الأقدم.

عملياً، يمكن تنفيذ التنعيم الأسّي باستخدام برمجيات إحصائية تتضمن قدرات التنبؤ بسلسلة الزمن، مثل مكتبة statsmodels. تتضمن هذه الأدوات عادةً وظائف لتحسين تلقائي لمعاملات التنعيم بناءً على البيانات التاريخية.

التنعيم الأسّي هو طريقة متعددة الاستخدامات وقوية للتنبؤ ببيانات سلسلة الزمن، وهي مفيدة بشكل خاص عند الحاجة لتنعيم البيانات أو عند التعامل مع تيارات بيانات غير

معقدة ولكنها متقلبة. من الضروري للمحللين فهم كيفية تكوين وتكييف نماذج التتبع الأسّي لتتناسب الاحتياجات التجارية المحددة وأنواع البيانات. [7][8]

6.4 الشبكات العصبية المتكررة (RNN) ونوعها المحسن، الذاكرة طويلة الأمد القصيرة (LSTM)

هما من النماذج الهامة في مجال التعلم العميق، خاصة لمعالجة البيانات الزمنية المتسلسلة مثل التنبؤ بالسلاسل الزمنية. فيما يلي تعريف لهذه النماذج وشرح لآلية عملها في التنبؤ بالسلاسل الزمنية.

الشبكات العصبية المتكررة (RNN): هي فئة من الشبكات العصبية تعالج البيانات الزمنية بطريقة تتيح لها تذكر المدخلات السابقة في السلسلة. تكون مفيدة بشكل خاص في المهام التي تتطلب فهم سياق المدخلات السابقة لإجراء تنبؤات، مثل اللغة الطبيعية والسلاسل الزمنية.

الذاكرة طويلة الأمد القصيرة (LSTM): هي تطوير لنموذج RNN التقليدي لحل مشكلة اختفاء التدرج التي تظهر عندما تصبح السلاسل الزمنية طويلة. تتميز LSTM بوجود "بوابات" تتحكم في تدفق المعلومات، مما يجعلها أكثر فعالية في التعلم من السلاسل الزمنية الطويلة والمعقدة.


تعد شبكات LSTM RNN نوعًا خاصًا من شبكات RNN القادرة على تعلم التبعية طويلة المدى. على عكس شبكات RNN القياسية، التي تعاني من تبعية التعلم عبر

تسلسلات أطول بسبب مشكلات مثل مشكلة التدرج المتلاشي، تستخدم LSTMs بنية فريدة تشتمل على بوابات مختلفة تتحكم في تدفق المعلومات. تساعد هذه البوابات LSTM في تحديد المعلومات التي يجب الاحتفاظ بها أو التخلص منها، مما يجعلها أكثر ملاءمة للمهام التي تتطلب فهم التسلسلات الطويلة، مثل التنبؤ بالسلاسل الزمنية.

7. الدراسات المرجعية


تتضمن ادبيات الدراسة مجموعة واسعة من الخوارزميات والتقنيات للتنبؤ بالسلاسل الزمنية وبما ان القطاعات الخدمية لها وضع خاص فقد تنوعت هذه الاساليب فمنها الاساليب التقليدية ومنها التعلم العميق.

ونظرا لقلة الدراسات المرجعية في مجال التنبؤ في السلاسل الزمنية للقطاعات الخدمية في الجمهورية العربية السورية سيتم الاعتماد على دراسات مرجعية عالمية حيث تقسم ادبيات الدراسة للتنبؤ بالسلاسل الزمنية وفق طبيعة الخوارزمية المستخدمة كما هي موضحة بالشكل 1:



شكل 2 التنبؤ بالسلاسل الزمنية وفق طبيعة الخوارزمية

الشكل 3 يوضح تقسيم التنبؤ بالسلاسل الزمنية بشكل رئيسي حسب نطاق الاستخدام.



شكل 3 التنبؤ بالسلاسل الزمنية حسب نطاق الاستخدام

سيتم الاعتماد في هذا البحث على تقسيم الدراسات المرجعية وفق طبيعة الخوارزمية

المستخدمة للتنبؤ بالسلاسل الزمنية وذلك من اجل:

1. التعرف على التقنيات المستخدمة حالياً في مجال التنبؤ بالسلاسل الزمنية

2. التعرف على الطرائق الافضل من خلال عمليات المقارنة بين طرائق التنبؤ

بالسلاسل الزمنية

3. تحديد أسباب تفضيل خوارزمية عن أخرى في مجال التنبؤ بالسلاسل الزمنية

ركزت الدراسات معظم الدراسات على استخدام خوارزميتي ARIMA وخوارزميات التعلم

العميق بالمقابل تناولت بعض الدراسات استخدام خوارزميات أخرى مثل GRU و

MLP.

7.1 الطرائق التقليدية

تهدف الدراسة [9] إلى العثور على أفضل نموذج للتنبؤ بعدد حالات الوفاة المؤكدة في

إيران. ولهذا الغرض، تم تطبيق تسعة نماذج بما في ذلك نماذج الشبكة NNETAR،

ARIMA، Hybrid، Holt-Winter، BSTS، TBATS، Prophet، MLP، و

ELM. يتم تقييم جودة نماذج التنبؤ من خلال ثلاثة مقاييس للأداء، RMSE، وMAE،

وMAPE. يتم اختيار أفضل نموذج من خلال أقل قيمة لمقاييس الأداء. ثم عدد

الحالات المؤكدة وحالات الوفاة المتوقعة خلال الثلاثين يوماً القادمة. البيانات المستخدمة

في هذه الدراسة هي العدد المطلق لحالات الوفاة المؤكدة في الفترة من 20 فبراير إلى

15 أغسطس 2020.

وبناء على نتائج هذه الدراسة والبيانات الموجودة، تم الإشارة إلى أن نموذجي MLP و Holt-Winter كان لهما أقل خطأ في التنبؤ مقارنة بالطرق الأخرى. لم يتم تركيب بعض النماذج بشكل جيد في مرحلة الاختبار وذلك لأن العديد من العوامل الأخرى إما غير متوفرة أو تم تجاهلها في هذه الدراسة ويمكن أن تؤثر على دقة نتائج التنبؤ. واستناداً إلى اتجاه البيانات والنتائج المتوقعة، فإن عدد الحالات المؤكدة وحالات الوفاة يكاد يكون ثابتاً ومتناقصاً على التوالي. ومع ذلك، بسبب تطور المرض وتجاهل توصيات وبرتوكولات وزارة الصحة، هناك احتمال لظهور هذا المرض مرة أخرى بشكل أكثر خطورة في إيران وهذا يتطلب المزيد من الرعاية الوقائية.

تم في الدراسة [10] تطوير نموذج تنبؤي جديد لإشغال قسم الطوارئ باستخدام منهجية تحليل السلاسل الزمنية. تم إجراء تحليل لجميع زيارات قسم الطوارئ من مركز أكاديمي كبير خلال العام 2012 للتنبؤ بإشغال قسم الطوارئ في الساعة. ونظراً لتأثيرات الوقت من اليوم ويوم من الأسبوع، تم اختيار المتوسط المتحرك المتكامل الذاتي الانحداري الموسمي مع نموذج الانحدار الخارجي (SARIMAX). لكل ساعة من اليوم، تم تصميم نموذج SARIMAX للتنبؤ بإشغال قسم الطوارئ لمدة تصل إلى 4 ساعات. تم مقارنة دقة التنبؤ بالنموذج الناتج وفترات التنبؤ مع طرق التنبؤ بالسلاسل الزمنية التي تمت دراستها مسبقاً. شمل مجتمع الدراسة 65,132 زيارة لقسم الطوارئ في مركز طبي أكاديمي كبير خلال عام 2012. وتم استخدام جميع زيارات قسم الطوارئ للبالغين خلال

أول 265 يوماً كمجموعة بيانات تدريبية، في حين تضمنت زيارات قسم الطوارئ المتبقية مجموعة بيانات الاختبار. كان أداء نموذج SARIMAX هو الأفضل.

7.2 التعلم الآلي

قام الباحثون في الدراسة [11] باستخدام نماذج التعلم العميق لإظهار التنبؤ بكوفيد-19 في الهند والولايات المتحدة الأمريكية. تم تأكيد Covid-19 وحالات الوفاة في كلا البلدين. يعد الحد من بيانات Covid-19 عاملاً صعباً للتنبؤ ببيانات السلاسل الزمنية. يتم استخدام امتداد الشبكة العصبية المتكررة (RNN) كخلية ذاكرة طويلة المدى (LSTM) ومتغيراتها مثل LSTM المكسدة، و LSTM ثنائية الاتجاه، و LSTM التلافيفية لنمذجة التنبؤات. يتم اختيار أفضل نموذج على أساس معدل الخطأ في التنبؤات ويتم حساب الخطأ باستخدام متوسط النسبة المئوية للخطأ المطلق (MAPE). يعمل نموذج LSTM التلافيفي بشكل أفضل من النموذجين الآخرين حيث يتراوح معدل الخطأ من 2.0 إلى 3.3 بالمائة لجميع مجموعات البيانات الأربع. أداء نموذج LSTM المكس هو الأسوأ في الدراسة وفقاً للنتائج المتوقعة، سترتفع حالات الإصابة المؤكدة وحالات الوفاة في كلا البلدين خلال الشهر المقبل.

تم في البحث [12] تقييم التقنيات الإحصائية والعصبية والتجميعية المختلفة في قدرتها على التنبؤ بمتوسط إنفاق المرضى الأسبوعي على بعض أدوية الألم. تم استخدام

نموذج، الثبات (خط الأساس) والمتوسط المتحرك المتكامل الانحداري الذاتي (ARIMA)، ونموذج الإدراك الحسي متعدد الطبقات (MLP)، ونموذج الذاكرة الطويلة قصيرة المدى (LSTM)، ونموذج مجمع يجمع بين تنبؤات ARIMA و MLP و LSTM تمت معايرة النماذج للتنبؤ بالنفقات على اثنين من أدوية الألم المختلفة. في نماذج MLP و LSTM، كشفت النتائج أن نموذج المجموعة تفوق في الأداء على نماذج الثبات، ونماذج ARIMA، و MLP، و LSTM.

يقدم البحث [13] وصفاً تفصيلياً لحركة مرور الشبكة وهو مقياس لنقل البيانات عبر الشبكة في وقت معين. عادةً ما تظهر بيانات الشبكة في الأنظمة في حزم ثابتة، مما يعطي بنية الطبقات داخل النظام. تتناول هذه الورقة المشكلة الأساسية للتنبؤ بالشبكة باستخدام بيانات السلاسل الزمنية وتوفر أفضل حل ممكن بمساعدة XGBoost وخوارزمية prophet. تعمل هاتان الخوارزمتان معاً على حل مشكلة بيانات السلاسل الزمنية التي توفر نمذجة البيانات لدعم البنية التحتية للشبكة. خوارزمية prophet نفسها قادرة على القيام بالتنبؤ بكمية أكبر من البيانات ذات نمط بيانات غير طبيعي وغير منتظم. تدعم خوارزمية XGBoost الكمية الأصغر من البيانات ذات الطبيعة الدورية. تعتبر هاتان الخوارزمتان المكونات الأساسية لحل مشكلة تقدير حركة المرور لأنظمة الاتصالات باستخدام بيانات السلاسل الزمنية. تم رسم الرسم البياني لبيانات السلاسل

الزمنية المستلمة من المحطة الأساسية ويستخدم لرسم البياني لبيانات السلاسل الزمنية باستخدام خوارزمية prophet و XGBoost في ساعات الذروة.

تشكل مراكز الاتصال نقطة اتصال أساسية طوال رحلة العميل. وبالتالي، تعد الدقة العالية في التنبؤ فيما يتعلق بتنبؤات الوافدين إلى مركز الاتصال أمراً بالغ الأهمية لخلق جودة خدمة إيجابية ملحوظة من خلال تقليل أوقات الانتظار للعملاء وكذلك تقليل تكاليف الشركة عن طريق تجنب زيادة عدد الموظفين. وبالتالي، تعد تقنيات تحليلات الأعمال الكافية لإنتاج تنبؤات دقيقة عامل نجاح مهم في إدارة مركز الاتصال. ولذلك، تم في البحث [14] التحقق من التأثير التنبؤي المشترك لاختيار النموذج ومدى المهلة الزمنية كمعلمة تنظيمية حاسمة بشأن دقة التنبؤ. تم تحليل 174 أسبوعاً من البيانات الواردة من مركز اتصال إحدى الشركات الألمانية الرائدة في مجال البيع بالتجزئة عبر الإنترنت، بما في ذلك وصول المكالمات والبريد الإلكتروني لقائمة انتظار دعم العملاء. يتم مقارنة النماذج التقليدية و النماذج الجديدة أيضاً لعشرة فترات زمنية مختلفة (تتراوح من أربعة أسابيع إلى عدم وجود مهلة زمنية). وبشكل عام، تقل دقة التنبؤ مع زيادة المهلة الزمنية. وبشكل أكثر تحديداً، أنواع تنبؤات النماذج (التنبؤات المسبقة واللاحقة) تتأثر بشكل مختلف بالمهل الزمنية: بغض النظر عن المهلة الزمنية المدروسة، فإن نماذج الانحدار والتردد الراديوي قادرة على الحفاظ على مستويات دقتها تقريباً مع المهل الزمنية السابقة. في المقابل، تصبح التنبؤات المسبقة لنماذج السلاسل الزمنية غير دقيقة

أكثر كلما طالت المهلة الزمنية، أي كلما كانت القيم الأخيرة للسلاسل الزمنية المستخدمة للتنبؤ تقع في الماضي.

يعد الاحتفاظ بالعملاء أمراً مهماً في صناعة الخدمات المالية. تم دمج التعلم الآلي في تحليلات بيانات العملاء للتنبؤ بمخاطر تراجع العملاء. على الرغم من نجاحها، تستخدم الأساليب الحالية في المقام الأول البيانات المنظمة فقط، على سبيل المثال، التركيبة السكانية وتاريخ الحساب. يمكن أن يكشف استخراج البيانات باستخدام بيانات غير منظمة، على سبيل المثال، التفاعل مع العملاء، عن المزيد من الأفكار، والتي لم يتم الاستفادة منها بشكل كافٍ. قام الباحثون في الدراسة [15]، باقتراح نموذج للتنبؤ بتراجع العملاء باستخدام البيانات غير المنظمة، وهي المحتويات المنطوقة في الاتصالات الهاتفية. تم جمع مجموعة بيانات واسعة النطاق لمراكز الاتصال تضم مليوني مكالمة من أكثر من مائتي ألف عميل وتم إجراء تجارب مكثفة. تظهر النتائج أن النموذج يمكنه التنبؤ بدقة بمخاطر تراجع العميل وتوليد رؤى ذات معنى باستخدام التعلم الآلي القابل للتفسير مع السمات الشخصية وشرائح العملاء.

بعدما تم عرض التوجهات المستخدمة للتنبؤ بالسلاسل الزمنية في القطاعات لخدمة بدءاً من الطرق التقليدية ووصولاً إلى التعلم العميق.

تم ملاحظة أن كل من الطرائق التقليدية والتعلم العميق له محاسنه وسيئاته فتارة تكون الطرائق التقليدية أفضل وتارة يكون التعلم العميق أفضل وكلاهما يتم استخدامه في

متخلف نطاقات القطاعات الخدمية وبالتالي لم يتم الاجماع على طريقة دون عن الاخرى ولذلك في هذا البحث سيتم الاعتماد على خوارزمية ARIMA وخوارزمية التعلم العميق RNN و prophet نظراً لكثرة استخدامهم والاشادة بهم في الدراسات المرجعية في حين سيتم استخدام خوارزمية ES للرجبة في دراستها مع باقي الخوارزميات السابقة الموصى بها من قبل الدراسات المرجعية.

8. مقاييس الاداء

يعتبر تقييم الأداء ضرورياً لفهم مدى جودة أداء نموذج التنبؤ في توقع القيم المستقبلية. الهدف الرئيسي هو تقدير الخطأ أو الخسارة التي ستحدث عند تطبيق النموذج على بيانات جديدة، وهو أمر ضروري لاختيار النموذج والتحقق من صحته[16].

يمكن تقييم خطأ نموذج التنبؤ باستخدام عدة مقاييس، ويعتمد اختيار المقياس على خصائص البيانات المحددة وأهداف التحليل. تشمل المقاييس الشائعة:

- متوسط الخطأ التربيعي (MSE) يقيس متوسط مربعات الأخطاء - الفرق

المتوسط المربع بين القيم المقدرة والقيمة الفعلية.

$$MSE = \left(\frac{1}{n} \right) \sum_{t=1}^n (A_t - F_t)^2$$

- جذر متوسط الخطأ التربيعي (RMSE) جذر MSE ، مما يوفر الخطأ بنفس

وحدات البيانات.

$$RMSE = \sqrt{MSE}$$

- متوسط الخطأ المطلق (MAE) يقيس متوسط حجم الأخطاء في مجموعة من التوقعات، دون النظر إلى اتجاهها (أي بدون سالب).

$$MPE = (100\% / n) \sum_{t=1}^n \frac{(A_t - F_t)}{A_t}$$

- متوسط الخطأ المئوي المطلق (MAPE) يقيس حجم الخطأ بالنسبة المئوية.

$$MAPE = (100\% / n) \sum_{t=1}^n \left| \frac{(A_t - F_t)}{A_t} \right|$$

في هذا البحث تم استخدام معيار متوسط الخطأ التربيعي لتقييم الاداء.

9. الإعداد التجريبي

تم استخدام مجموعة البيانات التي تم الحصول عليها من مقسم المحطة وهي عبارة

عن عدد المكالمات الواردة الى المقسم خلال ثلاث سنوات من 2014 وحتى 2017 تحتوي على عمودين و 890 سطر.

يوضح الشكل 4 مجموعة البيانات المستخدمة.

2014-03-22 00:00:00	314
2014-03-24 00:00:00	40
2014-03-25 00:00:00	367
2014-03-28 00:00:00	1516
2014-03-29 00:00:00	891
2014-03-30 00:00:00	333
2014-03-31 00:00:00	1125

شكل 4 مجموعة البيانات المستخدمة

10. التطبيق العملي

من أجل تحليل السلاسل الزمنية والتنبؤ بها سيتم استخدام أربع خوارزميات لتحليل السلاسل الزمنية والتنبؤ بها وهي ARIMA و Profit و ES ومن ثم التعلم العميق باستخدام RNN LSTM.

• تحليل وتحضير البيانات

في البداية تم دراسة مجموعة البيانات المستخدمة لاختبار وجود قيم فارغة حيث يوضح الشكل 5 اختبار القيم الفارغة.

```
Date          0
count         0
dtype: int64
```

شكل 5 اختبار القيم الفارغة

ليتم بعد ذلك قراءة الايام الموجودة في مجموعة البيانات للتحقق من وجود انقطاعات في الايام المسجلة للمكالمات كما هو موضح في الشكل 6 فمن الواضح وجود فترات انقطاع لم يتم فيها تسجيل المكالمات.

```
DatetimeIndex(['2014-01-06', '2014-01-07', '2014-01-10', '2014-01-11',
               '2014-01-13', '2014-01-14', '2014-01-16', '2014-01-19',
               '2014-01-20', '2014-01-21',
               ...,
               '2017-12-18', '2017-12-19', '2017-12-21', '2017-12-22',
               '2017-12-23', '2017-12-24', '2017-12-25', '2017-12-28',
               '2017-12-29', '2017-12-30'],
              dtype='datetime64[ns]', name='Date', length=889, freq=None)
```

شكل 6 قراءة الايام الموجودة في مجموعة البيانات

من الواضح من الشكل 7 انه يمكن أن يكون التعامل مع بيانات التاريخ والوقت الحالية أمراً ليس ذو جدوى لذلك من الافضل التعامل مع متوسطات المكالمات اليومية لهذا الشهر بدلاً من ذلك. يوضح الشكل المتوسط الحسابي لعدد المكالمات بالشهر في عام 2014 (بداية مجموعة البيانات)

Date	
2014-01-01	480.230769
2014-02-01	368.000000
2014-03-01	857.352941
2014-04-01	567.428571
2014-05-01	431.937500
2014-06-01	695.052632
2014-07-01	601.111111
2014-08-01	457.312500
2014-09-01	992.458333
2014-10-01	769.000000
2014-11-01	980.227273
2014-12-01	1532.200000

شكل 7 المتوسط الحسابي لعدد المكالمات في كل شهر لعام 2014

يوضح الشكل 8 عدد المكالمات الاسبوعية والشهرية والربعية والسبوعية بعد عملية

تجميع تواريخ المكالمات.

weekly	count
2014-01-12	2713
2014-01-19	1250
2014-01-26	1656
2014-02-02	624
2014-02-09	15
Monthly	count
2014-01-31	6243
2014-02-28	1840
2014-03-31	14575
2014-04-30	7944
2014-05-31	6911
Quarterly	count
2014-03-31	22658
2014-06-30	28061
2014-09-30	41956
2014-12-31	64513
2015-03-31	27376
Annual	count
2014-12-31	157188
2015-12-31	170517
2016-12-31	198909
2017-12-31	215389

شكل 8 عدد المكالمات الاسبوعية والشهرية والربعية والسبوعية


يوضح الشكل 9 التغيرات الشهرية في عدد المكالمات (زيادة او انخفاض القيم كل

شهر عن الشهر السابق له)

	count	count_%_Change
2014-01-31	6243	NaN
2014-02-28	1840	-0.705270
2014-03-31	14575	6.921196
2014-04-30	7944	-0.454957
2014-05-31	6911	-0.130035

شكل 9 التغيرات الشهرية في عدد المكالمات


يوضح الشكل 10 توزيع المكالمات اليومية.



شكل 10 توزيع المكالمات اليومية

يوضح الشكل 11 توزيع المكالمات الربعية (كل ثلاث اشهر) من الواضح وجود نمط


تصاعدي.



شكل 11 توزيع المكالمات الربعية

يوضح الشكل 12 توزيع المكالمات الاسبوعية من الواضح وجود اسابيع معينة تتزايد

فيها المكالمات عن غيرها ويتكرر هذا النمط كل سنة.




شكل 12 توزيع المكالمات الاسبوعية

يوضح الشكل 13 تطبيق Autocorrelation و Partial Autocorrelation مع

Lag مساوياً ل 30 فمن الواضح عدم وجود تأثير الايام السابقة على اليوم الحالي

للمكالمات.



شكل 13 Autocorrelation و Partial Autocorrelation

بعد عملية تحليل البيانات والتعرف عليها بالشكل الامثل والقيام بعمليات المعالجة وفصل المكونات اصبحت البيانات الان جاهزة للقيام بالتجارب الاربعة وهي تجربة استخدام خوارزمية ARIMA و Prophit و ES و RNN LSTM و قياس مقدار الخطأ في النماذج الإحصائية باستخدام معيار MSE وبعد ذلك سيتم اعتماد الخوارزمية الاقل خطأً باستخدام هذا المعيار وتحديد التوجه الامثل الذي يخدم المقسم.

• التجربة الأولى

تم استخدام خوارزمية ARIMA ولكن من اجل ذلك في البداية يجب تحديد افضل بارامترات للخوارزمية كما هو موضح بالشكل 14. حيث تم الحصول على البارامترات

التالية (1, 1, 0, 12)، order=(1, 1, 1 14) seasonal_order=

```
ARIMA(1, 1, 0)x(1, 1, 0, 12)12 - AIC:300.6314069774217
ARIMA(1, 1, 0)x(1, 1, 1, 12)12 - AIC:302.3353978309796
ARIMA(1, 1, 1)x(0, 0, 0, 12)12 - AIC:649.0336651534955

/usr/local/lib/python3.10/dist-packages/statsmodels/base/model.py:607: ConvergenceWarning: Maximum Likelihood optimization failed to converge. Check mle_retvals
warnings.warn("Maximum Likelihood optimization failed to ")

ARIMA(1, 1, 1)x(0, 0, 1, 12)12 - AIC:241.6608564020181
ARIMA(1, 1, 1)x(0, 1, 0, 12)12 - AIC:460.4846723552135
ARIMA(1, 1, 1)x(0, 1, 1, 12)12 - AIC:281.3938830979203
ARIMA(1, 1, 1)x(1, 0, 0, 12)12 - AIC:469.53346268944307

/usr/local/lib/python3.10/dist-packages/statsmodels/base/model.py:607: ConvergenceWarning: Maximum Likelihood optimization failed to converge. Check mle_retvals
warnings.warn("Maximum Likelihood optimization failed to ")

ARIMA(1, 1, 1)x(1, 0, 1, 12)12 - AIC:368.03808738781794
ARIMA(1, 1, 1)x(1, 1, 0, 12)12 - AIC:298.61124697014565
ARIMA(1, 1, 1)x(1, 1, 1, 12)12 - AIC:283.3727040776406
```

شكل 14 افضل البارامترات لخوارزمية ARIMA

يوضح الجدول البارامترات المستخدمة في عملية تدريب نموذج ARIMA.

جدول 1 البارامترات المستخدمة في عملية تدريب نموذج ARIMA


البارامتر	القيمة
Order	(1, 1, 1)
seasonal_order	(12, 0, 1, 1)
enforce_invertibility	False

من ثم تم تدريب النموذج وفق بارامترات الجدول 1 والحصول على نتائج التدريب الموضحة بالشكل 15.

	coef	std err	z	P> z	[0.025	0.975]
ar.L1	0.1280	0.276	0.464	0.643	-0.413	0.669
ma.L1	-1.0000	0.450	-2.224	0.026	-1.881	-0.119
ar.S.L12	-0.2811	0.154	-1.826	0.068	-0.583	0.021
sigma2	3.029e+04	1.48e-05	2.04e+09	0.000	3.03e+04	3.03e+04


شكل 15 تدريب النموذج وفق بارامترات الجدول 1

يوضح الشكل 16 تشخيصات النموذج plot_diagnostics وتشير أن بقايا النموذج موزعة بشكل طبيعي تقريباً.




شكل 16 plot_diagnostics

ليتم بعد ذلك التنبؤ باستخدام النموذج السابق الذي تم تدريبه للتنبؤ ببيانات من عام 2016 وحتى نهاية مجموعة البيانات كما هو موضح بالشكل 17.



شكل 17 التنبؤ باستخدام *ARIMA*

يُظهر المخطط الخطي بالشكل 18 القيم المرصودة مقارنةً بالتنبؤات المتوقعة المتداولة. بشكل عام، تتوافق توقعات النموذج مع القيم الحقيقية بشكل جيد للغاية، مما يدل على اتجاه تصاعدي يبدأ من بداية العام ويلتقط الموسمية في نهاية العام. في حين كانت Mean Squared Error تساوي 40002



شكل 18 التنبؤ ببيانات من منتصف عام 2016

يُظهر المخطط الخطي القيم المرصودة مقارنةً بالتنبؤات المتوقعة المتداولة. بشكل عام،

تتوافق توقعاتنا مع القيم الحقيقية بشكل جيد للغاية. مع خطأ Mean Squared Error

تساوي 33346.68.


• التجربة الثانية باستخدام Prophet

يوضح الجدول البارامترات المستخدمة لبناء نموذج prophet.

جدول 2 البارامترات المستخدمة لبناء نموذج prophet


البارامتر	القيمة
interval_width	0.85

يوضح الشكل 19 نتيجة التنبؤ باستخدام نموذج propeht




شكل 19 نتيجة التنبؤ باستخدام نموذج propeht

يوضح الشكل 20 اتجاه السلسلة الزمنية.




شكل 20 اتجاه السلسلة الزمنية

يوضح الشكل 21 تقدير عدد المكالمات للسلسلة لحد عام 2021.



شكل 21 تقدير العدد

يوضح الشكل 22 عناصر السلسلة.



شكل 22 عناصر السلسلة

يوضح الشكل 23 مقدار الخطأ في كل تنبؤ قام به نموذج prophet

	Date	test_trend	test_yhat_lower	test_yhat_upper	test_trend_lower	test_trend_upper	test_additive_terms	test_additive_terms_lower	test_additive_terms_up
0	2014-01-06	747.954504	-1181.375187	2761.064533	747.954504	747.954504	153.096141	153.096141	153.096
1	2014-01-07	747.975532	-1453.922154	2256.489104	747.975532	747.975532	-251.182486	-251.182486	-251.182
2	2014-01-10	748.038618	-1308.715583	2556.924374	748.038618	748.038618	-98.122438	-98.122438	-98.122
3	2014-01-11	748.059647	-1489.979049	2365.741707	748.059647	748.059647	-329.442967	-329.442967	-329.442
4	2014-01-13	748.101704	-1186.536844	2527.975369	748.101704	748.101704	-25.548090	-25.548090	-25.548

شكل 23 yhat

• تجربة تطبيق ExponentialSmoothing

يوضح الجدول 3 بارامترات استخدام ExponentialSmoothing


جدول 3 البارامترات المستخدمة لبناء نموذج prophet

البارامتر	قيمه
damped_trend	False
Seasonal	Add
seasonal_periods	7
Trend	None

وكان MSE مساوياً لـ 1489604.3521516214

يوضح الشكل 24 التنبؤ باستخدام ExponentialSmoothing من الواضح من الشكل

21 عدم قدرة النموذج على التنبؤ بالشكل الافضل وعدم قدرته على اكتشاف نمط البيانات.



شكل 24 ExponentialSmoothing


• التجربة الرابعة تطبيق RNN LSTM

تم تطبيق نموذج RNN LSTM وفق البارامترات الموضحة بالجدول 4.

جدول 4 بارامترات بناء نموذج RNN LSTM


القيمة	البارامتر
5000	Epochs
2	عدد الطبقات

يوضح الشكل 25 مخطط التجربة.



شكل 25 مخطط التجربة الرابعة - الجزء الأول

بعد اجراء التجربة كانت MSE مساوية 1452942.19010795، يوضح الشكل 26 نموذج التنبؤ باستخدام RNN LSTM ومن الواضح ان اداء النموذج لم يكن جيداً.



شكل 26 التنبؤ باستخدام RNN

نظراً لأهمية التعلم العميق في مجالات الحياة كافة والرغبة في محاولة تحسين نتيجة اداء شبكة RNN البسيطة في التجربة السابقة تم دراسة تأثير عمق شبكة RNN على مجموعة البيانات المستخدمة.


➤ اضافة طبقة اخرى للتجربة (شبكة RNN البسيطة)

يوضح الشكل 27 مخطط التجربة الرابعة الجزء الثاني



شكل 27 مخطط التجربة الرابعة -الجزء الثاني

يوضح الشكل 28 المخطط البياني لنتيجة التجربة بعد عملية اضافة طبقة اخرى للتجربة (شبكة RNN البسيطة)




شكل 28 اضافة طبقة اخرى للتجربة (شبكة RNN البسيطة)

وبعد تنفيذ التجربة تم قياس MSE وكان MSE مساوياً لـ

1594527.1472637097

➤ اضافة طبقتين للتجربة (شبكة RNN البسيطة)


يوضح الشكل 29 مخطط التجربة



شكل 29 مخطط التجربة الرابعة - الجزء الثالث

يوضح الشكل 30 المخطط البياني لنتيجة التجربة بعد عملية اضافة طبقتين للتجربة

(شبكة RNN البسيطة)



شكل 30 اضافة طبقتين للتجربة (شبكة RNN البسيطة)


وبعد تنفيذ التجربة تم قياس MSE وكان MSE مساوياً لـ

1994205.6288355323

➤ اضافة طبقتين للتجربة (شبكة RNN البسيطة) مع اضافة طبقة drop

out بين الطبقتين المضافتين


يوضح الشكل 31 مخطط التجربة



شكل 31 مخطط التجربة الرابعة الجزء الرابع

يوضح الشكل 32 المخطط البياني لنتيجة التجربة بعد عملية اضافة طبقتين للتجربة

(شبكة RNN البسيطة) مع اضافة طبقة drop out بين الطبقتين المضافتين.




شكل 32 اضافة طبقتين للتجربة (شبكة RNN البسيطة) مع اضافة طبقة drop out بين الطبقتين المضافتين

وبعد تنفيذ التجربة تم قياس MSE وكان MSE مساوياً لـ

1640354.357107821

➤ اضافة طبقتين للتجربة (شبكة RNN البسيطة) مع اضافة طبقتين drop out


يوضح الشكل 33 مخطط التجربة



شكل 33 التجربة الرابعة الجزء الخامس

يوضح الشكل 34 المخطط البياني بعد عملية اضافة طبقتين للتجربة (شبكة RNN

البسيطة) مع اضافة طبقتين drop out.



شكل 34 اضافة طبقتين للتجربة (شبكة RNN البسيطة) مع اضافة طبقة drop out بين الطبقتين المضافتين

وبعد تنفيذ التجربة تم قياس MSE وكان MSE مساوياً لـ 1516813.5571740123


➤ شبكة RNN مع ثلاث طبقات وطبقتين dropout

تم الابقاء ع هيكلية التجربة السابقة مع اضافة طبقة واحدة كما هو موضح بالشكل 35.



شكل 35 التجربة الرابعة الجزء السادس


يوضح الشكل 36 نتيجة تنفيذ التجربة



شكل 36 نتيجة التجربة الرابعة الجزء السادس


وبعد تنفيذ التجربة تم قياس MSE وكان MSE مساوياً لـ 1691830.3419243356

➤ شبكة RNN مع 4 طبقات وثلاث طبقات dropout. يوضح الشكل 37 مخطط التجربة.



شكل 37 التجربة الرابعة الجزء السابع

يوضح الشكل 38 نتيجة تنفيذ التجربة.




شكل 38 نتيجة التجربة الرابعة الجزء السابع

وبعد تنفيذ التجربة تم قياس MSE وكان MSE مساوياً لـ 1462335.908047153


نلاحظ ان مع زيادة عدد الطبقات لم تتحسن نتيجة التنبؤ بالسلسلة الزمنية وحتى مع اضافة طبقات drop out لم يكن الاداء افضل. حيث اثبتت التجارب التي تم القيام بها ان شبكة RNN البسيطة افضل من حيث معيار MSE من شبكة RNN متعددة الطبقات (3 طبقات او اكثر).

يوضح الشكل 39 MSE لكافة الخوارزميات



شكل 39 مقدار خطأ النمذج السابقة

في حين يوضح الشكل 40 مقدار الخطأ لكافة التجارب الخاصة بـ RNN.



شكل 40 مقدار الخطأ في كافة التجارب الخاصة ب RNN

12. الخاتمة والتطلعات المستقبلية

في هذا البحث تم دراسة عدة خوارزميات وهي ARIMA و ES و Prophet و RNN من اجل التنبؤ بالسلاسل الزمنية لعدد المكالمات الواردة الى مقسم المحطة وقد حققت خوارزمية ARIMA افضل اداء وبخطأ قدره 33346.7 في حين اثبتت جميع التجارب الخاصة ب RNN انه على الرغم من زيادة عدد الطبقات (زيادة عمق الشبكة) لم تعطي الخوارزمية افضل اداء متوقع. بالنسبة للتطلعات المستقبلية من الممكن دراسة خوارزميات اخرى مثل GRU .

13. جدول الاختصارات

ARIMA	Auto Regressive Integrated Moving Average
ES	Exponential Smoothing
RNN	Recurrent Neural Network
GRU	Gated Recurrent Unit
MSE	Mean Squared Error
MLP	Multi Layer Perceptron
MAPE	Mean absolute percentage error
MAE	Mean Absolute Error
LSTM	Long Short Term Memory

- [1] Lee, J., & McKibbin, W. J. (2018). Service sector productivity and economic growth in Asia. *Economic Modelling*, 74, 247–263.
<https://doi.org/10.1016/j.econmod.2018.05.018>
- [2] Ginzberg, E., & Vojta, G. J. (1981). The Service Sector of the U.S. Economy. *Scientific American*, 244(3), 48–55.
<http://www.jstor.org/stable/24964326>
- [3] Hungary. (n.d.). Google Books.
https://books.google.co.uk/books?hl=en&lr=&id=PNa-ge5UzsIC&oi=fnd&pg=PA57&dq=Telecommunications+sector+and+telephone+exchanges&ots=V5OurfNtkH&sig=cZao_urMxELZPUuU1QePdWByiKM&redir_esc=y#v=onepage&q&f=false
- [4] Brockwell, P. J., & Davis, R. A. (2002). Introduction to time series and forecasting. In *Springer texts in statistics*.
<https://doi.org/10.1007/b97391> [4] Cheng, Qian, et al. "Forecasting emergency department hourly occupancy using time series analysis." *The American Journal of Emergency Medicine* 48 (2021): 177–182.

- [5] Shumway, R. H., Stoffer, D. S., R.H. Shumway, & D.S. Stoffer. (2015). Time series analysis and it's applications (EZ Green Edition). http://www.akademikidea.org/aders/pluginfile.php/1006/mod_page/content/8/Shumway%2C%20Robert%20H.-Stoffer%2C%20David%20S.%20%282015%29Time%20Series%20Analysis%20and%20Its%20Applications%20With%20R%20%20Examples%2C%20EZ%20Edition%20%2C%20Springer.pdf
- [6] Duarte, D., & Faerman, J. (2019). Comparison of time series prediction of healthcare emergency department indicators with ARIMA and Prophet. In Computer Science & Information Technology (CS & IT) Computer Science Conference (Vol. 123, p. 33).
- [7] Nurhamidah, N., Nusyirwan, N., & Faisol, A. (2020). Forecasting seasonal time series data using the holt-winters exponential smoothing method of additive models. Jurnal Matematika Integratif, 16(2), 151-157.
- [8] Rabbani, M. B. A., Musarat, M. A., Alaloul, W. S., Rabbani, M. S., Maqsoom, A., Ayub, S., ... & Altaf, M. (2021). a comparison between seasonal autoregressive integrated moving average (SARIMA) and exponential smoothing (ES) based on time

series model for forecasting road accidents. Arabian Journal for Science and Engineering, 46(11), 11113–11138.

[9] Talkhi, Nasrin, et al. "Modeling and forecasting number of confirmed and death caused COVID–19 in IRAN: A comparison of time series forecasting methods." Biomedical signal processing and control 66 (2021): 102494.

[10] Cheng, Qian, et al. "Forecasting emergency department hourly occupancy using time series analysis." The American Journal of Emergency Medicine 48 (2021): 177–182.

[11] Sourabh Shastri, Kuljeet Singh, Sachin Kumar, Paramjit Kour, Vibhakar Mansotra, Time series forecasting of Covid–19 using deep learning models: India–USA comparative case study, Chaos, Solitons & Fractals, Volume 140, 2020.

[12] Kaushik, S., Choudhury, A., Sheron, P. K., Dasgupta, N., Natarajan, S., Pickett, L. A., & Dutt, V. (2020). AI in Healthcare: Time–Series Forecasting Using Statistical, Neural, and Ensemble Architectures. Frontiers in Big Data, 3. doi:10.3389/fdata.2020.00004

[13] Jain, G., & Prasad, R. R. (2020). Machine learning, Prophet and XGBoost algorithm: Analysis of Traffic Forecasting in Telecom

Networks with time series data. 2020 8th International Conference on Reliability, Infocom Technologies and Optimization (Trends and Future Directions) (ICRITO). doi:10.1109/icrito48877.2020.9197864

[14] Rausch, Theresa Maria, and Tobias Albrecht. "The impact of lead time and model selection on the accuracy of call center arrivals' forecasts." (2020).

[15] Nhi N.Y. Vo, Shaowu Liu, Xitong Li, Guandong Xu, Leveraging unstructured call log data for customer churn prediction, Knowledge-Based Systems, Volume 212, 2021.

[16] Lukas Blickensdörfer, Marcel Schwieder, Dirk Pflugmacher, Claas Nendel, Stefan Erasmi, Patrick Hostert, Mapping of crop types and crop sequences with combined time series of Sentinel-1, Sentinel-2 and Landsat 8 data for Germany, Remote Sensing of Environment, Volume 269, 2022, 112831.