

# دراسة وتصميم نظام تنبؤ بخرج منظومة طاقة شمسية في محافظة حمص بالاعتماد على القياسات وتقنيات تعلم الآلة

د.م. بسيم عمران

أستاذ مساعد في قسم هندسة التحكم الآلي والحواسيب

كلية الهندسة الميكانيكية والكهربائية - جامعة البعث

## الملخص

يعد التنبؤ بالسلوك المستقبلي لمحطات الطاقة البديلة من أهم التحديات التي تواجه اعتماد هذه الاستراتيجية، حيث تعتبر أنظمة توليد الطاقة البديلة المعتمدة على الألواح الشمسية الأكثر انتشاراً في المجتمع السوري في الظروف الراهنة، والتي بدورها تعتمد بشكل رئيسي على متغيرات المناخ التي لا تأخذ بعين الاعتبار في أنظمة التنبؤ. يهدف هذا البحث الى تصميم نظام تنبؤ مستقبلي لنظام توليد طاقة بديلة يعتمد على تقنية الألواح الشمسية باستخدام تقنيات تعلم الآلة. تم استخدام نموذج الشبكة العصبونية العميقة (DNN) للتنبؤ بخرج الطاقة لمحطة توليد طاقة بديلة حقيقية تقع في محافظة حمص. في هذا البحث تم تصميم شبكة عصبونية عميقة وتنفيذها باستخدام ثلاث قواعد بيانات، قاعدة البيانات الأولى عبارة عن قاعدة بيانات عالمية متواجدة على منصة kaggle وتم استخدامها لتدريب الشبكة العصبونية العميقة، قاعدة البيانات الثانية أيضاً قاعدة بيانات عالمية متواجدة على ذات المنصة، أما قاعدة البيانات الثالثة فهي عبارة عن قاعدة بيانات تم تجميعها

دراسة وتصميم نظام تنبؤ بخرج منظومة طاقة شمسية في محافظة حمص بالاعتماد على القياسات وتقنيات تعلم الآلة

من موقع العمل وتم استخدامها للتحقق من دقة النموذج المصمم واختبار المنظومة. تظهر النتائج انه يمكن الاعتماد على متغيرات المناخ وخرج المنظومة وتقنيات التعلم الآلي للتنبؤ المستقبلي بمخرجات نظام طاقة بديلة معتمد على الألواح الشمسية مع خطأ اقل من 8%.

## الكلمات المفتاحية

أنظمة الطاقة البديلة، الألواح الشمسية، تقنيات تعلم الآلة، الشبكات العصبونية العميقة، متغيرات المناخ.

## Study and design of a prediction system for an alternative energy system based on machine learning techniques in Homs governorate

**Dr .BASSIM OUMRAN**

**Assistant Professor in the Department of Automation and Computer Enginerring**

**Faculty of Mechanical and Electrical Engineering – AL BAATH University**

### Abstract

Predicting the future behavior of alternative energy plants is one of the most important challenges facing the adoption of this strategy, as alternative energy generation systems based on

solar panels are considered the most prevalent in the Syrian society in the current conditions, which in turn depend mainly on climate variables that are not taken into account in the systems Forecasting. This research aims to design a future prediction system for an alternative energy generation system based on solar panel technology using machine learning techniques. The deep neural network (DNN) model was used to predict the power output of a real alternative power plant located in Homs Governorate. In this research, a deep neural network was designed and implemented using three databases, the first database is a global database located on the kaggle platform and was used to train the deep neural network, the second database is also a global database located on the same platform, and the third database is It is a database collected from the job site and used to verify the accuracy of the designed model and test the system. The results show that it is possible to rely on climate variables, system output and machine learning techniques to predict the future outputs of an alternative energy system based on solar panels with an error of less than 8%.

### **Keywords**

Alternative energy systems, solar panels, machine learning techniques, deep neural networks, climate variables.

## 1. المقدمة

يعد الإقبال المتزايد على أنظمة الطاقة البديلة المتجددة من القضايا المهمة التي يتعامل معها المجتمع السوري في عام 2021، ومن المتوقع أن يزداد الاعتماد على الطاقة المتجددة بشكل كبير خلال الأعوام التالية وذلك لتقليل استخدام الوقود الأحفوري وترشيد استخدامه، ومن المتوقع أن تمثل الطاقة الشمسية الكهروضوئية والرياح أهم مصادر الطاقة البديلة المتجددة [5].

تعتمد معظم أنظمة الطاقة المتجددة على الظروف الجوية لتوليد الطاقة الكهربائية، ويعد الإشعاع الشمسي العامل الرئيسي الذي يتحكم في خرج أنظمة الطاقة الشمسية بالإضافة إلى متغيرات أخرى مثل درجة حرارة الهواء والرطوبة وسرعة الرياح وغيرها والتي تؤثر أيضا على أداء المنظومة [12].

قامت العديد من الدراسات السابقة بالتنبؤ بالمتغيرات المتعلقة بأنظمة الطاقة البديلة باستخدام تقنيات تعلم الآلة. في [3] تم استخدام الشبكات العصبونية متعددة الطبقات والبرمجة الجينية للتنبؤ بالإشعاع الشمسي في أنظمة الطاقة الشمسية وتم مقارنة أداء المنظومة باستخدام كلٍ من التقنيتين. في [6] تم استخدام تقنيات تعلم الآلة والانحدار للتنبؤ بخرج الطاقة لمنظومة الطاقة الشمسية. في [9] تم تصميم شبكة عصبونية تعتمد على تغييرات الأحوال المناخية للتنبؤ بخرج الطاقة لمنظومة طاقة شمسية. في [10] تم استخدام الشبكات العصبونية التلافيفية للتنبؤ بدرجة حرارة وسرعة الرياح ودراسة تأثيرها على أنظمة الطاقة الشمسية. في [4] تم استخدام تقنية SVM للتنبؤ بمتغيرات الأحوال الجوية وذلك بالاعتماد على بيانات

وكالة الأرصاد الجوية اليابانية. في [13] يتم تقديم دراسة مرجعية شاملة لتقنيات التعلم الآلي للتنبؤ بخرج أنظمة الطاقة الشمسية.

تعد الشبكات العصبونية من أكثر تقنيات التعلم الآلي استخداما للتنبؤ في أنظمة الطاقة المتجددة البديلة بشكل عام [9].

في هذه الدراسة تم تصميم نظام تنبؤ بخرج الطاقة لمنظومة طاقة شمسية حقيقية في محافظة حمص بالاعتماد على الشبكات العصبونية العميقة، الفكرة الأساسية في هذه الدراسة هي تقييم أداء منظومة الطاقة الشمسية في الموقع المدروس في محافظة حمص وذلك بالاعتماد على بيانات الطقس والشبكات العصبونية العميقة، حيث تم استخدام ثلاث مجموعات من البيانات لتصميم نظام التنبؤ ، قاعدة البيانات الأولى عبارة عن قاعدة بيانات عالمية متواجدة على منصة kaggle وتم استخدامها لتدريب الشبكة العصبونية العميقة، قاعدة البيانات الثانية أيضا قاعدة بيانات عالمية متواجدة على ذات المنصة، أما قاعدة البيانات الثالثة فهي عبارة عن قاعدة بيانات تم تجميعها من موقع العمل في محافظة حمص وتم استخدامها للتحقق من دقة النموذج المصمم وتقييم أداء المنظومة.

## 2. هدف البحث

يهدف هذا البحث الى دراسة وتصميم نظام تنبؤ بخرج الطاقة لمنظومة طاقة شمسية في محافظة حمص بالاعتماد على تقنيات التعلم الآلي وقياسات بيانات الطقس مثل درجة حرارة الهواء والرطوبة وسرعة الرياح وغيرها من متغيرات هامة.

## 3. الدراسات السابقة

قام الباحثون في المرجع [8] باستخدام الشبكات العصبونية العادية ANN للتنبؤ بخرج منظومة طاقة شمسية، تم تصميم شبكة عصبونية مؤلفة من 5 عصبونات في طبقة الدخل، وعصبون واحد في طبقة الخرج والذي يعبر عن خرج الطاقة المتنبئ به، كما تم استخدام 30 عصبون في الطبقة الخفية. قام الباحثون في المرجع [4] باستخدام الشبكات العصبونية Elmann ANN، والذي يتميز بتغذية أمامية عكسية من طبقة الخرج الى طبقة الدخل، في هذه الدراسة تم تصميم شبكة عصبونية مؤلفة من ثلاث طبقات، طبقة الدخل وتتكون من عصبون واحد، وطبقة الخرج المكونة أيضا من عصبون واحد، والطبقة الخفية المكونة من 5 عصبونات. في المرجع [7] تم استخدام الشبكات العصبونية الديناميكية NAR للتنبؤ بخرج الطاقة لمنظومة كهروضوئية هجينة، قام الباحثون بتصميم شبكتين عصبونيتين للتنبؤ بمتغيرات الطقس وهي الإشعاع الشمسي ودرجة حرارة الهواء كما تم تصميم شبكة عصبونية ANN والتي تأخذ خرج الشبكتين العصبونيتين في المرحلة السابقة كمداخل لها، ويمثل خرج هذه الطبقة خرج المنظومة أي الطاقة المتنبئ بها. في المرجع [11] تم استخدام كل من الشبكات العصبونية العادية والخوارزميات الجينية بنموذج هجين للتنبؤ بخرج منظومة الطاقة الشمسية، ولكن تجدر الإشارة الى انه في هذه الدراسة تم استخدام قواعد بيانات مختلفة عن القواعد المستخدمة في هذا البحث.

#### 4. المواد وطرق البحث

يقع النظام الشمسي الذي تم تحليله في محافظة حمص ويغطي مساحة إجمالية قدرها 120 م<sup>2</sup>، ويتألف من 30 وحدة سيليكونية باستطاعة 465 واط للوح الواحد وبزاوية ميلان 30 درجة، وباستطاعة اسمية 13950 واط، واستطاعة فعلية 9765 واط.

#### 5. تجميع ومعالجة البيانات

تم إجراء هذا البحث خلال شهري الربيع وشهور الصيف من عام 2021 في الفترة الزمنية الممتدة من بداية شهر أذار الى بداية شهر آب، وتم تجميع البيانات باستخدام حساس LP-PYRA02 لقياس متوسط الإشعاع الشمسي خلال الساعة الواحدة، وحساس PT100 لقياس كلٍ من درجة حرارة الهواء ودرجة حرارة الألواح. بالإضافة الى ذلك تم استخدام متغيرين إضافيين وهما الساعة التي تم عندها التقاط البيانات خلال اليوم بمجال من 0 الى 23 والساعة خلال العام بمجال من 0 الى 8759، وذلك بغرض دراسة تأثير موقع الشمس على كمية الإشعاع الشمسي. وبذلك يكون دخل المنظومة مكون من 6 مداخل كما هو موضّح بالجدول 1. ونظراً لكون البيانات قد تم تجميعها من حساسات فانه غالباً ما تحتوي البيانات المجمعّة على بيانات مفقودة وذلك نتيجة لعدم وجود إشعاع شمسي خلال ساعات الليل، وبما أنه لا يوجد إنتاج طاقة من المنظومة خلال ساعات الليل فان

فقدان هذه البيانات لا يشكل مشكلة للبحث، لذلك تم إزالة جميع السجلات التي تحتوي على بيانات مفقودة.

الجدول 1: دخل النموذج المصمم

DATE	اليوم الذي تم فيه التقاط البيانات
HOUR_DAY	الساعة خلال اليوم التي تم فيها التقاط البيانات
HOUR_YEAR	الساعة خلال العام التي تم فيها التقاط البيانات
AMBIENT_TEMPERATURE	درجة حرارة الهواء
MODULE_TEMPERATURE	درجة حرارة الألواح
IRRADIATION	الإشعاع الشمسي

## 6. نماذج الشبكات العصبونية العميقة المقترح تصميمها

النموذج المقترح تصميمه من قبل الباحث في هذا البحث هو عبارة عن شبكة عصبونية عميقة مكونة من عدة طبقات مترابطة بشكل كامل وكل طبقة مكونة من عدة خلايا عصبونية، الطبقة الأولى وهي طبقة الدخل والمكونة من ستة خلايا بعدد متغيرات الدخل للمنظومة والموجودة في قواعد البيانات وهي الإشعاع الشمسي

، درجة حرارة الهواء ، درجة حرارة الألواح ، الساعة خلال اليوم، الساعة خلال العام، واليوم الذي تم فيه التقاط البيانات، والطبقة الأخيرة عبارة عن عصبون واحد وهو خرج الطاقة المراد التنبؤ به، ويعتبر كل من طبقة الدخل وطبقة الخرج ذات عدد ثابت من الخلايا العصبونية ، بينما يوجد بين هاتين الطبقتين عدد من الطبقات المخفية ويعتبر عدد هذه الطبقات وعدد الخلايا في كل منها متغير، والذي نسعى لتحسينه للحصول على اقل خطأ وفضل أداء.

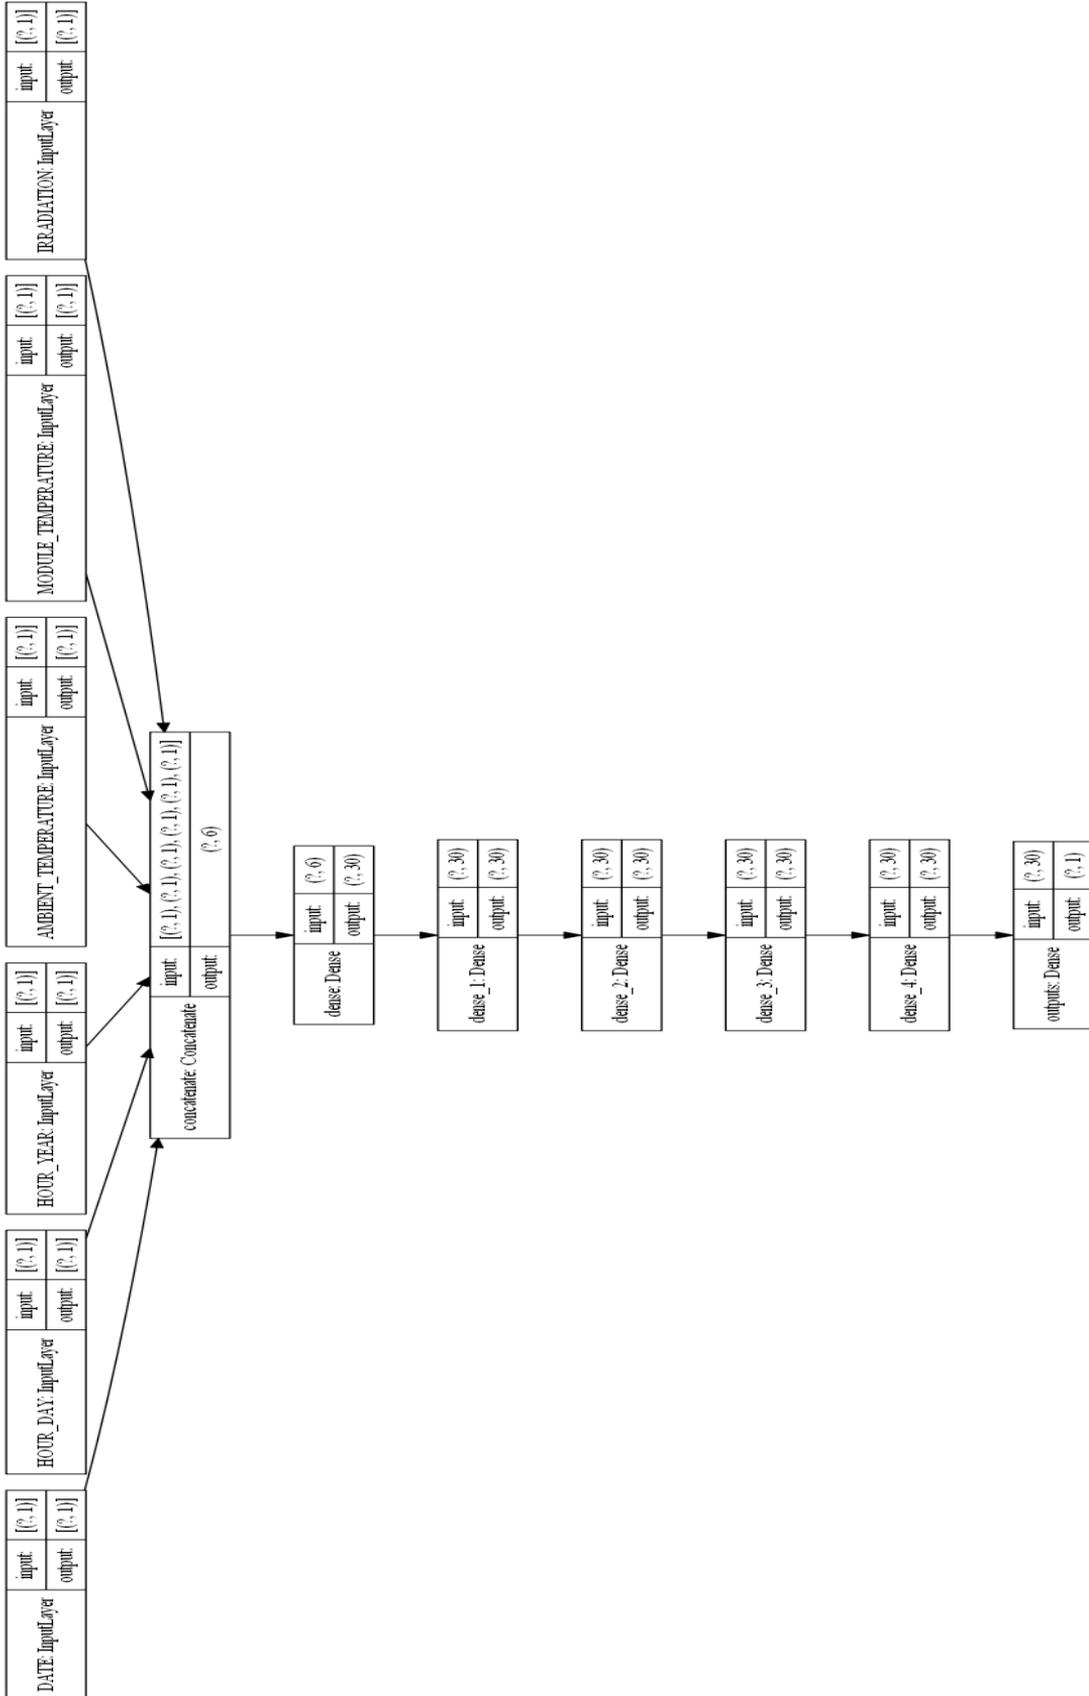
تستخدم الخلايا العصبونية في الطبقات المخفية تابع التنشيط ReLU وتستخدم لتدريب منهجية التعلم الدفعي Batch learning في حين تم اختيار خوارزمية الأمثلة Adam للتدريب. ولتصميم بنية الشبكة العصبونية تم إنشاء عدة نماذج واختبارها لاختيار النموذج الأفضل بينها ومقارنته مع الدراسات السابقة، النموذج الأول وهو عبارة عن شبكة عصبونية عميقة مكونة من خمس طبقات خفية وكل طبقة خفية مكونة من 30 عصبون والطبقات الخفية متصلة فيما بينها بشكل كامل كما هو موضح في الشكل 1، وتم اختيار عدد العصبونات في الطبقات الخفية بناءً على نتائج الدراسات السابقة والتي تم فيها إثبات أن الشبكة العصبونية العادية ذات الطبقة الخفية الواحدة المكونة من 30 عصبون تحقق أفضل النتائج.

النموذج الثاني تم فيه توزيع الدخل على الطبقات الخفية في الشبكة العصبونية المصممة، ونظراً لكون معامل متوسط الإشعاع الشمسي يعد اهم البارامترات المدخلة للشبكة، لذلك تم إدخاله للشبكة العصبونية أولاً وذلك لتتم معالجته أولاً وتميرها لطبقة خفية مكونة من 30 عصبون، ومن ثم يتم إدخال درجة حرارة الألواح وتجميعها مع خرج الطبقة الخفية الأخيرة، ومن ثم يتم تمرير خرج طبقة

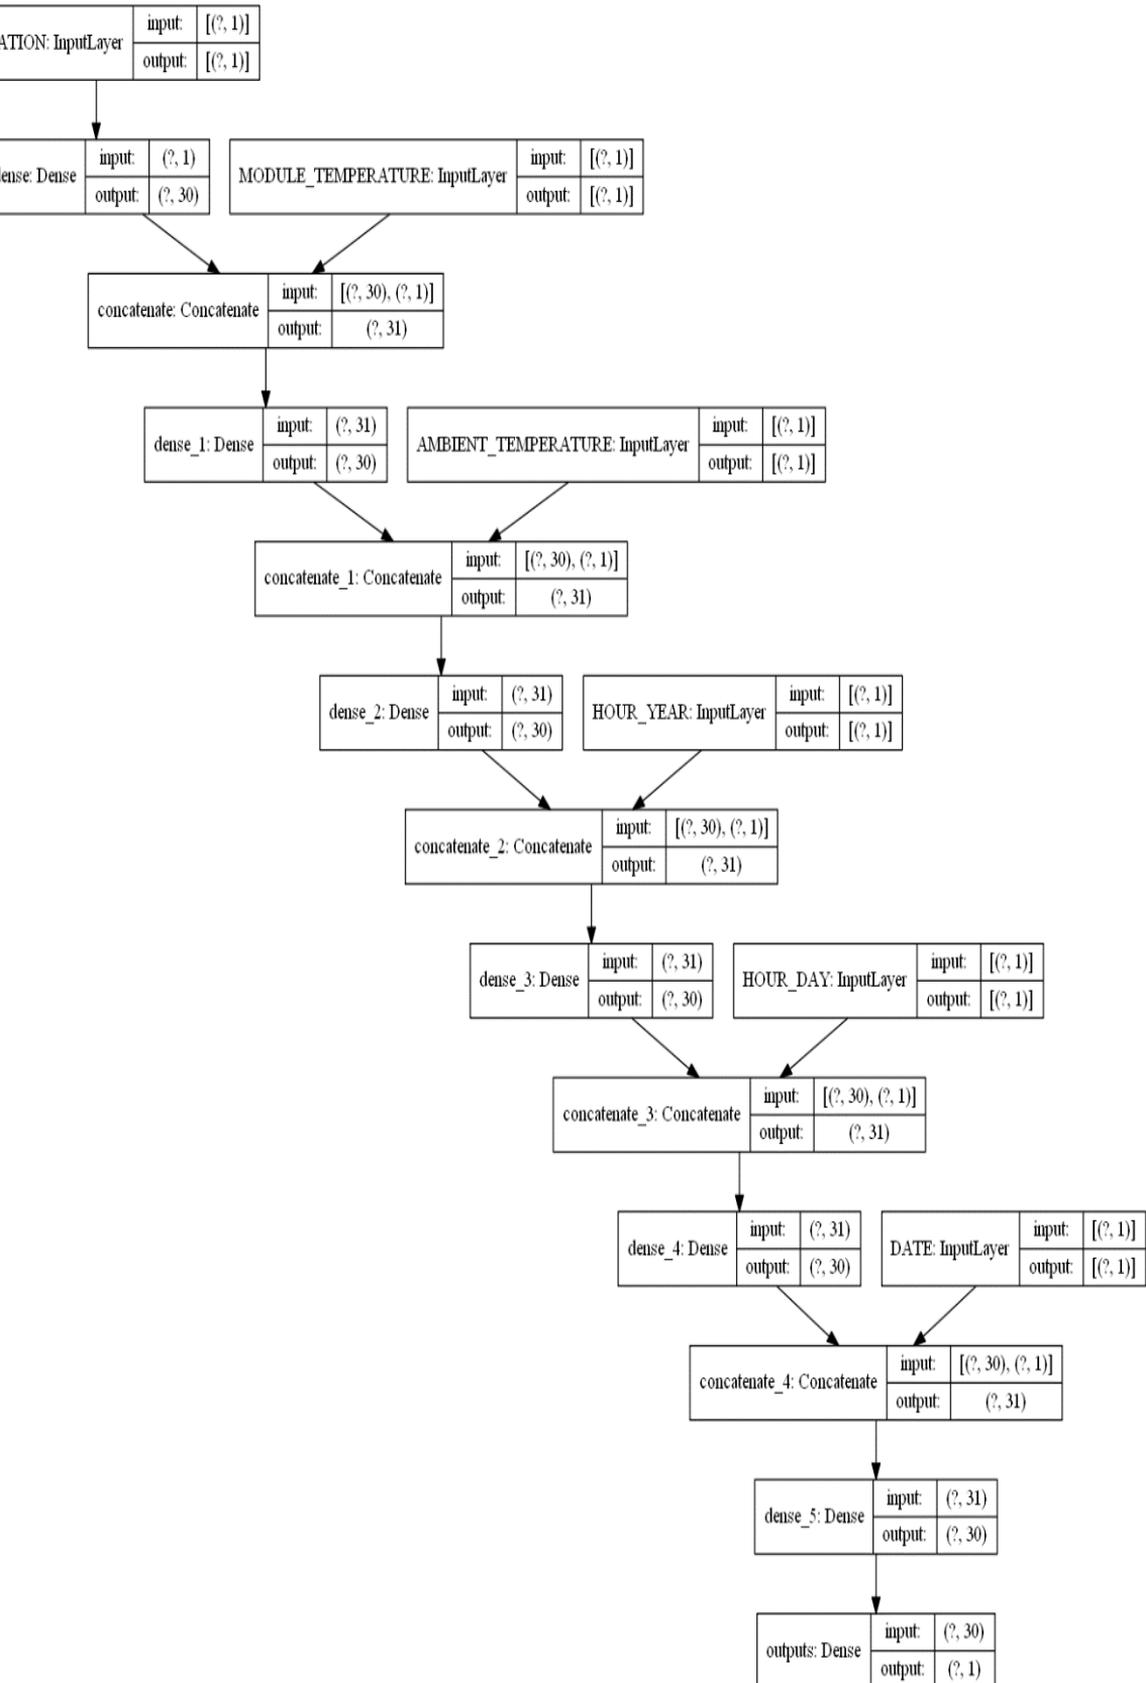
دراسة وتصميم نظام تنبؤ بخرج منظومة طاقة شمسية في محافظة حمص بالاعتماد على القياسات  
وتقنيات تعلم الآلة

---

التجميع الى طبقة خفية ليتم معالجتها بواسطة 30 عصبون، وكذلك الأمر بالنسبة  
للإدخالات الأخرى كما هو موضّح الشكل 2.

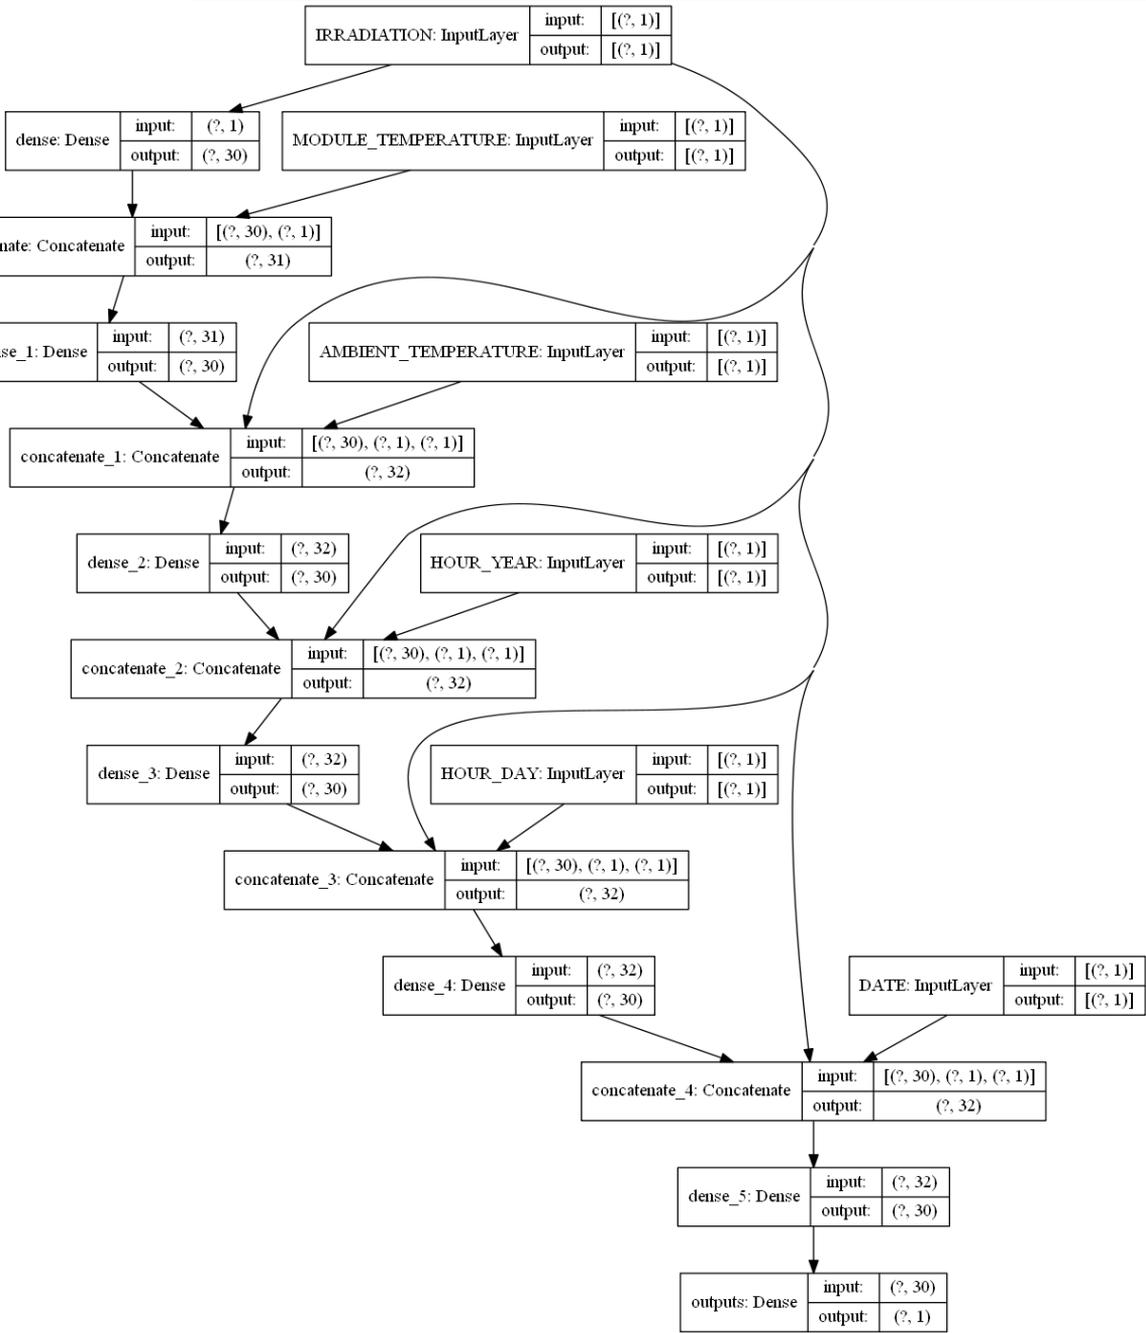


الشكل 1 النموذج الأول للشبكة العصبونية المصممة



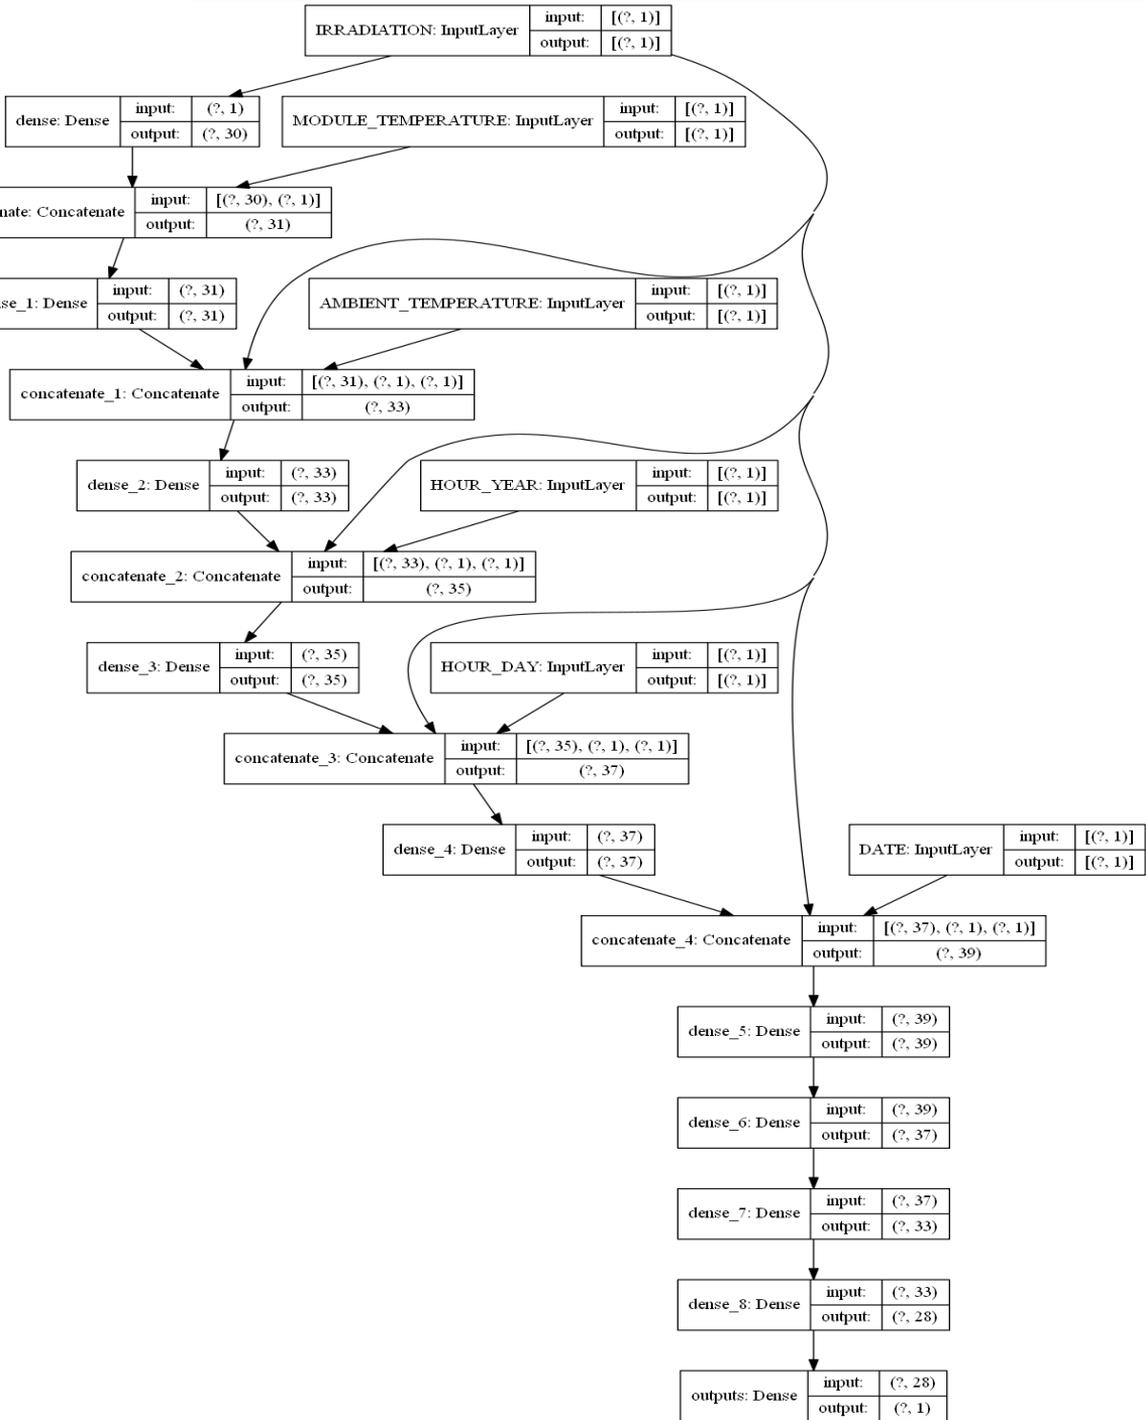
### الشكل 2 النموذج الثاني للشبكة العصبونية المصممة

النموذج الثالث عبارة عن تطوير للنموذج الثاني ولكن نظراً لأهمية بارامتر شدة الإشعاع الشمسي تم اقتراح تمريره الى كافة الطبقات الخفية وذلك بهدف زيادة معالجة أهم البارامترات، في حين أنه في طبقة التجميع تم تجميع خرج المرحلة السابقة المكون من 30 خرج مع الدخل الجديد بالإضافة الى بارامتر شدة الإشعاع الشمسي، وبذلك يكون خرج طبقة التجميع 32 خرج والتي يتم تمريرها الى الطبقة الخفية المكونة من 30 عصبوناً لتتم معالجتها كما هو موضّح الشكل 3.



الشكل 3 النموذج الثالث للشبكة العصبونية المصممة

إن خرج طبقة التجميع في النموذج الثالث عبارة عن 32 عصبوناً والتي يتم تمريرها الى 30 عصبوناً في الطبقة الخفية في كل مرحلة، وهذا ما يؤدي الى تقليل أداء المعالجة نظراً لتقليل العصبونات في كل مرحلة ومن ثم زيادتها، لذلك تم اقتراح تعديل تصميم النموذج الثالث كما هو موضّح الشكل 4.



الشكل 4 النموذج الرابع للشبكة العصبونية المصممة

## 7. تدريب واختبار النماذج الأربعة المصممة

تم في هذا البحث استخدام ثلاث مجموعات من البيانات لتصميم نظام التنبؤ، قاعدة البيانات الأولى عبارة عن قاعدة بيانات عالمية متواجدة على منصة kaggle وتم استخدامها لتدريب الشبكة العصبونية العميقة، قاعدة البيانات الثانية أيضاً قاعدة بيانات عالمية متواجدة على ذات المنصة وتم استخدامها لاختبار الشبكة العصبونية العميقة، أما قاعدة البيانات الثالثة فهي عبارة عن قاعدة بيانات تم تجميعها من موقع العمل في محافظة حمص وتم استخدامها للتحقق من دقة النموذج المصمم وتقييم أداء المنظومة. ولكل من قواعد البيانات الثلاث ذات الهيكلية حيث تحتوي قاعدة البيانات على 6 بارامترات وهي شدة الإشعاع الشمسي ودرجة حرارة الألواح ودرجة حرارة الهواء وتعد هذه البارامترات أهم مداخل المنظومة، ومن ثم اليوم الذي تم فيه التقاط البيانات والساعة خلال اليوم والساعة خلال العام.

تم تدريب واختبار النماذج الأربعة بالاعتماد على قواعد البيانات الثلاث المذكورة سابقاً، وباستخدام البارامترات الست المذكورة سابقاً أيضاً.

### 7. محددات الخطأ المستخدمة لتقييم أداء العمل

تستخدم ثلاثة مقاييس خطأ لتقييم أداء نموذج الشبكة العصبونية العميقة المصممة عند التنبؤ بخرج الطاقة:

1. متوسط انحياز الخطأ (MBE: mean bias error)

$$MBE = \sum_{i=1}^N \frac{X_i - Y_i}{N} \quad \dots (1)$$

2. جذر متوسط مربع الخطأ (RMSE: root mean square error)

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

3. جذر متوسط مربع الخطأ الطبيعي (NRMSE: normalised root mean

square error

... (3)

$$NRMSE = \frac{\sqrt{\frac{\sum_{i=1}^N (X_i - Y_i)^2}{N}}}{Y_{max}}$$

حيث أن:

$X_i$ : القيمة التي تم التنبؤ بها (خرج النموذج المصمم)

$Y_i$ : القيمة الحقيقية (المأخوذة من المنظومة)

$N$ : عدد العينات وهو عدد الساعات التي تم خلالها التقاط البيانات

$Y_{max}$ : هي أكبر قيمة لمجموعة البيانات ( $45^\circ\text{C}$  لدرجة الحرارة،  $450 \text{ W/M}^2$

للإشعاع الشمسي و

$9765 \text{ W}$  للإنتاج الكهروضوئية)

## 8. مقارنة النتائج

تمت مقارنة تنبؤات الطاقة الكهروضوئية التي تم الحصول عليها من نموذج

الشبكة العصبونية العميقة المصممة في إطار سيناريوهات التدريب والاختبار مع

القياسات الكهروضوئية الحقيقية المأخوذة من المنظومة. وتمت مقارنة محددات

تقييم الخطأ باستخدام كلٍ من المتوسط الحسابي  $\mu$  والانحراف المعياري  $\sigma$ .

$$\mu = \frac{\sum_{i=1}^N x_i}{N}$$

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

حيث أن:

$\mu$ : المتوسط الحسابي

$\sigma$ : الانحراف المعياري

$x_i$ : عينات البيانات

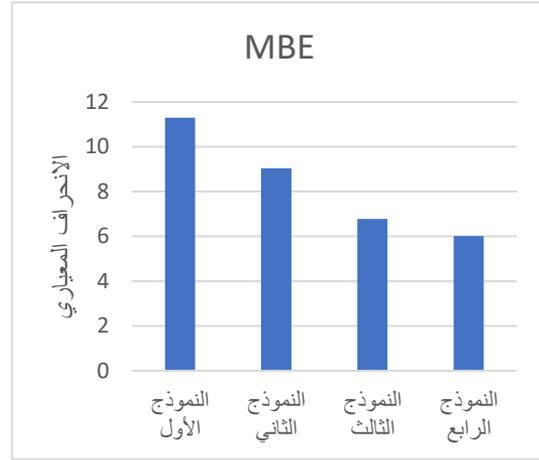
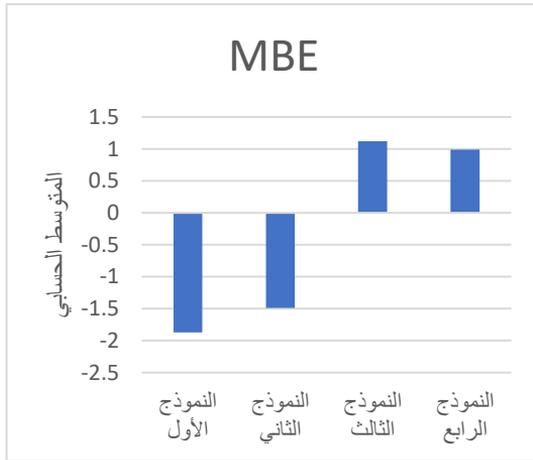
$N$ : عدد العينات

يوضح الجدول 2 مقارنة نتائج كل من النماذج الأربعة المصممة

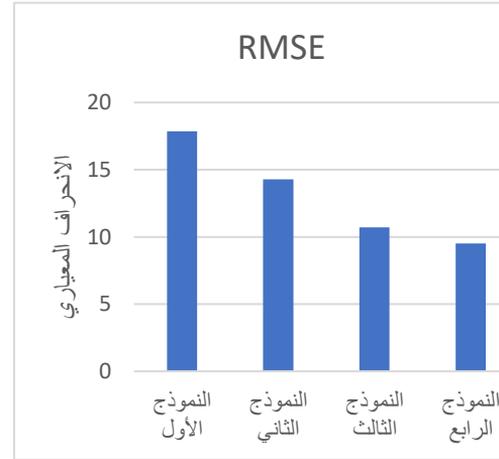
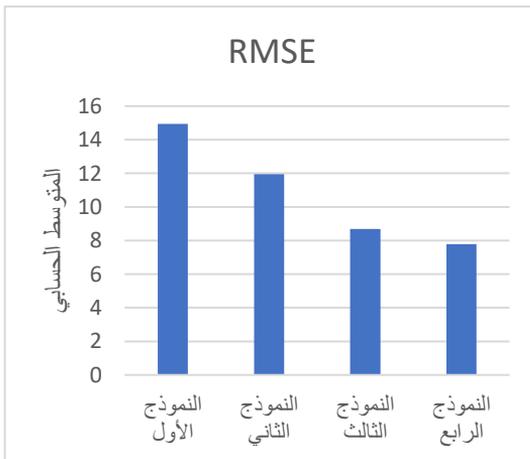
النموذج	MBE		RMSE		NRMSE [%]	
	$\mu$	$\sigma$	$\mu$	$\sigma$	$\mu$	$\sigma$
الأول	-1.87	11.3	14.94	17.86	1.76	2.1
الثاني	-1.49	9.04	11.95	14.28	1.41	1.68
الثالث	1.12	6.78	8.69	10.71	1.05	1.26
الرابع	0.99	6.02	7.79	9.52	0.94	1.12

الجدول 2 نتائج اختبار النماذج الأربعة

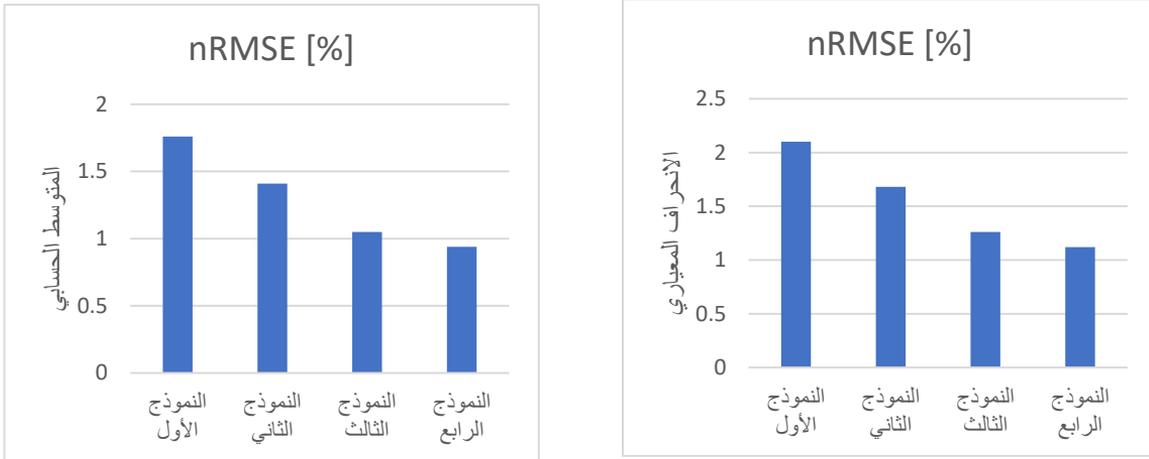
يشير MBE و RMSE إلى مقدار متوسط الخطأ حيث يصف MBE اتجاه انحياز الخطأ وترتبط قيمة بحجم عينة البحث، ولكنهما لا يقدمان معلومات نسبة متوسط الفرق وهذا ما يقدمه NRMSE. تكون قيمة MBE سلبية عندما تكون قيم التنبؤات أقل قيمة من القيم الحقيقية وهو ما نلاحظه في كل من النموذج الأول والثاني. توضح الأشكال (5,6,7) مقارنة النتائج المذكورة في الجدول 2



الشكل 5 مقارنة قيم MBE



الشكل 6 مقارنة قيم RMSE



الشكل 7 مقارنة قيم  $nRMSE$

من مقارنة النتائج السابقة نلاحظ أن النموذج الرابع يحقق اقل نسبة خطأ ويتفوق على النماذج الثلاث الأخرى، حيث يحقق النموذج الرابع خطأ بمعدل 780w تقريباً وهو ما يعادل 8% ويقابل  $NRMSE=1.12\%$ ، في حين يحقق النموذج الثالث خطأ بمعدل 880w وهو ما يعادل 9% ويقابل  $NRMSE=1.26\%$ ، أما النموذج الثاني يحقق خطأ بمعدل 1170 w وهو ما يعادل 12% ويقابل  $NRMSE=1.68\%$ ، وأخيراً النموذج الأول يحقق نسبة خطأ بمعدل 1460w وهو ما يعادل 15% ويقابل  $NRMSE=1.12\%$ .

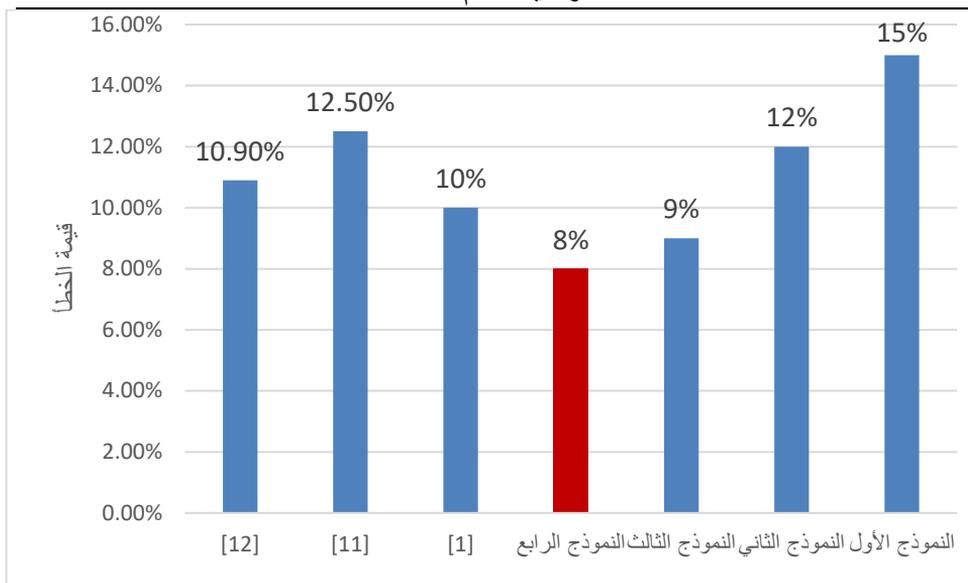
يوضح الجدول (3) مقارنة قيم الخطأ للنماذج المدروسة مع الدراسات المرجعية. حيث حققت الدراسة في المرجع [8] خطأ بمعدل اقل من 10% كقيمة عظمى وهو ما يقابل خطأ بنسبة 25kw باستخدام الشبكات العصبونية العادية ANN، في حين حققت الدراسة المرجعية في المرجع [4] خطأ بمعدل 12.5% كقيمة دنيا باستخدام

الشبكات العصبونية Elmann ANN، وفي المرجع [7] تم تحقيق خطأ بمعدل 10.9% كأدنى قيمة وذلك باستخدام الشبكات العصبونية العادية ANN كما هو موضح بالشكل (8)، في المرجع [11] تم استخدام كلا من الشبكات العصبونية العادية والخوارزميات الجينية بنموذج هجين حيث حققت الشبكات العصبونية العادية خطأ بنسبة 142kw والنموذج الهجين 104kw ولكن تجدر الإشارة الى انه في هذه الدراسة تم استخدام قواعد بيانات مختلفة عن القواعد المستخدمة في هذا البحث.

	النموذج الأول	النموذج الثاني	النموذج الثالث	النموذج الرابع	[1]	[11]	[12]
الخطأ	15%	12%	9%	8%	10%	12.5%	10.9%

الجدول 3 مقارنة قيمة الخطأ للنماذج المدروسة مع الدراسات السابقة

## دراسة وتصميم نظام تنبؤ بخرج منظومة طاقة شمسية في محافظة حمص بالاعتماد على القياسات وتقنيات تعلم الآلة



الشكل 8 مقارنة قيم الخطأ

### 9. الخلاصة والاستنتاجات

في هذا البحث تم استخدام ثلاث قواعد بيانات لتدريب واختبار والتحقق من النموذج المصمم، وكما تم تصميم أربع نماذج للشبكة العصبونية العميقة، وأثبتت النتائج أن النموذج الرابع يحقق أفضل نسبة خطأ بالمقارنة مع النماذج الأخرى، وكما أوضحت مقارنة النتائج مع الدراسات السابقة أن تقنيات التعلم الآلي وبالتحديد الشبكات العصبونية العميقة تحقق أداء أفضل من الشبكات العصبونية العادية والتقنيات الأخرى وتحقق اقل نسبة خطأ ممكنة.

تم التوصل من خلال هذا البحث الى النتائج التالية:

1. إن النموذج الرابع المصمم أعطى أفضل نتائج من حيث نسبة الخطأ مقارنة مع النماذج الثلاث المصممة وأهم الدراسات المرجعية الموجودة في هذا المجال.
2. إن استخدام تقنيات تعلم الآلة وبالتحديد الشبكات العصبونية العميقة تحقق أداء أفضل من الشبكات العصبونية العادية.

## 10. التوصيات المستقبلية

بالرغم من التقدم الكبير في مجال الأنظمة البديلة إلا انه ما يزال هناك مجال متاح للأبحاث المستقبلية، حيث يمكن أن تركز الأبحاث المستقبلية على البارامترات الأخرى التي لم تأخذ بعين الاعتبار ودراسة تأثيرها على أنظمة الطاقة البديلة، حيث يمكن دراسة تأثير الرياح على تبريد الواح الطاقة وتأثير هطول الأمطار على أداء المنظومة بالإضافة الى تأثير تراكم الأوساخ والغبار على الألواح، كما انه يمكن دراسة أداء ودقة التنبؤ عند استخدام تقنيات أخرى مختلفة من تقنيات التعلم الآلي مثل تقنيات التجميع ودمجها مع الشبكات العصبونية العميقة.

## 11. المراجع

1. Alharthi, Y.Z.; Siddiki, M.K.; Chaudhry, G.M. Resource assessment and techno-economic analysis of a grid-connected solar PV-wind hybrid system for different locations in Saudi Arabia. *Sustainability* 2018, 10, 3690.
2. Antonanzas, J.; Osorio, N.; Escobar, R.; Urraca, R.; Martinez-de-Pison, F.J.; Antonanzas-Torres, F. Review of photovoltaic power forecasting. *Solar Energy* 2016, 136, 78–111, doi:10.1016/j.solener.2016.06.069.
3. De Paiva, G.M.; Pimentel, S.P.; Alvarenga, B.P.; Marra, E.G.; Mussetta, M.; Leva, S. Multiple site intraday solar irradiance

- forecasting by machine learning algorithms: MGGP and MLP neural networks. *Energies* 2020, 13, doi:10.3390/en13113005.
4. Giorgi, M.G.D.; Congedo, P.M.; Malvoni, M. Photovoltaic power forecasting using statistical methods: Impact of weather data. *IET Sci. Meas. Technol.* 2014, 8, 90–97, doi:10.1049/iet-smt.2013.0135.
  5. IEA. *Global Energy Review 2020*; IEA: Paris, France, 2020. Available online: <https://www.iea.org/reports/global-energy-review-2020> (accessed on October 22, 2020).
  6. Junior, J.G.d.S.F.; Oozeki, T.; Ohtake, H.; Shimose, K.-i.; Takashima, T.; Ogimoto, K. Forecasting regional photovoltaic power generation—A comparison of strategies to obtain one-day-ahead data. *Energy Proc.* 2014, 57, 1337–1345, doi:10.1016/j.egypro.2014.10.124.
  7. Leva, S.; Dolara, A.; Grimaccia, F.; Mussetta, M.; Ogliari, E. Analysis and validation of 24 hours ahead neural network forecasting of photovoltaic output power. *Math. Comput. Simul.* 2017, 131, 88–100, doi:10.1016/j.matcom.2015.05.010.
  8. López Gómez, J., Ogando Martínez, A., Troncoso Pastoriza, F., Febrero Garrido, L., Granada Álvarez, E., & Orosa García, J. A. (2020). Photovoltaic Power Prediction Using Artificial Neural

- Networks and Numerical Weather Data. *Sustainability*, 12(24), 10295.
9. López Gómez, J.; Troncoso Pastoriza, F.; Granada Álvarez, E.; Eguía Oller, P. Comparison between geostatistical interpolation and numerical weather model predictions for meteorological conditions mapping. *Infrastructures* 2020, 5, 15.
10. Mehrkanoon, S. Deep shared representation learning for weather elements forecasting. *Knowledge-Based Syst.* 2019, 179, 120–128, doi:10.1016/j.knosys.2019.05.009.
11. Pedro, H.T.C.; Coimbra, C.F.M. Assessment of forecasting techniques for solar power production with no exogenous inputs. *Solar Energy* 2012, 86, 2017–2028, doi:10.1016/j.solener.2012.04.004.
12. Richardson, W.; Krishnaswami, H.; Vega, R.; Cervantes, M. A low cost, Edge computing, all-sky imager for cloud tracking and intra-hour irradiance forecasting. *Sustainability* 2017, 9, 482.
13. Wang, F.; Mi, Z.; Su, S.; Zhao, H. Short-term solar irradiance forecasting model based on artificial neural network using statistical feature parameters. *Energies* 2012, 5, 1355–1370.