

## نمذجة شبكة عصبونية صناعية متعددة الطبقات لتقدير نسبة التشغيل لمبدل رافع الجهد المستمر لتتبع نقطة الاستطاعة العظمى لنظم الطاقة الكهروضوئية

د. إيمان ديلانة\*

(تاريخ الإيداع 9 / 5 / 2018. قُبِلَ للنشر في 6 / 12 / 2018)

### □ ملخص □

يتناول البحث نمذجة شبكة عصبونية صناعية متعددة الطبقات ذات تغذية أمامية مدربة باستخدام خوارزمية الانحدار التدريجي للخطأ ذات معامل الزخم ومعدل التعلم المتغير، وذلك لتقدير خرج الشبكة العصبونية الموافق لنسبة التشغيل الأمثل لمبدل رافع الجهد المستمر اعتماداً على استخدام قياسات تغيرات كل من درجة حرارة الخلية الشمسية وشدة الإشعاع الشمسي، لتتبع نقطة الاستطاعة العظمى MPP لنظم الطاقة الشمسية الكهروضوئية. بالتالي يعتبر المتحكم DMPPT-ANN (Developed MPPT-ANN) المقترح في البحث، مستقلاً في عمله عن استخدام القياسات الكهربائية لخرج نظام PV لتحديد نسبة التشغيل، ودون الحاجة لاستخدام متحكم تناسبي-تكاملي (Proportional PI) Integral للتحكم في دورة عمل مبدل الجهد، وهذا من شأنه تحسين الأداء الديناميكي للمتحكم المقترح بتحديد نسبة التشغيل بدقة وسرعة فائقة. في هذا السياق، يناقش البحث الاختيار الأمثل لهيكلية الشبكة المقترحة من حيث تحديد العدد الأمثل للطبقات الخفية والعدد الأمثل للعصبونات الموجودة فيها، بتقييم قيم متوسط مربع الخطأ ومعامل الارتباط الناتجة بعد كل عملية تدريب للشبكة العصبونية. بعد ذلك يعتمد نموذج الشبكة النهائي الذي يمتلك الهيكلية الأمثل، ليشكل المتحكم المقترح في البحث DMPPT-ANN لتتبع نقطة MPP لنظام PV. أظهرت نتائج المحاكاة المنجزة في بيئة Matlab/Simulink، الأداء الأفضل للمتحكم DMPPT-ANN المقترح المرتكز على نموذج الشبكة العصبونية MLFFNN، وذلك بدقة تقدير نسبة التشغيل وتحسين سرعة استجابة نظام PV في الوصول لنقطة MPP، بالإضافة إلى التخلص بشكل نهائي من التذبذبات الناتجة في الحالة المستقرة في منحنى استجابة استطاعة خرج نظام PV مقارنة مع استخدام عدد من المتحكمات المرجعية المستخدمة: متحكم تتبع متقدم MPPT-ANN-PI مرتكز على شبكة عصبونية ANN لتقدير توتر نقطة MPP مع متحكم PI تقليدي، متحكم عائم MPPT-FLC ومتحكم تتبع تقليدي MPPT-INC يستخدم تقنية زيادة الناقلية INC.

**الكلمات المفتاحية:** شبكة عصبونية صناعية متعددة الطبقات، خوارزمية الانحدار التدريجي ذات معامل الزخم ومعدل التعلم المتغير، تتبع نقطة الاستطاعة العظمى.

\* أستاذ مساعد- قسم هندسة القوى الميكانيكية -كلية الهندسة الميكانيكية والكهربائية - جامعة تشرين - اللاذقية - سورية.

[imanedilaneh@gmail.com](mailto:imanedilaneh@gmail.com)

## Modeling of a Multi-Layers Artificial Neural Networks to estimate the Duty Cycle of DC-DC Boost Converter to track the Maximum Power Point of Photovoltaic Energy Systems

Dr. Imane Dilaneh\*

(Received 9 / 5 / 2018. Accepted 6 / 12 / 2018)

### □ ABSTRACT □

This research deals with the modeling of a Multi-Layers Feed Forward Artificial Neural Networks (MLFFNN), trained using Gradient Descent algorithm with Momentum factor & adaptive learning rate, to estimate the output of the neural network corresponding to the optimal Duty Cycle of DC-DC Boost Converter to track the Maximum Power Point of Photovoltaic Energy Systems. Thus, the DMPPT-ANN “Developed MPPT-ANN” controller proposed in this research, independent in his work on the use of electrical measurements output of PV system to determine the duty cycle, and without the need to use a Proportional-Integrative Controller to control the cycle of the work of the of DC-DC Boost Converter, and this improves the dynamic performance of the proposed controller to determine the optimal Duty Cycle accurately and quickly. In this context, this research discusses the optimal selection of the proposed MLFFNN structure in the research in terms of determining the optimum number of hidden layers and the optimal number of neurons in them, evaluating the values of the Mean square error and the resulting Correlation Coefficient after each training of the neural network. The final network model with the optimal structure is then adopted to form the DMPPT-ANN Controller to track the MPP point of the PV system. The simulation results performed in the Matlab / Simulink environment demonstrated the best performance of the proposed DMPPT-ANN controller based on the MLFFNN neural network model, by accurately estimating the Duty Cycle and improving the response speed of the PV system output to MPP access, , as well as finally eliminating the resulting oscillations in the steady state of the Power response curve of PV system compared with the use of a number of reference controls: an advanced tracking controller MPPT-ANN-PI based on ANN network to estimate MPP point voltage with conventional PI controller, a MPPT-FLC and a conventional MPPT-INC uses the Incremental Conductance technique INC

**Key words:** Multi-Layers Artificial Neural Networks, Gradient Descent algorithm with Momentum factor & adaptive learning rate, Maximum Power Point tracking.

---

\* Assistant Professor, Department of Mechanical Power Engineering, faculty of Mechanical and Electrical Engineering, Tishreen University, Lattakia, Syria. imanedilaneh@gmail.com.

## مقدمة

يستخدم متتبع نقطة الاستطاعة العظمى (Maximum Power Point Tracker, MPPT) لنظم الطاقة الشمسية الكهروضوئية (Photovoltaic System, PV)، للحصول على الطاقة القصوى الممكنة من هذه النظم في ظل التغيرات الجوية من شدة إشعاع شمسي ودرجة حرارة الجو المحيط. يعتمد عمل متتبع نقطة الاستطاعة MPPT على استخدام تقنيات تحكم مختلفة، منها التقليدية كتقنية الاضطراب والمراقبة، تقنية زيادة الناقلية، وتقنية توتر الدارة المفتوحة [1]. تمتاز هذه التقنيات التقليدية ببساطتها وسهولة في تنفيذها، غير أن هذه التقنيات التقليدية تستغرق وقتاً لتحديد نسبة التشغيل المناسبة لضبط عمل نظام PV عند نقطة (Maximum Power Point) MPP، مما يضعف من كفاءة وأداء هذه التقنيات عند تتبع نقطة MPP عند التغيرات الجوية السريعة. في هذا السياق، تمكن تقنيات التتبع المركزة على استخدام تقنيات الذكاء الصناعي كالمناطق العائم (المنطق الضبابي) والشبكات العصبونية، من التغلب على عيوب ومشاكل تقنيات التتبع التقليدية. يعتبر المتحكم العائم (Fuzzy Logic Controller, FLC) من أكثر تقنيات التحكم المتقدمة استخداماً، حيث أنه يمكن من تتبع نقطة MPP لنظم PV بكفاءة عالية. يعتمد التصميم الجيد للمتحكم العائم FLC بشكل أساسي على خبرة المصمم وفهمه العميق للعلاقة الرابطة بين كل من متغيرات الدخل والخرج للمتحكم، لذلك يمكن أن يفشل تصميم المتحكم FLC في حالة غياب المعرفة الدقيقة لهذه العلاقة [2,3]. إن استخدام الشبكات العصبونية الصناعية (Artificial Neural Networks, ANN) لتصميم متحكم MPPT، ينسجم بالسهولة والبساطة مقارنة مع تصميم متحكم MPPT مرتكز على استخدام FLC. حيث يمكن بناء متحكم ANN بسهولة في حال توفر بيانات تدريب كافية، وبالاختيار الصحيح لهيكلية الشبكة العصبونية الصناعية، المحققة لمعايير الأداء الجيد [4,5]. في المرجع [6]، تم نمذجة شبكة عصبونية صناعية مكونة من طبقة دخل وطبقة خفية واحدة، وطبقة خرج لتقدير تيار نقطة MPP، أظهرت هذه الدراسة تحسین سرعة تتبع نقطة MPP عند التغيرات الجوية السريعة باستخدام المتحكم MPPT-ANN المطور في البحث مقارنة مع استخدام تقنيات التتبع التقليدية. في المرجع [7]، تم تطوير شبكة عصبونية صناعية ذات طبقة خفية واحدة وخرج بعصبون واحد لتقدير VMPP الممثل لتوتر نقطة MPP. أظهرت نتائج هذه الدراسة دقة نموذج الشبكة الناتج في تقدير قيم التوتر VMPP عند التغيرات الجوية المختلفة، حيث تم استخدام متحكم تناسبي-تكاملي تقليدي لضبط توتر خرج نظام PV عند توتر التشغيل الأمثل VMPP. أما في المرجع [8]، فقد تم نمذجة شبكة عصبونية مكونة من طبقة دخل تحوي متغير واحد ممثل لاستطاعة النظام PV، طبقة خفية واحدة، وطبقة خرج التي تحوي عصبون واحد لتقدير نسبة التشغيل المستخدمة للتحكم في دورة عمل مبدل رافع الجهد المستمر، أظهرت نتائج هذه الدراسة الأداء الأفضل للمتحكم MPPT-ANN المعتمد على نموذج الشبكة العصبونية مقارنة مع متحكم معتمد على تقنية الاضطراب والمراقبة في زيادة الاستطاعة المستخلصة من نظام PV. أغفلت الدراسات المرجعية السابقة دراسة وتحليل أداء الشبكات العصبونية متعددة الطبقات، وخاصة فيما يتعلق بدراسة أثر إضافة طبقات خفية فيها وزيادة عدد العصبونات الموجودة فيها. من جهة أخرى، ركزت هذه الدراسات على مقارنة أداء متحكم تتبع MPPT-ANN مع تقنيات تتبع تقليدية ولم تقارنها مع تقنيات تحكم متقدمة كالمتحكم العائم.

## أهمية البحث وأهدافه

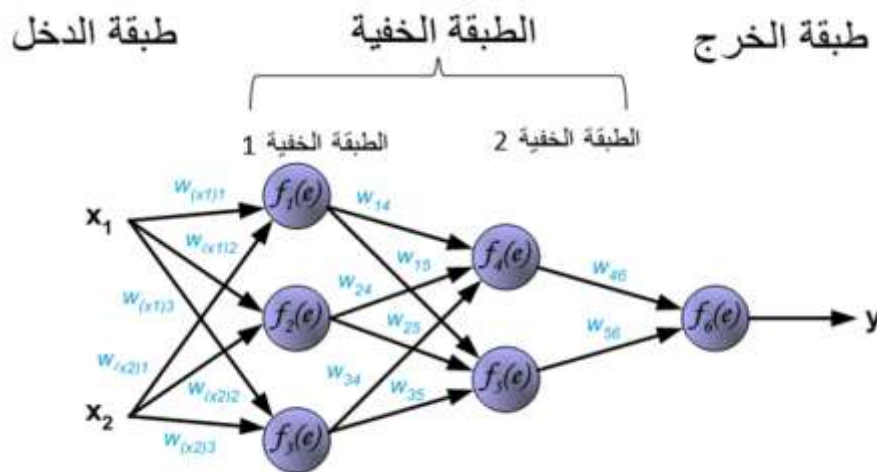
يقدم البحث مساهمة جديدة في تقديم استراتيجية تحكم تعتمد على استخدام الشبكات العصبونية الصناعية متعددة الطبقات ذات التغذية الأمامية (Multi-Layers Feed Forward Neural Networks, MLFFNN) المدربة باستخدام خوارزمية الانتشار العكسي للخطأ المعروفة بخوارزمية الانحدار التدريجي للخطأ ذات معامل الزخم ومعدل التعلم المتغير (Gradient Descent algorithm with Momentum & Adaptive Learning Rate) وذلك لتقدير خرج الشبكة العصبونية الموافق لنسبة التشغيل الأمثل، اعتماداً على استخدام تغيرات درجة الحرارة المحيطة وشدة الإشعاع الشمسي. في هذا السياق، يهدف البحث إلى بناء نموذج رياضي باستخدام الشبكات العصبونية لنمذجة العلاقة بين تغيرات درجة الحرارة المحيطة وشدة الإشعاع الشمسي، وبين تغيرات نسبة التشغيل للتحكم مباشرة في دورة عمل مبدل رافع الجهد المستمر، مما يمكن من الاستغناء عن استخدام عدد من المعادلات الرياضية اللاخطية المستخدمة لنمذجة العلاقة بين التغيرات الجوية وبين تغيرات بارامترات خرج النظام الكهروضوئي PV. لهذا الغرض، يناقش البحث الاختيار الأمثل لهيكلية الشبكة MLFFNN المقترحة في البحث من حيث تحديد العدد الأمثل للطبقات الخفية وللعصبونات الموجودة فيها، باستخدام معايير تقييم الأداء للشبكة من متوسط مربع الخطأ ( $E$ ، Mean square error) ومعامل الارتباط ( $R$ ، Correlation Coefficient). في خطوة لاحقة، يستخدم نموذج الشبكة النهائي ليشكل المتحكم المقترح في البحث DMPPT-ANN (Developed MPPT-ANN)، والمستخدم بالتالي لتقدير نسبة التشغيل الأمثل لتتبع نقطة MPP لنظام PV. بناء على ذلك، يقدم البحث نموذجاً لمتحكم يتتبع نقطة MPP يمتاز بالسرعة الفائقة والدقة العالية في تقدير نسبة التشغيل دون الحاجة لاستخدام أي من قياسات خرج النظام الكهروضوئي وبدون الحاجة لاستخدام متحكم تناسبي-تقليدي، مما من شأنه أن يحسن الأداء الديناميكي للمتحكم عند التغيرات الجوية المختلفة.

## طرائق البحث ومواده

تعتمد نمذجة الشبكة العصبونية الصناعية MLFFNN المقترحة على استخدام توابع خاصة معرفة في مكتبة Neural Network Toolbox الموجودة في Matlab، بالإضافة لتقييم أداء الشبكة بالاعتماد على مدى تحقق معايير الأداء الجيد المتعلقة بتقييم قيمة متوسط مربع الخطأ أصغري وقيمة معامل الارتباط. كما يعتمد اختبار أداء وفعالية المتحكم DMPPT-ANN المرتكز على نموذج الشبكة MLFFNN، على مقارنة نتائج المحاكاة الناتجة في بيئة Matlab/Simulink مع تلك الناتجة باستخدام عدة متحكمات تتبع مرجعية.


## 1 الشبكة العصبونية الصناعية

تعرف الشبكة العصبونية الصناعية (Artificial Neural Network) بأنها عبارة عن نظام لمعالجة البيانات بشكل يحاكي ويشابه الطريقة التي تقوم بها الشبكات العصبونية الطبيعية للإنسان، حيث تتشابه الشبكة العصبونية الصناعية مع الدماغ البشري في أنها تكتسب المعرفة بالتدريب، وتخزن هذه المعرفة باستخدام قوى وصل داخل العصبونات تسمى الأوزان التشابكية. يبين الشكل (1) الهيكلية العامة لشبكة MLFFNN تتكون من عدة طبقات: طبقة دخل (Input Layer)، طبقة خرج (Output Layer)، وطبقة خفية (Hidden Layer) والتي تتواجد بين طبقة الدخل والخرج.



الشكل (1) الهيكلية العامة لشبكة عصبونية متعددة الطبقات ذات التغذية الأمامية.

يعتمد هذا البحث، على استخدام شبكة عصبونية صناعية ذات تغذية أمامية، ويُقصد بالتغذية الأمامية للشبكات انتشار البيانات الداخلة إلى الشبكة باتجاه الأمام دائماً من طبقة الدخل باتجاه طبقة الخرج، ومن الأمثلة على هذا النوع من الشبكات، الشبكة العصبية ذات الانتشار العكسي للخطأ (Error Back Propagation). يبين الشكل (2) بنية العصبون الصناعي.



الشكل (2) بنية العصبون الصناعي.

يتضمن كل عصبون في الطبقة الخفية وطبقة الخرج، وحدة معالجة تقوم بتحديد خرج العصبون من خلال تطبيق عمليتين حسابيتين متتاليتين كما هو موضح بالشكل (2)، تتضمن العملية الأولى، تحديد ناتج مجموع جداء متغيرات دخل الطبقة السابقة  $X_i$  بالأوزان  $W_{i1}$ ، مضاف لها قيم الانزاح  $b$  ليتم في العملية الثانية تحديد خرج العصبون  $Y$  وذلك باستخدام ناتج العملية الأولى كمتغير لتابع التفعيل  $f(\cdot)$ .

## 2 النموذج الرياضي للنظام الكهروضوئي PV وللمبدل رافع الجهد المستمر:

تحدد الخصائص الكهربائية (تيار - توتر) لنظام PV المكون من  $N_s$  عدد من الخلايا الشمسية الموصولة على التسلسل، بالاعتماد على العلاقات التالية [2]:

$$I_{PV} = I_p - I_0 \left( e^{\left( \frac{V_{PV} + R_s * I_{PV}}{V_t a} \right)} - 1 \right) - \frac{V_{PV} + R_s * I_{PV}}{R_p} \quad (1)$$

يمثل  $I_{PV}$  و  $V_{PV}$  تيار وتوتر خرج نظام PV على التوالي، حيث يقاس التيار بالأمبير [A] والتوتر بالفولت [V]. كما يمثل  $I_p$  [A] التيار الضوئي المتولد، يمثل  $I_0$  [A] تيار الإشباع العكسي،  $V_t = kTN_s/q$  الجهد الحراري

،  $a$  عامل مثالية الديود.  $k$  ثابت بولتزمان،  $q$  شحنة الالكترون. كما تمثل  $R_s$  والمقاومة التسلسلية و  $R_p$  المقاومة التفرعية وتقاس بالأوم.

لتحقيق عمل المتحكم MPPT في تتبع نقطة MPP للنظام PV نستخدم مبدل رافع الجهد المستمر، حيث يكون توتر خرج المبدل المذكور  $V_{out}[V]$  أكبر من توتر دخل المبدل  $V_{pv}[V]$ ، بينما يكون تيار خرج المبدل  $I_{out}[A]$  أصغر من تيار دخل المبدل  $I_{pv}[A]$ . ترتبط متغيرات دخل وخرج المبدل بالعلاقات التالية [2]:


$$D = 1 - \frac{V_{pv}}{V_{out}} \quad (2)$$

$$I_{out} = (1 - D) * I_{pv} \quad (3)$$

$D$  : تمثل نسبة تشغيل ترانزستور مبدل الجهد، وهي عدد لا بعدي تتراوح قيمته بين الصفر والواحد، وتساوي لنسبة الزمن الذي يكون الترانزستور فيه مغلقاً إلى زمن الدور الكلي (المساوي مجموع زمن الإغلاق والفتح للترانزستور).

### نمذجة الشبكة العصبونية الصناعية MLFFNN

يعتمد النموذج المقترح للشبكة العصبونية الصناعية لتتبع نقطة MPP لنظام PV، على شبكة عصبونية متعددة الطبقات ذات تغذية أمامية. تحوي طبقة دخل لهذه الشبكة على متغيري دخل، يمثل متغير الدخل الأول درجة حرارة الخلية الشمسية  $T [^{\circ}C]$  ، بينما يمثل متغير الدخل الثاني شدة الإشعاع الشمسي  $G [W/m^2]$ . كما تحوي طبقة الخرج على عصبون واحد، ممثل لنسبة التشغيل الأمثل  $\widehat{D}_{MPP}$  المستخدمة للتحكم في دورة عمل مبدل رافع الجهد المستمر لتحقيق عمل النظام PV عند نقطة MPP عند التغيرات الجوية. في حين، تحوي الطبقة الخفية على عدة طبقات يتم تحديد عددها وعدد العصبونات في كل طبقة فيها خلال عملية التدريب بشكل يضمن تحقيق معايير الأداء المثلى للشبكة. يوضح الشكل (3) البنية العامة للشبكة MLFFNN المقترحة.



الشكل (3) بنية الشبكة العصبونية الصناعية MLFFNN لتتبع نقطة MPP لنظام PV.

يستخدم لتقييم أداء نموذج الشبكة الناتج كل من متوسط مربع الخطأ  $E$  ومعامل الارتباط  $R$ . حيث يعبر كل من  $R$  و  $E$  عن مدى التقارب بين كل من القيم الحقيقية النظرية والقيم المقدرة لخرج الشبكة العصبونية الممثلة لقيم لنسبة التشغيل الأمثل  $\widehat{D}_{MPP}$  الناتجة عند تغيرات جوية مختلفة، و يحدد كل من  $R$  و  $E$  باستخدام العلاقات التالية [9]:

$$E = \frac{1}{N} \sum_{K=1}^N (D_{mppK} - \widehat{D}_{mppK})^2 \quad (4)$$

$$R = \sqrt{1 - \frac{\sum_{K=1}^N (Dmpp_K - \overline{Dmpp_K})^2}{\sum_{K=1}^N (Dmpp_K - \overline{Dmpp_K})^2}} \quad (5)$$

$$\overline{Dmpp_K} = \frac{1}{N} \sum_{K=1}^N Dmpp_K \quad (6)$$

حيث  $Dmpp_K$  تمثل القيم الحقيقية المرغوبة للخروج و  $\overline{Dmpp_K}$  تمثل القيم المقدرة الناتجة من الشبكة عند وحدة الإخراج . أما  $\overline{Dmpp_K}$  تمثل المتوسط الحسابي للقيم الحقيقية للخروج  $Dmpp_K$  والتي عددها يساوي  $N$  . حيث إن الأداء المثالي للشبكة المدربة يتوافق مع قيمة  $E$  أصغرية، وقيمة معامل الارتباط  $R$  قريبة من الواحد. تقارب قيمة  $R$  من الواحد، يظهر التقارب الدقيق بين نتائج المخرجات الحقيقية  $Dmpp_K$  والمقدرة الناتجة عن الشبكة  $\overline{Dmpp_K}$ ، وعندما تكون قيمة  $R$  قريبة من الصفر تدل على أن النموذج الناتج للشبكة غير جيد نتيجة التباعد بين قيم  $Dmpp_K$  و  $\overline{Dmpp_K}$ .

### اختيار هيكلية الشبكة MLFFNN باستخدام معايير الأداء $E$ و $R$

تتم نمذجة الشبكة العصبونية الصناعية في بيئة Matlab بإدخال أزواج بيانات تدريب الشبكة. تمثل هذه البيانات مدخلات الشبكة الممثلة بالمصفوفة "inputs" الممثلة لتغيرات درجة حرارة الخلية الشمسية وتغيرات شدة الإشعاع الشمسي، والقيم المرغوبة للخروج الممثلة بالمصفوفة "targets" والموافقة لقيم نسبة التشغيل الأمل  $D_{MPP}$ . بناء على ذلك وباستخدام تابع "newff" يتحدد نموذج الشبكة العصبونية الصناعية ذات التغذية الأمامية كما يلي:

net = newff (inputs, targets,[ n<sub>1</sub> n<sub>2</sub> n<sub>3</sub>],{'tansig','tansig','tansig','purelin'},'traingdx');

- تمثل  $n_3, n_2, n_1$ : عدد العصبونات في الطبقة الخفية الأولى، الثانية والثالثة على التوالي. بينما يمثل التابع 'tansig' تابع التفعيل سيغمويد (تابع الظل القطعي) في الطبقات الخفية، بينما يمثل 'purelin' تابع التفعيل الخطي في طبقة الخرج.

الجدول (1) يوضح سيناريوهات الشبكة التي تم بناؤها مع قيم  $E$  و  $R$

في مرحلة التدريب والاختبار و التحقق الناتجة باستخدام تابع التدريب "traingdx"

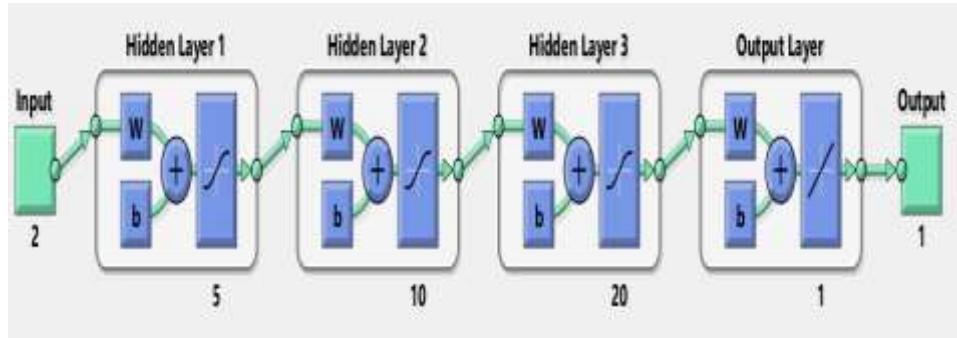
عدد الطبقات الخفية	عدد العصبونات في كل طبقة خفية في الشبكة العصبونية الصناعية المرئية باستخدام التابع traingdx	مرحلة التدريب training		مرحلة التحقق validation		مرحلة الاختبار testing	
		متوسط مربع الخطأ E	معامل الارتباط R	متوسط مربع الخطأ E	معامل الارتباط R	متوسط مربع الخطأ E	معامل الارتباط R
		طبقة خفية واحدة	n1=2;	0.0117	0.2254	0.0132	0.1334
	n1=5;	0.0105	0.7193	0.0108	0.6359	0.0100	0.5739
	n1=10;	0.0098	0.7521	0.0071	0.7659	0.0102	0.7642
	n1=15;	0.0026	0.9019	0.0039	0.8313	0.0027	0.9055
	n1=20;	0.0015	0.9465	0.0016	0.9132	0.0021	0.9306
طبقتين خفيتين	n1=2; n2=2	0.0035	0.8375	0.0038	0.8463	0.0037	0.9152
	n1=5; n2=2;	0.0018	0.9294	0.0018	0.9151	0.0016	0.9321
	n1=5; n2=5;	0.0017	0.9317	0.0012	0.9617	0.0010	0.9513
	n1=5; n2=10;	7.987e-04	0.9738	9.48e-04	0.9651	0.0015	0.9622
	n1=5; n2=20;	5.259e-04	0.9774	8.52e-04	0.9706	7.35e-04	0.9776
ثلاث طبقات خفية	n1=5; n2=2; n3=2;	9.02e-04	0.9632	9.50e-04	0.9714	8.51e-04	0.9612
	n1=5; n2=5; n3=2;	7.51e-04	0.9702	7.58e-04	0.9712	8.17e-04	0.9661
	n1=5; n2=5; n3=10;	4.31e-04	0.9829	5.49e-04	0.9798	4.94e-04	0.9782
	n1=5; n2=10; n3=10;	3.89 e-04	0.9864	5.29e-04	0.9810	4.84e-04	0.9798
	n1=5; n2=10; n3=20;	3.254e-04	0.9871	3.53e-04	0.9877	4.82e-04	0.9814

بناء على ما سبق، وباختيار عدة سيناريوهات لتدريب الشبكة العصبونية باستخدام تابع التدريب "traingdx" الممثل لخوارزمية الانحدار التدريجي للخطأ ذات معامل معدل التعلم المتغير القيمة، نجد أن هيكلية شبكة MLFFNN المختارة في البحث هي الموافقة للسيناريو الأخير والتي تمتلك القيم الأفضل لكل من E و R في مرحلة التدريب والاختبار و التحقق كما هو مبين في الجدول (1)، وبالتالي تمتلك التركيبة التالية:

- طبقة الدخل مؤلفة من دخلين، ممثلين لدرجة حرارة الخلية الشمسية وشدة الإشعاع الشمسي.
- ثلاث طبقات خفية، عدد عصبونات الطبقة الخفية الأولى خمسة عصبونات، أما عدد عصبونات الطبقة الخفية الثانية فهو عشرة، وعشرون عصبون في الطبقة الخفية الثالثة.
- طبقة خرج بعصبون واحد، ممثل لنسبة التشغيل.

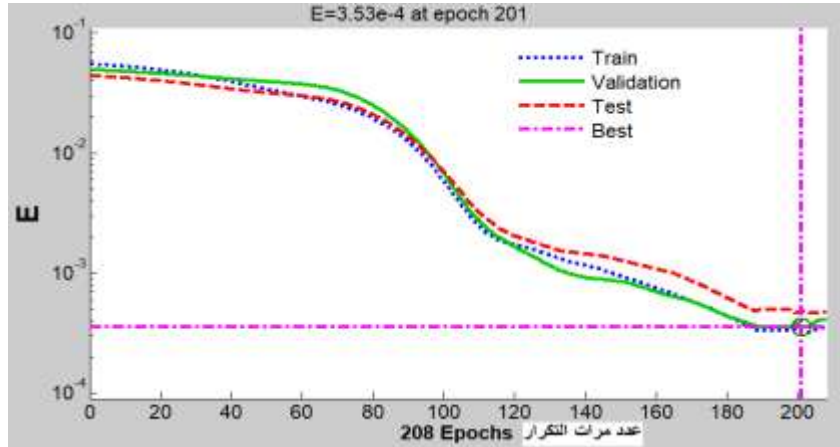
يبين الجدول (1)، إن الاستمرار بزيادة عدد الطبقات الخفية وزيادة عدد العصبونات فيها سيؤدي إلى تحقيق قيمة أصغر لمتوسط مربع خطأ ويحقق قيمة أفضل لمعامل الارتباط مقارنة إلى الواحد، ولكنه يزيد من حجم وتعقيد الشبكة، لذلك تم اعتبار أن السيناريو الأخير يحقق اختيار الهيكلية الأفضل للشبكة العصبونية المختارة في البحث.

يبين الشكل (4) هيكلية الشبكة MLFFNN النهائية المستخدمة في البحث. كما يظهر الشكل (5)، منحنى الأداء للشبكة العصبونية الموافق للسيناريو الأخير، حيث يتضمن الشكل المذكور أربعة منحنيات: منحنى عملية التدريب (Train)، منحنى صلاحية الشبكة العصبونية أي التحقق (Validation)، منحنى عملية الاختبار (Test)، ومنحنى القيم الأفضل (Best). نرى من خلال الشكل أن المنحنيات جميعها تقاربت إلى قيمة متوسط مربع الخطأ،  $E = 3.53 * 10^{-4}$  عند التكرار (Epochs) 201. بينما يظهر الشكل (6)، قيمة معاملات الارتباط R للمجموعات الثلاث (التدريب-التحقق-الاختبار) المتقاربة إلى الواحد، وهذا يظهر دقة نموذج MLFFNN الناتج، كما يظهر العلاقة الخطية بين قيم نسبة التشغيل النظرية وتلك الناتجة عن الشبكة.

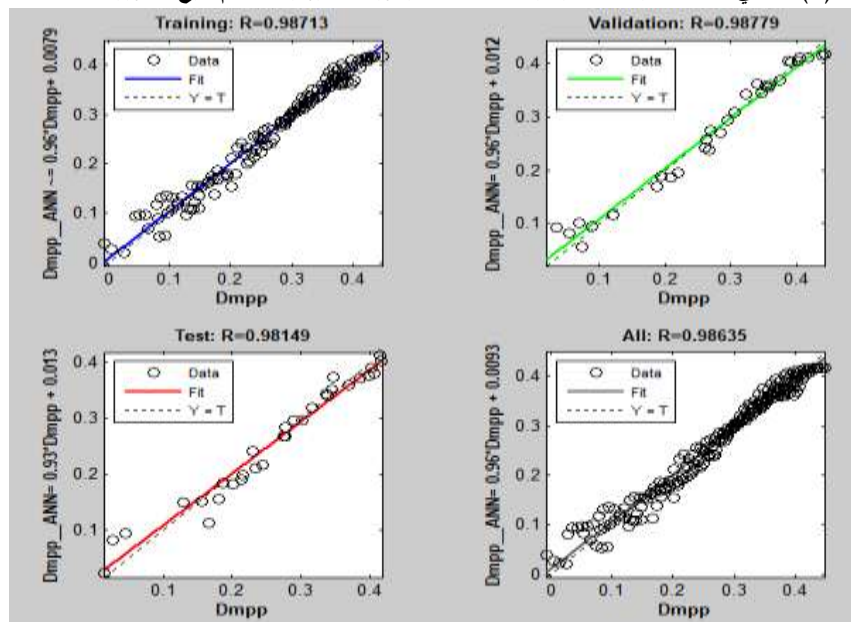


الشكل (4) هيكلية الشبكة العصبونية MLFFNN الموافقة للسيناريو الأخير الناتجة في بيئة Matlab.






الشكل (5) منحنى الأداء للشبكة العصبونية الموافقة للسيناريو الأخير باستخدام تابع التدريب "traingdx".



الشكل (6) معاملات الارتباط للشبكة العصبونية الموافقة للسيناريو الأخير باستخدام تابع التدريب "traingdx".

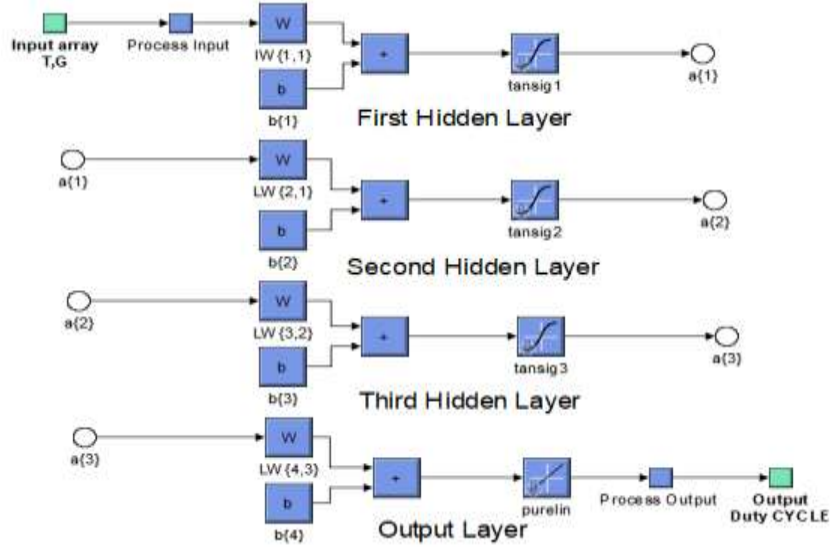


الشكل (7) تغيرات معدل التعلم أثناء عملية تدريب الشبكة العصبونية المقترحة باستخدام "traingdx".


يظهر الشكل (7)، تغيرات معدل التعلم أثناء عملية تدريب الشبكة العصبونية، حيث تزداد قيمته بداية التدريب لتحقيق سرعة تقارب أفضل لخوارزمية التدريب نحو القيمة الصغرى لمتوسط مربع الخطأ، ثم تتناقص قيمته تدريجياً لتنتهي إلى الصفر عند تقارب تدرج الخطأ نحو الصفر أي عند تقارب الخوارزمية من الحل الأمثل الموافق للقيمة الصغرى للخطأ.

## 6- محاكاة نموذج المتحكم DMPPT-ANN الناتج من النموذج النهائي لشبكة MLFFNN

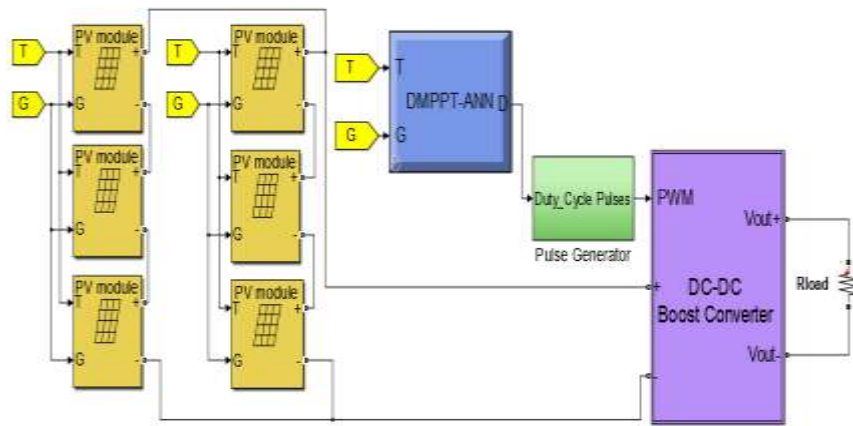
بعد انتهاء عملية تدريب الشبكة والحصول على الهيكلية الأفضل لشبكة MLFFNN لها، نعتد الأوزان والانزياحات الناتجة في هذه المرحلة، ليتم استخدامها في محاكاة شبكة MLFFNN في بيئة Matlab/Simulink، كما هو موضح في الشكل (8) الذي يظهر الطبقات الخفية الثلاثة للشبكة متعددة الطبقات المعتمدة. بناء على ذلك، يستخدم النموذج النهائي الناتج للشبكة، ليشكل نموذج المتحكم المعتمد في البحث (DMPPT-ANN Developed) (MPPT-ANN) كما هو موضح في الشكل (9)، والمستخدم لتقدير نسبة التشغيل الأمثل للتحكم في دورة عمل مبدل رافع للجهد المستمر بما يحقق تتبع نقطة MPP للنظام PV، كما هو مبين في الشكل (10).



الشكل (8) محاكاة الشبكة MLFFNN المستخدمة لتقدير نسبة التشغيل في بيئة Matlab/Simulink.



الشكل (9) نموذج المتحكم DMPPT-ANN المرتكز على نموذج الشبكة MLFFNN.



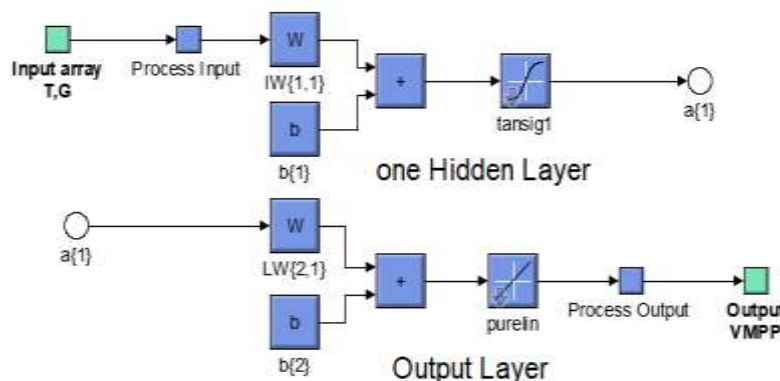
الشكل (10) محاكاة نظام تتبع نقطة MPP باستخدام المتحكم DMPPT-ANN في بيئة Matlab/Simulink.

### محاكاة المتحكمات المرجعية المستخدمة لتتبع نقطة MPP


استعرضنا فيما سبق محاكاة المتحكم DMPPT-ANN المقترح في البحث، والمستقل في عمله عن الحاجة لاستخدام أي من القياسات الكهربائية لخرج نظام PV، حيث يرتبط عمله مباشرة بتغيرات شدة الإشعاع الشمسي ودرجة حرارة الخلية الشمسية، لتقدير نسبة التشغيل المثلى بسرعة فائقة ومباشرة. كما يركز عمل المتحكم المقترح على طريقة التحكم المباشر لضبط دورة عمل مبدل الجهد المستمر، أي يتم تقدير نسبة التشغيل دون الحاجة لاستخدام متحكم PI وهذا من شأنه تحسين أداء المتحكم في الاستجابة بسرعة للتغيرات الجوية، ومما يجعل تصميم المتحكم يتسم بالسهولة والبساطة. لتوضيح ذلك نورد فيما يلي نتائج محاكاة عدد من المتحكمات المرجعية.

### 1 محاكاة المتحكم المرجعي المعتمد على شبكة ANN أحادية الطبقة الخفية لتقدير VMPP

يستخدم المتحكم MPPT-ANN المقترح في المرجع [7]، شبكة عصبونية صناعية ANN ذات طبقة خفية واحدة وطبقة خرج بعصبون واحد لتقدير التوتر VMPP كما هو مبين في الشكل (11). يتم ضبط توتر خرج النظام PV عند التوتر VMPP باستخدام متحكم تناسبي-تقليدي. وبالتالي يتطلب تحقيق تتبع نقطة MPP حلقتين تحكم، الأولى لتقدير التوتر VMPP باستخدام الشبكة ANN، والثانية تستخدم إشارة خرج المتحكم PI لتوليد إشارة النبضة المستخدمة للتحكم في عمل ترانزستور مبدل الجهد كما هو مبين في الشكل (12). لذلك يسمى هذا النوع من التحكم الذي يستخدم متحكم PI تقليدي، بالتحكم غير المباشر ويرمز للمتحكم بالرمز MPPT-ANN-PI.



الشكل (11) محاكاة الشبكة ANN أحادية الطبقة الخفية المستخدمة لتقدير التوتر VMPP في بيئة Matlab/Simulink.



الشكل (12) نموذج المحاكاة للمتحكم المرجعي MPPT-ANN-PI في بيئة Matlab/Simulink.

## 2 محاكاة المتحكم العائم المرجعي

يستخدم المتحكم العائم MPPT-FLC المقترح في المرجع [3]، القياسات اللحظية لتيار وتوتر خرج نظام PV لتحديد كل من تغيرات الاستطاعة  $\Delta P$  وتغيرات التيار  $\Delta I$  لخرج النظام PV، لتشكل هذه المتغيرات دخل المتحكم العائم، أما خرج المتحكم MPPT-FLC فيمثل تغير نسبة التشغيل  $\Delta D(k)$ . تعرف هذه المتغيرات كما يلي:

$$\Delta P = P(k) - P(k - 1) \quad (9)$$


$$\Delta I = I(k) - I(k - 1) \quad (10)$$

$$\Delta D(k) = D(k) - D(k - 1) \quad (11)$$


توضح الأشكال (13)، (14) و(15) عملية تعويم متغيرات دخل وخرج المتحكم العائم MPPT-FLC باستخدام توابع انتماء تحقق انتقال سلس وتدرجي من مجموعة عائمة إلى أخرى لذلك تم اختيار توابع لها شكل شبه منحرف وأخرى مثلثية، والممثلة بالمتغيرات اللغوية التالية:

NB: Negative-Big, NS: Negative-Small, PS: Positive-Small, PB: Positive-Big.


يبين الشكل (16) محاكاة النموذج النهائي لهذا المتحكم والناتج باستخدام Fuzzy Logic Toolbox. حيث تمثل  $K_1$  و  $K_2$  عوامل التقييس المستخدمة لضبط مجال تغير كل من  $\Delta P$  و  $\Delta I$  ضمن المجال  $[-1,1]$ .




الشكل (13) توابع الانتماء لإشارة الدخل الأول للمتحكم MPPT-FLC الممثلة لتغير استطاعة خرج نظام PV.



الشكل (14) توابع الانتماء لإشارة الدخل الثانية للمتحكم MPPT-FLC الممثلة لتغير تيار خرج نظام PV.



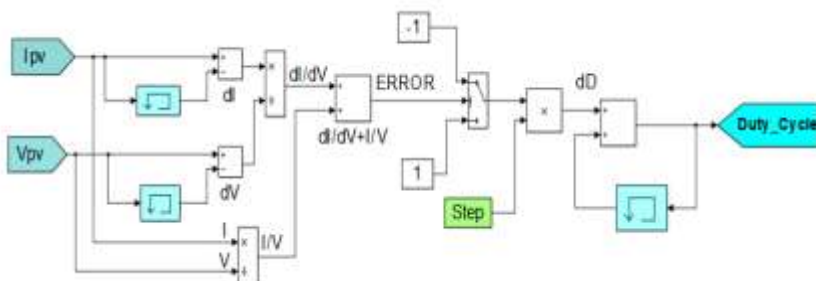
الشكل (15) توابع الانتماء لإشارة الخرج للمتحكم MPPT-FLC الممثلة لتغير نسبة التشغيل  $\Delta D$ .



الشكل (16) محاكاة المتحكم العائم MPPT-FLC المرجعي في بيئة Matlab/Simulink.

### 3 محاكاة المتحكم المرجعي المعتمد على تقنية زيادة الناقلية

يعتمد المتحكم المرجعي الأخير على تعتبر تقنية زيادة الناقلية (Incremental conductance, INC) [2]. تعتمد تقنية INC في عملها على طريقة البحث التدريجي والدوري عن نقطة MPP وذلك بإجراء اضطراب زيادة أو نقصاناً على قيمة نسبة التشغيل السابقة  $D_{K-1}$  بمقدار محدد ثابت  $Step$  لتحديد قيمة نسبة التشغيل اللحظية  $D_K$  وذلك اعتماداً على مقارنة نسبة تغيرات تيار وتوتر النظام  $\frac{dI}{dV}$  مع القيم اللحظية المقاسة  $\frac{I}{V}$  لخرج نظام PV. يبين الشكل (17) محاكاة المتحكم التقليدي MPPT-INC المرتكز على تقنية INC في بيئة Matlab/Simulink.

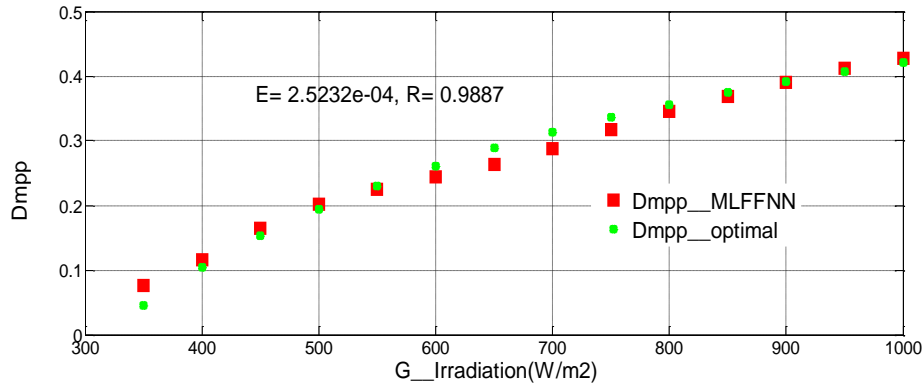


الشكل (17) محاكاة المتحكم التقليدي MPPT-INC المرتكز على تقنية INC في بيئة Matlab/Simulink.

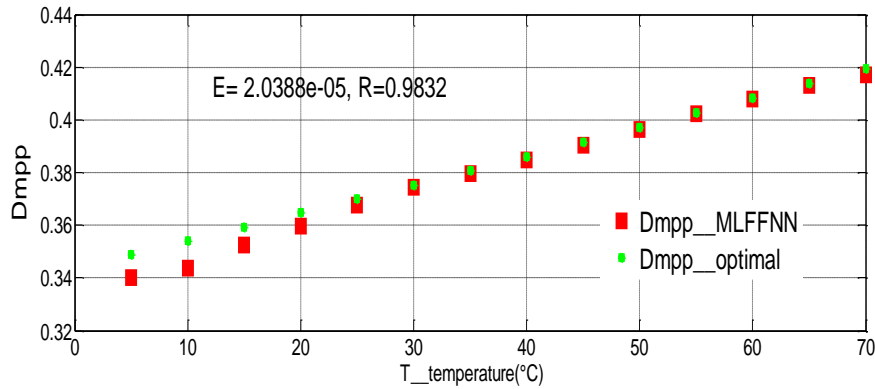
### النتائج والمناقشة

يمكن التحقق من كفاءة أداء نموذج المتحكم DMPPT-ANN المرتكز على الشبكة MLFFNN والمستخدم لتقدير قيم نسبة التشغيل  $\widetilde{D}_{MPP} = D_{MPP\_MLFFNN}$ ، بمقارنة نتائجه مع نتائج قيم نسبة التشغيل الأمثل النظرية  $D_{MPP\_optimal}$ . حيث كما تظهر نتائج الشكل (18)، والنتيجة عند تغيرات مختلفة لشدة الإشعاع الشمسي مع ثبات درجة حرارة الخلية الشمسية  $T = 45[^\circ\text{C}]$ ، ونتائج الشكل (19) الناتجة عند تغيرات درجة حرارة الخلية الشمسية مع ثبات شدة الإشعاع الشمسي  $G = 900 [\text{W}/\text{m}^2]$ ، نلاحظ أن هناك تقارب كبير بين قيم نسبة التشغيل النظرية  $D_{MPP\_optimal}$  والمقدرة  $\widetilde{D}_{MPP}$  عند كل من التغيرات الجوية المختلفة، وكما هو مبين يمتلك نموذج الشبكة قيم

جيدة لكل من معامل الارتباط  $R$  ومتوسط مربع الخطأ  $E$  الناتجة في كلا الحالتين. وبالتالي هذا يظهر كفاءة أداء نموذج شبكة MLFFNN المستخدم لتقدير قيم  $\widehat{D_{MPP}}$ .




الشكل (18) تغيرات نسبة التشغيل النظرية والمقدرة خرج MLFFNN عند تغير شدة الإشعاع الشمسي مع ثبات درجة الحرارة.



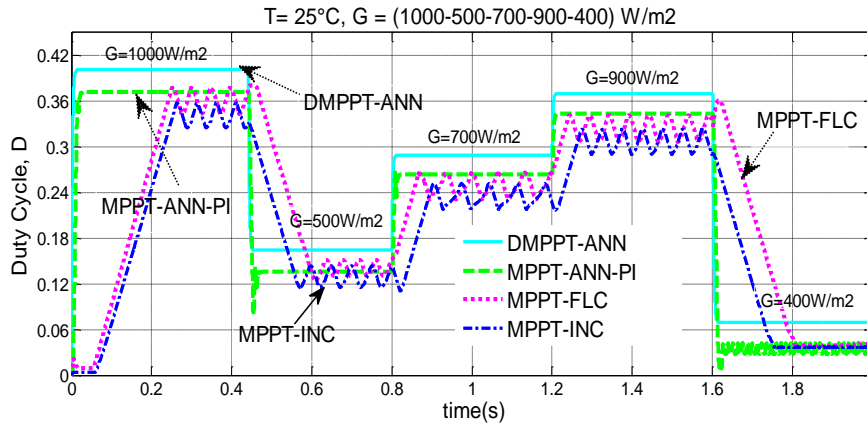
الشكل (19) تغيرات نسبة التشغيل النظرية والمقدرة خرج MLFFNN عند تغير درجة الحرارة وشدة إشعاع شمسي ثابتة.

نعرض فيما يلي نتائج المحاكاة المنجزة في بيئة Matlab/Simulink لتتبع نقطة MPP لنظام PV باستخدام كل من المتحكم DMPPT-ANN المطور في البحث، وباستخدام عدد من المتحكمات المرجعية التالية: MPPT-ANN-PI، MPPT-FLC، MPPT-INC. حيث يتكون نظام PV من سلسلتين من الألواح كهروضوئية، تحوي كل سلسلة على ثلاثة ألواح كهروضوئية، باستطاعة [W] 150 للوح الكهروضوئي الواحد، ومنه الاستطاعة الكلية لنظام PV [W] 900.

لذلك نفرض بداية تغيرات فجائية سريعة لشدة الإشعاع الشمسي (Irradiance, G) :  $G = 1000 - 900 - 700 - 500 [W/m^2]$  مع اعتبار أن درجة حرارة الخلية الشمسية ثابتة  $T = 25 [^{\circ}C]$ . يظهر الشكل (20)، تغير استطاعة خرج نظام PV مع تغير شدة الإشعاع الشمسي G، حيث تتناقص الاستطاعة مع تناقص G والعكس بالعكس. كما يلاحظ أن قيمة استطاعة خرج نظام PV المتحصل عليها باستخدام المتحكم المطور DMPPT-ANN، هي أكبر من تلك الناتجة باستخدام كل من المتحكمات المرجعية MPPT-ANN-PI، MPPT-FLC و MPPT-INC عند التغيرات المختلفة في شدة الإشعاع الشمسي.



الشكل (20) استطاعة خرج نظام PV عند شروط تغير شدة الإشعاع الشمسي مع ثبات درجة الحرارة.

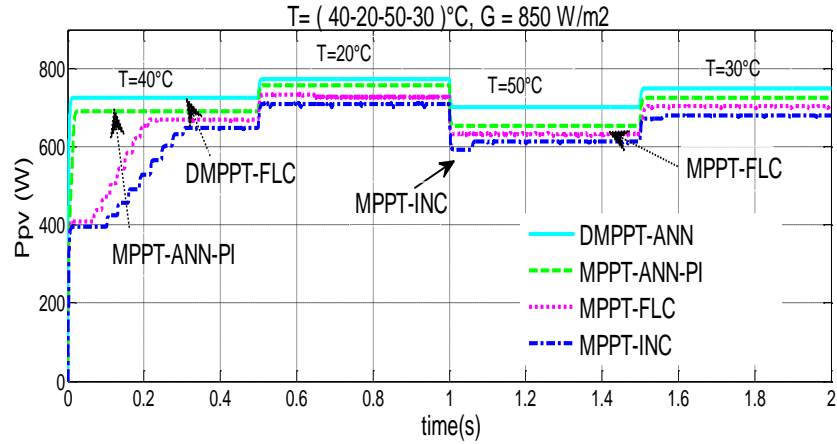


الشكل (21) تغير نسبة التشغيل D عند شروط تغير شدة الإشعاع الشمسي مع ثبات درجة الحرارة.

كما يظهر الشكل (21)، الأداء الجيد للمتحكم المطور DMPPT-ANN في تحديد قيم نسبة التشغيل المثلى بسرعة ودقة فائقة عند الانتقال من سوية إشعاع شمسي إلى أخرى، بالإضافة للتخلص بشكل نهائي من التذبذبات الناتجة في قيم نسبة التشغيل وهذا لم يتم تحقيقه باستخدام كل من المتحكمات المرجعية. وهذا نتج عنه، تحسن سرعة استجابة النظام في العمل عند نقطة MPP عند التغيرات الجوية السريعة والفجائية.

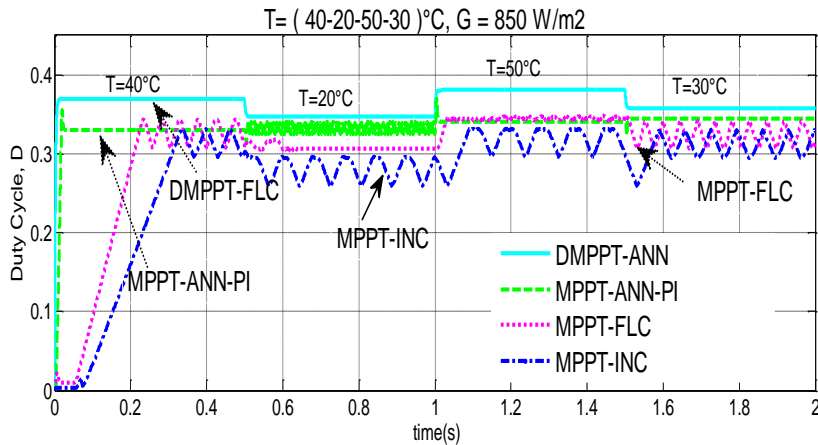
يمكن دراسة أثر تغير درجة حرارة الجو المحيط على استطاعة خرج نظام PV، من خلال افتراض تغيرات مختلفة ولدجة حرارة الخلية الشمسية واقعة ضمن المجالات الحرارية التالية:  $T = 40 - 20 - 50 - 30 [^{\circ}\text{C}]$ ، مع اعتبار شدة إشعاع شمسي ثابتة  $G = 850 [W/m^2]$ . يظهر الشكل (21)، تزايد استطاعة خرج نظام PV مع انخفاض درجة حرارة الخلية الشمسية، والعكس بالعكس وهذا يظهر العلاقة العكسية بين تغير درجة حرارة الخلية الشمسية وتغير استطاعة خرج نظام PV. كما يظهر الشكل (22) أن استطاعة خرج نظام PV المتحصل عليها باستخدام المتحكم المطور DMPPT-ANN، هي أكبر من تلك الناتجة باستخدام كل من المتحكمات المرجعية السابقة الذكر ويعود ذلك للأداء الأفضل للمتحكم DMPPT-ANN، بتحديد القيم المثلى لنسبة التشغيل بدقة كبيرة كما هو مبين في الشكل (23). وهذا سيساهم بالتالي من رفع قيمة عامل كفاءة نظام PV مقارنة مع حالة استخدام المتحكمات المرجعية الأخرى





الشكل (22) استطاعة خرج نظام PV عند تغير درجة الحرارة وشدة إشعاع شمسي ثابتة.

يبين الجدول (2) و(3)، التقارب الكبير بين قيم نسبة التشغيل  $\overline{D_{MPP}}$  الناتجة باستخدام المتحكم المطور DMPPT-ANN وبين تلك القيم المقابلة النظرية  $D_{MPP}$ ، مقارنة أيضاً مع قيم نسبة التشغيل الناتجة باستخدام كل من المتحكمات المرجعية عند تغيرات جوية مختلفة. وبالتالي هذا يظهر أيضاً كفاءة نموذج شبكة MLFFNN الناتج بتقدير قيم  $\overline{D_{MPP}}$  بدقة كبيرة.



الشكل (23) تغير نسبة التشغيل D عند تغير درجة الحرارة وشدة إشعاع شمسي ثابتة.

تتضمن كل من الجداول (4)، (5) قيم  $\eta_{PV}$  عامل كفاءة نظام PV، الناتج بقسمة  $P_{pv}$  الممثلة لاستطاعة خرج نظام PV، على الاستطاعة النظرية العظمى  $P_{MPP}$  المحددة عند نفس الشروط الجوية. بمقارنة نتائج الجداول المذكورة، نلاحظ أن المتحكم DMPPT-ANN، ساهم بتحسين عامل كفاءة نظام PV بشكل أفضل مقارنة مع استخدام كل من المتحكمات المرجعية المستخدمة عند التغيرات الجوية المختلفة.



الجدول (2) قيم نسبة التشغيل النظرية ونسبة التشغيل خرج متحكمات MPPT-ANN، MPPT-ANN-PI، MPPT-FLC و MPPT-INC عند تغيرات مختلفة لشدة الإشعاع الشمسي مع ثبات درجة حرارة الخلية الشمسية  $T = 25 [^{\circ}C]$ .

شدة الإشعاع الشمسي [W/m <sup>2</sup> ]	نسبة التشغيل الأمثل النظرية DMPP	نسبة التشغيل D <sub>MPP</sub> خرج DMPPT-ANN	نسبة التشغيل D <sub>MPP</sub> خرج MPPT-ANN-PI	نسبة التشغيل D <sub>MPP</sub> خرج MPPT-FLC	نسبة التشغيل D <sub>MPP</sub> خرج MPPT-INC
1000	0.4011	0.4011	0.3714	0.3478	0.3320
900	0.3700	0.3700	0.3435	0.3332	0.2995
700	0.2890	0.2890	0.2634	0.2566	0.2315
500	0.1641	0.1641	0.1355	0.1403	0.1253
400	0.0694	0.0694	0.0371	0.0400	0.0372

الجدول (3) قيم نسبة التشغيل النظرية ونسبة التشغيل خرج متحكمات MPPT-ANN، MPPT-ANN-PI، MPPT-FLC و MPPT-INC عند شدة إشعاع شمسي ثابتة  $G = 850 [W/m^2]$  و عند تغير درجة حرارة الخلية الشمسية.

درجة حرارة الخلية الشمسية [ <sup>o</sup> C]	نسبة التشغيل الأمثل النظرية DMPP	نسبة التشغيل D <sub>MPP</sub> خرج DMPPT-ANN	نسبة التشغيل D <sub>MPP</sub> خرج MPPT-ANN-PI	نسبة التشغيل D <sub>MPP</sub> خرج MPPT-FLC	نسبة التشغيل D <sub>MPP</sub> خرج MPPT-INC
50	0.3804	0.3805	0.3432	0.3438	0.3152
40	0.3691	0.3691	0.3300	0.3281	0.3125
30	0.3579	0.3580	0.3444	0.3268	0.3098
20	0.3469	0.3470	0.3340	0.3059	0.2827

الجدول (4) عامل كفاءة نظام PV الناتج باستخدام كل من المتحكمات MPPT-ANN، MPPT-ANN-PI، MPPT-FLC و MPPT-INC، عند سويات مختلفة للإشعاع الشمسي مع ثبات درجة حرارة الخلية الشمسية  $T = 25 [^{\circ}C]$ .

شدة الإشعاع الشمسي [W/m <sup>2</sup> ]	$\eta_{pv}$ DMPPT-ANN	$\eta_{pv}$ MPPT-ANN-PI	$\eta_{pv}$ MPPT-FLC	$\eta_{pv}$ MPPT-INC
1000	0.9983	0.9590	0.9485	0.8980
900	0.9998	0.9574	0.9463	0.8976
700	0.9997	0.9527	0.9428	0.8931
500	0.9999	0.9431	0.9333	0.8827
400	0.9998	0.9280	0.9234	0.8760

الجدول (5) عامل كفاءة نظام PV الناتج باستخدام كل من المتحكمات MPPT-FLC، MPPT-ANN-PI، DMPPT-ANN و MPPT-INC، عند شدة إشعاع شمسي ثابتة  $G = 850 [W/m^2]$  و عند تغير درجة حرارة الخلية الشمسية.

درجة الحرارة [°C]	$\eta_{pv}$ DMPPT-ANN	$\eta_{pv}$ MPPT-ANN-PI	$\eta_{pv}$ MPPT-FLC	$\eta_{pv}$ MPPT-INC
50	0.9996	0.9308	0.9008	0.8738
40	0.9997	0.9516	0.9223	0.8932
30	0.9997	0.9682	0.9386	0.9089
20	0.9997	0.9803	0.9426	0.9209

### الاستنتاجات والتوصيات:

تم في هذا البحث العمل على تطوير نموذج لشبكة عصبونية صناعية متعددة الطبقات MLFFNN مدربة باستخدام خوارزمية الانحدار التدريجي للخطأ ذات معدل التعلم المتغير القيمة لتقدير نسبة التشغيل المستخدمة للتحكم في دورة عمل مبدل رافع للجهد المستمر لتتبع نقطة MPP لنظام PV في بيئة Matlab/Simulink. كما تم اختبار فعالية وأداء المتحكم المقترح DMPPT-ANN في تتبع نقطة MPP، مقارنة مع أداء كل من المتحكمات المرجعية MPPT-FLC، MPPT-ANN-PI و MPPT-INC عند تغيرات جوية مختلفة، بناء على ذلك تم الوصول إلى الاستنتاجات التالية:

- شكل المتحكم DMPPT-ANN المطور في البحث المرتكز على نموذج الشبكة العصبونية MLFFNN، نموذج حاسوبي مكن من تحديد بسرعة فائقة ودقة عالية قيم نسبة التشغيل المثلى مباشرة باستخدام القياسات اللحظية لدرجة حرارة الخلية الشمسية وشدة الإشعاع الشمسي، مما حقق بشكل واضح تحسين سرعة استجابة نظام التحكم لضبط عمل نظام PV عند نقطة MPP عند التغيرات الجوية المختلفة.
  - أظهرت المتحكمات المرتكزة على استخدام الشبكات العصبونية لتتبع نقطة MPP أداء أفضل من المتحكمات المرجعية الأخرى. حيث حقق المتحكم المقترح DMPPT-ANN أداء أفضل من حيث دقة وسرعة تتبع نقطة MPP لنظام PV، مقارنة مع المتحكم MPPT-ANN-PI وذلك يعود للاستغناء عن استخدام المتحكم PI الذي لا يبدي أداء جيد عند التحكم بالنظم اللاخطية، بينما تفوق أداء كل من المتحكمات DMPPT-ANN و MPPT-ANN-PI على أداء المتحكم القائم MPPT-FLC الذي تفوق بدوره على أداء المتحكم التقليدي MPPT-INC.
  - مكن المتحكم المطور DMPPT-ANN من التخلص بشكل نهائي من التذبذبات الدائمة في استجابة الحالة المستقرة لمنحني استطاعة نظام PV، مما نتج عنه التخلص من مشكلة الضياع في الطاقة الناتجة عن هذه التذبذبات وهذا ما لم يتم تحقيقه بكفاءة عالية باستخدام كل من المتحكمات المرجعية المستخدمة.
- نوصي بتطوير نماذج أخرى للمتحكم MPPT باستخدام أنواع مختلفة من الشبكات العصبونية ومقارنة أدائها مع الشبكة المطورة في البحث، كذلك نوصي بدراسة استخدام خوارزميات تدريب أخرى للشبكات العصبونية. كما يمكن تطوير نظام تحكم هجين يمكن أن يكون ذو أداء أفضل بحيث يتمتع بمزايا كل من تقنيات التحكم المدمجة فيه.

## المراجع:

- [1] SARAVANA, S.; PRATAP, N.; UMayAL .A *Review on Photovoltaic MPPT Algorithms*. International Journal of Electrical and Computer Engineering 6, 2016, 567-582.
- [2] KUMAR, M.; Kapoor, S. R.; NAGAR, R.; VERMA, A. *Comparison between IC and Fuzzy Logic MPPT Algorithm Based Solar PV System using Boost Converter*. International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering 4, 2015, 4927- 4939.
- [3] ZAHAB, E.; ZAKIB, A.; EL-SOTOUHY.M. *Design and control of a standalone PV water pumping system*. Journal of Electrical Systems and Information Technology 96, 2017, No. of Pages16.
- [4] MUTLAG, A.; MOHAMED, A.; SHAREEF, H. *A Comparative study of artificial intelligent-based Maximum Power Point tracking for Photovoltaic Systems*. International Conference on Advances in Renewable Energy and Technologies 32, 2016, 1-4.
- [5] NAGARJUNA, J.; MANJUNATHA, B. M.; MALLIKARJUNA, M. *Improving efficiency of Photovoltaic System with Neural Network Based MPPT Connected to DC Shunt Motor*. International Journal of Modern Engineering Research 3, 2013, 2901-2907.
- [6] HEIDARI, M. *Improving Efficiency of Photovoltaic System by Using Neural Network MPPT and Predictive Control of Converter*. International Journal of Renewable Energy Research, 6, 2016, 1524- 1529.
- [7] ELGHARBI, A.; MEZGHANI, D.; MAMI, A. *A Maximum Power Point tracking Method based on Artificial Neural Network for PV System*. International Journal of Advances in Engineering & Technology 5, 2012, 130-140.
- [8] MAKHLOUFI, T.; KHIREDINE, S.; ABDESSEMED, Y.; BOUTARFA, A . *Tracking Power Photovoltaic System using Artificial Neural Network Control Strategy*. Intelligent Systems and Applications 12, 2014, 17-26.
- [9] SUGANTHI, S.; MURUGESAN, K.; RAGHAVAN, S. *ANN Model of RF MEMS Lateral SPDT Switches for Millimeter Wave Applications*. Journal of Microwaves, Optoelectronics and Electromagnetic Applications, 11, 2012, 130-143.