

تطوير متحكم مرتكز على الشبكات العصبونية الصناعية ذات التغذية الأمامية وعلى طريقة التحكم المباشر لتحسين كفاءة نظم الطاقة الشمسية الكهروضوئية باستخدام Matlab/Simulink

د. إيمان ديلانة*

(تاريخ الإيداع 27 / 6 / 2016. قُبل للنشر في 30 / 1 / 2017)

□ ملخص □

يقدم البحث منهجية جديدة لتطوير متحكم مرتكز على الشبكات العصبونية الصناعية ANN وعلى طريقة التحكم المباشر، بهدف الحصول على الطاقة القصوى الممكنة من النظم الشمسية الكهروضوئية في ظل التغيرات الجوية المختلفة من شدة إشعاع شمسي ودرجة حرارة محيطية. في هذا السياق، يقدم البحث نموذج جديد لمتحكم MPPT-ANN لتتبع نقطة الاستطاعة العظمى MPP للنظم الشمسية الكهروضوئية في بيئة Matlab/Simulink. يرتكز المتحكم MPPT-ANN المطور على شبكة عصبونية صناعية ذات تغذية أمامية FFNN مدربة باستخدام خوارزمية الانتشار العكسي للخطأ، لتحديد توتر التشغيل الأمثل للنظام الكهروضوئي PV عند التغيرات الجوية المختلفة. كما يقترح البحث، خوارزمية تحكم تعتمد على طريقة التحكم المباشر لتحديد نسبة التشغيل المستخدمة للتحكم مباشرة في دورة عمل مبدل جهد مستمر، وذلك اعتماداً على مقارنة الفرق الناتج بين توتر خرج النظام الكهروضوئي وتوتر التشغيل الأمثل خرج الشبكة العصبونية. إن لمتحكم المطور MPPT-ANN المرتكز على شبكة FFNN، يمتاز بسرعة فائقة بقتب نقطة MPP وبتحقيق كفاءة عالية لنظام PV عند التغيرات الجوية. أظهرت نتائج المحاكاة المنجزة في بيئة Matlab/Simulink، الأداء الأفضل للمتحكم المطور MPPT-ANN بتحقيق أداء ديناميكي أفضل ودقة عالية عند تتبع نقطة MPP، مقارنة مع استخدام متحكم آخر MPPT-ANN-PI يعتمد على شبكة عصبونية صناعية ومتحكم تناسبي-تكاملي تقليدي، ومقارنة أيضاً مع متحكم تقليدي MPPT-P&O مرتكز على تقنية الاضطراب والمراقبة عند التغيرات الجوية المختلفة.

الكلمات المفتاحية: نظام كهروضوئي، شبكة عصبونية صناعية ذات تغذية أمامية، طريقة التحكم المباشر، تقنية الاضطراب والمراقبة.

*مدرسة- قسم هندسة القوى الميكانيكية -كلية الهندسة الميكانيكية والكهربائية - جامعة تشرين - اللاذقية - سورية

Developing a Controller based on Feed Forward Neural Networks and Direct Control Method to improve the efficiency of Solar Photovoltaic Energy Systems using Matlab/Simulink

Dr. Imane Dilaneh *

(Received 27 / 6 / 2016. Accepted 30 / 1 / 2017)

□ ABSTRACT □

This research presents a new methodology for the development of a controller based on Artificial Neural Networks and Direct control method in order to obtain the maximum available energy from Solar Photovoltaic (PV) Energy systems under different atmospheric changes of the solar insolation and ambient temperature. In this context, this research presents a new model for MPPT-ANN in order to track the Maximum Power Point of PV systems in Matlab/Simulink environment. The developed controller is based on Feed Forward Neural Network FFNN trained by Back-propagation algorithm of error to determine the optimal voltage operation of the system PV system at different atmospheric changes. This research also suggests, control algorithm based on the direct control method in order to determine the duty cycle, which used to control directly the operating of DC-DC Voltage Converter, depending on a comparison of the difference between the output voltage of PV system and the optimal voltage output of the neural network. The developed controller MPPT-ANN based on a network FFNN, Characterized by fast speed to track of MPP point and achieve high efficiency for the PV system under the atmospheric changes. The simulation results completed in Matlab/Simulink environment, showed the best performance of developed controller MPPT-ANN by achieving a better dynamic performance and high accuracy when tracking the MPP, compared with the use of the another PI-ANN controller based on artificial neural network and the conventional Proportional-Integral Controller, and compared with the use of the conventional MPPT-P&O based on Perturb and Observe (P&O) technique under different atmospheric changes.

Key words: Photovoltaic System, Feed Forward Neural Network, Direct control method, Perturb and Observe technique.

* Assistant Professor, Department of Mechanical Power Engineering, faculty of Mechanical and Electrical Engineering, Tishreen University, Lattakia, Syria.

مقدمة:

طورت عدة تقنيات تحكم لتتبع نقطة الاستطاعة العظمى (Maximum Power Point, MPP) للنظم الشمسية الكهروضوئية (Photovoltaic System, PV)، بهدف الحصول على الطاقة القصوى من هذه النظم الكهروضوئية في ظل تغير شدة الإشعاع الشمسي، تغير درجة حرارة الجو المحيط واضطرابات الحمل المربوط معها. تركزت معظم تقنيات تتبع نقطة الاستطاعة العظمى (Maximum Power Point Tracking, MPPT)، على استخدام تقنيات تتبع تقليدية. تختلف هذه التقنيات التقليدية فيما بينها من حيث بساطتها، سهولتها في التنفيذ، تكلفتها، دقتها في تتبع نقطة MPP ومن حيث استخدامها لطريقة التحكم المباشر أو غير المباشر [3,2,1]. من أكثر التقنيات التقليدية استخداماً، نذكر تقنية الاضطراب والمراقبة (Perturb and Observer, P&O) وتقنية زيادة الناقلية (Incremental conductance, INC). تتميز تقنيات P&O و INC التقليدية، المرتكزة على طريق التحكم المباشر بأداء أفضل مقارنة مع تلك المستخدمة لطريقة التحكم الغير مباشر المتطلبه استخدام متحكم تناسبي-تكاملي تقليدي (Proportional Integral Controller, PI). إن استخدام متحكم PI تقليدي للتحكم في دورة عمل مبدل الجهد لتحقيق عمل نظام PV عند نقطة MPP، يخفض من الأداء الديناميكي لنظام التحكم كما أنه لا يعتبر الحل الأنسب عند التحكم بالأنظمة اللاخطية كنظم PV.

يمكن استخدام تقنيات التحكم المتقدمة، كالتحكم الضبابي (Fuzzy Logic Controller, FLC) والشبكات العصبونية الصناعية (Artificial Neural Networks, ANN)، لضمان أداء أفضل لعمل أنظمة التحكم في تتبع نقطة MPP مقارنة مع استخدام تقنيات P&O و INC [6,5,4]. يعتبر المتحكم الضبابي FLC من أكثر تقنيات التحكم المتقدمة استخداماً، حيث أنه يمكن من تتبع نقطة MPP لنظم PV بكفاءة عالية. يعتمد التصميم الجيد للمتحكم الضبابي 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. إن استخدام الشبكات العصبونية ANN لتصميم متحكم MPPT، يتسم 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. في المرجع [5]، تم نمذجة شبكة ANN لتحديد تيار التشغيل الأمثل IMPP الموافق لنقطة MPP، حيث تم ضبط تيار خرج النظام PV عند تيار التشغيل IMPP باستخدام متحكم PI تقليدي. أما في المرجع [6]، تم اعتبار أن نسبة التشغيل هي خرج شبكة ANN، أما مدخل الشبكة فهي الاستطاعة خرج نظام PV. أظهرت هذه الدراسات المرجعية، تحقيق المتحكم المرتكز على شبكة ANN سلوك حالة عابرة جيد يتميز بسرعة استجابة عالية لتتبع نقطة MPP عند التغيرات الجوية المختلفة مقارنة مع تقنيات التحكم الأخرى.

أهمية البحث وأهدافه

يقدم البحث منهجية جديدة لتطوير متحكم MPPT مرتكز على الشبكات العصبونية الصناعية ANN في بيئة Matlab/Simulink، لتحسن كفاءة نظم الطاقة الشمسية الكهروضوئية في ظل التغيرات الجوية المختلفة. في هذا السياق، يقدم البحث نموذج لشبكة عصبونية صناعية ذات تغذية أمامية (Forward Neural Networks, FFNN) (Feed) مدربة باستخدام خوارزمية الانتشار العكسي (Back-propagation) للخطأ، وذلك لتقدير خرج الشبكة

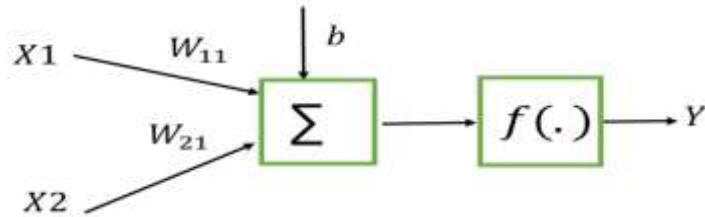
العصبونية الموافق لتوتر التشغيل الأمثل VMPP لنظام PV، اعتماداً على عدد محدد من البارامترات الجوية، التي يمكن قياسها بدقة وسهولة، وهي درجة الحرارة وشدة الإشعاع الشمسي. كما يقترح البحث، خوارزمية تحكم مرتكزة على طريقة التحكم المباشر (Direct Control Method)، لتحديد نسبة التشغيل (Duty Cycle, D) الأمثل المستخدمة للتحكم في دورة عمل مبدل رافع للجهد المستمر، وهذا ما لا يمكن تحقيقه بكفاءة عالية باستخدام متحكم PI تقليدي. يمتاز المتحكم المطور في البحث، بتحقيق أداء ديناميكي جيد ودقة عالية في تتبع نقطة MPP بالإضافة لتحسين كفاءة نظام PV عند التغيرات الجوية المختلفة، مقارنة مع استخدام متحكم MPPT-ANN-PI المطور في المرجع [7]، المعتمد على استخدام شبكة عصبونية صناعية ومتحكم PI تقليدي، ومقارنة أيضاً مع متحكم تقليدي MPPT-P&O مرتكز على تقنية الاضطراب والمراقبة عند التغيرات الجوية المختلفة.

طرائق البحث ومواده

تعتمد نمذجة الشبكة العصبونية الصناعية ذات التغذية العكسية الأمامية FFNN، على استخدام توابع خاصة ببناء شبكة FFNN معرفة في مكتبة Neural Network Toolbox الموجودة في Matlab. كما يعتمد اختبار أداء وفعالية المتحكم MPPT-ANN المطور، على مقارنة نتائج المحاكاة المنجزة في بيئة Matlab/Simulink، مع تلك الناتجة باستخدام متحكم MPPT-ANN-PI ومتحكم MPPT-P&O تقليدي. بالإضافة لمقارنة نتائج عامل الكفاءة لنظام PV الناتج باستخدام كل من المتحكمات المذكورة مع حالة عدم استخدام متحكم MPPT أي حالة الوصل المباشر لحمل أومي مع نظام PV عند التغيرات الجوية الفجائية والسريعة.

الشبكة العصبونية الصناعية

تعرف الشبكة العصبونية الصناعية ANN، بأنها عبارة عن نظام لمعالجة البيانات بشكل يحاكي ويشابه الطريقة التي تقوم بها الشبكات العصبية عند الإنسان. حيث تتشابه الشبكة العصبية الصناعية مع الدماغ البشري في أنها تكتسب المعرفة بالتدريب، وتخزن هذه المعرفة باستخدام قوى وصل العصبونات (Neurons) والتي تسمى بالأوزان التشابكية. تربط الأوزان (Weights) العصبون في كل طبقة مع كل عصبون في الطبقة التالية، حيث يمكن تدريب الشبكة على إنجاز وظائف معينة من خلال ضبط قيم هذه الأوزان التشابكية. تتكون الشبكات العصبية ذات التغذية الأمامية FFNN من نظام من الخلايا العصبية، التي يتم ترتيبها في طبقات، حيث تتكون هذه الشبكات من طبقة على الأقل من الطبقات المخفية (Hidden Layer) فضلاً عن طبقة الدخل (Input Layer) وطبقة الخرج (Output Layer).


$$Y = f\left(\sum_{i=1}^n (W_{i1}X_i + b)\right) \quad (1)$$


الشكل (1) بنية العصبون.

يتضمن كل عصبون، وحدة معالجة تقوم بتحديد خرج العصبون من خلال تطبيق عمليتين حسابيتين متتاليتين كما هو موضح بالشكل (1)، تتضمن العملية الأولى، تحديد ناتج مجموع جداء متغيرات دخل الطبقة السابقة X_i بالأوزان التشابكية W_{i1} ، مضاف لها قيم الانزياح b لينتج في العملية الثانية تحديد خرج العصبون Y وذلك باستخدام ناتج العملية الأولى كمتغير لتابع تنشيط العصبون $f(.)$ كما هو موضح بالعلاقة (1).

بنية الشبكة العصبونية الصناعية ذات التغذية الأمامية FFNN المقترحة لتتبع نقطة MPP لنظام PV

تتكون بنية الشبكة العصبونية الصناعية ذات التغذية الأمامية FFNN المقترحة لتتبع نقطة MPP لنظام PV، من ثلاث طبقات: طبقة دخل، طبقة مخفية وطبقة خرج. تحوي طبقة الدخل على متغيري دخل، يمثل متغير الدخل الأول درجة حرارة الخلية الشمسية $T [^{\circ}C]$. بينما يمثل متغير الدخل الثاني شدة الإشعاع الشمسي $G [W/m^2]$. في حين، تحوي طبقة الخرج على عصبون واحد ممثل لخرج الشبكة VMPP والموافق لتوتر التشغيل الأمثل لنظام PV. أما عدد عصبونات الطبقة المخفية، حدد خلال عملية تدريب الشبكة بأربع عصبونات كما هو موضح بالشكل (2) الذي يبين بنية شبكة FFNN المقترحة لتتبع نقطة MPP لنظام PV.



الشكل (2) بنية الشبكة العصبونية الصناعية FFNN المقترحة لتتبع نقطة MPP لنظام PV.

لتقييم أداء الشبكة المدربة سنستخدم على دليل الأداء (Performance Index) الممثل لقيمة متوسط مربع الخطأ (Mean square error MSE) المحدد كما يلي:

$$MSE = \frac{1}{N} \sum_{j=1}^N (\widehat{VMPP}_j - VMPP_j)^2 \quad (2)$$

تمثل $VMPP_j$ و \widehat{VMPP}_j : القيم الحقيقية للخرج والقيم الناتجة عن الشبكة عند وحدة الإخراج على التوالي. حيث أن الأداء المثالي للشبكة المدربة يتوافق مع قيمة MSE أصغر من متناهية إلى الصفر. كما يمكن التحقق من أداء وموثوقية الشبكة، بتقييم قيمة معامل الارتباط R (Correlation Coefficient)، الذي يحدد دقة نموذج شبكة ANN الناتج، وذلك بمقارنة نتائج المخرجات الحقيقية والناتجة عن الشبكة. فعند اقتراب قيمة R من 1 يعني أن النموذج جيد، وعندما تكون قيمة R بالقرب من 0 تدل على أن النموذج الناتج للشبكة العصبونية غير جيد.

نمذجة شبكة FFNN المقترحة لتتبع نقطة MPP لنظام PV في Matlab

لتحقيق بناء نموذج شبكة FFNN المقترح بالشكل (2)، اعتمدنا على برمجة عملية بناء الشبكة في Matlab باستخدام تابع "newff" المستخدم لنمذجة شبكات FFNN، وباستخدام توابيع أخرى معرفة في مكتبة Neural Network Toolbox. حيث تتطلب ذلك تحديد ما يلي:

• إدخال بيانات يصل عددها إلى 300 عينة مرتبة على شكل مصفوفة، تمثل هذه البيانات قيم مختلفة لمتغيري دخل الشبكة، والموافقة لتغيرات درجة حرارة خلية الشمسية الواقعة ضمن المجال: $T = [0.65]^\circ\text{C}$ ، ولتغيرات مختلفة لشدة الإشعاع الشمسي $G = [200.1000]W/m^2$ ، بالإضافة لإدخال بيانات خرج الشبكة الممثلة لقيم VMPP الموافقة لكل من تغيرات T و G . حيث تم الحصول على قيم VMPP باعتبارها حلول المعادلة (4)، الناتجة باستخدام علاقة استطاعة نظام PV التالية:

$$= [I_p - I_0 (e^{\frac{V_{PV} + R_s * I_{PV}}{V_t a}} - 1) - \frac{V_{PV} + R_s * I_{PV}}{R_p}] * V_{PV} \quad (3)$$

$$\frac{dP_{PV}}{dV_{PV}} = 0 \quad (4)$$

يمثل $I_{PV}[A]$ ، $V_{PV}[A]$ تيار وتوتر خرج نظام PV على التوالي. يمثل $I_p[A]$ التيار الضوئي المتولد، $I_0[A]$ تيار الإشباع العكسي، $V_t = kTN_s/q$ الجهد الحراري، α عامل مثالية الديود. k ثابت بولتزمان، q شحنة الإلكترون، T درجة حرارة الخلية الشمسية. R_s المقاومة التسلسلية و R_p المقاومة التفرعية وتقاس بالأوم. • قُسمت البيانات المدخلة عشوائياً إلى ثلاث مجموعات هي: مجموعة التدريب، مجموعة التحقق ومجموعة الاختبار، وذلك بنسبة 70% لمجموعة التدريب وبنسبة 15% لمجموعتي التحقق والاختبار.

• تم اختيار تابع التدريب "trainlm"، الممثل لخوارزمية التدريب العكسي Marquardt Levenberg، التي تعتبر الأكثر انتشاراً واستخداماً في تدريب شبكات FFNN، لأنها تمتاز بسرعة عالية في الوصول إلى الحل الأمثل الموافق لتحقيق متوسط خطأ أصغري MSE. كما تم اعتماد تابع التفعيل سيغمويد (تابع الظل القطعي): "tansig" في الطبقة المخفية، وتابع التفعيل الخطي "purelin" في طبقة الخرج. • حُدد عدد العصبونات في الطبقة المخفية بالتجريب، وذلك بتغيير عدد عصبونات هذه الطبقة وتدريب الشبكة لغاية الحصول على معايير الأداء المثلى للشبكة المدربة.


تم اعتماد ثلاثة سيناريوهات لبناء الشبكة العصبونية، تحوي جميعها على طبقة دخل بمدخلين، وطبقة خرج بعصبون واحد بينما عدد عصبونات الطبقة المخفية، يختلف من اثنين إلى ثلاثة إلى أربعة، كما هو موضح بالجدول (1). كما تم الاعتماد على تقييم قيمة متوسط الخطأ MSE وقيم معامل الارتباط R في مرحلة التدريب والتحقق والاختبار، لاعتماد هيكلية الشبكة العصبونية FFNN النهائية المعتمدة في البحث.

الجدول (1) يوضح سيناريوهات الشبكة التي تم بناؤها مع قيم MSE و R في مرحلة التدريب والاختبار والتحقق.


هيكلية الشبكة	مرحلة التدريب training		مرحلة التحقق validation		مرحلة الاختبار testing	
	معامل الارتباط R	متوسط الخطأ MSE	معامل الارتباط R	متوسط الخطأ MSE	معامل الارتباط R	متوسط الخطأ MSE
2-2-1	0.99995	$8.0794 * 10^{-4}$	0.99998	$2.8192 * 10^{-4}$	0.99997	$7.5086 * 10^{-4}$
2-3-1	0.99998	$1.1542 * 10^{-5}$	0.9999	$1.4593 * 10^{-5}$	0.99998	$1.28121 * 10^{-5}$
2-4-1	1.000	$2.796 * 10^{-6}$	1.000	$3.0344 * 10^{-6}$	1.000	$3.0182 * 10^{-6}$

من الجدول (1)، يتضح أن الاستمرار بزيادة عدد عصبونات الطبقة المخفية سيؤدي إلى تحقيق قيمة أصغر لمتوسط مربع خطأ ، ولكنه يزيد من حجم وتعقيد الشبكة، لذلك نعتبر أن السيناريو الذي يعطي الشبكة المثالية هو الأخير، الذي يعطي أقل قيمة لمتوسط مربع خطأ MSE ، ويحقق قيمة مثلى لمعامل الارتباط R مساوية للواحد. وبالتالي النموذج الأمثل لشبكة FFNN يمتلك الهيكلية التالية: طبقة الدخل مؤلفة من دخلين، طبقة مخفية بأربع عصبونات، وطبقة خرج بعصبون واحد، كما هو موضح بالشكل (3) الذي يبين بنية الشبكة FFNN النهائية المستخدمة في البحث.

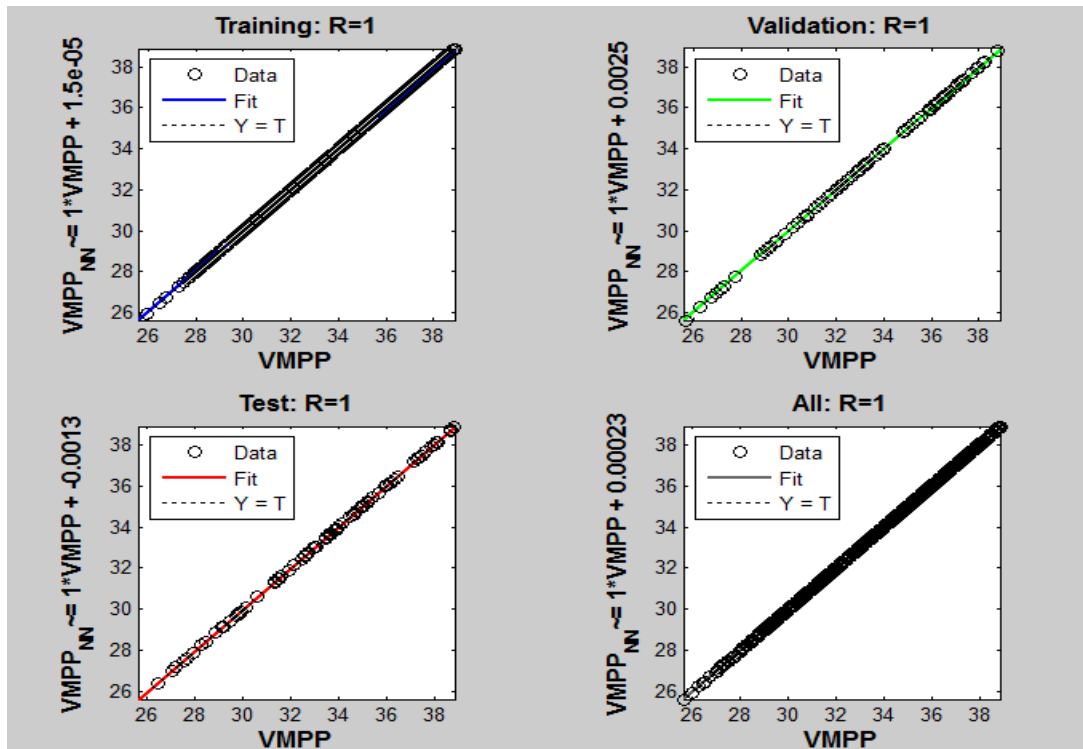
يظهر الشكل (4)، منحنى الأداء للشبكة العصبونية الموافق للسيناريو الأخير، حيث يتضمن الشكل المذكور أربعة منحنيات: منحنى عملية التدريب (Train)، منحنى صلاحية الشبكة العصبونية أي التحقق (Validation)، منحنى عملية الاختبار (Test)، ومنحنى القيم الأفضل (Best). نرى من خلال الشكل أن المنحنيات جميعها تقاربت إلى قيمة متوسط مربع الخطأ ، $MSE = 3.0345 * 10^{-6}$ عند التكرار (Epochs) 1000. بينما يظهر الشكل (5)، قيمة معاملات الارتباط R للمجموعات الثلاث (التدريب-التحقق-الاختبار) مساوية للواحد، وهذا يظهر دقة نموذج FFNN الناتج، كما يظهر العلاقة الخطية بين قيم الخرج النظرية وتلك الناتجة عن الشبكة. بعد انتهاء عملية تدريب الشبكة والحصول على النموذج الأمثل لها، نعتمد الأوزان والانزياحات الناتجة في هذه المرحلة، ليتم استخدامها في محاكاة شبكة FFNN في بيئة Matlab/Simulink. وبذلك نحصل على النموذج النهائي لشبكة FFNN المطور في بيئة Matlab/Simulink والممثل بالمخطط الصندوقي الموضح بالموضح بالشكل (7). تمثل كل من $LW_{\{2,1\}}$ ، $IW_{\{1,1\}}$ مصفوفة الأوزان عبر الارتباطات من طبقة الدخل إلى عصبونات الطبقة المخفية، ومصفوفة الأوزان عبر الارتباطات من عصبونات الطبقة المخفية إلى عصبون طبقة الخرج على التوالي. أما $b_{\{2\}}$ ، $b_{\{1\}}$ فتمثل مصفوفات الانزياحات. كما يبين الشكل اعتماد تابع التفعيل سيغمويد "tansig" في الطبقة المخفية، وتابع "purelin" في طبقة الخرج.



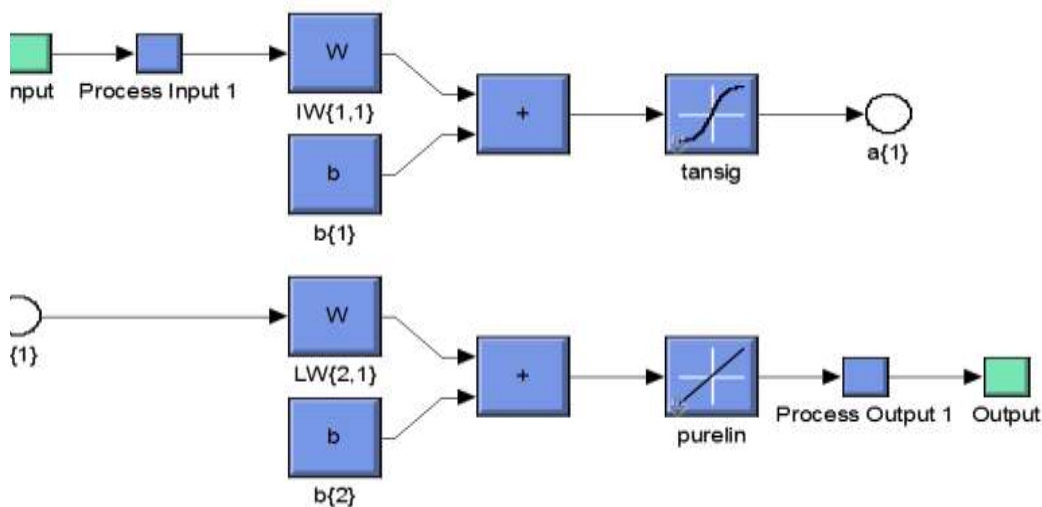
الشكل (3) بنية الشبكة FFNN النهائية المعتمدة في بيئة Matlab.




الشكل (4) منحنى الأداء للشبكة العصبونية FFNN للمجموعات الثلاث (التدريب-التحقق-الاختبار).



الشكل (5) معاملات الارتباط للمجموعات الثلاث (التدريب-التحقق-الاختبار).



الشكل (6) محاكاة شبكة FFNN في بيئة Matlab/Simulink.



الشكل (7) نموذج شبكة التغذية الأمامية FFNN المطور في بيئة Matlab/Simulink.

خوارزمية التحكم المباشر المقترحة لتحديد نسبة التشغيل المرتكزة على خرج شبكة FFNN

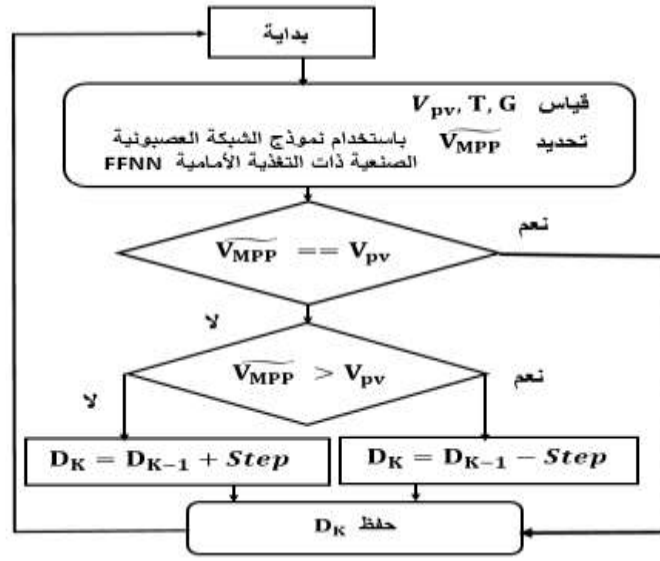
لتحقيق عمل المتحكم MPPT في تتبع نقطة MPP لنظام PV، يجب تحديد نسبة التشغيل المستخدمة للتحكم

في دورة عمل مبدل جهد مستمر، عند التغيرات الجوية المختلفة. لهذا الغرض، اقترحنا خوارزمية تحكم، تمكننا من

تحديد نسبة التشغيل بالاعتماد على مقارنة توتر خرج نظام PV مع توتر التشغيل الأمثل \widehat{V}_{MPP} الناتج من نموذج

الشبكة العصبونية FFNN استجابة لتغيرات كل من T و G ، لتيم بناء على ذلك تحديد قيمة نسبة التشغيل $D(k)$

وذلك بزيادة أو انقاص قيمة نسبة التشغيل السابقة $D(k-1)$ بمقدار محدد ثابت $Step$.



الشكل (8) خوارزمية التحكم المقترحة لتحديد نسبة التشغيل بالاعتماد على التوتر الأمثل $\widetilde{V_{MPP}}$ خرج شبكة FFNN.

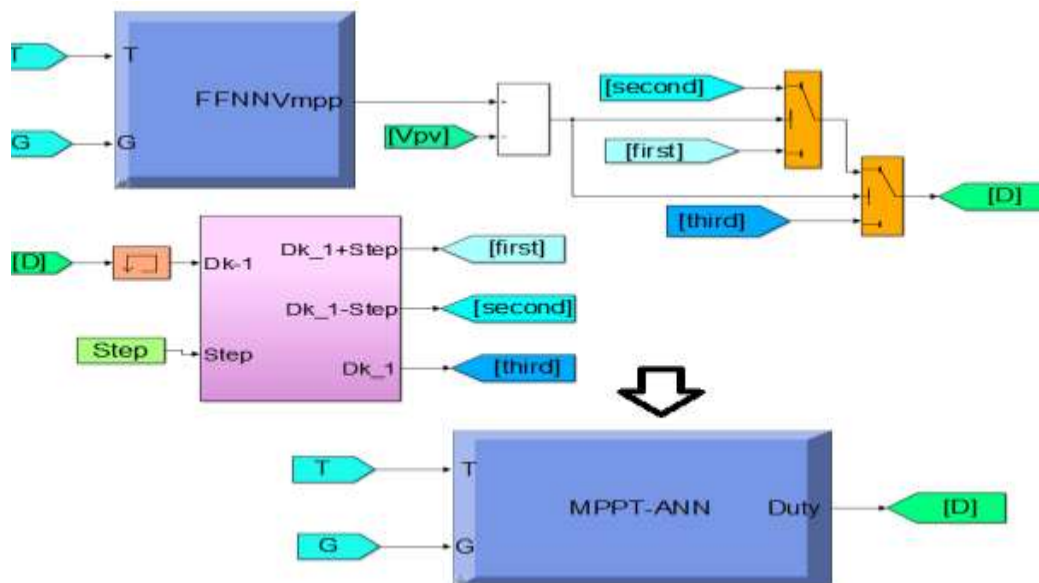
يعتمد تحقيق عمل المتحكم MPPT، في البحث على مبدل رافع للجهد المستمر، يقوم هذا المبدل برفع توتر الدخل V_{pv} الممثل لتوتر خرج النظام PV إلى توتر الحمل V_{out} بالاعتماد على نسبة التشغيل D المحددة بالعلاقة التالية:

$$D = 1 - \frac{V_{pv}}{V_{out}}$$


تعتبر D عدد لا بعدي، يمثل نسبة تشغيل ترانزستور مبدل الجهد، الناتجة من نسبة الزمن الذي يكون الترانزستور مغلقاً إلى زمن الدور. يقاس كل من التوتر V_{pv} و V_{out} بالفولت [V].

محاكاة متحكم MPPT-ANN ومتحكم P&O في بيئة Matlab/Simulink

يبين الشكل (9)، محاكاة متحكم تتبع نقطة MPP لنظام PV، MPPT-ANN المرتكز على شبكة FFNN باستخدام طريقة التحكم المباشر المطبقة بالاعتماد على خوارزمية التحكم الموضحة بالشكل (8)، المستخدمة لضبط V_{pv} توتر خرج نظام PV عند التوتر الأمثل $\widetilde{V_{MPP}}$ خرج شبكة FFNN، ليتم تحديد قيمة تحديد نسبة التشغيل المناسبة $D(k)$ للتحكم في دورة عمل المبدل رافع الجهد المستمر.



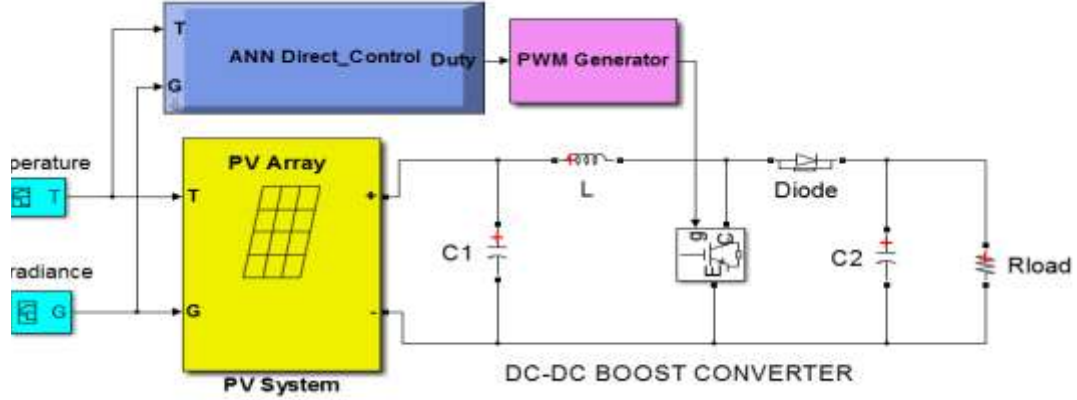
الشكل (9) محاكاة متحكم MPPT مرتكز على شبكة FFNN باستخدام طريقة التحكم المباشر في بيئة Matlab/Simulink. كما يبين الشكل (10)، محاكاة المتحكم MPPT-P&O المرتكز على تقنية الاضطراب والمراقبة P&O المباشرة. تعتمد تقنية P&O المباشرة على تحديد نسبة التشغيل $D(k)$ ، بالاعتماد على تحديد نوع إشارة كل من تغيرات الاستطاعة ΔP وتغيرات التوتر ΔV لخرج النظام PV، ليتم تحديد زيادة أو تخفيض قيمة نسبة التشغيل في الخطوة السابقة $D(k-1)$ بمقدار محدد ثابت $Step$.



الشكل (10) محاكاة متحكم MPPT-P&O باستخدام طريقة التحكم المباشر في بيئة Matlab/Simulink.

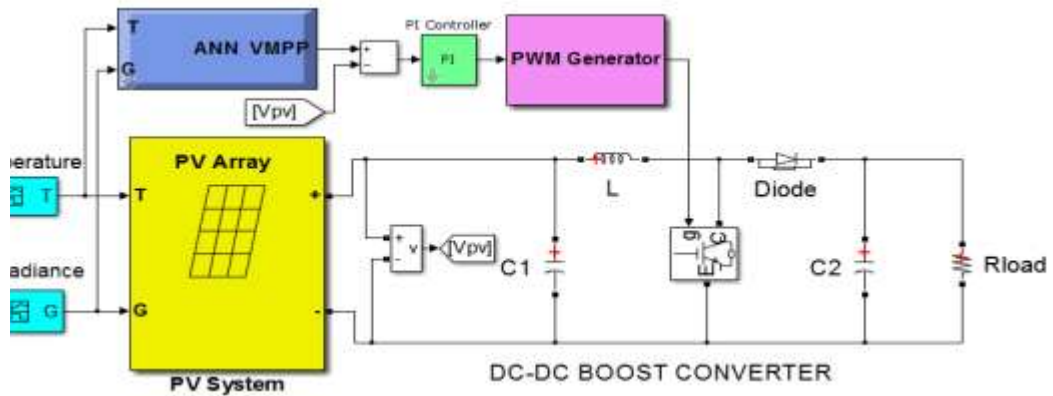
محاكاة نظام تتبع نقطة MPP باستخدام متحكم MPPT-ANN ومتحكم MPPT--PI ANN ومتحكم MPPT-P&O في بيئة Matlab/Simulink

يعتمد فحص واختبار فعالية أداء المتحكم MPPT-ANN، على نموذج المحاكاة لنظام تتبع نقطة MPP لنظام PV المنجز في بيئة Matlab/Simulink والموضح بالشكل (11). يتكون النظام بالإضافة للمتكم MPPT-ANN من نظام PV ، مبدل رافع للجهد المستمر (DC-DC Boost Converter).




الشكل (11) محاكاة نظام تتبع نقطة MPP لنظام PV، مركّز على متحكم ANN المطور في بيئة Matlab/Simulink.

أما الشكل (12)، يبين المحاكاة مع متحكم MPPT-ANN-PI المعتمد على شبكة عصبونية صناعية لتحديد توتر التشغيل الأمثل VMPP الذي يتم مقارنته مع توتر خرج النظام PV لتحديد الخطأ الممثل كمدخل لمتحكم PI تقليدي. بناء على ذلك، يقوم المتحكم PI بتوليد إشارة النبضة المستخدمة للتحكم في عمل ترانزستور مبدل الجهد كما هو موضح في المرجع [7]. كذلك يبين الشكل (13) المحاكاة الناتجة مع متحكم MPPT-P&O.



الشكل (12) محاكاة نظام تتبع نقطة MPP لنظام PV، مركّز على متحكم MPPT-ANN-PI في بيئة Matlab/Simulink.



الشكل (13) محاكاة نظام تتبع نقطة MPP لنظام PV، مرتكز على متحكم MPPT-P&O في بيئة Matlab/Simulink.

النتائج والمناقشة

يمكن الحصول على قيم توتر التشغيل الأمثل \widehat{V}_{MPP} الموافقة لتوتر نقطة MPP عند التغيرات الجوية المختلفة باستخدام نموذج شبكة FFNN الموضح بالشكل (7). يبين الجدول (2) مقارنة قيم \widehat{V}_{MPP} خرج شبكة FFNN مع القيم النظرية V_{MPP} الناتجة عند تغيرات مختلفة لشدة الإشعاع الشمسي $G [W/m^2]$ مع ثبات درجة حرارة الخلية الشمسية $T = 25[^\circ C]$. أما الجدول (3)، يبين المقارنة عند تغيرات مختلفة لدرجة حرارة الخلية الشمسية مع ثبات قيمة شدة الإشعاع الشمسي $G = 800 [W/m^2]$. كما تظهر نتائج الجدول (2) و(3)، أن قيم قيمة متوسط مربع الخطأ MSE متناهية في الصغر، مما يعني تقارب قيم \widehat{V}_{MPP} الناتجة مع القيم النظرية، وهذا يعكس دقة نموذج شبكة FFNN المعتمد في تقدير قيم \widehat{V}_{MPP} بدقة كبيرة. وبذلك، يمكن اعتبار نموذج شبكة FFNN عبارة عن نموذج رياضي لتقدير قيمة \widehat{V}_{MPP} عند أي تغيرات جوية بدقة وبسرعة فائقة.

الجدول (2) قيم التوتر الأمثل النظري V_{MPP} وتوتر التشغيل الأمثل \widehat{V}_{MPP} خرج شبكة FFNN وقيمة MSE عند تغيرات مختلفة لشدة الإشعاع الشمسي G مع ثبات درجة حرارة الخلية الشمسية $T = 25[^\circ C]$.


شدة الإشعاع الشمسي [W/m ²]	توتر الأمثل V _{MPP} النظري [V]	توتر الأمثل خرج شبكة FFNN V _{MPP} [V]	(V _{MPPj} - V _{MPPj}) ²
1000	34.50	34.4976	0.0058* 10 ⁻³
900	34.3649	34.3368	0.7896* 10 ⁻³
800	34.1319	34.1438	0.1416* 10 ⁻³
700	33.9043	33.9068	0.0062* 10 ⁻³
600	33.6100	33.6119	0.0036* 10 ⁻³
500	33.2400	33.2395	0.0003* 10 ⁻³
400	32.7550	32.7559	0.0008* 10 ⁻³
$MSE = \frac{1}{N} \sum_{j=1}^N (V_{MPPj} - \widehat{V}_{MPPj})^2 = 1.3541 * 10^{-4}$			

الجدول (3) قيم التوتر الأمثل النظري $VMPP$ وتوتر التشغيل الأمثل \widehat{VMPP} خرج شبكة FFNN وقيمة MSE عند تغيرات مختلفة لدرجة حرارة الخلية الشمسية T مع ثبات شدة الإشعاع الشمسي $G = 800 [W/m^2]$.


درجة حرارة الخلية الشمسية [°C]	VMPP النظرية [V]	\widehat{VMPP} توتر الأمثل خرج شبكة FFNN [V]	$(\widehat{VMPP}_j - VMPP_j)^2$
25	34.1319	34.1438	$0.1416 * 10^{-3}$
30	33.3877	33.4101	$0.5018 * 10^{-3}$
35	32.6992	32.6790	$0.4080 * 10^{-3}$
40	31.9422	31.9507	$0.0723 * 10^{-3}$
45	31.2286	31.2251	$0.0122 * 10^{-3}$
50	30.4982	30.5024	$0.0176 * 10^{-3}$
55	29.7774	29.7825	$0.0260 * 10^{-3}$

$MSE = \frac{1}{N} \sum_{j=1}^N (\widehat{VMPP}_j - VMPP_j)^2 = 1.6851 * 10^{-4}$ قيمة متوسط مربع الخطأ

قبل عرض نتائج المحاكاة الناتجة باستخدام المتحكم MPPT-ANN، يمكن دراسة تغير الاستطاعة النظرية العظمى P_{MPP} لنظام PV، مع تغير شدة الإشعاع الشمسي G ودرجة حرارة الخلية الشمسية T . حيث تزداد الاستطاعة النظرية P_{MPP} بزيادة G عند ثبات درجة الحرارة T كما هو موضح بالشكل (14). بينما تتناقص الاستطاعة P_{MPP} مع زيادة T وثبات قيمة G كما هو موضح بالشكل (15). يتكون النظام PV المدروس من 72 خلية شمسية موصولة على التسلسل للحصول على الاستطاعة الكلية للنظام $P_{MPP} = 150 [W]$ والمحددة عند الشروط القياسية النظامية $G = 1000 [W/m^2]$, $T = 25 [°C]$.



الشكل (14) منحنى الخصائص المميزة (P-V) للنظام PV عند تغير شدة الإشعاع الشمسي ودرجة حرارة ثابتة.

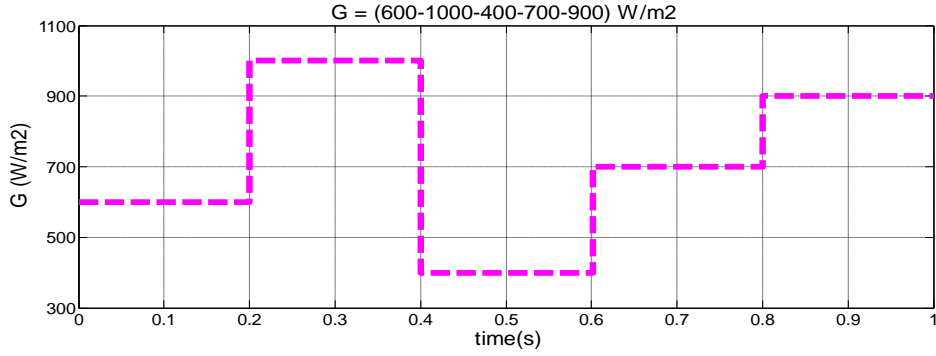


الشكل (15) منحنى الخصائص المميزة (P-V) للنظام PV عند تغير درجة الحرارة وشدة إشعاع شمسي ثابتة.

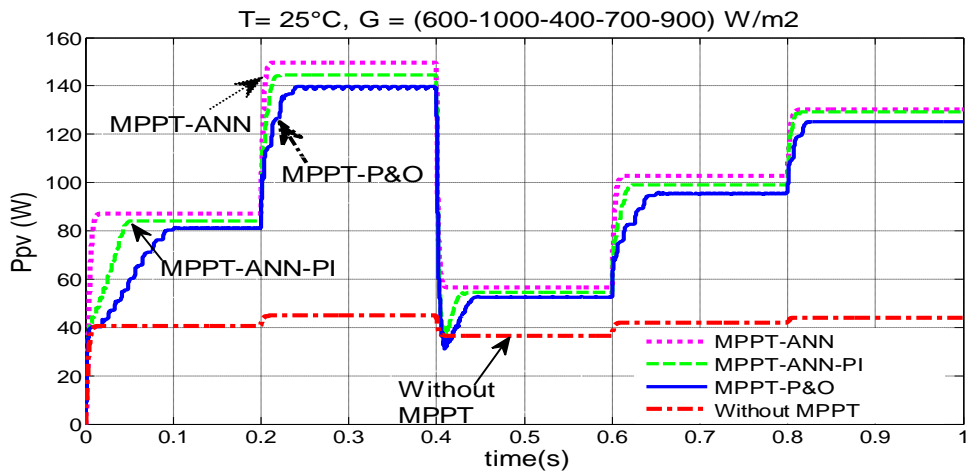
مقارنة أداء المتحكم المطور MPPT-ANN مع المتحكم MPPT-ANN-PI والمتحكم

التقليدي MPPT-P&O:


لتقييم أداء المتحكم المطور في البحث، نعد الآن إلى مقارنة نتائج المحاكاة مع تلك الناتجة باستخدام المتحكم MPPT-ANN-PI المطور في المرجع [7]، ومع حالة استخدام المتحكم التقليدي MPPT-P&O. نعرض فيما يلي نتائج المحاكاة الناتجة عند اعتبار ثبات درجة حرارة الخلية الشمسية $T = 25[^\circ\text{C}]$ ، ومع افتراض تغيرات لشدة الإشعاع الشمسي: $G = 600 - 100 - 400 - 700 - 900 [W/m^2]$ ، موضحة بالشكل (16). كما يظهر من الشكل (17)، أن استطاعة خرج النظام PV الناتجة عند التغيرات المختلفة لشدة الإشعاع الشمسي، هي أكبر باستخدام المتحكم المطور MPPT-ANN مقارنة مع استخدام كل من المتحكم المرجعي MPPT-ANN-PI والمتحكم MPPT-P&O، ومقارنة مع حالة الوصل المباشر للنظام PV مع الحمل أي دون استخدام متحكم MPPT (Without MPPT). من جهة أخرى، يظهر المتحكم MPPT-ANN تحقيق سلوك حالة عابرة أفضل لنظام PV عند تتبع نقطة MPP، حيث يلاحظ سرعة عالية في الوصول لقيمة MPP الجديدة عند التغيرات الجوية المفاجئية السريعة الموافقة للانتقال من شروط سوية إشعاع شمسي إلى أخرى، مقارنة مع استخدام كل من MPPT-ANN-PI و MPPT-P&O. يعود ذلك لدقة وسرعة المتحكم MPPT-ANN في تحديد نسبة التشغيل مقارنة مع كل من المتحكم MPPT-ANN-PI و MPPT-P&O كما هو موضح بالشكل (18). مما نتج عنه التحكم الفعال في دورة عمل مبدل رافع الجهد لتحقيق عمل نظام PV عند نقطة MPP بدقة كبيرة استجابة للتغيرات في شدة الإشعاع الشمسي.



الشكل (16) تغيرات شدة الإشعاع الشمسي.

الشكل (17) استطاعة خرج نظام PV عند شروط تغير شدة الإشعاع الشمسي ودرجة حرارة ثابتة. η_{PV} لنظام PV

المبينة في الجدول (4)، والناجمة بقسمة استطاعة خرج نظام PV الناتجة عند الحالة المستقرة الثابتة على الاستطاعة النظرية العظمى P_{MPP} الناتجة عند نفس الشروط الجوية. فمن الجدول (4) نلاحظ أن النظام PV يمتلك عامل كفاءة أعلى باستخدام متحكم MPPT-ANN مقارنة مع استخدام المتحكم MPPT-ANN-PI و MPPT-P&O ومع حالة عدم استخدام متحكم Without MPPT.




الشكل (18) تغير نسبة التشغيل D عند شروط تغير شدة الإشعاع الشمسي ودرجة حرارة ثابتة.

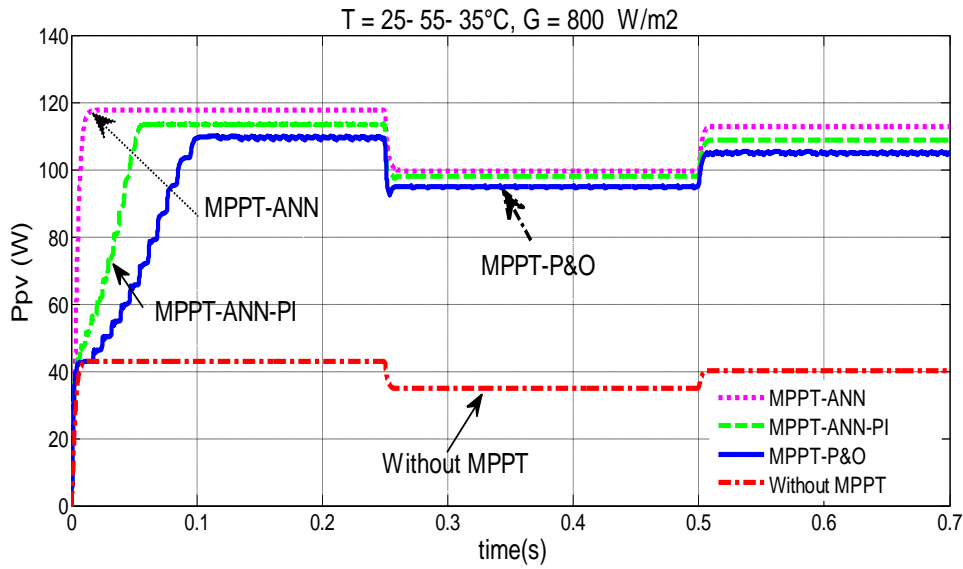
الجدول (4) عامل كفاءة نظام PV عند الحالة المستقرة مع متحكم MPPT-ANN، MPPT-ANN-PI، MPPT-P&O ودون متحكم MPPT عند مستويات مختلفة للإشعاع الشمسي

شدة الإشعاع الشمسي [W/m ²]	η_{pv} MPPT-ANN	η_{pv} MPPT-ANN-PI	η_{pv} MPPT-P&O	η_{pv} Without MPPT
1000	0.9980	0.9626	0.9387	0.2991
900	0.9952	0.9607	0.9379	0.3272
700	0.9941	0.9588	0.9260	0.4007
600	0.9933	0.9582	0.9119	0.4625
400	0.9911	0.9562	0.9391	0.6433


نفترض الآن شروط جوية أخرى موافقة لتغيرات لدرجة حرارة الخلية الشمسية T مع ثبات شدة الإشعاع الشمسي $G = 800 [W/m^2]$ مع تغيرات لدرجة الحرارة $T = 25 - 55 - 35 [^{\circ}C]$ كما هو موضح بالشكل (19). كما هو موضح بالشكل (20)، يحقق المتحكم MPPT-ANN أداءً ديناميكيًا أفضل لنظام PV، حيث يتقارب منحنى الاستطاعة بزمن أقل بكثير نحو قيم P_{MPP} مقارنة مع استخدام المتحكم MPPT-ANN-PI و MPPT-P&O. كما يبدي المتحكم MPPT-ANN سرعة استجابة أفضل للتغيرات في درجة الحرارة للوصول بسرعة فائقة نحو قيم نسبة التشغيل المثلى D_{MPP} كما هو مبين في الشكل (21). كما تبين نتائج الجدول (5)، يحقق المتحكم MPPT-ANN عامل كفاءة أفضل لنظام PV عند شروط ثبات شدة الإشعاع الشمسي $G = 800 [W/m^2]$ مع تغيرات مختلفة لدرجة حرارة الخلية الشمسية $T = 25 - 55 - 35 [^{\circ}C]$ مقارنة مع استخدام MPPT-ANN-PI و MPPT-P&O ومن دون استخدام متحكم MPPT.



الشكل (19) تغيرات درجة الحرارة.



الشكل (20) استطاعة خرج نظام PV عند تغير درجة الحرارة وشدة إشعاع شمسي ثابتة.



الشكل (21) تغير نسبة التشغيل D عند تغير درجة الحرارة وشدة إشعاع شمسي ثابتة.

الجدول (5) عامل كفاءة نظام PV عند الحالة المستقرة مع متحكم MPPT-P&O·MPPT-ANN-PI·MPPT-ANN

ودون متحكم MPPT عند $G = 800 [W/m^2]$ و عند تغير درجة الحرارة.

25	0.9890	0.9545	0.9310	0.3621
35	0.9915	0.9564	0.9159	0.3534
55	0.9825	0.9488	0.8841	0.3361

الاستنتاجات والتوصيات:

- تم في هذا البحث العمل على تطوير متحكم MPPT-ANN مركب على شبكة عصبونية صناعية ذات تغذية أمامية FFNN وعلى طريقة التحكم المباشر لتتبع نقطة MPP لنظام PV في بيئة Matlab/Simulink. كما تم اختبار فعالية وأداء المتحكم المطور MPPT-ANN، مقارنة مع استخدام كل من المتحكم MPPT-ANN-PI و MPPT-P&O. بناء على ذلك تم الوصول إلى الاستنتاجات التالية:
- أظهر نموذج شبكة FFNN المعتمد في البحث، سرعة فائقة ودقة كبيرة في تقدير قيمة توتر التشغيل الأمثل عند التغيرات المختلفة لشدة الإشعاع الشمسي ودرجة الحرارة.
- أظهر المتحكم MPPT-ANN، المعتمد على خوارزمية التحكم المباشر المقترحة، دقة وسرعة فائقة في تحديد قيم نسبة التشغيل المثلى المستخدمة للتحكم في دورة عمل مبدل رافع للجهد المستمر، مقارنة مع المتحكم MPPT-ANN-PI وذلك يعود للاستغناء عن استخدام المتحكم PI الذي لا يبدي أداء جيد عند التحكم بالنظم اللاخطية.
- حقق استخدام المتحكم MPPT-ANN المطور عامل كفاءة أفضل لنظام PV عند التغيرات الجوية السريعة، مقارنة مع المتحكم MPPT-ANN-PI و MPPT-P&O.
- يتجلى الأداء الأفضل للمتحكم MPPT-ANN، من جهة بتحقيق أداء ديناميكي جيد لنظام PV وذلك بتحقيق سرعة تقارب عالية نحو نقطة MPP المتغيرة استجابة للتغيرات الجوية، ومن جهة أخرى، بتخفيض قيمة خطأ الحالة المستقرة مما نتج عنه ضبط استطاعة النظام PV عند قيم الاستطاعة النظرية العظمى.
- يتسم تصميم المتحكم MPPT-ANN المطور، بالبساطة والسهولة حيث يمكن بناء متحكم ANN بسهولة في حال توفر بيانات تدريب كافية، وبالاختيار الصحيح لهيكلية الشبكة العصبونية الصناعية، المحققة لمعايير الأداء الجيد من متوسط خطأ أصغري وقيمة لمعامل الارتباط مساوية للواحد.
- أوضحت نتائج المحاكاة صحة ودقة تصميم المتحكم المطور MPPT-ANN. حيث توافقت استجابة النظام PV مع الاستجابة المرغوبة المتوقعة باستخدام المتحكم MPPT-ANN عند كل التغيرات الجوية.
- يمكن استكمال العمل باستخدام تقنيات تحكم متقدمة أخرى كالتحكم باستخدام المنطق الضبابي والخوارزميات الجينية، ومقارنة نتائج هذه التقنيات مع التقنيات المستخدمة في هذا البحث.

المراجع:

- [1] DOLARA, A.; FARANDA, R; LEVA, S. *Energy Comparison of Seven MPPT Techniques for PV Systems*. Journal of Electromagnetic Analysis and Applications. 1, 2009, 152-162.
- [2] GAIKWAD, D.; CHAVAN, M. *A Novel Algorithm for MPPT for PV Application System by use of Direct Control Method*. International Journal of Computer Applications. 109, 2015, 10-15.
- [3] GAIKWAD, D.; CHAVAN, M. *Implementation of DC-DC Converter for MPPT by Direct Control Method*. International Journal of Engineering and Technical Research. 3, 2014, 1244-1248.
- [4] CHEIKH, M.; LARBES, C.; TCHOKETCHT, G.; ZERGUERRASZ, A. *Maximum power point tracking using a fuzzy logic control scheme*. Revue des Energies Renouvelables 10, 2007, 387 – 395.

[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] MAKHLOUFI, T.; KHIREDDINE, S.; ABDESSEMED, Y.; BOUTARFA, A. . *Tracking Power Photovoltaic System using Artificial Neural Network Control Strategy*. Intelligent Systems and Applications 12, 2014, 17-26.

[7] ELGHARBI, A.; MEZGHANI, D.; MAMI, A. *A Maximum Power Point Tracking Method Based on Artificial Neural Network for a PV System*. International Journal of Advances in Engineering & Technology 5, 2012, 130-140.