

Prediction of Electric Power Consumption Using RNN Networks

Dr. Mariam Saii*
Dr. George Isber **
Dr. Oulfat Jolaha ***
Jina Mhanna****

(Received 29 / 10 / 2022. Accepted 5 / 1 / 2023)

□ ABSTRACT □

The electric power service in the Syrian Arab Republic suffers from many difficulties resulting from the lack of resources (fuel), in addition to the sabotage of many generation centers by terrorist groups, which led to the implementation of rationing programs in the governorates according to the consumption of those governorates and the production centers located in them. (factories, pumping centers, hospitals and the population).

Forecasting electric energy consumption also requires knowledge of daily consumption quantities, consumption times and other influencing factors that constitute large amounts of data. Predicting the exact electrical load is still a challenging task due to many problems such as the non-linear nature of the time series or the seasonal patterns it displays, which are very time consuming and affect the accuracy of the prediction performance. The process can be improved by using RNNs.[2]

Initially, the optimal and appropriate consumption for the region was determined, compared with production and the possibility of passing the surplus to other backup operations or providing production centers with the surplus that could be obtained through the previous forecasting process.

Also, Recurrent Neural Networks (RNN) were used, which are time series based on data sequences according to time indices and their ability to predict future values based on past data. Then the performance of those networks was compared with DNN networks (Dense Neural Network) to obtain an optimal future prediction that can be served by the Ministry of Electricity in the Syrian Arab Republic and to solve the problem of predicting the electrical load compared to previous studies.

The time-based successive division method has also been adopted, which has the ability to work more accurately for randomly sampled data. For cases of low regulation of the hourly data for wattage consumption, we can sample a set of data over time and take 20 percent of the data for example as training and test samples.

Based on the prediction values resulting from this study, work is being done to distribute electrical energy in the most appropriate manner and in accordance with the importance of higher usage.

Keywords: RNNs, DNNs, energy rationalization, consumption prediction, neural networks.

* Professor; Faculty of Electrical & Mechanical Engineering; University of Tishreen; Lattakia; Syria.

** Professor; Faculty of Electrical & Mechanical Engineering; University of Tishreen; Lattakia; Syria.

*** Associate Professor; Faculty of Electrical & Mechanical Engineering; University of Tishreen; Lattakia; Syria

****PHD student; Faculty of Electrical & Mechanical Engineering; University of Tishreen; Lattakia; Syria.

التنبؤ باستهلاك الطاقة الكهربائية باستخدام شبكات RNN

د. مريم ساعي *

د. جورج اسبر **

د. ألفت جولحة ***

جينا مهنا ****

(تاريخ الإيداع 29 / 10 / 2022. قُبل للنشر في 5 / 1 / 2023)

□ ملخص □

تعاني خدمة الطاقة الكهربائية في الجمهورية العربية السورية من العديد من الصعوبات الناتجة عن نقص الموارد (الفيول) بالإضافة إلى التخريب الذي تعرضت له العديد من مراكز التوليد من قبل المجموعات الإرهابية، ترافق ذلك مع حصار جائر تعرضت له بلدنا أدى إلى تخفيض كميات وقود التشغيل الذي تزود به محطات التوليد، وقد تسبب كل ماسبق إلى تطبيق برامج التقنين في المحافظات وفقاً لاستهلاك تلك المحافظات ومراكز الإنتاج الموجودة فيها (مصانع، مراكز ضخ، مستشفيات وعدد السكان).

كما يتطلب التنبؤ باستهلاك الطاقة الكهربائية معرفة كميات الاستهلاك اليومية وأوقات الاستهلاك وغيرها من العوامل المؤثرة والتي تشكل كميات كبيرة من البيانات [1]. ولا يزال التنبؤ الدقيق بالحمل الكهربائي يمثل مهمة صعبة بسبب العديد من المشاكل مثل الطابع غير الخطي للسلسلة الزمنية أو الأنماط الموسمية التي يعرضها، والتي تستغرق وقتاً كبيراً كما تؤثر على دقة الأداء في التنبؤ. يمكن تحسين العملية باستخدام شبكات RNN. [2]

بدايةً، تم تحديد الاستهلاك المثالي والمناسب للمنطقة ومقارنته مع الإنتاج وإمكانية تمرير الفائض لعمليات احتياطية أخرى أو تزويد مراكز الإنتاج بالفائض الذي يمكن الحصول عليه من خلال عملية التنبؤ السابقة.

كما تم استخدام الشبكات العصبية التكرارية (RNN (Recurrent Neural Network وهي عبارة عن سلاسل زمنية تعتمد على تسلسل البيانات وفقاً لدلائل زمنية وقدرتها على التنبؤ بالقيم المستقبلية اعتماداً على البيانات السابقة. ثم تم مقارنة أداء تلك الشبكات مع شبكات DNN (Dense Neural Network) للحصول على تنبؤ مستقبلي أمثل قابل لخدمة وزارة الكهرباء في الجمهورية العربية السورية وحل مشكلة التنبؤ بالحمل الكهربائي بالمقارنة مع الدراسات السابقة.

تم أيضاً اعتماد طريقة التقسيم المتتالي القائم على الوقت، والتي لها القدرة على العمل بصورة أعلى دقة بالنسبة للبيانات ذات العينات العشوائية. وبالنسبة لحالات انخفاض تنظيم البيانات الساعية لاستهلاك القدرة الكهربائية، يمكن لنا أخذ عينات لمجموعة من البيانات بالنسبة للزمن وأخذ 20 بالمئة من البيانات على سبيل المثال كعينات تدريب واختبار.

بناءً على قيم التنبؤ الناتجة عن هذه الدراسة يتم العمل على توزيع الطاقة الكهربائية بالشكل الأنسب وبما يتوافق مع أهمية الاستخدام الأعلى.

الكلمات المفتاحية: شبكات RNN، شبكات DNN، ترشيد استهلاك الطاقة، التنبؤ بالاستهلاك والشبكات العصبية.

* أستاذ - كلية الهندسة الكهربائية والميكانيكية اختصاص تحليل نظم التعرف باستخدام معالجة الصورة - جامعة تشرين - اللاذقية - سورية.

** أستاذ - كلية الهندسة الكهربائية والميكانيكية اختصاص برمجة نظم الطاقة الكهربائية - جامعة تشرين - اللاذقية - سورية.

*** أستاذ مساعد - كلية الهندسة الكهربائية والميكانيكية اختصاص التحكم الآلي والتسيير الذاتي - جامعة تشرين - اللاذقية - سورية.

**** طالبة دكتوراه - كلية الهندسة الكهربائية والميكانيكية اختصاص تحكم آلي - جامعة تشرين - اللاذقية - سورية.

مقدمة:

تبدأ حياة الانسان وفقاً لسلم التوقيت وذلك حسب متطلباته المختلفة، ومعظمنا يقوم بمهامه في أوقات محددة من اليوم، أغلبنا ينام في الليل ويقوم بنشاطاته المختلفة خلال النهار مما يجعل استهلاك الطاقة مختلفاً وفقاً لساعات العمل المختلفة. يختلف نموذج الحديث عن هذه المهام عندما يمر على مسامعنا مصطلحات مثل تعلم الآلة، تدريب النموذج، أو بناء قواعد البيانات التسلسلية اعتماداً على الطرق الاحصائية مثل ARIMA و SARIMAX أو استخدام الشبكات العصبية. الفكرة الأساسية هنا بأن البيانات في اللحظة الزمنية t هي نتيجة لمجموعة نقاط بيانات سابقة.

واجهت خدمة الطاقة الكهربائية العديد من الصعوبات والظروف القاسية بالإضافة إلى الأذى الذي تعرضت له العديد من مراكز التوليد الأمر الذي أدى إلى تطبيق برامج التقنين في المحافظات وفقاً لاستهلاك تلك المحافظات ومراكز الإنتاج الموجودة فيها.

تهدف الدراسة إلى التنبؤ باستهلاك الطاقة الكهربائية المطلوب لمدينة اللاذقية من خلال الفترات الزمنية المختلفة بحيث يمكن تحديد الاستهلاك المثالي والمناسب للمنطقة ومقارنته مع الانتاج وإمكانية تمرير الفائض لعمليات احتياطية أخرى أو تزويد مراكز الانتاج بالفائض الذي يمكن الحصول عليه من خلال عملية التنبؤ السابقة.

تعتمد الدراسة على استخدام الشبكات العصبية التكرارية (RNN (Recurrent Neural Network وهي عبارة عن سلاسل زمنية تعتمد على تسلسل البيانات وفقاً لدلائل زمنية وقدرتها على التنبؤ بالقيم المستقبلية اعتماداً على البيانات السابقة. كذلك تم مقارنة أداء تلك الشبكات مع شبكات (DNN (Dense Neural Network للحصول على تنبؤ مستقبلي أمثل قابل لخدمة وزارة الكهرباء في الجمهورية العربية السورية.

ازدادت في الفترة الأخيرة الدراسات التي ركزت على تحليل عمليات استهلاك الطاقة، بما في ذلك الاستهلاك السنوي لعمليات الاستهلاك المختلفة، الخصائص المؤثرة على استهلاك الطاقة، والتنبؤ بالاستهلاك. رافق ذلك تطوير لمقاييس الطاقة الذكية وطرق جمع البيانات الأخرى. أكدت العديد من الدراسات على أهمية طرق تعلم الآلة من أجل نمذجة استهلاك القدرة الكهربائية وذلك في كلا القطاعين الاقتصادي والسكني.

من أجل تقليل تأثير العشوائية في استهلاك المستخدمين المختلفين للطاقة الكهربائية، فقد ركزت الدراسات الرئيسية لنمذجة الطاقة إما للمناطق السكنية [3,4,5,6,7,8,9] أو الأبنية التجارية [10,11,12,13,14]. على سبيل المثال، قدم كل من Jain و smit نتائج لنمذجة الطاقة الكهربائية في الأبنية السكنية متعددة العائلات [3] مع استهلاك العائلات الافردية ضمن مستوى البناء. قام الباحثان ببناء نموذج تنبؤ بالقدرة باستخدام خوارزمية (SVM) support vector regression على نماذج مختلفة من البيانات، واعتماداً على هذه النماذج تم الوصول إلى النموذج الأكثر فعالية مع الاستهلاك الساعي في المستوى الأرضي للبناء مع قيمة $capacity\ factor=2.16$ وهو معامل يحدد كميات التميرر المسموحة للطاقة الكهربائية عبر الشبكة وخطأ انحراف بمقدار 28%.

بينما ركزت دراسة الباحثان Y. Liu و W.Wang على عملية التنبؤ الهندسي [4] اعتماداً على خوارزمية sliding window empirical mode decomposition (SWEMD) وشبكة إلمان العصبونية Elman Neural Network (IENN) للتنبؤ بمستويات حمل الطاقة الكهربائية للمستخدمين.

كما قدم الباحث Katarina et al طريقة لاستخدام كل من الشبكات العصبية Neural Network وشعاع دعم الآلة (SVM) ووضحت دقة استخدام هاتين الطريقتين من أجل التنبؤ باستهلاك القدرة الكهربائية باستخدام بيانات [14] event-related attribute.

درس كل من F.Zhang و C.deb مجموعات بيانات استهلاك القدرة الكهربائية في المؤسسات باستخدام شعاع دعم الانحدار الموزون [24]، حيث بينت الوثيقة المقدمة من قبل Fazil Kaytez نتائج استخدام نموذج LS-SVM وسرعتها للتنبؤ بالإضافة إلى دقتها المرتفعة مقارنة مع كل من Artificial Neural [16] Regression Analysis، Network.

بالنسبة لمجالات التنبؤ بالاستهلاك للمناطق السكنية ذات المناطق المنفصلة، تم إجراء الدراسات الأولية على مجموعات البيانات التفصيلية [13]، [28] للتنبؤ بالحمولات المنزلية بما في ذلك استخدام البيانات الاستكشافية السكانية، خصائص المساكن وملكية الأجهزة، بالإضافة إلى كشف الاشغالات والتي تم اعتمادها على المستويات الدنيا [29].

بالنسبة للدراسة التي قدمت من قبل [13] Richard E. Edwards and Joshua New قامت بتسليط الضوء على الأبنية السكنية حيث قام الباحثان بدراسة مجموعة بيانات خاصة تضمنت ثلاثة مجمعات سكنية تتضمن 140 منزلاً. قدمت هذه الدراسة نتائج وافية من أجل التنبؤ بالاستهلاك الاقتصادي والسكني بحيث حددت أن الطريقة المعتمدة على الشبكات العصبية هي الأفضل من أجل التنبؤ بالاستهلاك الاقتصادي.

بخصوص التنبؤ بحمل الطاقة الكهربائية، تم الاعتماد في على العديد من التقنيات بما في ذلك الشبكات العصبية ANN [11]، شعاع الدعم المتجه SVM [13] [21]، خوارزمية (ARIMA) [24] [32] والنماذج الانحدارية [32] regression models، بالإضافة إلى تقنيات العنقدة clustering techniques [14] وخوارزمية empirical mode decomposition (EMD) [11].

تم الاعتماد على الشبكات العصبية بصورة رئيسية بهدف التنبؤ بالطاقة الكهربائية في حين تم اعتماد شعاع المتجه الانحداري SVR من أجل حل مشاكل اللاخطية والمشاكل المتعلقة بالسلاسل الزمنية [24].

طرائق البحث ومواده:

1- حدود البحث:

أصبح الاعتماد على الذكاء الصناعي في الوقت الحالي عملية بالغة الأهمية نظراً لقابلية نظم الذكاء الصناعي على التكيف والعمل مع طيف واسع من نماذج البيانات، وتعتبر عمليات التصنيف Classification والتنبؤ أحد أهم هذه النماذج المستخدمة. تسمح عمليات التصنيف باستنباط نماذج تحليلية تحدد سلوك نماذج البيانات المدروسة وتسمح بالتنبؤ بالقيم الجديدة اعتماداً على القيم السابقة.

تعتمد هذه الدراسة على استخدام الشبكات العصبية التكرارية Recurrent Neural Networks والشبكات العصبية الكثيفة Dense Neural Networks للتنبؤ بحمل الطاقة الكهربائية المطلوب في مدينة اللاذقية وتوزيعه وفقاً للبيانات الموزعة في الفترة ما بين 2018 و 2020 والمقدمة من قبل شركة الكهرباء. تم إجراء هذه الدراسة من أجل تحديد الحمل الأصغري المناسب للشبكة والذي يمكن له أن يقدم حاجة المدينة الأساسية ضمن الظروف العامة التي تتعرض لها الشبكة في الفترة الراهنة مع الأخذ بعين الاعتبار فترات التقنين المثالية ومن ثم يمكن لنا تحديد الفائض (إن وجد) والذي يمكن الحصول عليه وتزويده للمواقع التي تحتاج إلى توفر حمل كهربائي دائم.

2- أدوات البحث:

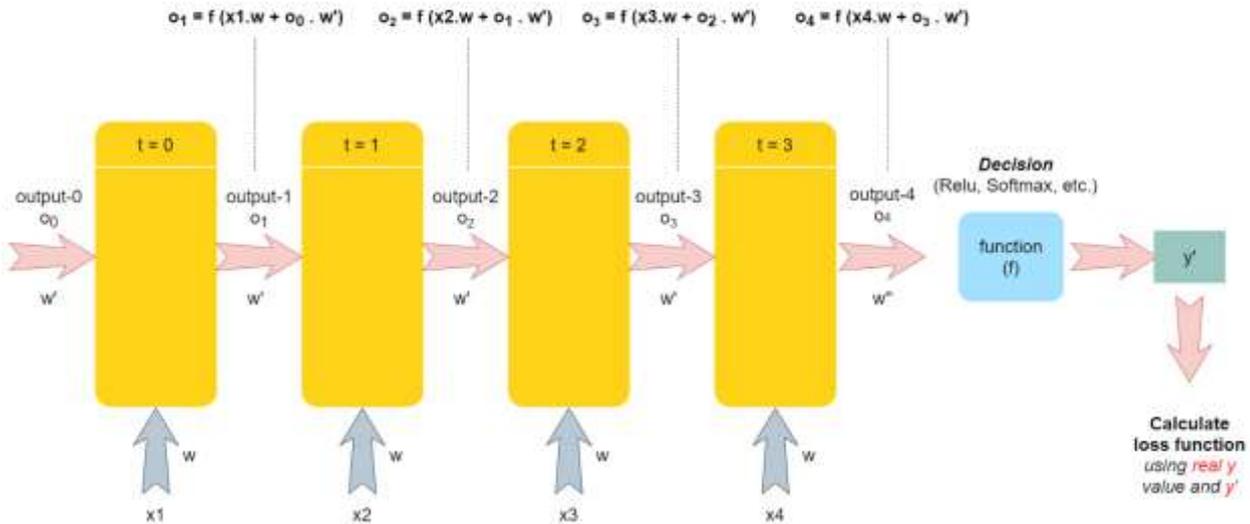
من أجل القيام بالبحث المطروح، يوجد العديد من اللغات والنماذج البرمجية التي يمكن الاعتماد عليها من أجل البناء، تم الاعتماد على لغة البايثون Python نظراً لكونها اللغة الأقوى حالياً في مجال تحليل البيانات بالإضافة إلى تضمينها

العديد من المكتبات الفعالة في كافة مجالات تحليل البيانات. تتضمن لغة البايثون أيضاً مكتبات الشبكات العصبية والتي تسمح لنا بدراسة وتحليل البيانات المقدمة والتنبؤ بالقيم اللاحقة. تم إدخال البيانات كملف من نمط CSV حيث يتم تحويلها برمجياً من أجل معالجتها باستخدام البايثون إلى البنية المصفوفية، وبعد ذلك يتم بناء مجموعات التدريب والاختبار التي سيتم تمريرها إلى الشبكات العصبية، ثم تقوم الشبكات العصبية بالتعلم وتعديل الأوزان وفقاً للبيانات المتاحة عليها المرحلة الأخيرة وهي التنبؤ بقيمة الحمل لفترة زمنية محددة ومتاحة ضمن الشبكة المدروسة.

2-1 الشبكات العصبية التكرارية RNN:

عند دراسة قواعد البيانات، وبالأخص تلك التي تعتمد بصورة رئيسية على الصيغة التسلسلية، فإن كل نقطة بيانات في اللحظة t تتعلق بعلاقة ما مع البيانات السابقة في اللحظة $t-1$. على سبيل المثال، إذا أخذنا بعين الاعتبار نماذج البيانات من نمط اللغات الطبيعية (Natural Language Programing) NLP، فإن تكرارية النموذج تتشكل اعتماداً على تسلسل من العبارات السابقة لها أي اعتماداً على تكاملية الجملة المشكلة. خلال قراءة كتاب ما، فإن التسلسل المعروف من 3 إلى 4 كلمات يتم ملاحظته ويسمح بتشكيل وبناء الجملة وعليه فإننا نستمر بقراءة الكتاب ببساطة. في نظم تعلم الآلة، يمكن لنا استخدام الشبكات العصبية التكرارية لاستخلاص المعنى الرئيسي ونموذج العمل من قواعد البيانات التسلسلية. على سبيل المثال، يتضمن الفيديو مجموعة من الإطارات المتكاملة وفقاً لموضوع ومحتوى هذا الفيلم حيث يمكن لنا التنبؤ في اللحظة التالية باللقطة التالية وذلك بعد تشكيلنا لفهم عام عن هذا الفيلم. يمكن للشبكات التكرارية التنبؤ بالمستقبل من خلال التعرف على النموذج التدفقي للبيانات التكرارية، حيث تقوم بتشكيل مخطط سلاسل زمنية من مخططات البيانات المتغيرة زمنياً لكشف التدفق وإنشاء التنبؤ.

يوضح المخطط المبين في الشكل (1) كيفية عمل الشبكات العصبية التكرارية مع مجموعة من البيانات التسلسلية مؤلفة من 4 بيانات خلال 4 لحظات زمنية حيث تتمتع بنموذج عمل مشابه للشبكات العصبية ذات التغذية الأمامية.



الشكل (1) الشبكات العصبية التكرارية (RNN) يتألف النظام من أربع عقد زمنية t يتم تفعيلها وفقاً لتابع تفعيل o مع مجموعة من الأوزان w ويتم تمرير المدخلات x_1, x_2, x_3, x_4 بصورة متسلسلة بحيث يتعلق دخل المرحلة اللاحقة بخرج المرحلة السابقة. عند تمرير العينة الأخيرة يقوم تابع التفعيل ReLU أو SoftMax بتحديد الخرج المتنبأ به y والذي نقوم بمقارنته مع القيمة التالية الفعلية لحساب قيمة الخطأ.

يتم تمرير الأوزان التي يتم اسنادها إلى المداخل باتجاه المخارج بعد مرورها على مجموعة من الطبقات ويتم مقارنتها مع الخرج الفعلي لتحديد معدل الخسارة (وهي المسافة عن الخرج الذي يجب أن تتوضع عنده). اعتماداً على قيمة الخسارة هذه يتم تعديل الأوزان من جديد ويتم تكرار هذه العملية بصورة مستمرة. الهدف الرئيسي من تعديل الأوزان هي تقليل قيمة الخطأ والحصول على قيم الأوزان المثالية.

تصمم الشبكات التكرارية من ناحية أخرى بصورة تسلسلية، أي بصيغة عكسية لكشف العلاقة بين البيانات في الزمن t والزمن $t-1$ حيث قد يتم حساب القيمة الجديدة اعتماداً على 10 قيم سابقة على سبيل المثال.

على سبيل المثال لنفترض أنه لدينا أربعة نقاط بيانات X_1, X_2, X_3, X_4 حيث تمثل البنى الصفراء في المخطط الطبقات التي تتألف منها شبكات RNN حيث توضح العلاقات في المخطط العلاقات الحاكمة للطبقات، وكما نلاحظ فإن خرج كل طبقة يمثل دخل إضافي للطبقة التالية. في حين يعتمد الخرج النهائي للطبقات على تابع التفعيل ومن ثم يحسب الانحراف للنتيجة الأخيرة، يتم بعد ذلك تعديل الأوزان اعتماداً على خسارة الخرج حيث يتم تحديثها اعتماداً على عمليات التغذية الخلفية للشبكة.

2-2 تلاشي المشتق Vanishing Gradient Descent :

وهي الحالة التي يتم الوصول إليها عندما لا يكون لدينا القدرة على حساب النقطة الصغرى العامة global minimum point وتحدث هذه الحالة في شبكات RNN عند وجود العديد من الطبقات في الشبكة مع تعديل الأوزان باستخدام تابع من نمط Sigmoid function حيث تكون القيمة الناتجة محصورة بين الصفر والواحد. يكون التعلم في البداية وأثناء تدريب الشبكة أصغرياً حيث يتم تعديل الأوزان ضمن مستويات منخفضة وبالتالي يتم تجاهل هذه المداخل وأوزانها والاعتماد في عملية التدريب على المداخل الأخيرة.

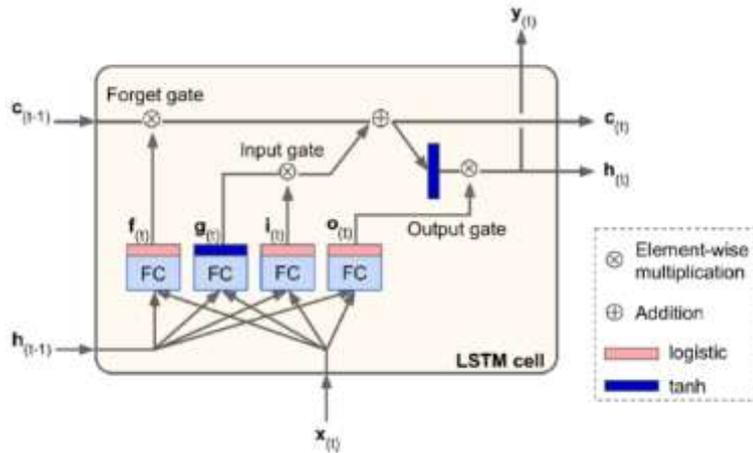
عند استخدام توابع تفعيل أخرى مثل ReLU فإن بنية معاكسة لعملية التدرج المتلاشي يتم اعتمادها وبالتالي يتم إجراء تغييرات كبيرة على الأوزان وبالتالي لا يتم الوصول إلى نقطة النهاية الصغرى إلا بصورة آمنة.

3-2 الذاكرة طويلة- قصيرة الأمد Long-Short Term Memory :

وهي بنية تم تصميمها لتجنب تجاهل المداخل الأولى في السلسلة التتابعية خلال عمليات تحديث الأوزان، يوضح الشكل (2) كيف يقوم نموذج LSTM بتجنب مشكلة عدم أخذ البيانات الأولى بعين الاعتبار (أوزان البيانات السابقة) والغير هامة في عمليات ضبط الأوزان.

يقوم التابع Logistic (Sigmoid) activation function بإخراج قيم البيانات بين الصفر والواحد. وبالتالي يتم تقدير قيم البيانات بين الصفر والواحد حيث تصبح قيمة الصفر غير هامة ويمكن لنا أن نقوم بتجاهلها في حين تقدر القيمة 1 أن البيانات هامة ويجب الحفاظ عليها.

يقوم تابع التفعيل Tanh activation function بتنظيم البيانات بقيم 1 و -1 كقيم خرج.



الشكل (2) عمليات ضبط الأوزان في الشبكات العصبية التكرارية، يتم تمرير خرج الخلية $h(t-1)$ والدخل الحالي $x(t)$ عبر تابع $\text{logistic}(\text{sigmoid})$ ويتم جداء الحالة طويلة الأمد $\text{long-term state } c(t-1)$ مع القيمة الناتجة $f(t)$. تسمى كامل هذه العملية ببوابة النسيان forget gate حيث تحدد عملياً ماهي البيانات الهامة وماهي البيانات التي يجب تجاهلها.

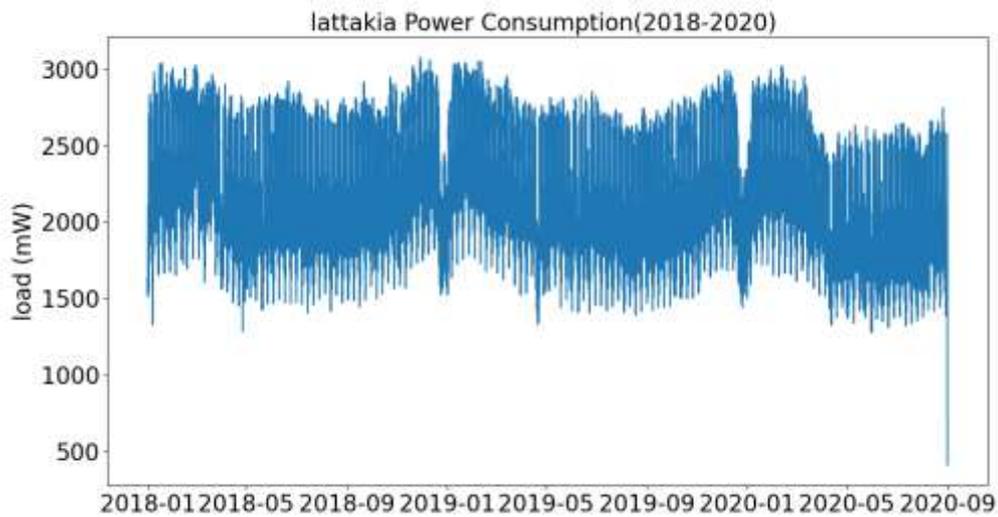
3- مراحل النظام المقترح:

أولاً: يتم تمرير خرج الخلية $h(t-1)$ والدخل الحالي $x(t)$ عبر تابع $\text{logistic}(\text{sigmoid})$ ويتم جداء الحالة طويلة الأمد $c(t-1)$ مع القيمة الناتجة $f(t)$. تسمى كامل هذه العملية ببوابة النسيان forget gate حيث تحدد عملياً ماهي البيانات الهامة وماهي البيانات التي يجب تجاهلها. ثانياً: يتم الحصول أيضاً على قيمة تابع Sigmoid والتي تم الحصول عليها من المرحلة السابقة (الإشارة $i(t)$) مع نفس المدخلات السابقة ومن ثم تمرر إلى تابع التنغيع tanh وتضرب مع خرج تابع Sigmoid $g(t)$ في هذه المرحلة والتي تسمى (بوابة الدخل) تحدد الإشارة $i(t)$ مقدار أهمية الإشارة $g(t)$. ثالثاً: يتم دمج الحالتين السابقتين (بوابة الدخل والنسيان) لتشكيل حالة خلية جديدة $c(t)$. بالإضافة لذلك، يتم تنظيم هذه القيمة من خلال تمريرها إلى تابع tanh ويتم جدها بخرج تابع Sigmoid $o(t)$ لكلا مدخلات الحالة السابقة (خرج الخلية السابق $h(t-1)$ والدخل الحالي $x(t)$) للحصول على حالة الذاكرة القصيرة short-term state المعرفة بالإشارة $h(t)$ وتسمى هذه المرحلة ببوابة الخرج.

تم تدريب النموذج باستخدام LSTM و DNN اعتماداً على استهلاك الطاقة الكهربائية الساعي في مدينة اللاذقية في الفترة بين عام 2018 و 2020. تتألف البيانات المدروسة من 93500 قيمة استهلاك كل ربع ساعة، تحتاج هذه البيانات إلى عملية تعرف بعملية التنظيف Data Cleaning وذلك لكون بعض البيانات غير موجودة أولاً، أو لضمان الترتيب المتسلسل للبيانات حيث أن أي خلل في تسلسل البيانات أو محتواها سيكون ذو تأثير ضخم على دقة وفعالية النموذج المقترح. وفي حال وجود بعض البيانات الفارغة فقد تم استبدالها بالمتوسط الحسابي للساعات السابقة واللاحقة. قد تتضمن البيانات أيضاً قيم غير منطقية لحالة الطقس والرطوبة وكذلك يمكن لنا في هذه الحالة أن نأخذ المتوسط الحسابي بعين الاعتبار.

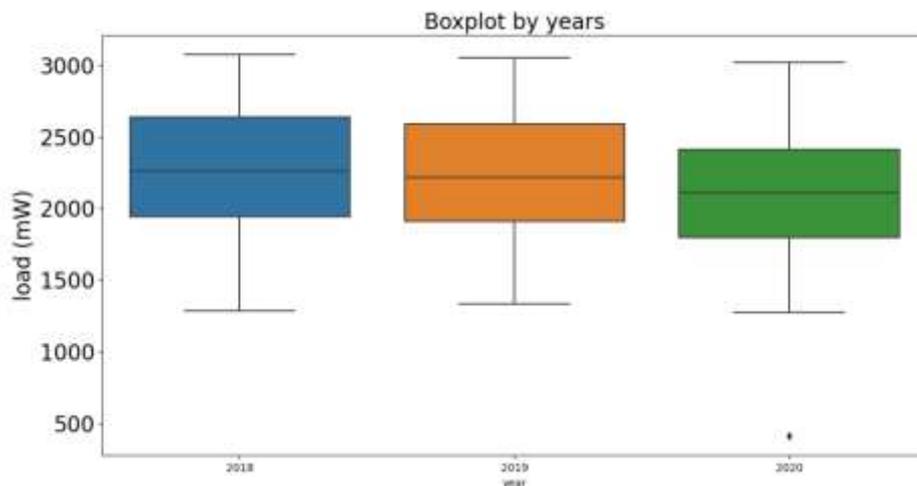
يلي ذلك عملية تهيئة البيانات حيث تم تقسيم مجموعة البيانات المتاحة إلى بيانات تدريب وبيانات اختبار، تتضمن مجموعة البيانات تلك قيم استهلاك الطاقة الكهربائية والتي تتغير كل 15 دقيقة حيث تم تحويل تلك القيم إلى استهلاك ساعي اعتماداً على جمع كل أربع قيم (من 0 إلى 15 دقيقة، من 15 إلى 30 دقيقة، من 30 إلى 45 دقيقة ومن 45

إلى 60 دقيقة). يوضح الشكل (3) التالي مخططاً بيانياً لاستهلاك القدرة الكهربائية في مدينة اللاذقية خلال فترة الاختبار المدروسة.

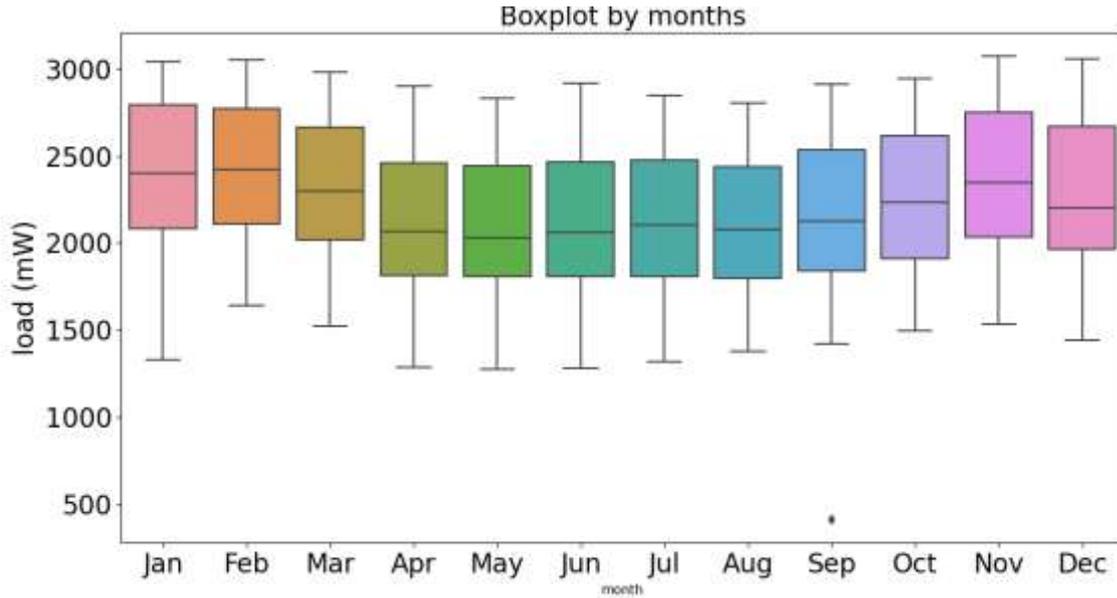


الشكل (3) يوضح الشكل استهلاك مدينة اللاذقية من الطاقة الكهربائية بالميجاواط خلال الفترة من الشهر الأول 2018 وحتى الشهر التاسع 2020 ونلاحظ خلال الفترة مواقع استهلاك الطاقة العظمى والصغرى.

نلاحظ من المخطط السابق أن مجموع قيمة الاستهلاك تتراوح بين (1500) و(3000) ميغا وات وقد كانت بذروتها في الشهر الأول من العام 2018 والعام 2019 ، وبعد إضافة الأشهر والسنوات بنفس الطريقة تم عرض الاستهلاك الشهري والسنوي أيضاً.



الشكل (4) توزيع حمل الطاقة الكهربائية خلال سنوات الدراسة

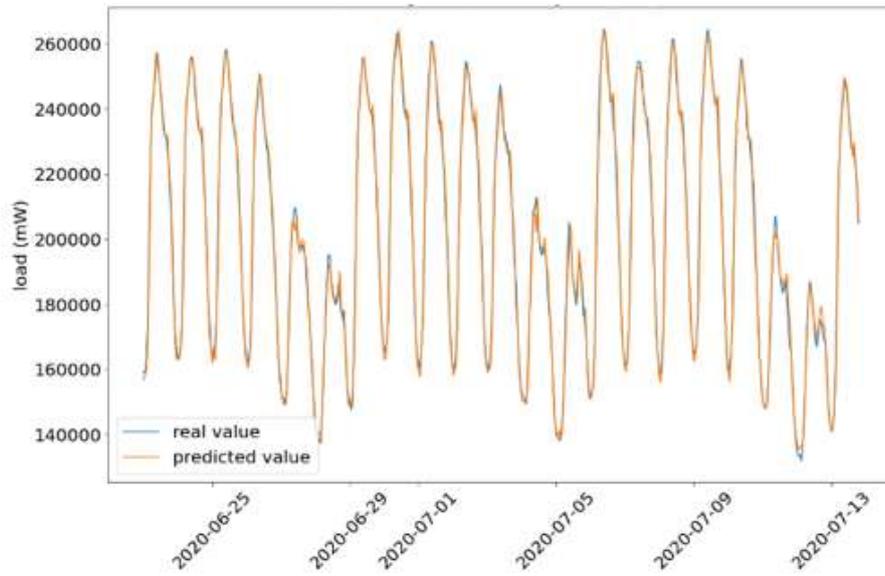


الشكل (5) توزيع حمل الطاقة الكهربائية خلال العام 2020 بالميجاواط خلال أشهر السنة مع هامش الخطأ المتوقع

كما نلاحظ من مخططات الاستهلاك السنوي والشهري أن أعلى قيم للاستهلاك الشهري كانت في أشهر كانون الثاني وشباط وتشرين الثاني، في حين كانت أقل كميات استهلاك في شهري أيار وآب. ينخفض الاستهلاك في هذين الشهرين نظراً لخروج السكان من منازلهم ويمكن لنا أن نأخذ هذا الفائض بعين الاعتبار وتوفيره للاستخدام في الأشهر الأعلى استهلاكاً.

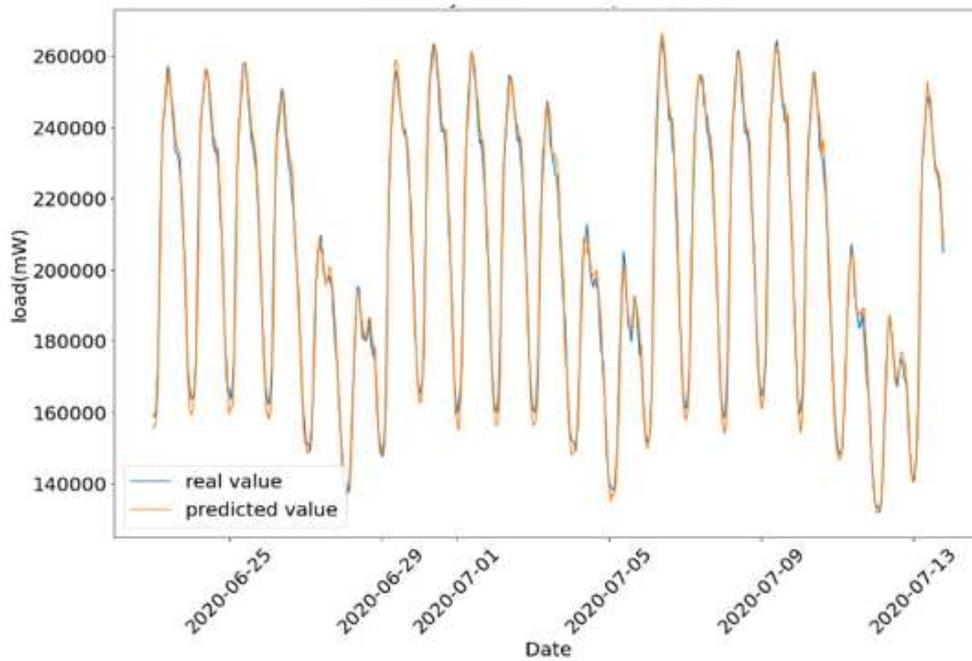
تم بعد ذلك إعادة ضبط البيانات وتصميمها وفقاً لدخل الشبكة العصبية باستخدام الاستراتيجية التالية: تم إعداد الدخل $last_n=24$ وهو مؤلف من بيانات اليوم 24 ساعة بصورة تسلسلية و 25 قيمة خرج بيانات. على سبيل المثال يكون لدينا 24 خرج عندما نستخدم من 0 حتى 24 دخل، 25 خرج عندما نستخدم من 1 حتى 25 دخل، 26 خرج عندما نستخدم من 2 حتى 26 دخل وهكذا دواليك.

بما أننا قمنا بتصميم نموذج LSTM من النمط $return_sequence=true$ حتى آخر طبقة ضمن النموذج و تم تدريب النموذج. في نهاية عملية التدريب يتم تعديل الأوزان والتنبؤ بقيم بيانات الاختبار والتدريب بصورة منفصلة.



الشكل (6) القيم الحقيقية والقيم المتنبأ بها خلال فترة الدراسة باستخدام RNN

في المرحلة التالية تم بناء النموذج باستخدام الطبقات الكثيفة dense layers لتدريب النموذج باستخدام الشبكة العصبية العميقة وتم أيضاً ضبط البيانات لتناسب دخل الطبقة العصبية وتم الحصول على قيم التنبؤ التالية كما موضح في الشكل (7):



الشكل (7) القيم الحقيقية والقيم المتنبأ بها خلال فترة الدراسة باستخدام DNN

النتائج والمناقشة:

يسمح استخدام التقنيات الذكية من أجل تحليل البيانات لإدارة الطاقة الكهربائية بإنشاء نماذج تنبؤية من أجل المزيد من خدمات القدرة الكهربائية. سمحت هذه الدراسة بالبحث في دقة نماذج الذكاء الاصطناعي وتعلم الآلة للتنبؤ باستهلاك الطاقة الكهربائية في مدينة اللاذقية. بخلاف العديد من الدراسات الأخرى والتي ركزت على المناطق السكنية فقط، فقد ركزت هذه الدراسة على الاستهلاك العام لمدينة اللاذقية بغض النظر عن مركز الاستهلاك (مصنع، مشفى أو مبنى سكني) والذي تم الحصول عليه من بيانات مراكز التوزيع الرئيسية في مدينة اللاذقية.

يسمح التصميم الدقيق للمقاييس الذكية بالإضافة إلى تقنيات جمع البيانات بالحصول على بيانات دقيقة للاستهلاك الكهربائي، تم اعتماد العديد من الطرق لتقسيم البيانات إلى بيانات اختبار وبيانات تدريب، إلا أننا استنتجنا أن اعتماد طريقة التقسيم المتتالي القائم على الوقت لها القدرة على العمل بصورة أعلى دقة بالنسبة للبيانات ذات العينات العشوائية. وبالنسبة لحالات انخفاض تنظيم البيانات الساعية لاستهلاك القدرة الكهربائية، يمكن لنا أخذ عينات لمجموعة من البيانات بالنسبة للزمن وأخذ 20 بالمئة من البيانات على سبيل المثال كعينات تدريب واختبار.

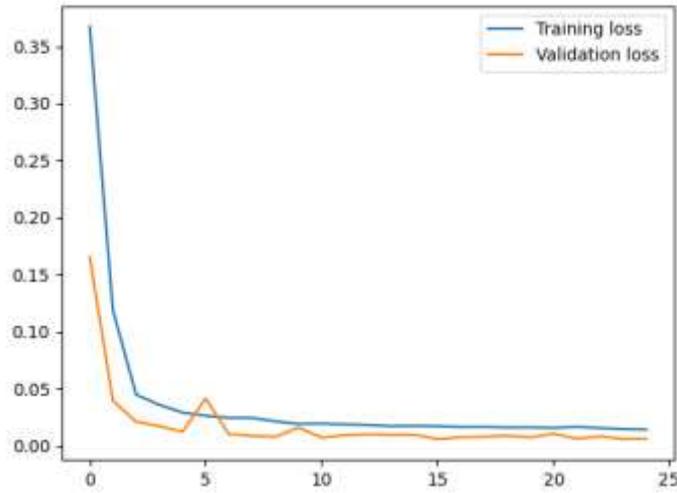
بسبب عشوائية البيانات الخاصة بالاستهلاك تبين لنا أن استخدام البيانات على أساس يومي يمكن له أن يعطي نتائج تنبؤية أكثر دقة من البيانات الساعية، حيث وجدنا أن تحويل البيانات بهذه الطريقة يتمتع بالفعالية من أجل تخفيف تأثير العشوائية في الاستهلاك الساعي. تعتمد شبكات LSTM على تدريب النموذج بعد تعديل الأوزان مع الأخذ بعين الاعتبار البيانات السابقة للذاكرة الطويلة long-term historical data. في حين تعتمد شبكات DNN على تعديل الأوزان باستخدام توابع التفعيل بين الدخل والخرج اعتماداً على انحيازات الشبكة العصبية.

عند مقارنة النتائج في الشكلين 6 و 7 نلاحظ أن الخرجين متقاربين تقريباً. إلا أن شبكات RNN تعطي خرجاً ومخططاً أكثر فاعلية عند القيم الصغرى للذرى العليا وخصوصاً عند قيم نقاط الذرى الدنيا. في حين أعطت شبكات DNN ذرى صغرى أقل مما يجب أن تكون عليه. بالنسبة ل LSTM أعطت قيم مخطط أكثر دقة وفعالية حتى عند الانحرافات العظمى والدنيا.

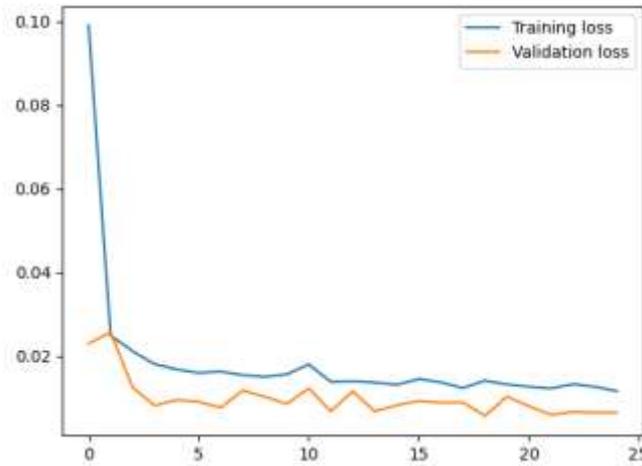
بما أن تصميم LSTM يعتمد بصورة رئيسية على أخذ البيانات السابقة بعين الاعتبار، فإنها تقوم بعملية التدريب بصورة أكثر فعالية. لذلك خلال عملية التدريب، يمكن أن تجعل شبكات DNN الخطأ كجزء رئيسي من عملية التدريب بخلاف شبكات LSTM والتي تجعل النموذج أكثر استقراراً في هذه الحالة. كما أن نموذج قاعدة البيانات يسلك نموذجاً محدداً (كما في الشكل 3)، فإنه عند التمييز بين الطريقتين يمكن بدقة ملاحظة مخطط تنبؤ الخرج كما أن دقة شبكات LSTM يمكن الحصول عليه عندما تكون البيانات أكثر عشوائية (من الصعب الحصول على النموذج).

يوضح الشكلين (8) و (9) أخطاء التدريب والاختبار عند استخدام كلاً من نموذجي الشبكتين العصبيتين، حيث يسمح خطأ التدريب بتحديد عدد الدورات الأعظمى واللازم من أجل تدريب الشبكة بصورة صحيحة وبالتالي تخفيض الاسهاب الزمني اللازم من أجل إنهاء تلك العملية. كما نلاحظ من الشكل (8) أن خطأ التدريب قد انخفض لدرجة كبيرة بعد الدورة الخامسة (وهي تمثل مجال مناسب للحصول على الدقة المقبولة).

من ناحية أخرى نلاحظ أيضاً انخفاض خطأ التقييم والذي يتضمن قمماً حادة ناتجة عن تغيير نموذج البيانات المستخدمة في عملية التدريب بالإضافة إلى وجود انقطاعات أو أخطاء ضمن البيانات.



الشكل (8) خطأ التدريب والتقييم باستخدام RNN



الشكل (9) خطأ التدريب والتقييم باستخدام DNN

كذلك ومن خلال تتبع خطأ التدريب والتقييم لشبكة DNN المستخدمة، فإننا نلاحظ ارتفاع خطأ التقييم والاختبار ضمن هذه الشبكة بالإضافة إلى تعرض الشبكة لبعض الصعوبات في عمليات التقييم وهو ما يعود بصورة سلبية على هذه الشبكة مقارنة مع الشبكة من النمط RNN. يلعب انخفاض كمية البيانات المدروسة وعشوائيتها دوراً كبيراً في انخفاض دقة النظام المدروس.

الاستنتاجات والتوصيات:

تعتبر تقنيات الذكاء الصناعي على اختلاف أنواعها ونماذجها إحدى التقنيات الحديثة التي تسمح بعمليات التنبؤ والتحكم في النظم المختلفة، ولعل نظم الطاقة الكهربائية واحدة من أهم هذه النظم. اعتمدت تقنيات مختلفة من أجل التنبؤ والتحكم بالطاقة الكهربائية مثل تقنيات التصنيف كمصنف الجار الأقرب ومصنف متجه شعاع الدعم. تقنيات أخرى استخدمت الشبكات العصبية ذات التمرير الأمامي أو الشبكات العميقة أو الشبكات التكرارية. سمح استخدام الشبكات التكرارية بتحقيق نسبة تنبؤ عالية لاستهلاك الطاقة الكهربائية في مدينة اللاذقية بحيث يمكن تحديد الاستهلاك الاصغري المطلوب لخدمة جميع المرافق مما يسمح بتوفير فائض في الطاقة الكهربائية بالإضافة إلى

إمكانية النظام للتحكم بعمليات التقنين بصورة آلية عن طريق استخدام النموذج المقترح لتحديد تقريبي لعدد ساعات التقنين وفقاً للقيمة المتنبأ بها وتعديل أوقاتها بصورة آلية. يمكن ربط خرج هذا النظام مستقبلاً بأي نظام تحكيمي عن طريق المبدلات والقواطع بحيث يتم تحديد المواقع التي يتم تزويدها بالطاقة الكهربائية بالإضافة إلى إمكانية توصيله مستقبلياً على شكل بنية شبكية قابلة للتنبؤ والتحكم على كامل أراضي الجمهورية العربية السورية.

References:

- 1.S.Canada, "Households and the environment survey: Energy use, 2013," <http://www.statcan.gc.ca/dailyquotidien/160318/dq160318d-eng.htm>, Mar 2016.
- 2.U. D. of Energy, "Green button," <https://energy.gov/data/green-button>.
- 3.R. K. Jain, K. M. Smith, P. J. Culligan, and J. E. Taylor, "Forecasting energy consumption of multi-family residential buildings using support vector regression: Investigating the impact of temporal and spatial monitoring granularity on performance accuracy," *Applied Energy*, vol. 123, pp. 168–178, 2014.
- 4.Y. Liu, W. Wang, and N. Ghadimi, "Electricity load forecasting by an improved forecast engine for building level consumers," *Energy*, vol. 139, pp. 18–30, 2017.
- 5.R. E. Edwards, J. New, and L. E. Parker, "Predicting future hourly residential electrical consumption: A machine learning case study," *Energy and Buildings*, vol. 49, pp. 591–603, 2012.
- 6.T. K. Wijaya, M. Vasirani, S. Humeau, and K. Aberer, "Cluster-based aggregate forecasting for residential electricity demand using smart meter data," in *Big Data (Big Data)*, 2015 IEEE International Conference on. IEEE, 2015, pp. 879–887.
- 7.S. Humeau, T. K. Wijaya, M. Vasirani, and K. Aberer, "Electricity load forecasting for residential customers: Exploiting aggregation and correlation between households," in *Sustainable Internet and ICT for Sustainability (SustainIT)*, 2013. IEEE, 2013, pp. 1–6.
- 8.Z. Li and B. Dong, "A new modeling approach for shortterm prediction of occupancy in residential buildings," *Building and Environment*, vol. 121, pp. 277–290, 2017.
- 9.M. R. Biswas, M. D. Robinson, and N. Fumo, "Prediction of residential building energy consumption: A neural network approach," *Energy*, vol. 117, pp. 84–92, 2016.
- 10.H.-x. Zhao and F. Magoules, "A review on the prediction of building energy consumption," *Renewable and Sustainable Energy Reviews*, vol. 16, no. 6, pp. 3586–3592, 2012.
- 11.K. Grolinger, A. L'Heureux, M. A. Capretz, and L. Seewald, "Energy forecasting for event venues: Big data and prediction accuracy," *Energy and Buildings*, vol. 112, pp. 222–233, 2016.
- 12.S. Abdelkader, K. Grolinger, and M. A. Capretz, "Predicting energy demand peak using m5 model trees," in *Machine Learning and Applications (ICMLA)*, 2015 IEEE 14th International Conference on. IEEE, 2015, pp. 509–514.
- 13.D. B. Araya, K. Grolinger, H. F. ElYamany, M. A. Capretz, and G. Bitsuamlak, "An ensemble learning framework for anomaly detection in building energy consumption," *Energy and Buildings*, vol. 144, pp. 191–206, 2017.
- 14.F. Zhang, C. Deb, S. E. Lee, J. Yang, and K. W. Shah, "Time series forecasting for building energy consumption using weighted support vector regression with differential evolution optimization technique," *Energy and Buildings*, vol. 126, pp. 94–103, 2016.

- 15.C. Robinson, B. Dilkina, J. Hubbs, W. Zhang, S. Guhathakurta, M. A. Brown, and R. M. Pendyala, "Machine learning approaches for estimating commercial building energy consumption," *Applied Energy*, vol. 208, pp. 889–904, 2017.
- 16.Q. Sun, H. Li, Z. Ma, C. Wang, J. Campillo, Q. Zhang, F. Wallin, and J. Guo, "A comprehensive review of smart energy meters in intelligent energy networks," *IEEE Internet of Things Journal*, vol. 3, no. 4, pp. 464–479, 2016.
- 17.A. Tascikaraoglu, A. Boynuegri, and M. Uzunoglu, "A demand side management strategy based on forecasting of residential renewable sources: A smart home system in turkey," *Energy and Buildings*, vol. 80, pp. 309–320, 2014.
- 18.P. Lusi, K. R. Khalilpour, L. Andrew, and A. Liebman, "Short-term residential load forecasting: Impact of calendar effects and forecast granularity," *Applied Energy*, vol. 205, pp. 654–669, 2017.
- 19.B. Yildiz, J. Bilbao, J. Dore, and A. Sproul, "Recent advances in the analysis of residential electricity consumption and applications of smart meter data," *Applied Energy*, 2017.
- 20.C. Beckel, L. Sadamori, T. Staake, and S. Santini, "Revealing household characteristics from smart meter data," *Energy*, vol. 78, pp. 397–410, 2014.
- 21.Y.-H. Hsiao, "Household electricity demand forecast based on context information and user daily schedule analysis from meter data," *IEEE Transactions on Industrial Informatics*, vol. 11, no. 1, pp. 33–43, 2015.
- 22.M. Rossi and D. Brunelli, "Electricity demand forecasting of single residential units," in *Environmental Energy and Structural Monitoring Systems (EESMS)*, 2013 IEEE Workshop on. IEEE, 2013, pp. 1–6.
- 23.M. Hinterstocker, P. Schott, and S. von Roon, "Evaluation of the effects of time-of-use pricing for private households based on measured load data," in *European Energy Market (EEM)*, 2017 14th International Conference on the. IEEE, 2017, pp. 1–6.
- 24.O. E. Board, "Electricity rates," <https://www.oeb.ca/ratesand-your-bill/electricity-rates>.
- 25.L. Diao, Y. Sun, Z. Chen, and J. Chen, "Modeling energy consumption in residential buildings: A bottomup analysis based on occupant behavior pattern clustering and stochastic simulation," *Energy and Buildings*, vol. 147, pp. 47–66, 2017.
- 26.F. Kaytez, M. C. Taplamacioglu, E. Cam, and F. Hardalac, "Forecasting electricity consumption: a comparison of regression analysis, neural networks and least squares support vector machines," *International Journal of Electrical Power & Energy Systems*, vol. 67, pp. 431–438, 2015.
- 27.B. Yildiz, J. Bilbao, and A. Sproul, "A review and analysis of regression and machine learning models on commercial building electricity load forecasting," *Renewable and Sustainable Energy Reviews*, vol. 73, pp. 1104–1122, 2017.
- 28.B. Dong, Z. Li, S. M. Rahman, and R. Vega, "A hybrid model approach for forecasting future residential electricity consumption," *Energy and Buildings*, vol. 117, pp. 341–351, 2016.
- 29.A. Grandjean, J. Adnot, and G. Binet, "A review and an analysis of the residential electric load curve models," *Renewable and Sustainable Energy Reviews*, vol. 16, no. 9, pp. 6539–6565, 2012.
- 30.F. Rodrigues, C. Cardeira, and J. M. F. Calado, "The daily and hourly energy consumption and load forecasting using artificial neural network method: a case study using a set of 93 households in portugal," *Energy Procedia*, vol. 62, pp. 220–229, 2014.
- 31.R. Miller, L. Golab, and C. Rosenberg, "Modelling weather effects for impact analysis of residential time-of-use electricity pricing," *Energy Policy*, vol. 105, pp. 534–546, 2017.

- 32.K. Gajowniczek and T. Zabkowski, "Electricity forecasting on the individual household level enhanced based on activity patterns," PloS one, vol. 12, no. 4, p. e0174098, 2017.
- 33.V. N. Vapnik and S. Kotz, Estimation of dependences based on empirical data. Springer-Verlag New York, 1982, vol. 40.
- 34.B. Gilmour, "City of london: Integrated energy mapping strategy (l-iems)," Canadian Urban Institute, Tech. Rep., 2011.
- 35.J. Hosking, R. Natarajan, S. Ghosh, S. Subramanian, and X. Zhang, "Short-term forecasting of the daily load curve for residential electricity usage in the smart grid," Applied Stochastic Models in Business and Industry, vol. 29, no. 6, pp. 604–620, 2013.
- 36.A. Tascikaraoglu and B. M. Sanandaji, "Short-term residential electric load forecasting: A compressive spatiotemporal approach," Energy and Buildings, vol. 111, pp. 380–392, 2016.
- 37.S. Rathi, K. Rawal, Y. Pawar, D. Zalte, S. Shivarkar, and B. Students, "Short term power demand forecasting," International Journal of Engineering Science, vol. 3423, 2016