



الجمهورية الديمقراطية الشعبية الجزائرية

وزارة التعليم العالي والبحث العلمي

جامعة الشهيد حمه لخضر الوادي

كلية التكنولوجيا

مذكرة تخرج لنيل شهادة

ماستر أكاديمي

ميدان: العلوم والتكنولوجيا

شعبة: هندسة كهربائية

تخصص: شبكات كهربائية

من اعداد الطلبة:

رويسي عبد العزيز

لعويد خالد

تحت إشراف الأستاذ:

الربي ياسين

الموضوع

تحسين تتبع نقطة القدرة العظمى MPPT في الأنظمة الكهروضوئية باستخدام
الشبكات العصبية الاصطناعية ANNs

نوقشت في: 2026/06/14

أمام لجنة المناقشة:

رئيسا

مؤطرا

ممتحنا

الأستاذ الدكتور: نورالدين بركة

الأستاذ الدكتور: الربي ياسين

الأستاذ الدكتور: معمر اسامة

الموسم الجامعي: 2026/2025

الشكر والعرفان

نتقدم بخالص الشكر والتقدير وعظيم الامتنان إلى المشرف الدكتور لبي ياسين، على توجيهاته القيّمة، ودعمه المستمر، وملاحظاته العلمية البناءة طوال مراحل إعداد هذه المذكرة. لقد كان لخبرته الأكاديمية وتشجيعه الدائم أثرٌ بالغ في إنجاز هذا العمل وإتمامه على الوجه المطلوب.

كما نتشرف بتقديم جزيل الشكر والامتنان إلى السادة أعضاء لجنة المناقشة المحترمين، لتفضلهم بقبول مناقشة هذه المذكرة، ولما سيقدمونه من ملاحظات وتوجيهات قيّمة من شأنها إثراء هذا العمل وتحسينه.

ونتوجه كذلك بخالص الشكر إلى أساتذة وموظفي قسم الهندسة كهربائية، كلية التكنولوجيا، بجامعة الشهيد حمة لخضر – الوادي، على ما قدموه من دعم أكاديمي ومعرفي طيلة سنوات الدراسة.

كما نتوجه بالشكر إلى كل من قدم لنا المساعدة أو الدعم بأي شكل من الأشكال خلال فترة إنجاز هذه المذكرة.

الملخص

تهدف هذه المذكرة إلى تحسين تتبع نقطة القدرة العظمى في الأنظمة الكهروضوئية باستعمال الشبكات العصبية الاصطناعية، وذلك من أجل رفع كفاءة استخراج الطاقة من اللوح الشمسي تحت ظروف تشغيل متغيرة. تنطلق الدراسة من كون النظام الكهروضوئي يتميز بسلوك كهربائي غير خطي، حيث تتغير نقطة القدرة العظمى تبعاً لتغير شدة الإشعاع الشمسي ودرجة حرارة الخلايا، إضافة إلى تأثير التظليل الجزئي والحمل الكهربائي. لذلك، فإن تشغيل النظام عند نقطة ثابتة لا يضمن دائماً الحصول على أكبر قدرة ممكنة.

تم في الجانب التطبيقي بناء نموذج للنظام الكهروضوئي في بيئة MATLAB/Simulink، ثم اعتماد سيناريوهات مختلفة للإشعاع الشمسي ودرجة الحرارة من أجل توليد قاعدة بيانات تدريبية. استُعملت قيم الجهد V_{pv} والتيار I_{pv} كمداخلات للشبكة العصبية، بينما استُعملت دورة العمل المرجعية D_{ref} ، الناتجة عن خوارزمية P&O، كمخرج تدريبي. بعد ذلك، تم تدريب الشبكة العصبية وإدماجها داخل نموذج المحاكاة لإنتاج دورة العمل D_{ANN} والتحكم في المحول الرفع عبر إشارة PWM.

أظهرت نتائج التدريب والمحاكاة أن المتحكم العصبي المقترح قادر على تقريب دورة العمل المرجعية بدقة عالية، وتحقيق توافق واضح بين خرج الشبكة D_{ANN} والقيم المرجعية D_{ref} . كما بينت النتائج أن استعمال الشبكة العصبية في MPPT يسمح بتحسين استقرار القدرة المستخرجة وتقليل التذبذبات مقارنة بالطريقة التقليدية، مع قدرة أفضل على التكيف مع تغيرات الإشعاع والحرارة. وبذلك تؤكد الدراسة أن الشبكات العصبية الاصطناعية تمثل حلاً فعالاً لتحسين أداء أنظمة تتبع نقطة القدرة العظمى في الأنظمة الكهروضوئية.

الكلمات المفتاحية: الأنظمة الكهروضوئية، تتبع نقطة القدرة العظمى، MPPT، الشبكات العصبية الاصطناعية، ANN، خوارزمية P&O، MATLAB/Simulink، دورة العمل.

Abstract

This thesis aims to improve maximum power point tracking in photovoltaic systems using artificial neural networks in order to increase the efficiency of energy extraction under varying operating conditions. Photovoltaic systems exhibit nonlinear electrical behavior, as the maximum power point changes with solar irradiance, cell temperature, partial shading, and electrical load. Therefore, operating the system at a fixed point does not ensure maximum power extraction.

A photovoltaic system was modeled in MATLAB/Simulink, and different irradiance and temperature scenarios were used to generate the training dataset. The photovoltaic voltage V_{pv} and current I_{pv} were used as neural network inputs, while the reference duty cycle D_{ref} , obtained from the P&O algorithm, was used as the target output. The trained neural network was then integrated into the simulation model to generate the duty cycle D_{ANN} and control the boost converter through a PWM signal.

Training and simulation results showed that the proposed neural controller accurately approximates the reference duty cycle, with strong agreement between D_{ANN} and D_{ref} . The ANN-based MPPT method also improves the stability of the extracted power, reduces oscillations compared with the conventional method, and provides better adaptation to irradiance and temperature variations. These results confirm the effectiveness of artificial neural networks in improving the performance of photovoltaic MPPT systems.

Keywords: Photovoltaic systems, maximum power point tracking, MPPT, artificial neural networks, ANN, P&O algorithm, MATLAB/Simulink, duty cycle.

قائمة الاختصارات والرموز

■ قائمة الاختصارات:

- PV: النظام الكهروضوئي، ويقصد به تحويل الإشعاع الشمسي إلى طاقة كهربائية.
- MPPT: تتبع نقطة القدرة العظمى، وهي تقنية تستعمل للحصول على أكبر قدرة ممكنة من اللوح الشمسي.
- MPP: نقطة القدرة العظمى، وهي النقطة التي يعطي فيها اللوح أكبر استطاعة.
- ANN: الشبكة العصبية الاصطناعية، وهي تقنية ذكية تتعلم من البيانات وتستعمل لتحسين أداء التتبع.
- MPPT-ANN: متحكم تتبع نقطة القدرة العظمى باستعمال الشبكة العصبية الاصطناعية.
- P&O: خوارزمية الاضطراب والمراقبة، وهي خوارزمية تقليدية استعملت في هذه المذكرة كمرجع لتوليد البيانات.
- DC: تيار مستمر.
- DC-DC: محول مستمر-مستمر، يستعمل لتغيير قيمة الجهد والتحكم في نقطة تشغيل النظام.
- Boost Converter: محول رافع للجهد، يرفع جهد الخرج مقارنة بجهد الدخل.
- PWM: إشارة تعديل عرض النبضة، وتستعمل للتحكم في عمل المحول الإلكتروني.
- MATLAB/Simulink: برنامج وبيئة محاكاة استعمالاً لنمذجة النظام الكهروضوئي وتدريب المتحكم العصبي.
- MSE: متوسط مربع الخطأ، وهو مؤشر يستعمل لتقييم دقة تدريب الشبكة العصبية.
- MAE: متوسط الخطأ المطلق، وهو مؤشر يبين مقدار الخطأ بين القيم المتوقعة والقيم المرجعية.
- R: معامل الارتباط، يستعمل لقياس مدى توافق خرج الشبكة مع القيم المرجعية.
- Overfitting: الإفراط في التعلم، يحدث عندما تحفظ الشبكة بيانات التدريب بدل تعلم العلاقة العامة.

■ قائمة الرموز:

V_{pv} : جهد اللوح الكهروضوئي.

I_{pv} : تيار اللوح الكهروضوئي.

P_{pv} : القدرة المنتجة من اللوح الكهروضوئي.

D : دورة العمل أو معامل التشغيل الخاص بالمحول.

D_{ref} : دورة العمل المرجعية المستخرجة من خوارزمية O&P.

D_{ANN} : دورة العمل الناتجة عن الشبكة العصبية الاصطناعية.

D_{po} : دورة العمل الناتجة عن خوارزمية P&O.

V : الجهد الكهربائي.

I : التيار الكهربائي.

P_{max} : القدرة العظمى الممكن استخراجها من النظام.

I_{ph} : التيار الضوئي الناتج عن الإشعاع الشمسي.

I_d : تيار الصمام الثنائي.

I_{sh} : تيار التسرب عبر المقاومة التفرعية.

R_s : المقاومة التسلسلية داخل الخلية.

R_p : المقاومة التفرعية داخل الخلية.

I_{sc} : تيار القصر.

V_{oc} : جهد الدارة المفتوحة.

I_{mp} : التيار عند نقطة القدرة العظمى.

V_{mp} : الجهد عند نقطة القدرة العظمى.

G : شدة الإشعاع الشمسي.

X : متجه إدخال الشبكة العصبية، ويتكون من V_{pv} و I_{pv} .

η : كفاءة التحويل الطاقوي للنظام.

فهرس المحتويات

IV	المخلص
V	Abstract
V	قائمة الاختصارات والرموز
1	المقدمة العامة
6	الفصل الأول: الأسس النظرية والنمذجة الكهربائية للأنظمة الكهروضوئية
6	1.1 مقدمة
7	2.1 التطور التاريخي للطاقة الكهروضوئية
8	3.1 الظاهرة الكهروضوئية
9	4.1 بنية الخلية الكهروضوئية
10	5.1 الوحدة والنظام الكهروضوئي
12	6.1 النموذج الكهربائي للخلية الكهروضوئية
14	7.1 الخصائص الكهربائية للخلية الكهروضوئية
16	8.1 تأثير الإشعاع الشمسي
17	9.1 تأثير درجة الحرارة
18	10.1 تأثير التظليل الجزئي
20	11.1 الحاجة إلى تتبع نقطة القدرة العظمى
21	12.1 خلاصة الفصل
23	الفصل الثاني: استراتيجيات تتبع النقطة القصوى للطاقة (MPPT) في الأنظمة الكهروضوئية
23	1.2 مقدمة
24	2.2 مبدأ MPPT
25	3.2 المحول ودورة العمل
26	4.2 طرق MPPT
28	5.2 خوارزمية P&O
30	6.2 حدود خوارزمية P&O
31	7.2 خلاصة الفصل
33	الفصل الثالث: أساسيات الشبكات العصبية الاصطناعية وتطبيقاتها
33	1.3 مقدمة
33	2.3 مفهوم الشبكات العصبية
34	3.3 بنية الشبكة العصبية
35	4.3 التعلم الموجه
37	5.3 تدريب الشبكة وتقييم الأداء
39	6.3 توظيف الشبكات العصبية في MPPT
42	7.3 خلاصة الفصل
43	الفصل الرابع: تنفيذ وتقييم متحكم ANN-MPPT

43	1.4 مقدمة
43	2.4 نموذج النظام الكهروضوئي
44	3.4 سيناريوهات التشغيل
46	4.4 تحضير قاعدة البيانات
49	5.4 تدريب الشبكة العصبية
54	6.4 إدماج الشبكة العصبية في Simulink
57	7.4 نتائج المحاكاة
58	8.4 المقارنة مع خوارزمية P&O
61	9.4 خلاصة الفصل
63	الخاتمة العامة
65	المراجع

فهرس الأشكال

الصفحة	عنوان الشكل	رقم الشكل
9	مبدأ عمل الخلية الكهروضوئية	الشكل 1.1
10	بنية الخلية الكهروضوئية	الشكل 2.1
12	بنية النظام الكهروضوئي	الشكل 3.1
13	النموذج أحادي الصمام	الشكل 4.1
15	منحنى I-V	الشكل 5.1
15	منحنى P-V ونقطة القدرة العظمى	الشكل 6.1
17	تأثير الإشعاع الشمسي	الشكل 7.1
18	تأثير درجة الحرارة	الشكل 8.1
19	تأثير التظليل الجزئي	الشكل 9.1
24	مبدأ عمل MPPT	الشكل 1.2
25	المحول الرفع Boost Converter	الشكل 2.2
29	خوارزمية P&O	الشكل 3.2
34	العصبون الاصطناعي	الشكل 1.3
35	بنية الشبكة العصبية	الشكل 2.3
41	توظيف ANN في MPPT	الشكل 3.3
44	نموذج النظام الكهروضوئي	الشكل 1.4
46	تطبيق السيناريو الخامس	الشكل 2.4
48	توزيع عينات التدريب	الشكل 3.4
48	العلاقة بين P_{pv} و D_{ref}	الشكل 4.4
49	بنية الشبكة العصبية	الشكل 5.4
51	أداء التدريب	الشكل 6.4
52	الانحدار	الشكل 7.4
52	توزيع الخطأ	الشكل 8.4
53	مقارنة D_{ANN} و D_{ref} على عينات قاعدة البيانات	الشكل 9.4

55	إدماج الشبكة العصبية في Simulink	الشكل 10.4
56	خرج الشبكة DANN	الشكل 11.4
56	إشارة PWM	الشكل 12.4
57	استجابة النظام مع ANN-MPPT	الشكل 13.4
59	مقارنة القدرة بين ANN و P&O	الشكل 14.4
61	مقارنة دورة العمل بين ANN و P&O	الشكل 15.4

فهرس الجداول

الصفحة	عنوان الجدول	رقم الجدول
27	مقارنة بين طرق MPPT	الجدول 1.2
45	بروفيلات الإشعاع والحرارة	الجدول 1.4
45	قيم P_{max} و D_{po}	الجدول 2.4
46	مثال للسيناريو الخامس	الجدول 3.4
47	خصائص قاعدة البيانات	الجدول 4.4
50	خصائص تدريب الشبكة	الجدول 5.4
51	نتائج تقييم الشبكة	الجدول 6.4
53	نتائج تقييم الشبكة العصبية	الجدول 7.4
59	مقارنة القدرة	الجدول 8.4
60	مقارنة الطاقة الكلية المستخرجة	الجدول 9.4
60	مقارنة دورة العمل	الجدول 10.4

المقدمة العامة

المقدمة العامة:

تشهد السنوات الأخيرة توجهًا متزايدًا نحو استغلال مصادر الطاقة المتجددة، نتيجة ارتفاع الطلب العالمي على الطاقة من جهة، وتزايد الاهتمام بالحد من الآثار البيئية الناتجة عن استعمال مصادر الطاقة التقليدية من جهة أخرى [1، 6]. وفي هذا السياق، تعد الطاقة الشمسية الكهروضوئية من أهم البدائل الطاقوية الواعدة، لما تتميز به من وفرة في مصدرها، وإمكانية تحويل الإشعاع الشمسي مباشرة إلى طاقة كهربائية باستعمال الخلايا الكهروضوئية [7، 9].

غير أن أداء الأنظمة الكهروضوئية لا يكون ثابتًا في جميع ظروف التشغيل، إذ يتأثر بعدة عوامل بيئية وتشغيلية، من أبرزها شدة الإشعاع الشمسي، ودرجة حرارة الخلايا، وظروف التظليل الجزئي، إضافة إلى طبيعة الحمل الكهربائي المرتبط بالنظام [11، 52]. وتؤدي هذه العوامل إلى تغير الخصائص الكهربائية للمولد الكهروضوئي، خاصة منحنيي التيار-الجهد والاستطاعة-الجهد، مما يجعل نقطة التشغيل المثلى للنظام متغيرة باستمرار.

ومن أجل تحسين استغلال الطاقة المتاحة من الألواح الشمسية، تم تطوير تقنيات تتبع نقطة القدرة العظمى MPPT، التي تهدف إلى تشغيل النظام الكهروضوئي عند النقطة التي تسمح باستخراج أكبر قدرة كهربائية ممكنة في مختلف ظروف التشغيل [46، 47]. وتعتمد هذه التقنيات عادة على التحكم في دورة العمل الخاصة بالمحول (DC-DC) المستمر-المستمر، بما يسمح بضبط نقطة تشغيل المولد الكهروضوئي وفقًا لتغيرات الإشعاع والحرارة والحمل.

وقد استُخدمت عدة خوارزميات تقليدية في مجال تتبع نقطة القدرة العظمى، من أبرزها خوارزمية الاضطراب والمراقبة P&O وخوارزمية الناقلية التزايدية Incremental Conductance، وذلك بسبب بساطتها وسهولة تنفيذها [48]. غير أن هذه الطرق قد تعاني من بعض المحدوديات، خاصة عند تغير ظروف التشغيل بسرعة أو في حالة التظليل الجزئي، حيث قد تظهر عدة نقاط قدرة محلية، مما يصعب الوصول إلى نقطة القدرة العظمى الحقيقية [49].

ومع تطور تقنيات الذكاء الاصطناعي، برزت الشبكات العصبية الاصطناعية بوصفها إحدى الأدوات الفعالة في نمذجة الأنظمة غير الخطية والمعقدة، نظرًا لقدرتها على التعلم من البيانات وتمثيل العلاقات المعقدة بين المتغيرات [59، 60]. وبناءً على ذلك، يمكن توظيف الشبكات العصبية في تحسين أداء أنظمة MPPT، من خلال تدريبها على بيانات مرجعية مستخرجة من خوارزميات تقليدية، ثم استعمالها لإنتاج دورة العمل المناسبة في الزمن الحقيقي.

انطلاقًا من ذلك، تهدف هذه المذكرة إلى تحسين تتبع نقطة القدرة العظمى في نظام كهروضوئي باستعمال

شبكة عصبية اصطناعية، اعتمادًا على النمذجة والمحاكاة في بيئة MATLAB/Simulink. ويتم ذلك من خلال اعتماد خوارزمية P&O-MPPT كمرجع لتوليد قاعدة البيانات التدريبية، ثم تدريب شبكة عصبية على العلاقة بين القياسات الكهربائية للوح الكهروضوئي ودورة العمل المرجعية. كما تسعى الدراسة إلى تقييم أداء المتحكم العصبي المقترح ومقارنته بالطريقة التقليدية من حيث دقة التتبع، استقرار القدرة المستخرجة، وسرعة الاستجابة.

إشكالية البحث:

رغم فعالية تقنيات تتبع نقطة القدرة العظمى في تحسين مردود الأنظمة الكهروضوئية، إلا أن الطرق التقليدية قد لا تحقق الأداء الأمثل في جميع ظروف التشغيل، خصوصًا عند تغير شدة الإشعاع الشمسي أو ارتفاع درجة حرارة الخلايا أو حدوث التظليل الجزئي. وتزداد أهمية هذه الإشكالية بالنظر إلى الطبيعة غير الخطية للأنظمة الكهروضوئية، وإلى تغير موضع نقطة القدرة العظمى تبعًا للظروف البيئية المحيطة.

وعليه، يمكن صياغة إشكالية البحث على النحو الآتي:

إلى أي مدى يمكن أن تساهم الشبكات العصبية الاصطناعية في تحسين تتبع نقطة القدرة العظمى في الأنظمة الكهروضوئية مقارنة بالطرق التقليدية، من حيث دقة التتبع، سرعة الاستجابة، واستقرار القدرة الكهربائية المستخرجة؟

فرضيات البحث:

يقوم هذا البحث على الفرضيات الآتية:

تؤثر التغيرات البيئية، خاصة شدة الإشعاع الشمسي ودرجة الحرارة، تأثيرًا مباشرًا في موضع نقطة القدرة العظمى داخل النظام الكهروضوئي.

تسمح خوارزميات MPPT التقليدية، مثل خوارزمية الاضطراب والمراقبة P&O، بتحسين استخراج الطاقة، لكنها قد تُظهر تذبذبات حول نقطة القدرة العظمى، خاصة في ظروف التشغيل غير المستقرة.

يمكن للشبكات العصبية الاصطناعية، بعد تدريبها على بيانات مناسبة، أن تحقق أداءً أفضل في تتبع نقطة القدرة العظمى، من حيث سرعة الوصول إلى النقطة المثلى وتقليل التذبذبات.

تمثل بيئة MATLAB/Simulink أداة مناسبة لنمذجة النظام الكهروضوئي، ومحاكاة خوارزميات MPPT، وتقييم أداء المتحكم العصبي المقترح.

أهداف البحث:

تهدف هذه المذكرة إلى تحقيق مجموعة من الأهداف العلمية والتطبيقية، من أهمها:

- دراسة المبادئ الأساسية للأنظمة الكهروضوئية ومكوناتها الرئيسية.
- تحليل الخصائص الكهربائية للخلايا الكهروضوئية، خاصة منحنيي (التيار-الجهد) و(الاستطاعة-الجهد).
- إبراز تأثير الإشعاع الشمسي ودرجة الحرارة والتظليل الجزئي على أداء المولد الكهروضوئي.
- شرح مبدأ تتبع نقطة القدرة العظمى ودوره في تحسين مردود الأنظمة الكهروضوئية.
- دراسة خوارزمية الاضطراب والمراقبة P&O بوصفها طريقة تقليدية مرجعية في مجال MPPT.

- عرض الأسس النظرية للشبكات العصبية الاصطناعية وآليات تعلمها.
- توظيف الشبكات العصبية الاصطناعية في تحسين تتبع نقطة القدرة العظمى.
- بناء نموذج محاكاة للنظام الكهروضوئي في بيئة MATLAB/Simulink.
- تقييم أداء المتحكم العصبي المقترح من خلال تحليل منحنيات الجهد والتيار والقدرة ودورة العمل.
- مقارنة أداء المتحكم القائم على الشبكات العصبية الاصطناعية مع الطريقة التقليدية من حيث الدقة والاستقرار وسرعة الاستجابة.

أهمية البحث:

تنبع أهمية هذا البحث من كونه يعالج إحدى الإشكاليات الأساسية في الأنظمة الكهروضوئية، وهي تحسين استخراج أكبر قدرة ممكنة من اللوح الشمسي تحت ظروف تشغيل متغيرة. فكلما كان نظام MPPT أكثر دقة وسرعة في تحديد نقطة القدرة العظمى، تحسن مردود النظام وازدادت فعالية استغلال الطاقة الشمسية المتاحة [46 ، 47].

كما تبرز أهمية الدراسة من خلال توظيف الشبكات العصبية الاصطناعية في مجال التحكم الذكي، باعتبارها أدوات قادرة على تمثيل العلاقات غير الخطية بين متغيرات النظام والتعلم من البيانات [59، 60].

ويتيح هذا التوجه الانتقال من خوارزميات تقليدية تعتمد على قواعد حسابية مباشرة إلى متحكمات ذكية يمكنها تحسين الأداء ضمن ظروف تشغيل متغيرة.

ومن الناحية التطبيقية، يوفر استعمال MATLAB/Simulink بيئة مناسبة لبناء نموذج النظام الكهروضوئي، توليد البيانات، تدريب الشبكة العصبية، واختبار المتحكم المقترح قبل الانتقال مستقبلاً

إلى مرحلة التطبيق العملي أو التجريبي.

منهجية البحث:

اعتمدت هذه المذكرة على منهجية تجمع بين الدراسة النظرية والنمذجة التطبيقية. ففي الجانب النظري، تم تناول المفاهيم الأساسية المتعلقة بالأنظمة الكهروضوئية، خصائص الخلايا الشمسية، تأثير العوامل البيئية، ومبدأ تتبع نقطة القدرة العظمى. كما تم عرض خوارزمية P&O-MPPT والشبكات العصبية الاصطناعية باعتبارهما محورين أساسيين في الدراسة.

أما في الجانب التطبيقي، فقد تم بناء نموذج محاكاة للنظام الكهروضوئي في بيئة MATLAB/Simulink، ثم إعداد مجموعة من السيناريوهات المختلفة للإشعاع الشمسي ودرجة الحرارة. بعد ذلك، تم تشغيل خوارزمية P&O-MPPT لاستخراج دورة العمل المرجعية، ثم استعمال القيم الكهربائية V_{pv} و I_{pv} كمداخلات للشبكة العصبية، D_{ref} كمرجع تدريبي. وفي المرحلة الأخيرة، تم إدماج الشبكة العصبية داخل نموذج Simulink ومقارنة أدائها مع الخوارزمية المرجعية.

حدود البحث:

تقتصر هذه الدراسة على تحسين تتبع نقطة القدرة العظمى في نظام كهروضوئي باستعمال شبكة عصبية اصطناعية، وذلك في إطار المحاكاة العددية باستخدام MATLAB/Simulink. ولا تشمل الدراسة إنجاز نموذج تجريبي مخبري أو اختبار النظام على منصة حقيقية.

كما تركز الدراسة على المقارنة بين المتحكم العصبي المقترح وخوارزمية P&O-MPPT، دون التوسع في مقارنة خوارزميات أخرى مثل الخوارزميات الجينية، أسراب الجسيمات، أو تقنيات الذكاء الاصطناعي الأخرى. وترتبط النتائج المتحصل عليها بمجال البيانات التدريبية والسيناريوهات المعتمدة في المحاكاة.

هيكل المذكرة:

تم تقسيم هذه المذكرة إلى أربعة فصول مترابطة.

1. يتناول الفصل الأول الأسس النظرية والنمذجة الكهربائية للأنظمة الكهروضوئية، من خلال

عرض مفهوم الظاهرة الكهروضوئية، مكونات النظام الكهروضوئي، خصائص الخلايا الشمسية، والنماذج الكهربائية المستعملة في تمثيل سلوكها.

2. أما الفصل الثاني، فيخصص لدراسة تقنيات تتبع نقطة القدرة العظمى MPPT، مع التركيز

على تأثير الإشعاع الشمسي ودرجة الحرارة، إضافة إلى عرض خوارزمية P&O-MPPT ومبدأ عملها.

3. ويعرض الفصل الثالث المفاهيم الأساسية للشبكات العصبية الاصطناعية، من حيث بنيتها، آلية عملها، أنماط تعلمها، وإمكانية توظيفها في تحسين تتبع نقطة القدرة العظمى داخل الأنظمة الكهروضوئية.

4. أما الفصل الرابع، فيتناول تنفيذ وتقييم المتحكم العصبي المقترح في بيئة MATLAB/Simulink، من خلال توليد قاعدة البيانات، تدريب الشبكة العصبية، إدماجها داخل نموذج التحكم، ثم تحليل نتائج المحاكاة ومقارنتها بخوارزمية P&O-MPPT.

الفصل الأول:

الأسس النظرية والنمذجة الكهربائية
للأنظمة الكهروضوئية

الفصل الأول: الأسس النظرية والنمذجة الكهربائية للأنظمة الكهروضوئية

1.1 مقدمة:

تعد الطاقة الشمسية الكهروضوئية من أهم مصادر الطاقة المتجددة التي حظيت باهتمام واسع خلال العقود الأخيرة، نظرًا لقدرتها على تحويل الإشعاع الشمسي مباشرة إلى طاقة كهربائية دون المرور بعمليات ميكانيكية أو حرارية معقدة. ويعتمد هذا التحويل على الخلايا الكهروضوئية المصنوعة غالبًا من مواد شبه موصلة، حيث تسمح هذه الخلايا بإنتاج تيار كهربائي عند تعرضها للضوء، وفقًا لمبدأ الظاهرة الكهروضوئية. وقد أدى التطور المستمر في تقنيات تصنيع الخلايا الشمسية، وتحسين مردودها، وتخفيض تكاليفها، إلى توسيع مجال استعمالها في الأنظمة المستقلة، والأنظمة المرتبطة بالشبكة، وتطبيقات الضخ، والإضاءة، والاتصالات، وغيرها من التطبيقات الكهربائية [1، 6، 7].

ورغم المزايا التي تتمتع بها الأنظمة الكهروضوئية، فإن أدائها لا يكون ثابتًا في جميع ظروف التشغيل، بل يتغير تبعًا لمجموعة من العوامل البيئية والتشغيلية. ومن أهم هذه العوامل شدة الإشعاع الشمسي، ودرجة حرارة الخلية، وطبيعة الحمل الكهربائي، إضافة إلى حالات التظليل الجزئي التي قد تؤثر بشكل واضح في القدرة المنتجة. وتنعكس هذه العوامل مباشرة على الخصائص الكهربائية للخلية أو اللوح الكهروضوئي، خاصة منحنى التيار-الجهد ومنحنى القدرة-الجهد، حيث تتغير قيم التيار والجهد والقدرة تبعًا لتغير ظروف التشغيل [9، 11].

وتكمن أهمية دراسة الخصائص الكهربائية للنظام الكهروضوئي في أن هذا النظام يتميز بسلوك غير خطي، أي إن العلاقة بين الجهد والتيار ليست علاقة ثابتة أو بسيطة. كما أن القدرة الكهربائية المستخرجة من اللوح لا تبلغ قيمتها العظمى إلا عند نقطة تشغيل محددة تسمى نقطة القدرة العظمى. وتتغير هذه النقطة باستمرار عند تغير الإشعاع الشمسي أو درجة الحرارة، مما يجعل تشغيل النظام عند نقطة ثابتة غير كافٍ لضمان استخراج أكبر قدرة ممكنة من اللوح. لذلك، فإن فهم سلوك الخلية الكهروضوئية ونمذجتها يمثل خطوة أساسية قبل الانتقال إلى دراسة تقنيات تتبع نقطة القدرة العظمى MPPT [16، 46].

وانطلاقًا من ذلك، يهدف هذا الفصل إلى تقديم الأسس العامة للأنظمة الكهروضوئية، من خلال عرض مبدأ الظاهرة الكهروضوئية، والبنية الأساسية للخلية الشمسية، ومكونات النظام الكهروضوئي، ثم التطرق إلى النموذج الكهربائي للخلية وخصائصها الأساسية. كما يتناول الفصل تأثير كل من الإشعاع الشمسي ودرجة الحرارة على أداء اللوح، باعتبارهما عاملين رئيسيين في تغير نقطة القدرة العظمى. ويمهد هذا العرض للفصل الثاني، الذي سيخصص لدراسة مبدأ تتبع نقطة القدرة العظمى وخوارزمية P&O المعتمدة لاحقًا في الجانب التطبيقي من هذه المذكرة.

2.1 التطور التاريخي للطاقة الكهروضوئية:

يرتبط تطور الأنظمة الكهروضوئية بسلسلة من الاكتشافات العلمية والتطورات التقنية التي مهدت لاستغلال الإشعاع الشمسي في إنتاج الطاقة الكهربائية. وتعود البداية العلمية لهذا المجال إلى سنة 1839، عندما لاحظ الفيزيائي الفرنسي إدموند بيكريل ظهور تأثير كهربائي عند تعريض بعض المواد للضوء، وهو ما عُرف لاحقًا بالظاهرة الكهروضوئية. وقد مثّل هذا الاكتشاف الأساس الأول لفكرة تحويل الطاقة الضوئية إلى طاقة كهربائية باستعمال مواد حساسة للضوء [4].

وفي مطلع القرن العشرين، تعزز الفهم العلمي لهذه الظاهرة بعد تفسير ألبرت أينشتاين للأثر الكهروضوئي سنة 1905، حيث بيّن أن الضوء يمكن أن يُفهم على شكل كمّات من الطاقة تسمى الفوتونات، وأن امتصاص هذه الفوتونات من طرف المادة يمكن أن يؤدي إلى تحرير الإلكترونات. وقد ساهم هذا التفسير في ترسيخ الأساس الفيزيائي للظاهرة الكهروضوئية، وفتح المجال أمام تطوير تطبيقات عملية تعتمد على المواد شبه الموصلة [5].

أما الانتقال الفعلي من المبدأ الفيزيائي إلى التطبيق الهندسي، فقد تحقق بشكل واضح سنة 1954 مع تطوير أول خلية شمسية سيليكونية عملية في مختبرات Bell. وقد أظهر هذا الإنجاز إمكانية تحويل الإشعاع الشمسي مباشرة إلى طاقة كهربائية بمرود قابل للاستعمال، مما شكل نقطة تحول في تاريخ الطاقة الشمسية الكهروضوئية. ومنذ ذلك الوقت، استمر البحث في تحسين كفاءة الخلايا الشمسية، وتخفيض تكاليف تصنيعها، ورفع موثوقيتها في ظروف التشغيل المختلفة [6، 7].

وخلال العقود اللاحقة، توسع استعمال الخلايا الكهروضوئية تدريجيًا، بداية من التطبيقات الفضائية التي كانت تحتاج إلى مصادر طاقة مستقلة وموثوقة، ثم انتقلت هذه التقنية إلى التطبيقات الأرضية مثل أنظمة الإنارة، الضخ الشمسي، التغذية المستقلة، والأنظمة المرتبطة بالشبكة الكهربائية. وقد ساهم تطور إلكترونيات القدرة وتقنيات التحكم في تحسين استغلال الطاقة المنتجة من الألواح الشمسية، خاصة من خلال استعمال المحولات المستمرة وتقنيات تتبع نقطة القدرة العظمى MPPT [16، 46].

وبذلك لم تعد الأنظمة الكهروضوئية مجرد تطبيق مباشر للظاهرة الكهروضوئية، بل أصبحت منظومة متكاملة تجمع بين الخلية الشمسية، محولات القدرة، تقنيات التحكم، وخوارزميات تحسين الأداء. ويُعد هذا التطور مهمًا بالنسبة لهذه الدراسة، لأن تحسين مردود النظام الكهروضوئي لا يعتمد فقط على خصائص اللوح الشمسي، بل يرتبط أيضًا بطريقة التحكم في نقطة تشغيله واستخراج أكبر قدرة ممكنة منه.


3.1 الظاهرة الكهروضوئية :

تُعد الظاهرة الكهروضوئية المبدأ الفيزيائي الأساسي الذي تقوم عليه الخلايا الشمسية، إذ تسمح بتحويل الطاقة الضوئية الساقطة على سطح الخلية إلى طاقة كهربائية. وتحدث هذه الظاهرة داخل مواد شبه موصلة، ويُعد السيليكون من أكثر المواد استعمالاً في صناعة الخلايا الكهروضوئية، نظراً لخصائصه الكهربائية المناسبة وتوفره واستقراره في ظروف التشغيل المختلفة. فعند سقوط الإشعاع الشمسي على سطح الخلية، تقوم الفوتونات بنقل جزء من طاقتها إلى إلكترونات المادة شبه الموصلة. وإذا كانت طاقة الفوتون كافية لتجاوز فجوة الطاقة، تتحرر الإلكترونات من روابطها الذرية، وينتج عن ذلك أزواج من الإلكترونات والفجوات [7، 8].

ولا يكفي تحرير الشحنات الكهربائية وحده لإنتاج تيار مفيد، بل يجب فصل هذه الشحنات وتوجيهها في مسار كهربائي محدد. ولهذا تعتمد الخلية الشمسية على وصلة شبه موصلة من النوعين P و N، حيث تُنشئ هذه الوصلة مجالاً كهربائياً داخلياً يساعد على فصل الإلكترونات والفجوات ومنع إعادة اتحادهما بسرعة. تنتقل الإلكترونات نحو منطقة N، بينما تتحرك الفجوات نحو منطقة P. وعند توصيل الخلية بدائرة خارجية، تبدأ الشحنات في الحركة عبر الحمل، فيتولد تيار كهربائي مستمر يمكن استغلاله مباشرة أو تحويله حسب طبيعة النظام [12، 13].

تتأثر كمية التيار الناتج عن الخلية الكهروضوئية أساساً بشدة الإشعاع الشمسي، إذ يؤدي ارتفاع الإشعاع إلى زيادة عدد الفوتونات الممتصة، وبالتالي زيادة عدد الشحنات المتولدة داخل الخلية. أما الجهد الكهربائي الناتج فيرتبط بخصائص المادة شبه الموصلة وبدرجة حرارة الخلية. لذلك فإن الاستجابة الكهربائية للخلية لا تكون ثابتة، بل تتغير بتغير الظروف البيئية، خاصة الإشعاع الشمسي ودرجة الحرارة [9، 11].

يوضح الشكل الآتي المبدأ العام لعمل الخلية الكهروضوئية، حيث يؤدي سقوط الفوتونات على المادة شبه الموصلة إلى تحرير الشحنات الكهربائية، ثم فصلها بواسطة المجال الداخلي للوصلة P-N وتوجيهها نحو الدائرة الخارجية.



الشكل 1.1: مبدأ عمل الخلية الكهروضوئية.

يبين الشكل آلية تحويل الإشعاع الشمسي إلى تيار كهربائي داخل الخلية الكهروضوئية، حيث يؤدي امتصاص الفوتونات إلى توليد شحنات كهربائية يتم فصلها بواسطة المجال الداخلي للوصلة P-N، ثم تمر عبر الدائرة الخارجية لتغذية الحمل الكهربائي.

4.1 بنية الخلية الكهروضوئية :

تتكون الخلية الكهروضوئية من بنية شبه موصلة مصممة بطريقة تسمح بامتصاص الإشعاع الشمسي وتحويله إلى طاقة كهربائية. وتعتمد أغلب الخلايا الشمسية التقليدية على السيليكون، الذي تتم معالجته لتكوين طبقتين مختلفتين من حيث نوعية الشحنات الغالبة. الطبقة الأولى تكون من النوع N، وتتميز بوفرة الإلكترونات الحرة، بينما تكون الطبقة الثانية من النوع P، وتتميز بوجود فجوات تمثل حاملات شحنة موجبة. وعند اتصال هاتين الطبقتين تتشكل وصلة P-N، وهي الجزء الأساسي المسؤول عن توليد المجال الكهربائي الداخلي داخل الخلية [12، 13].


تؤدي وصلة P-N دورًا مهمًا في عمل الخلية، إذ تعمل على فصل الشحنات الكهربائية الناتجة عن امتصاص الفوتونات. فعند تولد أزواج الإلكترون-الفجوة داخل المادة شبه الموصلة، يقوم المجال الكهربائي الداخلي بدفع الإلكترونات نحو جهة، والفجوات نحو الجهة المقابلة. وبهذا الفصل المنتظم للشحنات، يظهر فرق جهد بين طرفي الخلية. وعند ربط الخلية بحمل خارجي، يسمح هذا الفرق في الجهد بمرور تيار كهربائي مستمر عبر الدائرة الخارجية [14، 15].

إضافة إلى الطبقتين شبه الموصلتين، تحتوي الخلية الكهروضوئية على أقطاب معدنية أمامية وخلفية تسمح بجمع التيار الكهربائي ونقله إلى الدائرة الخارجية. ويكون القطب الأمامي عادة على شكل شبكة

معدنية رقيقة حتى يسمح بمرور أكبر كمية ممكنة من الضوء نحو سطح الخلية، مع تقليل الفاقد الناتج عن التظليل. كما تُغطى الخلية غالبًا بطبقة مضادة للانعكاس، هدفها تقليل كمية الضوء المنعكس وزيادة كمية الإشعاع الممتص داخل المادة شبه الموصلة [23، 24].

ولا تعمل الخلية الشمسية منفردة في أغلب التطبيقات العملية، لأن الجهد والتيار الناتجين عن خلية واحدة يكونان محدودين. لذلك يتم تجميع عدد من الخلايا في وحدة كهروضوئية واحدة، من خلال توصيلها على التوالي أو على التوازي حسب القيم المطلوبة. يؤدي التوصيل على التوالي إلى زيادة الجهد الكلي للوحدة، بينما يؤدي التوصيل على التوازي إلى زيادة التيار الكلي. وبذلك تصبح الوحدة الكهروضوئية قادرة على تزويد الحمل الكهربائي بقدرة مناسبة للتطبيق المستهدف [21، 22].

يوضح الشكل الآتي البنية العامة للخلية الكهروضوئية، بما في ذلك طبقتا P و N، الأقطاب المعدنية، والطبقة الأمامية التي تسمح بامتصاص الإشعاع الشمسي.



الشكل 2.1: بنية الخلية الكهروضوئية.

يبين الشكل المكونات الأساسية للخلية الشمسية، حيث تمثل وصلة P-N العنصر المسؤول عن فصل الشحنات الكهربائية، بينما تسمح الأقطاب المعدنية بجمع التيار الناتج وتوجيهه نحو الدائرة الخارجية.

5.1 الوحدة والنظام الكهروضوئي:

رغم أن الخلية الكهروضوئية تمثل العنصر الأساسي في تحويل الإشعاع الشمسي إلى طاقة كهربائية، إلا أن قدرتها الكهربائية منفردة تكون محدودة من حيث الجهد والتيار. لذلك يتم تجميع عدد من الخلايا الشمسية ضمن بنية واحدة تسمى الوحدة الكهروضوئية. ويتم هذا التجميع عادة بربط الخلايا على التوالي أو على التوازي، أو باستعمال الطريقتين معًا، من أجل الحصول على القيم الكهربائية المناسبة للتطبيق

المطلوب. فعند ربط الخلايا على التوالي ترتفع قيمة الجهد الكلي، بينما يؤدي الربط على التوازي إلى زيادة التيار الكلي الخارج من الوحدة [21، 22].


تُغلف الخلايا داخل الوحدة الكهروضوئية باستعمال مواد عازلة وشفافة تسمح بمرور الضوء وتحمي الخلايا من العوامل الخارجية، مثل الرطوبة والغبار والصدمات الحرارية والميكانيكية. وتُستعمل عادة طبقات من الزجاج والمواد البوليمرية لحماية الخلايا وضمان استقرار أدائها خلال مدة تشغيل طويلة. وتكمن أهمية التغليف في الحفاظ على الخصائص الكهربائية للخلايا وتقليل الخسائر الناتجة عن التأثيرات البيئية، خاصة أن الوحدات الكهروضوئية تعمل غالباً في الهواء الطلق وتتعرض لتغيرات مستمرة في درجة الحرارة والإشعاع [23، 24].

وعند تجميع عدة وحدات كهروضوئية، نحصل على مولد كهروضوئي قادر على إنتاج قدرة أكبر. ويُعد هذا المولد المصدر الأساسي للطاقة داخل النظام الكهروضوئي. غير أن الطاقة الناتجة عن المولد تكون في شكل تيار مستمر، كما أن قيم الجهد والتيار تتغير باستمرار تبعاً للظروف البيئية والحمل المرتبط بالنظام. لذلك لا يقتصر النظام الكهروضوئي على الألواح الشمسية فقط، بل يتكون من عدة عناصر مكاملة تسمح بتكييف الطاقة المنتجة واستغلالها بشكل مناسب [16، 21].

يتكون النظام الكهروضوئي عادة من مولد كهروضوئي، محول قدرة، وحدة تحكم، وحمل كهربائي أو نظام تخزين. يقوم المولد الكهروضوئي بتحويل الإشعاع الشمسي إلى طاقة كهربائية مستمرة، بينما يعمل محول القدرة على ضبط الجهد والتيار بما يتناسب مع متطلبات الحمل. أما وحدة التحكم، فتقوم بمراقبة الإشارات الكهربائية للنظام وتوليد أوامر التحكم المناسبة للمحول. وفي الأنظمة التي تهدف إلى تحسين استغلال الطاقة المتاحة من اللوح، تُستعمل وحدة تتبع نقطة القدرة العظمى MPPT من أجل ضبط نقطة التشغيل واستخراج أكبر قدرة ممكنة [46، 47].

وتظهر أهمية هذا التنظيم في أن اللوح الكهروضوئي لا يعمل دائماً عند نقطة القدرة العظمى إذا تم ربطه مباشرة بالحمل. فاختلاف الحمل أو تغير الإشعاع والحرارة يؤدي إلى تغير نقطة التشغيل، وقد يجعل النظام يعمل بعيداً عن النقطة المثلى. لذلك يتم إدخال محول مستمر-مستمر DC-DC بين اللوح والحمل، بحيث يمكن التحكم في دورة العمل D الخاصة بالمحول لتعديل الجهد والتيار اللذين يراهما اللوح. وبهذه الطريقة يصبح بالإمكان نقل نقطة تشغيل اللوح نحو نقطة القدرة العظمى، وهو المبدأ الذي تقوم عليه تقنيات MPPT [16، 46].

يوضح الشكل الآتي البنية العامة للنظام الكهروضوئي، حيث يظهر المولد الكهروضوئي متصلاً بمحول قدرة ووحدة تحكم وحمل كهربائي. وتسمح هذه البنية بفهم العلاقة بين الجزء الطاقوي للنظام، المتمثل في اللوح والمحول، والجزء التحكمي، المتمثل في خوارزمية التتبع أو المتحكم الذكي.




الشكل 3.1: بنية النظام الكهروضوئي.

يبين الشكل المكونات الأساسية للنظام الكهروضوئي، حيث يقوم اللوح الشمسي بإنتاج الطاقة الكهربائية المستمرة، بينما يعمل محول القدرة ووحدة التحكم على تكييف نقطة التشغيل بما يسمح بتحسين الطاقة المستخرجة من النظام.

6.1 النموذج الكهربائي للخلية الكهروضوئية:

تُستعمل النماذج الكهربائية للخلية الكهروضوئية من أجل تمثيل سلوكها داخل برامج المحاكاة، وتحليل العلاقة بين التيار والجهد والقدرة تحت ظروف تشغيل مختلفة. ونظرًا لأن الخلية الشمسية عنصر غير خطي، فإن تمثيلها بدائرة كهربائية مكافئة يساعد على دراسة أدائها بطريقة أوضح، خاصة عند تغير الإشعاع الشمسي ودرجة الحرارة. وتسمح هذه النماذج بفهم كيفية تغير التيار والجهد الناتجين عن الخلية، كما تُعد أساسًا مهمًا لبناء نموذج النظام الكهروضوئي داخل بيئة MATLAB/Simulink [27، 31].

من أكثر النماذج استعمالًا في دراسة الخلايا الكهروضوئية النموذج أحادي الصمام. ويعتمد هذا النموذج على تمثيل الخلية بمصدر تيار ضوئي موصول على التوازي مع صمام ثنائي، حيث يمثل مصدر التيار التأثير الناتج عن امتصاص الإشعاع الشمسي، بينما يمثل الصمام الثنائي السلوك الداخلي للوصلة P-N. ويُضاف إلى هذا النموذج غالبًا مقاومة تسلسلية R_s ومقاومة تفرعية R_p من أجل تمثيل الخسائر الداخلية داخل الخلية. فالمقاومة التسلسلية تعبر عن الخسائر الناتجة عن مقاومة المادة والتوصيلات المعدنية، أما المقاومة التفرعية فتُمثل تيارات التسرب داخل الخلية [27، 28، 31].



الشكل 4.1: النموذج أحادي الصمام.

يبين الشكل الدائرة الكهربائية المكافئة للخلية الكهروضوئية وفق النموذج أحادي الصمام، حيث تتكون من مصدر تيار ضوئي، صمام ثنائي، مقاومة تسلسلية، ومقاومة تفرعية.

يعتمد التيار الخارج من الخلية في هذا النموذج على عدة مركبات. المركبة الأولى هي التيار الضوئي I_{ph} ، وهو التيار الناتج عن امتصاص الإشعاع الشمسي، وتزداد قيمته عادة بزيادة شدة الإشعاع. أما المركبة الثانية فهي تيار الصمام الثنائي I_d ، الذي يعبر عن السلوك غير الخطي للوصلة P-N. وتوجد أيضاً مركبة تيار التسرب عبر المقاومة التفرعية، وهي تمثل الخسائر الداخلية التي تقلل من التيار المفيد الخارج من الخلية. لذلك يمكن التعبير عن التيار الكلي الخارج من الخلية بأنه الفرق بين التيار الضوئي ومجموع التيارات الداخلية المفقودة.

تُكتب المعادلة العامة للتيار في النموذج أحادي الصمام بالشكل الآتي:

$$I = I_{ph} - I_d - I_{sh}$$

حيث يمثل:

I : التيار الخارج من الخلية.

I_{ph} : التيار الضوئي .

I_d : تيار الصمام الثنائي.

I_{sh} : تيار التسرب عبر المقاومة التفرعية.

وتوضح هذه العلاقة أن التيار الناتج عن الخلية لا يعتمد فقط على الإشعاع الشمسي، بل يتأثر أيضاً

بالخصائص الداخلية للخلية وبالخسائر الكهربائية المرتبطة بالمقاومات الداخلية [29، 31].
وتكمن أهمية هذا النموذج في أنه يسمح بتمثيل السلوك غير الخطي للخلية الكهروضوئية بطريقة مناسبة للمحاكاة. فعند تغيير الإشعاع الشمسي أو درجة الحرارة، تتغير قيم التيار الضوئي والتيار الصمام، مما يؤدي إلى تغير منحنى التيار-الجهد ومنحنى القدرة-الجهد. وبذلك يمكن استعمال هذا النموذج لدراسة تأثير العوامل البيئية على أداء اللوح، وكذلك لاختبار خوارزميات تتبع نقطة القدرة العظمى قبل تطبيقها عملياً [16، 27].

وعلى الرغم من وجود نماذج أخرى أكثر تفصيلاً، مثل النموذج ثنائي الصمام، فإن النموذج أحادي الصمام يُعد كافياً في كثير من دراسات المحاكاة، لأنه يحقق توازناً مناسباً بين الدقة والبساطة. فهو يوفر تمثيلاً مقبولاً لسلوك الخلية، مع عدد محدود من المعاملات، مما يجعله مناسباً لتحليل النظام الكهروضوئي وربطه لاحقاً بخوارزميات التحكم وتقنيات MPPT [31، 35].


7.1 الخصائص الكهربائية للخلية الكهروضوئية :

تتميز الخلية الكهروضوئية بخصائص كهربائية غير خطية، أي إن العلاقة بين التيار والجهد ليست علاقة تناسبية بسيطة كما هو الحال في العناصر الخطية. ويظهر هذا السلوك بوضوح من خلال منحنى التيار والجهد $I-V$ ، الذي يبين تغير التيار الخارج من الخلية بدلالة الجهد، ومنحنى القدرة والجهد $P-V$ ، الذي يوضح تغير القدرة الكهربائية الناتجة بدلالة الجهد.

وتعد دراسة هذين المنحنيين ضرورية لفهم سلوك الخلية الكهروضوئية، لأنهما يبرزان كيفية تغير نقطة التشغيل تبعاً لظروف الإشعاع الشمسي ودرجة الحرارة والحمل الكهربائي [16، 27]. كما تسمح هذه المنحنيات بتحديد أهم المعلمات الكهربائية للخلية، مثل تيار القصر، وجهد الدارة المفتوحة، ونقطة الاستطاعة العظمى.

وتمثل نقطة الاستطاعة العظمى الحالة التشغيلية المثلى التي تحقق عندها الخلية أعلى قدرة كهربائية ممكنة تحت شروط تشغيل محددة. ومن ثم، فإن تحليل منحنى $I-V$ و $P-V$ يشكل أساساً لتصميم خوارزميات تتبع نقطة الاستطاعة العظمى وتحسين المردود الطاقوي للأنظمة الكهروضوئية.

يمثل منحنى التيار-الجهد $I-V$ العلاقة بين الجهد والتيار في الخلية الكهروضوئية. فعند قصر طرفيها يكون الجهد قريباً من الصفر، بينما يبلغ التيار قيمته العظمى المسماة تيار القصر I_{sc} . وعند فتح الدارة يصبح التيار قريباً من الصفر، في حين يبلغ الجهد قيمته العظمى المسماة جهد الدارة المفتوحة V_{oc} . وبين هاتين النقطتين تتغير القيمتان بصورة غير خطية تبعاً لخصائص الخلية وظروف التشغيل [9، 16].



الشكل 5.1: منحنى I-V.


يبين الشكل العلاقة غير الخطية بين التيار والجهد في الخلية الكهروضوئية، حيث تظهر نقطتا تيار القصر I_{sc} وجهد الدارة المفتوحة V_{oc} ، إضافة إلى منطقة التشغيل التي تقع بينها نقطة القدرة العظمى.

أما منحنى القدرة-الجهد P-V فيتم الحصول عليه من حاصل ضرب الجهد في التيار عند كل نقطة

$$P = V \times I$$

تشغيل، حيث تعطى القدرة الكهربائية بالعلاقة:

ومن خلال هذا المنحنى، يمكن ملاحظة أن القدرة لا تزداد بشكل مستمر مع الجهد، بل ترتفع إلى غاية قيمة عظمى ثم تبدأ في الانخفاض. وتسمى النقطة التي تبلغ عندها القدرة أكبر قيمة ممكنة بنقطة القدرة العظمى MPP. عند هذه النقطة تكون القيم الموافقة للجهد والتيار هي V_{mp} و I_{mp} ، وتكون القدرة العظمى مساوية إلى P_{max} . وتمثل هذه النقطة أفضل حالة تشغيل للوح الكهروضوئي، لأنها تسمح باستخراج أكبر طاقة ممكنة من الإشعاع المتاح [46، 47].



الشكل 6.1: منحنى P-V ونقطة القدرة العظمى

يوضح الشكل وجود نقطة قدرة عظمى على منحنى $P-V$ ، وهي النقطة التي يجب أن يعمل عندها النظام الكهروضوئي من أجل تحقيق أفضل مردود طاقي.

تتغير نقطة القدرة العظمى باستمرار عند تغير ظروف التشغيل. فعندما تتغير شدة الإشعاع الشمسي، يتغير التيار الناتج عن الخلية بشكل واضح، مما يؤدي إلى تغير القدرة المنتجة وموضع نقطة MPP . وعندما تتغير درجة الحرارة، يتأثر الجهد بشكل أكبر، خاصة عند ارتفاع درجة حرارة الخلية، حيث ينخفض جهد الخرج وتتناقص القدرة العظمى الممكن استخراجها. لذلك فإن نقطة القدرة العظمى ليست ثابتة، بل تتحرك على منحنى $P-V$ تبعاً للظروف البيئية المحيطة [11، 52].


وتكمن أهمية هذه الخصائص الكهربائية في أنها توضح سبب الحاجة إلى استعمال تقنيات تتبع نقطة القدرة العظمى $MPPT$. فإذا تم ربط اللوح الكهروضوئي مباشرة بالحمل، فقد يعمل النظام عند نقطة تشغيل غير مثلى، مما يؤدي إلى ضياع جزء من القدرة المتاحة. لذلك يجب استعمال متحكم قادر على مراقبة الجهد والتيار وتعديل نقطة التشغيل، بحيث يبقى النظام قريباً من نقطة القدرة العظمى رغم تغير الإشعاع والحرارة والحمل. ومن هنا تظهر العلاقة المباشرة بين دراسة الخصائص الكهربائية للخلية وبين موضوع هذه المذكرة، الذي يهدف إلى تحسين تتبع نقطة القدرة العظمى باستعمال الشبكات العصبية الاصطناعية.

8.1 تأثير الإشعاع الشمسي

الخلية، زاد عدد الفوتونات الممتصة داخل المادة شبه الموصلة، مما يؤدي إلى زيادة عدد أزواج الإلكترون-الفجوة المتولدة. ونتيجة لذلك، يرتفع التيار الضوئي الناتج عن الخلية، وينعكس ذلك مباشرة على التيار الكلي الخارج من اللوح الكهروضوئي [9، 11].

يظهر تأثير الإشعاع الشمسي بوضوح على منحنى التيار-الجهد $I-V$ ، حيث يؤدي ارتفاع الإشعاع إلى انتقال المنحنى نحو قيم تيار أعلى، بينما يؤدي انخفاض الإشعاع إلى انخفاض التيار الناتج. ويكون تأثير الإشعاع على التيار أوضح بكثير من تأثيره على الجهد، إذ يتغير جهد الدارة المفتوحة V_{oc} بدرجة أقل مقارنة بتغير تيار القصر I_{sc} . لذلك يمكن القول إن الإشعاع الشمسي يتحكم أساساً في قيمة التيار المنتج، ومن ثم في القدرة الكهربائية التي يمكن استخراجها من اللوح [16، 52].

أما على منحنى القدرة-الجهد $P-V$ ، فإن تغير الإشعاع يؤدي إلى تغير واضح في قيمة القدرة العظمى P_{max} . فعند ارتفاع الإشعاع، ترتفع القدرة المتاحة من اللوح وتنتقل نقطة القدرة العظمى إلى مستوى أعلى. وعند انخفاض الإشعاع، تنخفض القدرة العظمى المتاحة، وقد يتغير موضع نقطة التشغيل المثلى. وهذا يعني أن النظام الكهروضوئي لا يمكن أن يعمل دائماً عند نفس نقطة التشغيل، بل يحتاج إلى تعديل مستمر تبعاً لتغير الإشعاع الشمسي.



الشكل 7.1: تأثير الإشعاع الشمسي

يوضح الشكل تأثير تغير شدة الإشعاع الشمسي على منحنيات I-V و P-V، حيث يؤدي ارتفاع الإشعاع إلى زيادة التيار والقدرة المستخرجة من اللوح، بينما يؤدي انخفاضه إلى تراجع القدرة المتاحة وتحرك نقطة القدرة العظمى.

تكمُن أهمية هذا العامل في أن الإشعاع الشمسي لا يكون ثابتاً أثناء التشغيل العملي، بل يتغير خلال اليوم تبعاً لزاوية سقوط الشمس، وحالة الجو، ووجود السحب أو العوائق المسببة للتظليل. لذلك فإن أي نظام كهروضوئي فعال يجب أن يكون قادراً على التكيف مع هذه التغيرات من خلال تعديل نقطة التشغيل. ومن هنا تظهر أهمية تقنيات تتبع نقطة القدرة العظمى MPPT، لأنها تسمح بملاحقة نقطة القدرة المثلى كلما تغيرت قيمة الإشعاع الشمسي [46، 47].


9.1 تأثير درجة الحرارة

إلى جانب الإشعاع الشمسي، تُعد درجة حرارة الخلية من العوامل الأساسية التي تؤثر في أداء الأنظمة الكهروضوئية. فعند تعرض اللوح الشمسي للإشعاع لفترة طويلة، ترتفع درجة حرارة الخلايا بسبب امتصاص جزء من الطاقة الحرارية وعدم تحويل كامل الإشعاع إلى طاقة كهربائية. ويؤدي هذا الارتفاع في درجة الحرارة إلى تغير الخصائص الكهربائية للخلية، خاصة الجهد الناتج، مما يؤثر في القدرة العظمى المتاحة من اللوح [11، 52].

يظهر تأثير درجة الحرارة بشكل واضح على جهد الخلية، إذ يؤدي ارتفاع درجة الحرارة إلى انخفاض جهد الدارة المفتوحة V_{oc} . ويرجع ذلك إلى تغير خصائص المادة شبه الموصلة وزيادة تيار الإشعاع العكسي للوصلة P-N عند ارتفاع درجة الحرارة. وفي المقابل، قد يزداد تيار القصر I_{sc} زيادة طفيفة مع ارتفاع الحرارة، إلا أن هذه الزيادة تكون عادة محدودة ولا تعوض الانخفاض الحاصل في الجهد. لذلك تكون النتيجة العامة لارتفاع درجة الحرارة هي انخفاض القدرة العظمى التي يمكن استخراجها من

اللوحة الكهروضوئية [16، 27].

على منحنى التيار-الجهد I-V، يؤدي ارتفاع درجة الحرارة إلى انتقال المنحنى نحو قيم جهد أقل، بينما يبقى تغير التيار أقل وضوحًا. أما على منحنى القدرة-الجهد P-V، فيؤدي ذلك إلى انخفاض قيمة القدرة العظمى وتحرك نقطة MPP نحو قيم جهد أدنى. ويُعد هذا السلوك مهمًا جدًا في تصميم أنظمة التحكم، لأن المتحكم يجب أن يأخذ في الاعتبار أن نقطة القدرة العظمى لا تتغير فقط بسبب الإشعاع، بل تتأثر أيضًا بدرجة حرارة الخلية.



الشكل 8.1: تأثير درجة الحرارة

يبين الشكل تأثير ارتفاع درجة الحرارة على الخصائص الكهربائية للخلية الكهروضوئية، حيث يؤدي ارتفاع الحرارة إلى انخفاض الجهد والقدرة العظمى، مع تغير موضع نقطة التشغيل المثلى على منحنى P-V.

وتزداد أهمية دراسة تأثير درجة الحرارة في التطبيقات العملية، لأن الألواح الشمسية تعمل غالبًا في ظروف خارجية قد تكون فيها درجة حرارة الخلايا أعلى بكثير من درجة حرارة الجو المحيط. كما أن ارتفاع درجة الحرارة يمكن أن يقلل من مردود النظام حتى في حالة توفر إشعاع شمسي مرتفع. لذلك فإن تحسين أداء النظام الكهروضوئي يتطلب فهم التأثير المشترك للإشعاع والحرارة، وهو ما يبرر استعمال سيناريوهات تشغيل مختلفة عند دراسة أو تدريب متحكمات MPPT.


10.1 تأثير التظليل الجزئي

إضافة إلى الإشعاع الشمسي ودرجة الحرارة، يُعد التظليل الجزئي من العوامل التي قد تؤثر بوضوح في أداء النظام الكهروضوئي. ويحدث التظليل الجزئي عندما يتعرض جزء من اللوح أو مجموعة من الخلايا إلى ظل ناتج عن الغيوم، المباني، الأشجار، الغبار، أو أي عائق آخر يحجب جزءًا من الإشعاع الشمسي. وفي هذه الحالة لا تستقبل جميع الخلايا نفس كمية الإشعاع، مما يؤدي إلى عدم تجانس التيارات

المنتجة داخل اللوح أو السلسلة الكهروضوئية [49، 52].

يؤدي هذا الاختلاف في الإشعاع بين الخلايا إلى ظهور سلوك كهربائي أكثر تعقيداً مقارنة بالحالة العادية. فعندما تكون الخلايا موصولة على التوالي، فإن الخلية المظلمة قد تحد من التيار الكلي المار في السلسلة، لأنها تنتج تياراً أقل من باقي الخلايا المعرضة للإشعاع الكامل. وقد يؤدي ذلك إلى انخفاض القدرة المنتجة، وظهور خسائر إضافية، بل ويمكن أن يسبب ارتفاعاً محلياً في درجة حرارة بعض الخلايا إذا لم تكن الحماية مناسبة. ولهذا السبب تُستعمل عادة صمامات التجاوز Bypass Diodes لحماية الخلايا وتقليل أثر التظليل على أداء اللوح [21، 22].

يظهر أثر التظليل الجزئي بشكل خاص على منحنى القدرة-الجهد P-V، حيث يمكن أن تظهر عدة قمم للقدرة بدل قمة واحدة. ففي ظروف الإشعاع المنتظم، يحتوي منحنى P-V عادة على نقطة قدرة عظمى واحدة، أما في حالة التظليل الجزئي فقد تظهر نقاط قدرة محلية متعددة، إضافة إلى نقطة قدرة عظمى عامة. وهذا يجعل عملية تتبع نقطة القدرة العظمى أكثر صعوبة، لأن بعض خوارزميات MPPT التقليدية قد تتوقف عند نقطة محلية ولا تصل إلى النقطة العامة التي تحقق أكبر قدرة ممكنة [48، 49].



الشكل 9.1: تأثير التظليل الجزئي

يوضح الشكل أثر التظليل الجزئي على منحنى القدرة-الجهد، حيث قد يؤدي عدم تجانس الإشعاع إلى ظهور عدة نقاط قدرة محلية، مما يزيد من صعوبة تتبع نقطة القدرة العظمى الحقيقية.

ورغم أن الجانب التطبيقي في هذه المذكرة يركز أساساً على تغير الإشعاع الشمسي ودرجة الحرارة،

فإن التطرق إلى التظليل الجزئي يبقى مهمًا من الناحية النظرية، لأنه يوضح أحد أهم التحديات التي تواجه أنظمة MPPT في التطبيقات الواقعية. كما يبرز الحاجة إلى متحكمات أكثر قدرة على التكيف مع تغيرات ظروف التشغيل، خاصة عندما يكون سلوك النظام غير خطي ومعقدًا.

11.1 الحاجة إلى تتبع نقطة القدرة العظمى

من خلال ما سبق، يتضح أن أداء اللوح الكهروضوئي يتغير باستمرار تبعًا لظروف التشغيل، خاصة الإشعاع الشمسي ودرجة الحرارة والحمل الكهربائي. ويؤدي هذا التغير إلى انتقال موضع نقطة القدرة العظمى على منحنى P-V، مما يجعل التشغيل عند نقطة ثابتة غير كافٍ لاستخراج أكبر قدرة ممكنة من اللوح. فإذا تم ربط اللوح مباشرة بالحمل، فإن نقطة التشغيل تتحدد حسب خصائص الحمل، وقد تكون بعيدة عن نقطة القدرة العظمى، وهو ما يؤدي إلى ضياع جزء من الطاقة المتاحة [46، 47].

تهدف تقنية تتبع نقطة القدرة العظمى MPPT إلى معالجة هذا المشكل من خلال تعديل نقطة تشغيل اللوح بشكل مستمر، بحيث يبقى النظام قريبًا من النقطة التي تعطي أكبر قدرة كهربائية ممكنة. ويتم ذلك عادة باستعمال محول مستمر-مستمر DC-DC بين اللوح والحمل، حيث تسمح دورة العمل D الخاصة بالمحول بتغيير العلاقة الكهربائية بين المصدر والحمل وبالتحكم في هذه الدورة، يمكن تعديل الجهد والتيار اللذين يعمل عندهما اللوح، ومن ثم دفعه نحو نقطة القدرة العظمى [16، 46].

توجد عدة خوارزميات تستعمل لتحقيق MPPT، وتختلف فيما بينها من حيث البساطة، سرعة الاستجابة، الدقة، والقدرة على التعامل مع تغير ظروف التشغيل. ومن بين الخوارزميات التقليدية واسعة الاستعمال خوارزمية الاضطراب والملاحظة P&O، التي تعتمد على إحداث تغير صغير في الجهد أو دورة العمل، ثم ملاحظة أثر هذا التغير على القدرة المستخرجة. فإذا زادت القدرة، يستمر التغير في نفس الاتجاه، أما إذا انخفضت، فيتم عكس الاتجاه [48].

غير أن الطرق التقليدية قد تظهر بعض المحدوديات، خاصة عند تغير ظروف التشغيل بسرعة، أو عند حدوث تذبذبات حول نقطة القدرة العظمى. ولذلك اتجهت العديد من الدراسات إلى استعمال تقنيات ذكية، مثل الشبكات العصبية الاصطناعية، بهدف تحسين عملية التتبع وتقليل التذبذبات وزيادة سرعة الاستجابة. وفي هذه المذكرة سيتم الاعتماد على خوارزمية P&O بوصفها مرجعًا لتوليد قاعدة بيانات تدريبية، ثم استعمال شبكة عصبية لتقريب العلاقة بين القياسات الكهربائية للوح ودورة العمل المناسبة.

وبذلك يمثل هذا القسم نقطة انتقال طبيعية نحو الفصل الثاني، الذي سيخصص لدراسة تقنيات MPPT وخوارزمية P&O بشكل أكثر تفصيلًا، باعتبارها الخوارزمية المرجعية المعتمدة في الجانب التطبيقي من هذه الدراسة.

12.1 خلاصة الفصل

تناول هذا الفصل الأسس العامة للأنظمة الكهروضوئية، انطلاقاً من التطور التاريخي للطاقة الشمسية الكهروضوئية، ثم مبدأ الظاهرة الكهروضوئية التي تسمح بتحويل الإشعاع الشمسي إلى طاقة كهربائية داخل الخلايا الشمسية. كما تم عرض بنية الخلية الكهروضوئية ودور وصلة P-N في فصل الشحنات الكهربائية وتوليد التيار، إضافة إلى توضيح كيفية تجميع الخلايا ضمن وحدات وأنظمة كهروضوئية قادرة على تزويد الأحمال الكهربائية بالطاقة.

كما تم التطرق إلى النموذج الكهربائي للخلية الكهروضوئية، خاصة النموذج أحادي الصمام، باعتباره من النماذج المستعملة في تمثيل السلوك غير الخطي للخلية داخل بيئات المحاكاة. وقد أتاح هذا النموذج فهم العلاقة بين التيار والجهد والقدرة، وكذلك تفسير شكل منحنى I-V و P-V، حيث تظهر نقطة القدرة العظمى بوصفها نقطة التشغيل المثلى التي تسمح باستخراج أكبر قدرة ممكنة من اللوح الكهروضوئي.

وأظهر الفصل أن أداء النظام الكهروضوئي يتأثر بشكل مباشر بالعوامل البيئية، خاصة شدة الإشعاع الشمسي ودرجة حرارة الخلية، إضافة إلى أثر التظليل الجزئي في بعض الحالات. وتؤدي هذه العوامل إلى تغير مستمر في موضع نقطة القدرة العظمى، مما يجعل تشغيل النظام عند نقطة ثابتة غير كافٍ لتحقيق أفضل مردود طاقي.

وبناءً على ذلك، تبرز ضرورة استعمال تقنيات تتبع نقطة القدرة العظمى MPPT، التي تهدف إلى تعديل نقطة تشغيل اللوح بشكل مستمر من أجل الحفاظ على استخراج أكبر قدرة ممكنة. ومن هنا ينتقل الفصل التالي إلى دراسة مبدأ MPPT وخوارزمية P&O، باعتبارها الخوارزمية المرجعية التي سيتم الاعتماد عليها لاحقاً في توليد قاعدة البيانات الخاصة بتدريب الشبكة العصبية.

الفصل الثاني:

استراتيجيات تتبع النقطة القصوى
للطاقة (MPPT) في الأنظمة
الكهروضوئية

الفصل الثاني: استراتيجيات تتبع النقطة القصوى للطاقة (MPPT) في الأنظمة الكهروضوئية

1.2 مقدمة

أظهر الفصل السابق أن أداء النظام الكهروضوئي يتأثر بشكل مباشر بتغير الإشعاع الشمسي ودرجة حرارة الخلية، مما يؤدي إلى تغير مستمر في منحنى التيار-الجهد والقدرة-الجهد. ونتيجة لذلك، فإن نقطة القدرة العظمى لا تبقى ثابتة، بل تنتقل من موضع إلى آخر تبعاً لظروف التشغيل. وهذا يعني أن ربط اللوح الكهروضوئي بالحمل مباشرة لا يضمن دائماً استخراج أكبر قدرة ممكنة، لأن نقطة التشغيل قد تكون بعيدة عن نقطة القدرة العظمى.

من أجل معالجة هذا الإشكال، تُستعمل تقنيات تتبع نقطة القدرة العظمى MPPT، التي تهدف إلى إجبار النظام الكهروضوئي على العمل قرب النقطة التي تعطي أكبر قدرة كهربائية ممكنة. ويتم ذلك عادة من خلال التحكم في محول مستمر-مستمر DC-DC، حيث تُعدّل دورة العمل D الخاصة بالمحول من أجل تغيير نقطة تشغيل اللوح، وتحسين توافقه مع الحمل الكهربائي [46، 47].

توجد عدة خوارزميات لتتبع نقطة القدرة العظمى، تختلف من حيث البساطة، سرعة الاستجابة، دقة التتبع، والحساسية تجاه تغير ظروف التشغيل. ومن بين هذه الخوارزميات، تُعد خوارزمية الاضطراب والملاحظة P&O من أكثر الطرق التقليدية استعمالاً، نظراً لبساطة مبدئها وسهولة تنفيذها داخل بيئات المحاكاة والأنظمة العملية [48]. وتعتمد هذه الخوارزمية على إحداث تغير صغير في نقطة التشغيل، ثم ملاحظة أثره على القدرة المستخرجة من اللوح الكهروضوئي.


يركز هذا الفصل على عرض مبدأ MPPT ودوره في تحسين مردود النظام الكهروضوئي، ثم توضيح علاقة المحول المستمر-المستمر بدورة العمل D، قبل الانتقال إلى دراسة خوارزمية P&O بوصفها الخوارزمية المرجعية المعتمدة لاحقاً في هذه المذكرة لتوليد قاعدة البيانات التدريبية الخاصة بالشبكة العصبية الاصطناعية.

2.2 مبدأ MPPT

تعتمد تقنية تتبع نقطة القدرة العظمى MPPT على فكرة أساسية تتمثل في جعل النظام الكهروضوئي يعمل عند النقطة التي تكون فيها القدرة الكهربائية المستخرجة من اللوح أكبر ما يمكن. وبما أن القدرة تعطى بالعلاقة $P = V \times I$ ، فإن أي تغيير في الجهد أو التيار يؤدي إلى تغيير القدرة الناتجة. لذلك فإن تحديد نقطة التشغيل المناسبة يتطلب مراقبة مستمرة للجهد والتيار، ثم تعديل نقطة التشغيل بما يسمح بالاقتراب من نقطة القدرة العظمى على منحنى P-V [46، 47].

لا تكون نقطة القدرة العظمى ثابتة، لأنها تتغير مع تغير الإشعاع الشمسي ودرجة حرارة الخلية والحمل الكهربائي. فعند ارتفاع الإشعاع، تزداد القدرة المتاحة من اللوح، بينما يؤدي انخفاض الإشعاع أو ارتفاع درجة الحرارة إلى تغيير موضع النقطة المثلى. ولهذا فإن النظام الذي يعمل عند نقطة ثابتة قد يفقد جزءاً من الطاقة المتاحة، خاصة في ظروف التشغيل المتغيرة. ومن هنا تظهر أهمية MPPT بوصفها آلية تحكم تسمح بتحسين استغلال الطاقة الشمسية المتاحة في كل لحظة [16، 52].

يعتمد متحكم MPPT عادة على قياس الجهد والتيار الخارجين من اللوح الكهروضوئي، ثم حساب القدرة ومقارنتها مع قيم سابقة أو مرجعية حسب الخوارزمية المستعملة. بعد ذلك، يقوم المتحكم بتعديل دورة العمل (D) الخاصة بالمحول المستمر-المستمر، مما يؤدي إلى تغيير الجهد والتيار اللذين يعمل عندهما اللوح. وبهذه الطريقة يتم نقل نقطة التشغيل تدريجياً نحو نقطة القدرة العظمى.



الشكل 1.2: مبدأ عمل MPPT

يبين الشكل أن متحكم MPPT يستقبل قيم الجهد والتيار من اللوح الكهروضوئي، ثم يولد إشارة تحكم للمحول من أجل تعديل نقطة التشغيل والاقتراب من نقطة القدرة العظمى.

تتمثل أهمية MPPT في أنها لا تزيد القدرة الناتجة من اللوح نفسه، وإنما تسمح باستخراج أكبر قدرة متاحة ضمن ظروف التشغيل الحالية. أي إن دورها هو تحسين نقطة التشغيل وليس تغيير الخصائص الفيزيائية للوح. لذلك تعد هذه التقنية عنصراً أساسياً في الأنظمة الكهروضوئية الحديثة، خاصة عندما


تكون الظروف البيئية متغيرة أو عندما يكون الحمل غير ثابت.

3.2 المحول ودورة العمل

يُعد المحول المستمر-المستمر DC-DC عنصرًا أساسيًا في أنظمة الطاقة الكهروضوئية، لأنه يسمح بتكييف الجهد والتيار بين اللوح الكهروضوئي والحمل الكهربائي. فاللوح لا يعطي جهدًا والتيارًا ثابتين، بل تتغير قيمه الكهربائية تبعًا للإشعاع الشمسي ودرجة الحرارة وطبيعة الحمل. لذلك، فإن الربط المباشر بين اللوح والحمل قد يجعل نقطة التشغيل بعيدة عن نقطة القدرة العظمى، مما يؤدي إلى ضياع جزء من القدرة المتاحة [16، 46].

تتمثل وظيفة المحول في تغيير العلاقة الكهربائية بين المصدر والحمل، بحيث يمكن التحكم في الجهد والتيار اللذين يعمل عندهما اللوح الكهروضوئي. ويتم ذلك من خلال التحكم في دورة العمل (D)، وهي النسبة بين زمن تشغيل المفتاح الإلكتروني وزمن الدورة الكلية لإشارة التحكم. فعندما تتغير قيمة (D)، تتغير خصائص المحول، وبالتالي تتغير نقطة تشغيل اللوح على منحنى القدرة-الجهد. لهذا السبب تُعد دورة العمل المتغير الأساسي الذي تتحكم فيه أغلب خوارزميات MPPT [46، 47].

في كثير من الأنظمة الكهروضوئية، يُستعمل المحول الرفع Boost Converter عندما يكون الهدف هو رفع جهد الخرج إلى قيمة أعلى من جهد اللوح. ويعتمد عمل هذا المحول على مفتاح إلكتروني، وملف، وديود، ومكثف. خلال فترة غلق المفتاح، يخزن الملف الطاقة في مجاله المغناطيسي، وخلال فترة فتح المفتاح، تُنقل هذه الطاقة إلى جهة الخرج مع جهد أعلى من جهد الدخل. وتتحكم قيمة دورة العمل (D) في مقدار رفع الجهد، وبالتالي في نقطة تشغيل اللوح [24، 46].



الشكل 2.2: المحول الرفع Boost Converter

يبين الشكل البنية العامة للمحول الرفع، حيث يتم التحكم في المفتاح الإلكتروني بواسطة إشارة PWM ناتجة عن دورة العمل (D). ويسمح تغيير هذه الدورة بتعديل الجهد والتيار، ومن ثم تغيير نقطة تشغيل اللوح الكهروضوئي.

تُؤد إشارة التحكم في المفتاح عادة باستعمال تقنية تعديل عرض النبضة PWM. في هذه التقنية، يتم تحويل قيمة دورة العمل (D) إلى إشارة نبضية بين حالتين، حالة تشغيل وحالة إيقاف. وكلما ارتفعت قيمة (D)، زادت مدة بقاء المفتاح في حالة التشغيل خلال كل دورة. وبذلك تصبح خوارزمية MPPT مسؤولة عن تحديد القيمة المناسبة لـ (D)، بينما يقوم مولد PWM بتحويلها إلى إشارة قابلة لقيادة المفتاح الإلكتروني.

تظهر أهمية هذا المفهوم في الجانب التطبيقي من هذه المذكرة، لأن خوارزمية P&O ستستعمل لاحقاً لتوليد قيمة مرجعية لدورة العمل (Dref). وبعد ذلك، سيتم تدريب شبكة عصبية اصطناعية على إنتاج هذه القيمة اعتماداً على القياسات الكهربائية للوح، أي الجهد (V_{pv}) والتيار (I_{pv}). وبذلك يصبح خرج الشبكة العصبية هو دورة العمل التي تتحكم في المحول الرفع داخل نموذج Simulink.

4.2 طرق MPPT

توجد عدة طرق وخوارزميات تستعمل لتتبع نقطة القدرة العظمى في الأنظمة الكهروضوئية، وتختلف هذه الطرق من حيث مبدأ العمل، عدد الحساسات المطلوبة، سرعة الاستجابة، الدقة، سهولة التنفيذ، والقدرة على التعامل مع تغير ظروف التشغيل. ويمكن تصنيف طرق MPPT عموماً إلى طرق تقليدية، وطرق ذكية، وطرق هجينة. ويعتمد اختيار الطريقة المناسبة على طبيعة النظام، مستوى التعقيد المقبول، ودقة التتبع المطلوبة [46، 47].

تُعد الطرق التقليدية من أكثر الطرق استعمالاً في التطبيقات البسيطة والمتوسطة، بسبب سهولة تنفيذها وقلة متطلباتها الحسابية. ومن أبرز هذه الطرق خوارزمية الاضطراب والملاحظة P&O وخوارزمية الناقلية التزايدية Incremental Conductance. تعتمد هذه الطرق غالباً على قياس الجهد والتيار، ثم حساب القدرة واستنتاج اتجاه تعديل نقطة التشغيل. وتتميز ببساطتها، لكنها قد تعاني من تذبذبات حول نقطة القدرة العظمى، خاصة في حالة التغير السريع للإشعاع الشمسي أو درجة الحرارة [48].

أما الطرق الذكية، فتعتمد على تقنيات قادرة على التعامل مع السلوك غير الخطي للنظام الكهروضوئي، مثل الشبكات العصبية الاصطناعية، المنطق الضبابي، والخوارزميات التطورية. وتتميز هذه الطرق بإمكانية تحسين سرعة الاستجابة وتقليل التذبذبات في بعض الحالات، لكنها تحتاج غالباً إلى تصميم أدق أو قاعدة بيانات مناسبة أو خبرة مسبقة في ضبط المتحكم. وتُعد الشبكات العصبية من بين الطرق التي يمكن توظيفها لتقريب العلاقة بين متغيرات النظام الكهربائية ودورة العمل المناسبة، وهو ما يجعلها

مناسبة لتطبيقات MPPT في الأنظمة غير الخطية [59، 60].

كما توجد طرق هجينة تجمع بين مزايا الطرق التقليدية والذكية، مثل استعمال خوارزمية تقليدية لتوليد بيانات مرجعية، ثم تدريب نموذج ذكي على تقليد سلوكها أو تحسين استجابتها. ويقع العمل المنجز في هذه المذكرة ضمن هذا الاتجاه، حيث يتم اعتماد خوارزمية P&O-MPPT كمرجع لتوليد دورة العمل المناسبة، ثم تُستعمل البيانات الناتجة لتدريب شبكة عصبية اصطناعية قادرة على إنتاج قيمة (D) انطلاقاً من القياسات الكهربائية للوح الكهروضوئي.

يعرض الجدول الآتي مقارنة موجزة بين بعض طرق MPPT الشائعة من حيث المبدأ والمزايا والمحددات.

الجدول 1.2: مقارنة بين طرق MPPT

المحددات	المزايا	المبدأ العام	الطريقة الاسم بالإنجليزية
تذبذب حول نقطة القدرة العظمى	بسيطة وسهلة التنفيذ	إحداث اضطراب صغير في نقطة التشغيل وملاحظة تغير القدرة	الاضطراب والملاحظة Perturb and Observe (P&O)
أكثر تعقيداً في الحساب والتنفيذ	أدق من P&O في بعض التغيرات السريعة	مقارنة الناقلية اللحظية بالناقلية الترايضية لتحديد اتجاه التتبع	الناقلية الترايضية Incremental Conductance (INC)
دقتها محدودة عند تغير الظروف	بسيطة جداً	تقريب جهد نقطة القدرة العظمى كنسبة من جهد الدارة المفتوحة	الجهد الثابت Constant Voltage (CV)
تحتاج قياساً أو تقديرًا لتيار القصر	سهولة التنفيذ	تقريب تيار نقطة القدرة العظمى كنسبة من تيار القصر	التيار الثابت Constant Current (CC)
يحتاج ضبطاً دقيقاً للقواعد	مناسب للأنظمة غير الخطية	استعمال قواعد لغوية للتحكم في دورة العمل	المنطق الضبابي Fuzzy Logic Control (FLC)
تعتمد على جودة وشمولية بيانات التدريب	سرعة في الاستجابة بعد التدريب	التعلم من بيانات تدريبية لربط المدخلات بدورة العمل المناسبة	الشبكات العصبية الاصطناعية Artificial Neural Networks (ANN)
تحتاج حسابات أكثر وزمن تنفيذ أكبر	مفيدة في حالات التظليل الجزئي	البحث عن نقطة القدرة العظمى باستعمال سلوك جماعي مستوحى من حركة الأسراب	أسراب الجسيمات Particle Swarm Optimization (PSO)
أكثر تعقيداً في التصميم والتنفيذ	تجمع مزايا أكثر من طريقة	دمج طريقتين أو أكثر لتحسين الأداء	الطرق الهجينة Hybrid Methods

يبين الجدول (1.2) أن طرق MPPT تختلف من حيث مبدأ العمل والدقة وسهولة التنفيذ. وتتميز الطرق التقليدية مثل P&O و INC ببساطتها واعتمادها المباشر على قياس الجهد والتيار، بينما تسمح الطرق الذكية مثل FLC و ANN بالتعامل بشكل أفضل مع السلوك غير الخطي للنظام الكهروضوئي. وفي هذه المذكرة، تم اعتماد خوارزمية P&O كمرجع لتوليد دورة العمل المناسبة، ثم استعمال هذه القيم لتدريب شبكة عصبية اصطناعية.

5.2 خوارزمية P&O


تُعد خوارزمية الاضطراب والملاحظة (Perturb and Observe (P&O) من أكثر خوارزميات تتبع نقطة القدرة العظمى استعمالاً في الأنظمة الكهروضوئية، وذلك بسبب بساطة مبدئها وسهولة تنفيذها داخل أنظمة التحكم الرقمية وبيئات المحاكاة. وتعتمد هذه الخوارزمية على فكرة إحداث تغيير صغير في نقطة تشغيل اللوح الكهروضوئي، ثم ملاحظة أثر هذا التغيير على القدرة الكهربائية المستخرجة. فإذا أدى الاضطراب إلى زيادة القدرة، يستمر التحكم في نفس الاتجاه، أما إذا أدى إلى انخفاض القدرة، فيتم عكس اتجاه الاضطراب [48].

يعتمد مبدأ عمل الخوارزمية على قياس الجهد (V_{pv}) والتيار (I_{pv}) الخارجين من اللوح الكهروضوئي، ثم حساب القدرة الكهربائية وفق العلاقة:

$$P_{pv} = V_{pv} \times I_{pv}$$

بعد ذلك تتم مقارنة القدرة الحالية ($P(k)$) بالقدرة السابقة ($P(k-1)$)، كما تتم مقارنة الجهد الحالي ($V(k)$) بالجهد السابق ($V(k-1)$). ومن خلال هاتين المقارنتين، تحدد الخوارزمية اتجاه تعديل نقطة التشغيل. فإذا كانت القدرة تزداد مع زيادة الجهد، فهذا يعني أن نقطة التشغيل تتحرك نحو نقطة القدرة العظمى، لذلك يستمر الاضطراب في نفس الاتجاه. أما إذا كانت القدرة تنخفض، فهذا يعني أن نقطة التشغيل ابتعدت عن النقطة المثلى، وبالتالي يجب تغيير اتجاه الاضطراب [48، 49].

يمكن تلخيص منطق خوارزمية P&O كما يلي: عندما يكون التغيير في القدرة موجباً، فإن اتجاه الاضطراب السابق كان مناسباً ويجب الحفاظ عليه. أما عندما يكون التغيير في القدرة سالباً، فإن اتجاه الاضطراب السابق كان غير مناسب ويجب عكسه. وبذلك تتحرك نقطة التشغيل تدريجياً على منحنى القدرة-الجهد حتى تقترب من نقطة القدرة العظمى. وعند الوصول إلى هذه النقطة، تبدأ الخوارزمية عادة في إحداث تذبذبات صغيرة حولها بسبب استمرار عملية الاضطراب والملاحظة.



الشكل 3.2: خوارزمية P&O

يوضح الشكل مراحل تنفيذ خوارزمية P&O، بداية من قياس الجهد والتيار، ثم حساب القدرة، ومقارنة القيم الحالية بالقيم السابقة، وصولاً إلى تعديل دورة العمل (D) الخاصة بالمحول.

في أنظمة التحكم التي تعتمد على المحول المستمر-المستمر، لا يتم التحكم في نقطة تشغيل اللوح مباشرة، بل يتم ذلك من خلال تعديل دورة العمل (D). لذلك فإن خرج خوارزمية P&O يكون عادة قيمة جديدة لدورة العمل، يتم إرسالها إلى مولد PWM للتحكم في مفتاح المحول. ويؤدي تغيير (D) إلى تغيير الجهد والتيار عند مدخل المحول، وبالتالي نقل نقطة تشغيل اللوح نحو نقطة القدرة العظمى.

تتميز خوارزمية P&O ببساطتها وعدم حاجتها إلى معرفة مسبقة دقيقة بخصائص اللوح الكهروضوئي، إذ يكفي قياس الجهد والتيار لحساب القدرة واتخاذ قرار التحكم. كما أنها سهلة التطبيق في MATLAB/Simulink، مما يجعلها مناسبة لتوليد بيانات مرجعية في هذه الدراسة. ولهذا السبب تم اعتمادها في الجانب التطبيقي من المذكرة لتوليد دورة العمل المرجعية (D_{ref})، التي ستستعمل لاحقاً

كهدف تدريبي للشبكة العصبية الاصطناعية.

ومع ذلك، فإن لهذه الخوارزمية بعض المحدوديات، من أهمها ظهور تذبذبات حول نقطة القدرة العظمى بعد الوصول إليها، لأن الخوارزمية تستمر في إحداث اضطرابات صغيرة حتى في حالة الاستقرار. كما يمكن أن تتأثر دقتها عند تغير الإشعاع الشمسي بسرعة، لأن الخوارزمية قد تفسر تغير القدرة الناتج عن تغير الإشعاع على أنه نتيجة للاضطراب المطبق، مما قد يؤدي إلى اتخاذ قرار غير مناسب في بعض الحالات الانتقالية [48، 49].

6.2 حدود خوارزمية P&O

رغم أن خوارزمية الاضطراب والملاحظة P&O تُعد من أكثر خوارزميات MPPT استعمالاً بسبب بساطتها وسهولة تنفيذها، إلا أن أدائها قد يتأثر ببعض المحدوديات المرتبطة بطبيعة مبدأ عملها. فهذه الخوارزمية تعتمد على إحداث اضطراب صغير في نقطة التشغيل، ثم ملاحظة تغير القدرة الناتجة عن هذا الاضطراب. وبما أن عملية الاضطراب تستمر حتى بعد الاقتراب من نقطة القدرة العظمى، فإن نقطة التشغيل لا تستقر تمامًا عند هذه النقطة، بل تظهر عادة تذبذبات صغيرة حولها [48].

تؤدي هذه التذبذبات إلى تغيرات مستمرة في الجهد والتيار ودورة العمل، مما قد يسبب فقداناً جزئياً في القدرة المستخرجة، خاصة إذا كانت قيمة خطوة الاضطراب كبيرة. فكلما كانت خطوة الاضطراب كبيرة، زادت سرعة الوصول إلى نقطة القدرة العظمى، لكن التذبذب حولها يصبح أكبر. أما إذا كانت خطوة الاضطراب صغيرة، فإن التذبذب يقل، لكن سرعة الاستجابة تصبح أبطأ. لذلك يوجد دائماً نوع من التوازن بين سرعة التتبع ودقة الاستقرار حول نقطة القدرة العظمى [48، 49].

كما قد تواجه خوارزمية P&O صعوبة في ظروف التشغيل السريعة التغير، خاصة عند حدوث تغير مفاجئ في الإشعاع الشمسي. ففي هذه الحالة، قد تتغير القدرة الناتجة من اللوح بسبب تغير الإشعاع، وليس بسبب الاضطراب الذي طبقته الخوارزمية. وقد يؤدي ذلك إلى تفسير غير دقيق لاتجاه تغير القدرة، وبالتالي اتخاذ قرار تحكم غير مناسب. وتظهر هذه المشكلة بوضوح عندما تكون تغيرات الإشعاع أسرع من قدرة الخوارزمية على التتبع [49، 52].

ومن جهة أخرى، يمكن أن يصبح أداء خوارزمية P&O أكثر تعقيداً في حالة التظليل الجزئي، حيث قد يحتوي منحنى القدرة-الجهد على عدة نقاط قدرة محلية. في مثل هذه الحالة، قد تتجه الخوارزمية نحو نقطة قدرة محلية بدل الوصول إلى نقطة القدرة العظمى العامة، خاصة إذا كان البحث محصوراً في منطقة معينة من منحنى P-V. وهذا يبين أن بساطة الخوارزمية قد تكون غير كافية في بعض ظروف التشغيل غير المنتظمة [49].

ومع ذلك، تبقى خوارزمية P&O مناسبة جدًا كخوارزمية مرجعية في هذه الدراسة، لأنها توفر طريقة مباشرة لتوليد قيم دورة العمل الموافقة لنقطة تشغيل قريبة من نقطة القدرة العظمى. وبناءً على ذلك، سيتم استعمال خرج هذه الخوارزمية في الجانب التطبيقي لتكوين قاعدة بيانات تدريبية، بحيث تتعلم الشبكة العصبية العلاقة بين القياسات الكهربائية للوح الكهروضوئي، والمتمثلة في الجهد (V_{pv}) والتيار (I_{pv})، وبين دورة العمل المرجعية (D_{ref}).

ومن هنا يظهر دور الشبكات العصبية الاصطناعية كخيار مساعد لتحسين عملية التتبع. فبدل الاعتماد في كل لحظة على الاضطراب والملاحظة، يمكن تدريب شبكة عصبية على بيانات ناتجة عن خوارزمية P&O، ثم استعمالها لاحقاً لإنتاج دورة العمل المناسبة مباشرة. وهذا ما سيتم التمهيد له في الفصل الثالث، من خلال عرض مبادئ الشبكات العصبية الاصطناعية وطريقة توظيفها في تطبيقات MPPT.

7.2 خلاصة الفصل

تناول هذا الفصل مبدأ تتبع نقطة القدرة العظمى MPPT في الأنظمة الكهروضوئية، باعتباره آلية أساسية لتحسين استغلال الطاقة المتاحة من اللوح الشمسي. وقد تم توضيح أن نقطة القدرة العظمى لا تكون ثابتة، بل تتغير تبعاً لتغير الإشعاع الشمسي ودرجة حرارة الخلية والحمل الكهربائي. لذلك فإن تشغيل النظام دون متحكم MPPT قد يؤدي إلى عمل اللوح عند نقطة غير مثلى، مما يسبب فقدان جزء من القدرة الممكن استخراجها.

كما تم التطرق إلى دور المحول المستمر-المستمر ودورة العمل (D) في ضبط نقطة تشغيل اللوح الكهروضوئي. وقد تبين أن خوارزمية MPPT لا تتحكم في اللوح مباشرة، وإنما تعدل دورة العمل الخاصة بالمحول، مما يؤدي إلى تغيير الجهد والتيار عند طرفي اللوح، وبالتالي نقل نقطة التشغيل نحو نقطة القدرة العظمى.

تم أيضاً عرض مجموعة من طرق MPPT، مع التمييز بين الطرق التقليدية، مثل خوارزمية الاضطراب والملاحظة P&O والناقلية التزايدية، والطرق الذكية مثل المنطق الضبابي والشبكات العصبية الاصطناعية. وقد أظهر هذا العرض أن لكل طريقة مزايا ومحدوديات، وأن اختيار الطريقة المناسبة يرتبط بطبيعة التطبيق، درجة التعقيد المقبولة، ودقة التتبع المطلوبة.

ركز الفصل بشكل خاص على خوارزمية P&O، باعتبارها الخوارزمية المرجعية المعتمدة في هذه المذكرة. وقد تم شرح مبدأ عملها القائم على إحداث اضطراب صغير في نقطة التشغيل وملاحظة أثره على القدرة المستخرجة. ورغم بساطتها وسهولة تنفيذها، فإنها قد تعاني من تذبذبات حول نقطة القدرة العظمى، كما قد تتأثر أداؤها عند تغير ظروف التشغيل بسرعة.

وبناءً على ما سبق، يمهد هذا الفصل للفصل الثالث، الذي سيخصص لدراسة الشبكات العصبية الاصطناعية. وسيتم التركيز فيه على كيفية توظيف هذه الشبكات لتعلم العلاقة بين القياسات الكهربائية للوح الكهروضوئي ودورة العمل المناسبة، تمهيداً لاستعمالها لاحقاً في تحسين تتبع نقطة القدرة العظمى داخل النموذج التطبيقي.

الفصل الثالث:

أساسيات الشبكات العصبية
الاصطناعية وتطبيقاتها.

الفصل الثالث: أساسيات الشبكات العصبية الاصطناعية وتطبيقاتها.

1.3 مقدمة

بعد أن تناول الفصل السابق مبدأ تتبع نقطة القدرة العظمى وخوارزمية الاضطراب والملاحظة P&O، تبين أن هذه الخوارزمية تمثل طريقة بسيطة وفعالة لتوليد دورة العمل المناسبة للمحول، غير أنها قد تعاني من بعض التذبذبات حول نقطة القدرة العظمى، خاصة في ظروف التشغيل المتغيرة [48، 49]. ومن هذا المنطلق، تظهر الحاجة إلى تقنيات قادرة على تمثيل العلاقة غير الخطية بين متغيرات النظام الكهروضوئي ودورة العمل المناسبة، مع تقليل الاعتماد على عمليات البحث أو الاضطراب المتكرر أثناء التشغيل.

تعد الشبكات العصبية الاصطناعية Artificial Neural Networks من أهم أدوات الذكاء الاصطناعي المستعملة في نمذجة الأنظمة غير الخطية، وذلك بفضل قدرتها على التعلم من البيانات واستخلاص العلاقة بين المدخلات والمخرجات دون الحاجة إلى صياغة رياضية دقيقة لكل تفاصيل النظام [59، 60]. وتكتسب هذه الخاصية أهمية خاصة في الأنظمة الكهروضوئية، لأن العلاقة بين الجهد والتيار والقدرة ودورة العمل المناسبة ليست علاقة خطية ثابتة، بل تتغير حسب ظروف التشغيل [61، 62].

وقد استُعملت الشبكات العصبية في عدة تطبيقات مرتبطة بتتبع نقطة القدرة العظمى، سواء من أجل تقدير الجهد الموافق لنقطة القدرة العظمى، أو تقدير القدرة القصوى، أو إنتاج دورة العمل المناسبة للمحول مباشرة [61، 62]. وفي سياق هذه المذكرة، لا تُستعمل الشبكة العصبية كبديل نظري عام لجميع خوارزميات MPPT، وإنما تُوظف بطريقة محددة، حيث يتم تدريبها على بيانات مرجعية مستخرجة من خوارزمية P&O-MPPT.

تتمثل فكرة العمل في استعمال الجهد V_{pv} والتيار I_{pv} كمدخلين للشبكة، بينما تمثل دورة العمل المرجعية D_{ref} المخرج المستهدف. وبذلك تتعلم الشبكة تقريب العلاقة بين الحالة الكهربائية للوح الكهروضوئي وقيمة دورة العمل المناسبة للتحكم في المحول الرفع. ويهدف هذا الفصل إلى عرض المفاهيم الأساسية للشبكات العصبية الاصطناعية بالقدر الذي يخدم التطبيق المعتمد في هذه الدراسة، تمهيداً لتنفيذها وتقييمها في الفصل الرابع.

2.3 مفهوم الشبكات العصبية


الشبكات العصبية الاصطناعية هي نماذج حسابية مستوحاة من طريقة عمل الجهاز العصبي الحيوي، لكنها تُستعمل هندسياً كأدوات رياضية قادرة على تمثيل العلاقات المعقدة بين مجموعة من المدخلات والمخرجات. وتعتمد هذه الشبكات على وحدات حسابية بسيطة تسمى العصبونات الاصطناعية، تقوم باستقبال إشارات دخل متعددة، ثم تضرب كل إشارة في وزن معين، وبعد ذلك تجمع القيم الناتجة وتطبق عليها دالة تنشيط لإنتاج خرج محدد. ومن خلال تعديل الأوزان أثناء التدريب، تصبح الشبكة قادرة على تقريب العلاقة بين البيانات المدخلة والنتائج المطلوبة [59، 60].

تكمُن أهمية الشبكات العصبية في قدرتها على التعامل مع الأنظمة غير الخطية، أي الأنظمة التي لا يمكن وصف العلاقة بين متغيراتها بمعادلة بسيطة أو مباشرة. فالعديد من الأنظمة الهندسية، ومنها الأنظمة الكهروضوئية، تتميز بسلوك متغير ومعقد بسبب تأثير عدة عوامل في الوقت نفسه، مثل الإشعاع الشمسي، درجة الحرارة، والحمل الكهربائي. في هذه الحالات، يمكن للشبكة العصبية أن تتعلم من أمثلة تدريبية سابقة، بحيث تستنتج النمط العام للعلاقة بين المدخلات والمخرجات دون الحاجة إلى بناء نموذج رياضي تفصيلي لكل جزء من النظام [60، 61].

في تطبيقات التحكم، لا تقتصر وظيفة الشبكة العصبية على التصنيف أو التنبؤ فقط، بل يمكن استعمالها لتوليد إشارة تحكم مناسبة اعتمادًا على حالة النظام. فبدل أن تعتمد وحدة التحكم على معادلات تحليلية مباشرة، يمكن تدريب الشبكة على مجموعة من الحالات المعروفة، بحيث تتعلم كيفية إعطاء الخرج المناسب عند ظهور حالة مشابهة. وهذا ما يجعلها مناسبة لتطبيقات MPPT، حيث تكون العلاقة بين الجهد والتيار ودورة العمل المناسبة علاقة غير خطية وتتغير بتغير ظروف التشغيل [61، 62].

في هذه المذكرة، تُستعمل الشبكة العصبية كأداة لتقريب سلوك خوارزمية P&O-MPPT. فبعد توليد قاعدة بيانات مرجعية باستعمال خوارزمية P&O، يتم تدريب الشبكة على العلاقة بين القيم الكهربائية للوح الكهروضوئي، المتمثلة في V_{pv} و I_{pv} ، وبين دورة العمل المرجعية Dref. وبذلك لا تُدرَّب الشبكة على الإشعاع والحرارة مباشرة، وإنما على الاستجابة الكهربائية الناتجة عن تغير هذه الظروف داخل النظام الكهروضوئي.

يوضح الشكل الآتي المبدأ العام للعصبون الاصطناعي، حيث تستقبل الوحدة الحسابية مجموعة من المدخلات، ثم تطبق عليها أوزانًا ومعامل انحياز، قبل تمرير النتيجة عبر دالة تنشيط لإنتاج الخرج.



الشكل 1.3: العصبون الاصطناعي

يبين الشكل البنية الأساسية للعصبون الاصطناعي، حيث يتم تجميع المدخلات بعد ضربها في الأوزان الموافقة، ثم تمريرها عبر دالة تنشيط للحصول على الخرج النهائي.

3.3 بنية الشبكة العصبية

تتكون الشبكة العصبية الاصطناعية من مجموعة من العصبونات المترابطة فيما بينها وفق بنية طبقية. وتضم هذه البنية عادة طبقة إدخال، طبقة أو أكثر مخفية، وطبقة خرج. تقوم طبقة الإدخال باستقبال المتغيرات التي تصف حالة النظام، بينما تتولى الطبقات المخفية معالجة هذه المعطيات من خلال الأوزان ودوال التنشيط، ثم تنتج طبقة الخرج القيمة المطلوبة. ويُعد اختيار عدد المدخلات والمخرجات وعدد العصبونات في الطبقات المخفية من العوامل المهمة التي تؤثر في قدرة الشبكة على التعلم والتعميم [59، 60].


تمثل طبقة الإدخال نقطة الاتصال بين الشبكة والبيانات المستعملة في التدريب. ففي تطبيقات التحكم في الأنظمة الكهروضوئية، يمكن أن تكون المدخلات عبارة عن متغيرات بيئية مثل الإشعاع ودرجة

الحرارة، أو متغيرات كهربائية مثل الجهد والتيار. وفي هذه المذكرة، تم اعتماد الجهد V_{pv} والتيار I_{pv} كمدخلين للشبكة العصبية، لأنهما يعبران مباشرة عن الحالة الكهربائية للوح الكهروضوئي، كما أنهما متغيران قابلان للقياس داخل النموذج وفي التطبيقات العملية.

أما الطبقات المخفية، فهي الجزء المسؤول عن معالجة العلاقة غير الخطية بين المدخلات والمخرج. تحتوي هذه الطبقات على عصبونات ترتبط فيما بينها بواسطة أوزان يتم تعديلها أثناء التدريب. وكلما كانت العلاقة بين المدخلات والمخرجات أكثر تعقيداً، زادت الحاجة إلى بنية قادرة على تمثيل هذا التعقيد. غير أن زيادة عدد العصبونات أو الطبقات بشكل مفرط قد تؤدي إلى تعقيد النموذج أو إلى الإفراط في التعلم، لذلك يجب اختيار بنية تحقق توازناً بين الدقة والبساطة [60، 63].

تمثل طبقة الخرج النتيجة التي تنتجها الشبكة بعد معالجة المدخلات. وفي هذه الدراسة، تتكون طبقة الخرج من عصبون واحد فقط، لأن الهدف هو إنتاج قيمة واحدة تمثل دورة العمل المرجعية D_{ref} أو دورة العمل الناتجة عن الشبكة D_{ANN} . وتُعد هذه القيمة ضرورية للتحكم في المحول الراجع، لأنها تُحول لاحقاً إلى إشارة PWM تقود المفتاح الإلكتروني داخل المحول.

بناءً على ذلك، يمكن تلخيص بنية الشبكة المستعملة في هذه المذكرة على النحو الآتي: مدخلان هما V_{pv} و I_{pv} ، طبقة أو طبقات مخفية لمعالجة العلاقة غير الخطية، ومخرج واحد يمثل دورة العمل المناسبة D . ويجعل هذا الاختيار الشبكة مرتبطة مباشرة بهدف الدراسة، وهو تقريب العلاقة بين القياسات الكهربائية للوح الكهروضوئي ودورة العمل المرجعية المستخرجة من خوارزمية P&O-MPPT.



الشكل 2.3: بنية الشبكة العصبية

يوضح الشكل البنية العامة للشبكة العصبية المستعملة، حيث تستقبل الشبكة قيمتي الجهد V_{pv} والتيار I_{pv} ، ثم تعالج هذه القيم داخل الطبقات المخفية لإنتاج دورة العمل D_{ANN} في طبقة الخرج.

4.3 التعلم الموجّه

يُعد التعلم الموجّه Supervised Learning من أكثر أنماط التعلم استعمالاً في تدريب الشبكات العصبية الاصطناعية، خاصة في التطبيقات الهندسية التي يكون فيها المخرج المطلوب معروفاً مسبقاً. ويعتمد هذا

النوع من التعلم على توفير قاعدة بيانات تحتوي على أزواج من المدخلات والمخرجات المرجعية، بحيث تتعلم الشبكة العلاقة التي تربط بينهما من خلال تكرار عملية التدريب وتعديل الأوزان الداخلية. وتكمن أهمية التعلم الموجه في قدرته على بناء نموذج تقريبي لعلاقة غير خطية، دون الحاجة إلى صياغة رياضية دقيقة لكل تفاصيل النظام المدروس [59، 60].

في هذا النمط من التعلم، تستقبل الشبكة العصبية متجه دخل يمثل حالة معينة للنظام، ثم تنتج خرجاً تتم مقارنته بالقيمة المرجعية الموافقة. وبناءً على الفرق بين الخرج المتوقع والخرج المرجعي، يتم حساب الخطأ ثم استعماله لتعديل الأوزان والانحيازات داخل الشبكة. وتتكرر هذه العملية عبر عدة مراحل تدريبية إلى أن يصبح خرج الشبكة قريباً من القيم المرجعية بدرجة مقبولة [60، 61].

يمكن التعبير عن مبدأ التعلم الموجه بشكل مبسط كما يلي:

- خرج الشبكة = القيمة المتوقعة من طرف النموذج
- القيمة المرجعية = القيمة الصحيحة أو المطلوبة
- الخطأ = القيمة المرجعية - خرج الشبكة

وبالرموز يمكن كتابة الخطأ كما يلي:

$$e = D_{ref} - D_{ANN}$$

حيث يمثل e خطأ التقدير، وتمثل D_{ref} دورة العمل المرجعية المستخرجة من خوارزمية P&O-MPPT، بينما تمثل D_{ANN} دورة العمل الناتجة عن الشبكة العصبية. وكلما كانت قيمة الخطأ صغيرة، دل ذلك على أن الشبكة استطاعت تقريب الخرج المرجعي بدقة أفضل [63، 64].

في سياق هذه المذكرة، تم اعتماد التعلم الموجه لأن الهدف من الشبكة العصبية واضح ومحدد، وهو إنتاج دورة العمل المناسبة للمحول الرافع اعتماداً على الحالة الكهربائية للوح الكهروضوئي. وتمثلت مدخلات الشبكة في جهد اللوح V_{pv} وتياره I_{pv} ، بينما مثلت دورة العمل المرجعية D_{ref} المخرج المستهدف. وقد تم الحصول على هذه القيم المرجعية باستعمال خوارزمية P&O-MPPT، التي استعملت بوصفها مرجعاً لتوليد قاعدة البيانات التدريبية.

ويمكن تمثيل مدخلات الشبكة في هذه الدراسة بالشكل الآتي:

$$X = [V_{pv} ; I_{pv}]$$

حيث يمثل X متجه الإدخال، ويمثل V_{pv} جهد اللوح الكهروضوئي، بينما يمثل I_{pv} تيار اللوح الكهروضوئي. أما خرج الشبكة فيمثل دورة العمل التي سيتم استعمالها لاحقاً في التحكم في المحول:

$$D_{ANN} = ANN(V_{pv}, I_{pv})$$

وتعني هذه العلاقة أن الشبكة العصبية تستقبل قيمتي الجهد والتيار، ثم تنتج قيمة دورة العمل المناسبة. أثناء التدريب، تتم مقارنة هذه القيمة مع D_{ref} ، وهي القيمة المرجعية الناتجة عن خوارزمية P&O-MPPT.

ولا تستعمل قيم الإشعاع الشمسي ودرجة الحرارة كمدخلات مباشرة للشبكة في هذا العمل، بل استعملت لتوليد ظروف تشغيل مختلفة داخل نموذج المحاكاة. ونتيجة تغير الإشعاع والحرارة، تتغير الاستجابة الكهربائية للوح، أي تتغير قيم V_{pv} و I_{pv} و P_{pv} ، ثم يتم استخراج قيمة D_{ref} الموافقة بواسطة خوارزمية P&O. وبذلك تتعلم الشبكة العلاقة الكهربائية المباشرة بين حالة اللوح ودورة العمل المناسبة، بدل أن

تتعلم من القيم البيئية مباشرة.

وتتوقف جودة التعلم الموجه بدرجة كبيرة على جودة قاعدة البيانات المستعملة في التدريب. فإذا كانت البيانات محدودة أو غير ممثلة لمجال التشغيل، فقد تحقق الشبكة نتائج جيدة داخل بيانات التدريب، لكنها تفشل في إعطاء نتائج دقيقة عند استعمالها في حالات جديدة. وتُعرف هذه المشكلة بالإفراط في التعلم Overfitting، حيث تميل الشبكة إلى حفظ أمثلة التدريب بدل تعلم العلاقة العامة بين المدخلات والمخرجات [60، 63].

ولهذا السبب، يجب أن تشمل قاعدة البيانات حالات تشغيل متنوعة تسمح للشبكة بالتعميم. وفي هذه الدراسة، تم توليد البيانات انطلاقاً من عدة سيناريوهات للإشعاع الشمسي ودرجة الحرارة، بهدف الحصول على قيم مختلفة للجهد والتيار ودورة العمل المرجعية. ويسمح هذا التنوع بتحسين قدرة الشبكة على تمثيل العلاقة بين V_{pv} و I_{pv} من جهة، و D_{ref} من جهة أخرى، وهو ما يهيئها للاستعمال لاحقاً داخل نموذج التحكم في Simulink.

5.3 تدريب الشبكة وتقييم الأداء

تُعد مرحلة تدريب الشبكة العصبية مرحلة أساسية في بناء النموذج، لأنها تسمح بضبط الأوزان والانحيازات الداخلية للشبكة حتى يصبح خرجها قريباً من القيم المرجعية المطلوبة. في بداية التدريب تكون الأوزان عادة غير مضبوطة بشكل مناسب، لذلك قد يكون الفرق بين خرج الشبكة والقيمة المرجعية كبيراً. ومع تكرار عملية التدريب، يتم تعديل هذه الأوزان تدريجياً اعتماداً على الخطأ المحسوب، مما يسمح بتحسين قدرة الشبكة على تمثيل العلاقة بين المدخلات والمخرجات [59، 60].

تعتمد عملية التدريب على تمرير بيانات الإدخال عبر طبقات الشبكة، ثم حساب الخرج الناتج ومقارنته مع الهدف المرجعي. بعد ذلك، يتم حساب الخطأ بين القيمتين، وتستعمل خوارزمية التدريب هذا الخطأ لتعديل معاملات الشبكة. وكلما تكررت هذه العملية على عدد أكبر من العينات، تصبح الشبكة أكثر قدرة على تقريب العلاقة المطلوبة، بشرط أن تكون البيانات المستعملة في التدريب ممثلة لمجال التشغيل المراد دراسته [60، 61].

في هذه الدراسة، تم تدريب الشبكة العصبية باستعمال قاعدة بيانات مستخرجة من نموذج النظام الكهروضوئي وخوارزمية P&O-MPPT. وتمثلت مدخلات الشبكة في جهد اللوح V_{pv} وتياره I_{pv} ، بينما مثلت دورة العمل المرجعية D_{ref} المخرج المستهدف. ويعني ذلك أن الشبكة دُرِبت على إنتاج قيمة دورة العمل المناسبة اعتماداً على القياسات الكهربائية للوح الكهروضوئي، وهو ما يتوافق مع الهدف التطبيقي للمذكورة.

يمكن تمثيل العلاقة التي تتعلمها الشبكة أثناء التدريب كما يلي:

$$X = [V_{pv} ; I_{pv}]$$

$$D_{ANN} = ANN(X)$$

أو بصورة مباشرة:

$$D_{ANN} = ANN(V_{pv}, I_{pv})$$

حيث يمثل X متجه الإدخال، وتمثل D_{ANN} خرج الشبكة العصبية. أثناء التدريب تتم مقارنة D_{ANN} مع D_{ref} ، أي مع دورة العمل المرجعية المستخرجة من خوارزمية P&O-MPPT. وكلما اقتربت D_{ANN} من D_{ref} ، دل ذلك على تحسن أداء الشبكة.

من أجل تقييم قدرة الشبكة على التعلم والتعميم، يتم عادة تقسيم قاعدة البيانات إلى ثلاث مجموعات رئيسية: مجموعة التدريب، مجموعة التحقق، ومجموعة الاختبار. تُستعمل مجموعة التدريب لتعديل أوزان الشبكة، بينما تُستعمل مجموعة التحقق لمراقبة الأداء أثناء التدريب والحد من الإفراط في التعلم. أما مجموعة الاختبار، فتُستعمل بعد انتهاء التدريب لتقييم أداء الشبكة على بيانات لم تعتمد عليها مباشرة في تعديل الأوزان [60، 63].

تسمح مجموعة التحقق بالكشف عن حالة الإفراط في التعلم Overfitting، وهي الحالة التي تصبح فيها الشبكة قادرة على إعطاء نتائج جيدة جدًا على بيانات التدريب، لكنها لا تعطي نفس الدقة على بيانات جديدة. ويظهر هذا الخلل عادة عندما يستمر خطأ التدريب في الانخفاض، بينما يبدأ خطأ التحقق في الارتفاع. لذلك فإن مراقبة أداء الشبكة على بيانات التحقق تعد خطوة مهمة لضمان أن الشبكة لا تحفظ العينات فقط، بل تتعلم العلاقة العامة بين المدخلات والمخرجات [60، 63].

من أهم المؤشرات العددية المستعملة في تقييم أداء الشبكات العصبية متوسط مربع الخطأ MSE. ويقاس هذا المؤشر متوسط مربعات الفروق بين خرج الشبكة والقيم المرجعية. ويمكن كتابته كما يلي:

$$MSE = \frac{1}{N} \sum (D_{ref} - D_{ANN})^2$$

حيث يمثل N عدد العينات، وتمثل D_{ref} القيم المرجعية، بينما تمثل D_{ANN} القيم الناتجة عن الشبكة العصبية. وكلما كانت قيمة MSE صغيرة، دل ذلك على أن خرج الشبكة قريب من القيم المرجعية. وتكمن أهمية هذا المؤشر في أنه يعطي وزنًا أكبر للأخطاء الكبيرة بسبب استعمال مربع الخطأ [63، 64].

إضافة إلى MSE، يمكن استعمال متوسط الخطأ المطلق MAE، وهو مؤشر يقيس متوسط القيمة المطلقة للفروق بين خرج الشبكة والقيم المرجعية. ويمكن كتابته كما يلي:

$$MAE = \frac{1}{N} \sum |D_{ref} - D_{ANN}|$$

يمتاز MAE بسهولة تفسيره، لأنه يعطي متوسط الخطأ بشكل مباشر دون تربيع. فإذا كانت قيمة MAE صغيرة، فهذا يعني أن الانحراف المتوسط بين القيم المتوقعة والقيم المرجعية محدود. ولهذا السبب يُستعمل هذا المؤشر غالبًا إلى جانب MSE للحصول على قراءة أوضح لجودة النموذج [63، 64].

كما يمكن استعمال الخطأ الأعظمي Max Error من أجل تحديد أكبر انحراف بين خرج الشبكة والقيمة المرجعية. وتكمن أهمية هذا المؤشر في أنه يكشف أسوأ حالة أداء للشبكة، حتى لو كان متوسط الخطأ العام صغيرًا. ويعد هذا الأمر مهمًا في تطبيقات التحكم، لأن قيمة واحدة بعيدة جدًا عن المجال المطلوب قد تؤثر على استقرار النظام أو تؤدي إلى دورة عمل غير مناسبة للمحول [63، 64].

إلى جانب مؤشرات الخطأ، يُستعمل معامل الارتباط R لتقييم درجة التوافق بين خرج الشبكة والقيم المرجعية. فإذا كانت قيمة R قريبة من الواحد، فهذا يدل على وجود علاقة قوية بين القيم المتوقعة والقيم المستهدفة، أي إن الشبكة استطاعت تمثيل الاتجاه العام للبيانات بصورة جيدة. أما إذا كانت قيمة R بعيدة عن الواحد، فهذا يشير إلى ضعف قدرة الشبكة على تقريب العلاقة المطلوبة [63، 64].

يمكن التعبير عن الخطأ بين الخرج المرجعي وخرج الشبكة كما يلي:

$$e = D_{ref} - D_{ANN}$$

ويمثل هذا الخطأ أساس حساب مختلف مؤشرات الأداء، مثل MSE و MAE والخطأ الأعظمي. وفي حالة التدريب الجيد، يجب أن تكون قيم e صغيرة ومتمركزة حول الصفر، مما يدل على أن الشبكة تعطي قيمًا قريبة من القيم المرجعية في أغلب العينات.

إضافة إلى المؤشرات العددية، تُستعمل بعض الرسومات البيانية لتحليل أداء التدريب بشكل أوضح. من أهم هذه الرسومات منحنى الأداء Performance Plot، الذي يوضح تطور الخطأ أثناء مراحل التدريب والتحقق والاختبار. فإذا انخفض الخطأ تدريجيًا ثم استقر عند قيمة صغيرة، فهذا يدل على أن التدريب تم بصورة مناسبة. أما إذا بدأ خطأ التحقق في الارتفاع بينما يستمر خطأ التدريب في الانخفاض، فقد يكون ذلك مؤشرًا على الإفراط في التعلم [60، 63].

كما يُستعمل منحنى الانحدار Regression Plot لدراسة العلاقة بين خرج الشبكة والقيم المرجعية. عندما تكون النقاط قريبة من خط الانحدار المثالي، فهذا يدل على أن القيم المتوقعة من الشبكة قريبة من القيم المستهدفة. أما مخطط توزيع الخطأ Error Histogram، فيوضح كيفية توزيع الأخطاء حول الصفر. ويُعد تمركز معظم الأخطاء قرب الصفر مؤشرًا إيجابيًا على جودة التدريب ودقة الشبكة [63، 64].

وبناءً على هذه المؤشرات والرسومات، يمكن الحكم على مدى صلاحية الشبكة قبل إدماجها داخل نموذج Simulink. فإذا كانت قيم MSE و MAE صغيرة، وكان معامل الارتباط R قريبًا من الواحد، وكانت الأخطاء متمركزة حول الصفر، فإن ذلك يدل على أن الشبكة قادرة على تقريب دورة العمل المرجعية D_{ref} بدقة جيدة. أما إذا كانت المؤشرات ضعيفة، فيجب إعادة النظر في بنية الشبكة، أو جودة قاعدة البيانات، أو طريقة التدريب قبل استعمالها داخل نظام التحكم.

في هذه المذكرة، تُمثل مرحلة تقييم التدريب خطوة ضرورية قبل استعمال الشبكة كمتحكم MPPT. فالهدف ليس فقط الحصول على شبكة مدربة، بل التأكد من أنها قادرة على إنتاج دورة عمل D_{ANN} قريبة من D_{ref} ضمن مجال البيانات المدروسة. وبعد التحقق من جودة التدريب، يمكن إدماج الشبكة داخل نموذج MATLAB/Simulink من أجل اختبار أدائها الديناميكي عند تغير الإشعاع الشمسي ودرجة الحرارة.

6.3 توظيف الشبكات العصبية في MPPT

أصبحت الشبكات العصبية الاصطناعية من الأدوات المهمة في تحسين أداء أنظمة تتبع نقطة القدرة العظمى، نظرًا لقدرتها على تمثيل العلاقات غير الخطية بين متغيرات النظام الكهروضوئي وإشارة التحكم المناسبة. ففي الأنظمة الكهروضوئية، تتغير نقطة القدرة العظمى تبعًا لتغير الإشعاع الشمسي ودرجة حرارة الخلية والحمل الكهربائي، مما يجعل العلاقة بين الجهد والتيار والقدرة ودورة العمل علاقة غير ثابتة. ولهذا السبب، يمكن استعمال الشبكات العصبية لتعلم هذه العلاقة من خلال بيانات تدريبية ممثلة لمجال التشغيل [59، 60].

في تطبيقات MPPT، يمكن توظيف الشبكات العصبية بعدة صيغ. فقد تُستعمل الشبكة لتقدير الجهد الموافق لنقطة القدرة العظمى، أو لتقدير التيار الموافق لها، أو لتحديد القدرة القصوى الممكنة، أو لإنتاج دورة العمل المناسبة للمحول مباشرة. ويُعد إنتاج دورة العمل مباشرة من أكثر الصيغ ارتباطًا بأنظمة التحكم، لأن دورة العمل تمثل المتغير الذي يتحكم في المحول المستمر-المستمر، ومن ثم في نقطة تشغيل اللوح الكهروضوئي [61، 62].

في هذه المذكرة، تم اعتماد الشبكة العصبية لإنتاج دورة العمل المناسبة للمحول الراجع. وتعتمد هذه المقاربة على استعمال الجهد V_{pv} والتيار I_{pv} كمداخل للشبكة، لأنهما يمثلان الحالة الكهربائية

المباشرة للوح الكهروضوئي. أما خرج الشبكة، فيتمثل في دورة العمل D_{ANN} ، وهي القيمة التي تُرسل لاحقاً إلى مولد PWM من أجل قيادة مفتاح المحول. ويمكن تمثيل ذلك بالعلاقة الآتية:

$$D_{ANN} = ANN(V_{pv}, I_{pv})$$

حيث تمثل D_{ANN} دورة العمل الناتجة عن الشبكة العصبية، وتمثل V_{pv} و I_{pv} القياسات الكهربائية المستخرجة من اللوح الكهروضوئي. وتوضح هذه العلاقة أن الشبكة لا تعتمد في خرجها على الإشعاع والحرارة مباشرة، بل تعتمد على أثرهما الكهربائي الظاهر في الجهد والتيار.

يعتمد تدريب الشبكة في هذا النوع من التطبيقات على وجود قيم مرجعية لدورة العمل. وفي هذه الدراسة، تم استعمال خوارزمية P&O-MPPT لتوليد دورة العمل المرجعية D_{ref} . ثم تُربط الشبكة على تقريب هذه القيم انطلاقاً من القيم الموافقة للجهد والتيار. وبذلك تصبح العلاقة المستهدفة أثناء التدريب هي جعل خرج الشبكة قريباً من خرج الخوارزمية المرجعية:

$$D_{ANN} \approx D_{ref}$$

وتعني هذه العلاقة أن الشبكة العصبية تهدف إلى إنتاج دورة عمل قريبة من الدورة المرجعية الناتجة عن خوارزمية P&O. وكلما كان الفرق بين D_{ANN} و D_{ref} صغيراً، دل ذلك على قدرة الشبكة على تقليد السلوك المرجعي للخوارزمية بدرجة جيدة [61، 62].

يمكن التعبير عن خطأ التقدير بين خرج الشبكة والقيمة المرجعية كما يلي:

$$eD = D_{ref} - D_{ANN}$$

حيث يمثل eD خطأ دورة العمل. ويُعد هذا الخطأ مؤشراً مهماً في تقييم أداء المتحكم العصبي، لأن دورة العمل هي الإشارة التي تتحكم في المحول. فإذا كان الخطأ صغيراً، فإن المحول يستقبل قيمة تحكم قريبة من القيمة المرجعية، مما يسمح للنظام بالعمل قرب نقطة القدرة العظمى. أما إذا كان الخطأ كبيراً، فقد تنتقل نقطة التشغيل بعيداً عن النقطة المثلى، مما يؤدي إلى فقدان جزء من القدرة المتاحة.

تمر عملية توظيف الشبكة العصبية في MPPT بعدة مراحل مترابطة. تبدأ المرحلة الأولى بتشغيل النظام الكهروضوئي تحت سيناريوهات مختلفة للإشعاع الشمسي ودرجة الحرارة، مما يؤدي إلى تغير القيم الكهربائية للوح. بعد ذلك، يتم تشغيل خوارزمية P&O-MPPT من أجل استخراج دورة العمل المرجعية الموافقة لكل حالة تشغيل. ثم تُنظم البيانات في قاعدة تدريبية تحتوي على المدخلات V_{pv} و I_{pv} ، والهدف التدريبي D_{ref} . وبعد تدريب الشبكة والتحقق من أدائها، يتم إدماجها داخل نموذج التحكم لتوليد D_{ANN} مباشرة أثناء المحاكاة.

ويمكن تلخيص تسلسل العمل كما يلي:


- تغير الإشعاع والحرارة
- ينتج عنه تغير في V_{pv} و I_{pv}
- تستعمل خوارزمية P&O لاستخراج D_{ref}
- تُدرَّب الشبكة على العلاقة بين V_{pv} و I_{pv} و D_{ref}
- بعد التدريب تنتج الشبكة D_{ANN} مباشرة

هذا التسلسل يوضح أن الشبكة العصبية لا تلغي دور خوارزمية P&O في مرحلة إعداد البيانات، بل تستفيد منها باعتبارها مصدراً مرجعياً. فالخوارزمية التقليدية تُستعمل أولاً لتوليد قيم D_{ref} ، ثم تتعلم

الشبكة هذه العلاقة حتى تتمكن لاحقاً من إنتاج دورة العمل المناسبة بصورة مباشرة وسريعة داخل نموذج التحكم.

تتميز هذه المقاربة بعدة مزايا. فمن جهة، تسمح الشبكة العصبية بعد تدريبها بإنتاج دورة العمل دون الحاجة إلى تنفيذ خطوات الاضطراب والملاحظة في كل لحظة تشغيل. ومن جهة أخرى، يمكنها تمثيل العلاقة غير الخطية بين القياسات الكهربائية ودورة العمل المناسبة، وهو ما يجعلها مناسبة للتعامل مع تغيرات النظام الكهروضوئي. ومع ذلك، فإن أداء المتحكم العصبي يبقى مرتبطاً بجودة قاعدة البيانات التي استُعملت في التدريب، وبمدى شمولها لمجال التشغيل المتوقع [60، 63].

كما يجب الانتباه إلى أن الشبكة العصبية لا تضمن أداءً جيداً خارج المجال الذي درست عليه. فإذا استقبلت الشبكة قيمةً للجهد أو التيار بعيدة جداً عن مجال بيانات التدريب، فقد تعطي خرجاً غير دقيق. لذلك، من الضروري أثناء بناء قاعدة البيانات أن تُستعمل سيناريوهات تشغيل متنوعة تغطي تغيرات مناسبة في الإشعاع الشمسي ودرجة الحرارة، حتى يتم الحصول على مجال كافٍ من قيم V_{pv} و I_{pv} و D_{ref} [60، 63].



الشكل 3.3: توظيف ANN في MPPT

يبين الشكل المبدأ العام لتوظيف الشبكة العصبية داخل نظام MPPT، حيث تستقبل الشبكة قيم الجهد V_{pv} والتيار I_{pv} ، ثم تنتج دورة العمل D_{ANN} التي تُحول إلى إشارة PWM من أجل قيادة المحول الرفع. من الناحية التطبيقية، يمثل خرج الشبكة D_{ANN} إشارة التحكم الأساسية في النظام. لذلك يجب أن تكون هذه القيمة ضمن مجال تشغيل مناسب لدورة العمل. وفي التطبيقات العملية أو داخل Simulink، يمكن إضافة مرحلة حماية مثل كتلة Saturation لضمان بقاء دورة العمل ضمن حدود مقبولة، خاصة أثناء الفترات الانتقالية أو عند ظهور قيم لحظية خارج مجال التدريب. ولا تُعد هذه المرحلة بديلاً عن جودة التدريب، وإنما إجراء حماية للتحكم.

وبذلك يمثل توظيف الشبكات العصبية في MPPT انتقالاً من التحكم القائم على البحث التكراري إلى التحكم القائم على التعلم من البيانات. فبدل أن تقوم الخوارزمية بتجربة اضطرابات متتالية في كل لحظة، يمكن للشبكة المدربة أن تعطي دورة العمل المناسبة مباشرة انطلاقاً من القياسات الكهربائية. وسيتم في الفصل الرابع تطبيق هذه الفكرة عملياً، من خلال توليد قاعدة البيانات باستعمال خوارزمية P&O

MPPT، ثم تدريب الشبكة العصبية، وإدماجها في نموذج MATLAB/Simulink، وأخيرًا تحليل نتائجها ومقارنتها بالخوارزمية المرجعية.

7.3 خلاصة الفصل

تناول هذا الفصل الأسس العامة للشبكات العصبية الاصطناعية، باعتبارها إحدى أدوات الذكاء الاصطناعي القادرة على تمثيل العلاقات غير الخطية بين المدخلات والمخرجات. وقد تم توضيح أن الشبكة العصبية تتكون من مجموعة من العصبونات المترابطة ضمن بنية طبقية، تشمل طبقة إدخال، وطبقة أو أكثر مخفية، وطبقة خرج. كما تم إبراز دور الأوزان والانحيازات ودوال التنشيط في معالجة البيانات وإنتاج الخرج المناسب [59، 60].

كما تم التطرق إلى مبدأ التعلم الموجه، وهو النمط المعتمد في هذه الدراسة، حيث تتعلم الشبكة من أمثلة تدريبية تحتوي على مدخلات وقيم مرجعية مقابلة. وفي سياق هذه المذكرة، تمثل المدخلات القيم الكهربائية للوح الكهروضوئي، أي الجهد V_{pv} والتيار I_{pv} ، بينما تمثل دورة العمل المرجعية D_{ref} الخرج المستهدف الناتج عن خوارزمية P&O-MPPT. وبهذا الشكل، تتعلم الشبكة العلاقة بين الحالة الكهربائية للوح وقيمة دورة العمل المناسبة.

وقد أبرزت أهمية مرحلة التدريب وتقييم الأداء، من خلال استعمال مؤشرات عددية مثل متوسط مربع الخطأ MSE، متوسط الخطأ المطلق MAE، الخطأ الأعظمي، ومعامل الارتباط R. وتسمح هذه المؤشرات بتقييم مدى قرب خرج الشبكة D_{ANN} من القيم المرجعية D_{ref} . كما تم توضيح أهمية الرسوم البيانية، مثل منحنى الأداء، ومنحنى الانحدار، ومخطط توزيع الخطأ، في تحليل جودة التدريب والتأكد من قدرة الشبكة على التعميم [63، 64].

وفي الجزء الأخير من الفصل، تم توضيح كيفية توظيف الشبكات العصبية في تطبيقات MPPT. وقد تم التركيز على المقارنة المعتمدة في هذه الدراسة، والمتمثلة في تدريب الشبكة العصبية على إنتاج دورة العمل المناسبة اعتمادًا على القياسات الكهربائية للوح الكهروضوئي. ويمكن تلخيص العلاقة الأساسية التي يقوم عليها المتحكم العصبي كما يلي:

$$D_{ANN} = ANN(V_{pv}, I_{pv})$$

أي إن الشبكة تستقبل الجهد والتيار كمدخلين، ثم تنتج دورة العمل D_{ANN} التي تُستعمل لاحقًا في التحكم في المحول الرفع عبر إشارة PWM. وبذلك تمثل الشبكة العصبية متحكمًا قادرًا على تقريب سلوك خوارزمية P&O-MPPT، اعتمادًا على قاعدة بيانات تدريبية مولدة مسبقًا.

يمهد هذا الفصل مباشرة للفصل الرابع، حيث سيتم تطبيق المفاهيم السابقة عمليًا داخل بيئة MATLAB/Simulink. وسيتم في الفصل الموالي عرض كيفية توليد قاعدة البيانات باستعمال خوارزمية P&O-MPPT، ثم تدريب الشبكة العصبية، وإدماجها داخل نموذج التحكم، وأخيرًا تحليل نتائجها ومقارنتها بالخوارزمية المرجعية.

الفصل الرابع:

تنفيذ وتقييم متحكم ANN-MPPT

الفصل الرابع: تنفيذ وتقييم متحكم ANN-MPPT

1.4 مقدمة

بعد عرض الأسس العامة للأنظمة الكهروضوئية في الفصل الأول، ودراسة تقنيات تتبع نقطة القدرة العظمى وخوارزمية P&O في الفصل الثاني، ثم توضيح مبادئ الشبكات العصبية الاصطناعية وآلية تدريبها في الفصل الثالث، يخصص هذا الفصل للجانب التطبيقي من المذكرة. ويتمثل الهدف الأساسي في تنفيذ وتقييم متحكم MPPT قائم على شبكة عصبية اصطناعية داخل نموذج كهروضوئي مبني في بيئة MATLAB/Simulink.

يعتمد العمل التطبيقي في هذا الفصل على استعمال خوارزمية P&O-MPPT كمرجع لتوليد دورة العمل المناسبة للمحول الرفع. وقد تم اختيار هذه الخوارزمية لأنها تمثل طريقة تقليدية بسيطة وواسعة الاستعمال في تطبيقات تتبع نقطة القدرة العظمى [48]. وبعد تشغيل النظام تحت سيناريوهات مختلفة للإشعاع الشمسي ودرجة الحرارة، تم استخراج القيم الكهربائية للوح الكهروضوئي، خاصة الجهد V_{pv} والتيار I_{pv} ، إضافة إلى دورة العمل المرجعية D_{ref} الناتجة عن خوارزمية P&O.

بعد ذلك، استُعملت هذه القيم لبناء قاعدة بيانات تدريبية للشبكة العصبية، حيث تم اعتماد V_{pv} و I_{pv} كمدخلين، بينما مثلت D_{ref} المخرج المستهدف. وبهذا تصبح الشبكة العصبية قادرة، بعد التدريب، على إنتاج دورة العمل D_{ANN} اعتماداً على القياسات الكهربائية للوح، دون الحاجة إلى تنفيذ خطوات خوارزمية P&O في كل لحظة تشغيل.

يركز هذا الفصل على عرض مراحل العمل التطبيقي بشكل متسلسل، بدءاً من نموذج النظام الكهروضوئي، ثم سيناريوهات توليد البيانات، وتحضير قاعدة التدريب، وتدريب الشبكة العصبية، ثم إدماجها داخل Simulink. وفي المرحلة الأخيرة، يتم تحليل استجابة النظام ومقارنة أداء المتحكم العصبي مع خوارزمية P&O-MPPT من حيث دورة العمل، القدرة المستخرجة، والاستقرار أثناء تغير ظروف التشغيل.

2.4 نموذج النظام الكهروضوئي

تم تنفيذ نموذج النظام الكهروضوئي في بيئة MATLAB/Simulink بهدف محاكاة سلوك اللوح الشمسي تحت ظروف تشغيل مختلفة، ثم اختبار أداء متحكم MPPT المعتمد على الشبكة العصبية. يتكون النموذج من مولد كهروضوئي، محول مستمر-مستمر من نوع رافع Boost Converter، حمل كهربائي، مولد إشارة PWM، إضافة إلى وحدة تحكم مسؤولة عن إنتاج دورة العمل المناسبة للمحول.


يعتمد النموذج على تغيير قيم الإشعاع الشمسي G ودرجة حرارة الخلية T من أجل محاكاة تغير ظروف التشغيل. وتؤدي هذه التغيرات إلى تغير القيم الكهربائية الخارجة من اللوح، خاصة الجهد V_{pv} والتيار I_{pv} والقدرة P_{pv} . ويتم حساب القدرة الكهروضوئية وفق العلاقة الآتية:

$$P_{pv} = V_{pv} \times I_{pv}$$

حيث تمثل P_{pv} القدرة الخارجة من اللوح الكهروضوئي، و V_{pv} جهد اللوح، و I_{pv} تياره. وتُستعمل هذه القيم لاحقاً في توليد قاعدة البيانات التدريبية وفي تقييم أداء المتحكم العصبي.

في المرحلة الأولى، تم تشغيل النموذج باستعمال خوارزمية P&O-MPPT من أجل استخراج دورة العمل المرجعية D_{ref} الموافقة لحالات التشغيل المختلفة. وتمثل هذه القيمة خرج الخوارزمية المرجعية، أي القيمة التي توجه المحول الرفع نحو نقطة تشغيل قريبة من نقطة القدرة العظمى. بعد ذلك، استُعملت القيم V_{pv} و I_{pv} مع D_{ref} لتكوين قاعدة بيانات التدريب الخاصة بالشبكة العصبية.

يوضح الشكل الآتي البنية العامة للنظام الكهروضوئي المستعمل في المحاكاة، حيث يظهر ارتباط اللوح بالمحول الرافع، ووحدة التحكم، ومولد PWM، والحمل الكهربائي.



الشكل 1.4: نموذج النظام الكهروضوئي

يبين الشكل البنية العامة للنظام المعتمد في المحاكاة. يستقبل المتحكم القياسات الكهربائية للوح، ثم يولد دورة العمل D التي يتم تحويلها إلى إشارة PWM لقيادة مفتاح المحول الرافع. ويسمح هذا التنظيم بتعديل نقطة تشغيل اللوح حسب تغير الإشعاع ودرجة الحرارة.

يعتمد العمل في هذا الفصل على نفس النموذج في مرحلتين أساسيتين. في المرحلة الأولى، يتم استعمال خوارزمية P&O-MPPT لتوليد القيم المرجعية D_{ref} . أما في المرحلة الثانية، فيتم استبدال خرج الخوارزمية بخرج الشبكة العصبية D_{ANN} من أجل اختبار قدرة المتحكم العصبي على إنتاج دورة العمل المناسبة ومقارنة أدائه مع الخوارزمية المرجعية.

3.4 سيناريوهات التشغيل

من أجل توليد قاعدة بيانات تدريبية متنوعة، تم تشغيل النظام الكهروضوئي تحت مجموعة من السيناريوهات المختلفة للإشعاع الشمسي ودرجة حرارة الخلية. ويهدف اعتماد هذه السيناريوهات إلى تمثيل تغير ظروف التشغيل التي قد يتعرض لها اللوح الكهروضوئي، حيث يؤدي تغير الإشعاع والحرارة إلى تغير القيم الكهربائية الخارجة من اللوح، خاصة الجهد V_{pv} والتيار I_{pv} والقدرة P_{pv} .

لا تُستعمل قيم الإشعاع G ودرجة الحرارة T كمداخل مباشرة للشبكة العصبية في هذه الدراسة، وإنما تُستعمل لإحداث تغيرات في نقطة تشغيل النظام. ونتيجة لهذه التغيرات، يتم الحصول على قيم مختلفة للجهد والتيار، ثم تستعمل خوارزمية P&O-MPPT لاستخراج دورة العمل المرجعية D_{ref} الموافقة لكل حالة تشغيل. وبذلك تصبح قاعدة التدريب مبنية على العلاقة بين القياسات الكهربائية للوح ودورة العمل المرجعية.

يوضح الجدول الآتي بروفيلات الإشعاع الشمسي ودرجة الحرارة المعتمدة في سيناريوهات التشغيل.

الجدول 1.4: بروفيلات الإشعاع والحرارة

السيناريو	زمن المحاكاة (s)	بروفيل الإشعاع الشمسي ($G W/m^2$)	بروفيل درجة الحرارة ($T ^\circ C$)
1	0-12	400 – 600 – 1000 – 400	37.5 – 43.75 – 56.25 – 37.5
2	0-12	1000 – 800 – 600 – 400	25 – 35 – 45 – 55
3	0-12	400 – 1000 – 600 – 800	55 – 25 – 50 – 35
4	0-12	600 – 1000 – 400 – 800	25 – 55 – 35 – 45
5	0-12	800 – 400 – 1000 – 600	30 – 50 – 35 – 55

يبين الجدول أن السيناريوهات لا تختلف فقط في القيم المستعملة، بل تختلف أيضاً في ترتيب تغييرها الزمني. ويسمح هذا التنوع بتوليد حالات تشغيل متعددة للوح الكهروضوئي، مما يساعد على بناء قاعدة تدريب أكثر تمثيلاً لسلوك النظام.

بعد تشغيل خوارزمية P&O-MPPT على السيناريوهات السابقة، تم تسجيل دورة العمل الناتجة عن الخوارزمية، إضافة إلى القدرة العظمى المسجلة في كل سيناريو. ويوضح الجدول الآتي مجال تغير D_{po} والقدرة العظمى P_{max} .

الجدول 2.4: قيم P_{max} و D_{po}

السيناريو	$D_{po} \text{ min}$	$D_{po} \text{ max}$	$D_{po} \text{ mean}$	$P_{max} (W)$
1	0.40319	0.42000	0.41178	48.158
2	0.30473	0.42000	0.39875	49.107
3	0.35737	0.42302	0.41541	49.098
4	0.32140	0.42000	0.36491	48.201
5	0.30951	0.42000	0.37433	48.792


توضح هذه النتائج أن خوارزمية P&O-MPPT أعطت قيماً مختلفة لدورة العمل حسب ظروف كل سيناريو. وتُستعمل هذه القيم لاحقاً كمرجع لتدريب الشبكة العصبية، بعد اختيار العينات المناسبة من الإشارات الكهربائية الناتجة عن النموذج.

ولغرض توضيح طريقة تطبيق السيناريوهات داخل Simulink، تم اختيار السيناريو الخامس كمثال تطبيقي، لأنه يتضمن تغيرات واضحة في الإشعاع ودرجة الحرارة على فترات زمنية منتظمة.

الجدول 3.4: مثال للسيناريو الخامس.

لمجال الزمني(s)	G (W/m ²)	T (°C)
0-3	800	30
3-6	400	50
6-9	1000	35
9-12	600	55

يبين الجدول أن قيم الإشعاع ودرجة الحرارة تتغير كل 3 ثوانٍ، مما يسمح باختبار استجابة النظام أمام تغيرات متقطعة في ظروف التشغيل. وقد تم تطبيق هذه القيم داخل Simulink باستعمال كتل Repeating Sequence Stair.



الشكل 2.4: تطبيق السيناريو الخامس.

يوضح الشكل طريقة إدخال بروفيلات الإشعاع الشمسي ودرجة الحرارة داخل نموذج Simulink، حيث يتم توليد تغيرات متقطعة تسمح بمحاكاة ظروف تشغيل مختلفة خلال زمن المحاكاة.

4.4 تحضير قاعدة البيانات

بعد تشغيل النظام الكهروضوئي تحت السيناريوهات السابقة، تم تسجيل الإشارات الكهربائية الأساسية الناتجة عن اللوح، والمتمثلة في الجهد V_{pv} ، التيار I_{pv} ، والقدرة P_{pv} ، إضافة إلى دورة العمل الناتجة عن خوارزمية P&O-MPPT. وتُعد هذه المرحلة أساسية لأنها تمثل حلقة الربط بين المحاكاة التقليدية المعتمدة على P&O وبين تدريب الشبكة العصبية الاصطناعية.

تم حساب القدرة الكهروضوئية انطلاقاً من الجهد والتيار وفق العلاقة:

$$P_{pv} = V_{pv} \times I_{pv}$$

حيث تمثل P_{pv} القدرة الكهربائية المستخرجة من اللوح، و V_{pv} جهد اللوح، و I_{pv} تياره. وبما أن خوارزمية P&O تستعمل هذه القيم لتحديد اتجاه التتبع، فقد تم اعتماد خرجها بوصفه مرجعاً لتوليد دورة العمل المناسبة.

في هذه المرحلة، تم التمييز بين دورة العمل الناتجة مباشرة عن خوارزمية P&O، والتي نرسم لها بـ D_{po} ، وبين دورة العمل المرجعية المستعملة في التدريب، والتي نرسم لها بـ D_{ref} . وتمثل D_{ref} القيم المختارة والمنظمة من خرج خوارزمية P&O بعد معالجة الإشارات واختيار العينات المناسبة. أما خرج الشبكة العصبية بعد التدريب فيرمز له بـ D_{ANN} .

يمكن تلخيص العلاقة بين هذه الرموز كما يلي:

- D_{po} : دورة العمل الناتجة عن خوارزمية P&O
- D_{ref} : دورة العمل المرجعية المعتمدة في التدريب
- D_{ANN} : دورة العمل الناتجة عن الشبكة العصبية

وبذلك تكون قاعدة التدريب مبنية على العلاقة الآتية:

- المدخلات: I_{pv} و V_{pv}
- المخرج المرجعي: D_{ref}


أي إن الشبكة العصبية تتعلم إعطاء دورة العمل المرجعية اعتمادًا على الحالة الكهربائية للوح الكهروضوئي.

يوضح الجدول الآتي خصائص قاعدة البيانات النهائية المعتمدة في تدريب الشبكة العصبية.

الجدول 4.4: خصائص قاعدة البيانات


المؤشر	القيمة
عدد العينات	600
حجم مصفوفة المدخلات	2×600
حجم مصفوفة الهدف	1×600
مجال V_{pv}	11.151369 إلى 18.833797 V
مجال I_{pv}	1.204650 إلى 2.381115 A
مجال P_{pv}	13.436783 إلى 44.789529 W
مجال D_{ref}	0.339324 إلى 0.403948

يبين الجدول أن قاعدة البيانات النهائية تتكون من 600 عينة، حيث تمثل كل عينة حالة تشغيل كهربائية للوح الكهروضوئي. وتضم مصفوفة المدخلات متغيرين هما V_{pv} و I_{pv} ، بينما تضم مصفوفة الهدف قيمة واحدة هي D_{ref} . كما توضح مجالات الجهد والتيار والقدرة أن العينات المختارة تغطي حالات تشغيل مختلفة، وهو ما يساعد الشبكة العصبية على تعلم العلاقة بين القياسات الكهربائية ودورة العمل المرجعية.



الشكل 3.4: توزيع عينات التدريب

يوضح الشكل توزيع عينات قاعدة البيانات في مستوى الجهد والتيار. وتظهر العينات ضمن مناطق تشغيل مختلفة، مما يدل على أن قاعدة التدريب لا تمثل نقطة تشغيل واحدة فقط، بل تتضمن عدة حالات كهربائية ناتجة عن تغير ظروف التشغيل. ويساعد هذا التنوع على تحسين قدرة الشبكة العصبية على تقريب العلاقة بين V_{pv} و I_{pv} من جهة، و D_{ref} من جهة أخرى.



الشكل 4.4: العلاقة بين D_{ref} و P_{pv}

يبين الشكل العلاقة بين القدرة الكهروضوئية P_{pv} ودورة العمل المرجعية D_{ref} . وتوضح هذه العلاقة أن قيم D_{ref} مرتبطة بحالات تشغيل مختلفة للوح الكهروضوئي، وهو ما يبرر استعمالها كهدف تدريبي للشبكة العصبية. فكلما تغيرت القدرة الناتجة عن اللوح نتيجة تغير الجهد أو التيار، تغيرت معها قيمة دورة العمل المناسبة التي تسمح بالاقتراب من نقطة القدرة العظمى.

5.4 تدريب الشبكة العصبية

بعد تحضير قاعدة البيانات النهائية، تم استعمالها لتدريب شبكة عصبية اصطناعية بهدف تقريب العلاقة بين القياسات الكهربائية للوح الكهروضوئي ودورة العمل المرجعية. وتمثلت مدخلات الشبكة في جهد اللوح V_{pv} وتياره I_{pv} ، بينما مثلت D_{ref} القيمة المرجعية المراد تعلمها. ويعني ذلك أن الشبكة العصبية لا تتعلم الإشعاع الشمسي أو درجة الحرارة بشكل مباشر، وإنما تتعلم الأثر الكهربائي الناتج عنهما من خلال تغير الجهد والتيار.

يمكن التعبير عن مدخلات الشبكة كما يلي:

$$X = [V_{pv} ; I_{pv}]$$

أما خرج الشبكة فيمثل دورة العمل الناتجة عن المتحكم العصبي:

$$D_{ANN} = ANN(V_{pv}, I_{pv})$$


وخلال مرحلة التدريب، تتم مقارنة D_{ANN} مع D_{ref} ، ويتم تعديل أوزان الشبكة من أجل تقليل الفرق بينهما. ويمكن تمثيل خطأ دورة العمل بالعلاقة الآتية:

$$eD = D_{ref} - D_{ANN}$$

حيث يمثل eD خطأ التقدير بين دورة العمل المرجعية ودورة العمل الناتجة عن الشبكة العصبية.

اعتمد تدريب الشبكة على التعلم الموجه، حيث تم استعمال قاعدة بيانات تحتوي على 600 عينة. وقد تم تقسيم هذه البيانات إلى مجموعات خاصة بالتدريب والتحقق والاختبار، بهدف تقييم قدرة الشبكة على التعلم والتعميم، وليس فقط حفظ بيانات التدريب. وتسمح هذه الطريقة بمراقبة أداء الشبكة أثناء التدريب، والتأكد من أن الخرج الناتج عنها يبقى قريباً من القيم المرجعية.

يوضح الشكل الآتي البنية العامة للشبكة العصبية المستعملة في التدريب.



الشكل 5.4: بنية الشبكة العصبية

يبين الشكل بنية الشبكة العصبية المعتمدة، حيث تستقبل الشبكة قيمتي V_{pv} و I_{pv} كمُدخلين، ثم تمرر هذه القيم عبر الطبقات المخفية من أجل إنتاج دورة العمل D_{ANN} في طبقة الخرج.

وضح الجدول الآتي أهم خصائص تدريب الشبكة العصبية.

الجدول 5.4: خصائص تدريب الشبكة.

المؤشر	القيمة
عدد المدخلات	2
مدخلات الشبكة	I_{pv} و V_{pv}
عدد المخرجات	1
مخرج الشبكة	DANN
الهدف التدريبي	D_{ref}
عدد العينات	600
نوع التعلم	تعلم موجه
معيار الأداء	MSE

يبين الجدول (5.4) أن الشبكة العصبية صُممت وفق بنية بسيطة ومباشرة، حيث تعتمد على مدخلين كهربائيين فقط ومخرج واحد يمثل دورة العمل. ويجعل هذا الاختيار الشبكة مناسبة لتطبيقات التحكم في MPPT، لأن الجهد والتيار متغيران قابلان للقياس داخل النظام، كما أنهما يعبران عن حالة تشغيل اللوح الكهروضوئي.


بعد انتهاء التدريب، تم تقييم أداء الشبكة باستعمال مؤشرات عددية وبيانية. وقد تم التركيز على متوسط مربع الخطأ MSE، متوسط الخطأ المطلق MAE، الخطأ الأعظمي، ومعامل الارتباط R. وتسمح هذه المؤشرات بالحكم على مدى قرب خرج الشبكة DANN من القيم المرجعية D_{ref} .

تم اختبار الشبكة العصبية خارج نموذج Simulink باستعمال قاعدة البيانات النهائية، حيث تراوح خرج الشبكة بين 0.339251 و 0.403972، وهو مجال قريب جداً من مجال القيم المرجعية D_{ref} الذي تراوح بين 0.339324 و 0.403948. كما بلغ متوسط الخطأ المطلق MAE قيمة قدرها 0.00005354، في حين لم يتجاوز الخطأ الأعظمي 0.00028002. وتؤكد هذه النتائج أن الشبكة استطاعت تقريب دورة العمل المرجعية بدقة عالية ضمن مجال بيانات التدريب.

الجدول 6.4: نتائج تقييم الشبكة.


المؤشر	القيمة
مجال D_{ANN}	0.339251 إلى 0.403972
مجال D_{ref}	0.339324 إلى 0.403948
MAE	0.00005354
Max Error	0.00028002
R	0.999995741207
MSE	$7.740916538586e - 09$

يبين الجدول (6.4) أن خرج الشبكة العصبية قريب جداً من القيم المرجعية، حيث كان الفرق بين D_{ANN} و D_{ref} صغيراً جداً. ويشير ذلك إلى جودة عملية التدريب، وإلى قدرة الشبكة على تمثيل العلاقة بين V_{pv} و I_{pv} من جهة، ودورة العمل المرجعية من جهة أخرى.




الشكل 6.4: أداء التدريب

يوضح الشكل (6.4) تطور متوسط مربع الخطأ MSE خلال مراحل التدريب والتحقق والاختبار. نلاحظ أن قيمة الخطأ تنخفض تدريجياً مع تزايد عدد الدورات التدريبية، حيث انتقلت من قيم مرتفعة في بداية التدريب إلى قيم صغيرة جداً قرب 10^{-8} عند نهاية التدريب. كما يظهر تقارب واضح بين منحنيات التدريب والتحقق والاختبار، مما يدل على أن الشبكة تعلمت العلاقة بين المدخلات V_{pv} و I_{pv} والمخرج المرجعي D_{ref} دون ظهور فرق كبير بين أداء التدريب وأداء التحقق أو الاختبار. وتؤكد هذه النتيجة جودة تدريب الشبكة العصبية وصلاحياتها للاستعمال لاحقاً داخل نموذج Simulink.



الشكل 7.4: الانحدار.


يوضح الشكل (7.4) علاقة الانحدار بين خرج الشبكة العصبية والقيم المرجعية لدورة العمل، وذلك في مراحل التدريب والتحقق والاختبار، إضافة إلى كامل قاعدة البيانات. نلاحظ أن نقاط البيانات تقع تقريباً على خط الانحدار المثالي، مما يدل على وجود توافق قوي بين القيم المتوقعة من طرف الشبكة D_{ANN} والقيم المرجعية D_{ref} . كما أن تقارب منحنيات التدريب والتحقق والاختبار يؤكد أن الشبكة لم تكتف بحفظ بيانات التدريب، بل استطاعت تعميم العلاقة بين المدخلات V_{pv} و I_{pv} والمخرج المرجعي D_{ref} بدرجة جيدة.



الشكل 8.4: توزيع الخطأ.

يوضح الشكل (8.4) توزيع خطأ الشبكة العصبية خلال مراحل التدريب والتحقق والاختبار. ويُلاحظ أن أغلب الأخطاء متمركزة حول خط الخطأ الصفري، مما يدل على تقارب كبير بين خرج الشبكة DANN والقيم المرجعية D_{ref} . كما يبين الشكل أن أخطاء المجموعات الثلاث تبقى ضمن مجال محدود، وهو ما يؤكد جودة التدريب وقدرة الشبكة على التعميم ضمن مجال البيانات المعتمد.

بناءً على نتائج التدريب ومؤشرات الأداء، يمكن اعتماد الشبكة العصبية داخل نموذج Simulink لاختبارها كمتحكم MPPT. وتتمثل الخطوة التالية في إدماج الشبكة داخل النموذج، بحيث تستقبل V_{pv} و I_{pv} مباشرة من اللوح الكهروضوئي، ثم تنتج دورة العمل DANN التي تُحوّل إلى إشارة PWM للتحكم في المحول الرفع.



الشكل 9.4: مقارنة D_{ref} و DANN على عينات قاعدة البيانات

يوضح الشكل (9.4) مقارنة بين دورة العمل المرجعية D_{ref} وخرج الشبكة العصبية DANN على عينات قاعدة البيانات المرتبة. نلاحظ وجود تطابق شبه تام بين المنحنيين، مما يدل على قدرة الشبكة العصبية على تقريب القيم المرجعية بدقة عالية ضمن مجال بيانات التدريب. وتدعم هذه النتيجة مؤشرات الأداء العددية السابقة، خاصة انخفاض قيم MSE و MAE وارتفاع معامل الارتباط R.

الجدول 7.4: نتائج تقييم الشبكة العصبية.

القيمة	لمؤشر
0.339251 إلى 0.403972	مجال DANN
0.339324 إلى 0.403948	مجال Dref
0.000000007741	MSE
0.000087982479	RMSE
0.000053542161	MAE
0.000280021240	Max Error
0.999995741207	R

يبين الجدول 7.4 أن الشبكة العصبية حققت دقة عالية في تقريب دورة العمل المرجعية، حيث بلغت قيمة متوسط مربع الخطأ MSE مقداراً صغيراً جداً يساوي 0.000000007741، كما بلغ متوسط الخطأ المطلق MAE قيمة 0.000053542161 فقط. ويؤكد الخطأ الأعظمي المحدود، الذي لم يتجاوز 0.000280021240، أن أكبر انحراف بين خرج الشبكة DANN والقيمة المرجعية D_{ref} بقي صغيراً. كما أن قيمة معامل الارتباط R، التي بلغت 0.999995741207، تدل على وجود توافق شبه تام بين القيم المتوقعة من طرف الشبكة والقيم المرجعية. وبناءً على ذلك، يمكن اعتبار الشبكة المدربة مناسبة للإدماج داخل نموذج Simulink واختبارها كمتحكم ANN-MPPT.

6.4 إدماج الشبكة العصبية في Simulink


بعد الانتهاء من تدريب الشبكة العصبية والتحقق من جودة أدائها، تم إدماجها داخل نموذج MATLAB/Simulink بهدف اختبارها كمتحكم لتتبع نقطة القدرة العظمى MPPT ضمن النظام الكهروضوئي. وتمثل هذه المرحلة انتقالاً من تقييم الشبكة اعتماداً على قاعدة البيانات التدريبية إلى اختبارها داخل نظام ديناميكي تتغير فيه الإشارات الكهربائية مع الزمن نتيجة تغير شدة الإشعاع الشمسي ودرجة حرارة الخلية وظروف الحمل.

في النموذج التطبيقي، تستقبل الشبكة العصبية قيمتي الجهد V_{pv} والتيار I_{pv} بوصفهما مدخلين، ثم تنتج دورة العمل DANN بوصفها مخرجا. وتمثل هذه القيمة إشارة التحكم الأساسية التي ترسل إلى مولد PWM من أجل قيادة مفتاح المحول الرفع. ويمكن التعبير عن وظيفة الشبكة داخل النموذج بالعلاقة الآتية:

$$DANN = ANN(V_{pv}, I_{pv})$$

حيث تمثل DANN دورة العمل الناتجة عن الشبكة العصبية، بينما تمثل V_{pv} و I_{pv} القياسات الكهربائية المستخرجة من اللوح الكهروضوئي. وبعد توليد DANN، يتم تحويلها إلى إشارة PWM تستعمل في التحكم في المحول الرفع، مما يسمح بتعديل نقطة تشغيل اللوح والاقتراب من نقطة القدرة العظمى.

تعمل الشبكة العصبية داخل النموذج بصورة مستمرة، إذ تعالج القيم المقاسة للجهد والتيار عند كل لحظة زمنية وتولد دورة العمل المناسبة تبعاً لحالة النظام. ويسمح هذا الإدماج بتقييم قدرة المتحكم العصبي على الاستجابة للتغيرات المفاجئة في ظروف التشغيل، إضافة إلى دراسة سرعة التتبع واستقرار القدرة المستخرجة. كما يتيح نموذج Simulink مقارنة أداء المتحكم العصبي بأداء خوارزمية P&O التقليدية من حيث دقة التتبع، وزمن الاستجابة، وحجم التذبذبات حول نقطة القدرة العظمى.




الشكل 10.4: إدماج الشبكة العصبية في Simulink.

يوضح الشكل 4.10 موضع إدماج الشبكة العصبية داخل نموذج التحكم، حيث تستقبل الشبكة قيمتي الجهد V_{pv} والتيار I_{pv} من اللوح الكهروضوئي، ثم تنتج دورة العمل DANN التي يتم تحويلها إلى إشارة PWM للتحكم في المحول الرفع. ويبين هذا الإدماج أن الشبكة أصبحت تؤدي دور متحكم MPPT داخل النظام، إذ تعمل على معالجة القيم الكهربائية المقاسة وتحديد دورة العمل المناسبة وفق ظروف التشغيل. كما يسمح هذا الربط بتعديل نقطة تشغيل اللوح بصورة آنية وتحسين القدرة على تتبع نقطة القدرة العظمى عند تغير الإشعاع الشمسي ودرجة الحرارة.


ومن أجل ضمان سلامة إشارة التحكم، يمكن إضافة كتلة Saturation بعد خروج الشبكة العصبية. ولا تهدف هذه الكتلة إلى تصحيح أداء الشبكة، لأن نتائج التدريب بينت أن خرجها قريب جداً من القيم المرجعية D_{ref} ، وإنما تُستعمل كإجراء حماية لضمان بقاء دورة العمل ضمن مجال تشغيل مقبول، خاصة أثناء الفترات الانتقالية أو عند بداية المحاكاة.

بعد إدماج الشبكة داخل النموذج، أصبح تسلسل التحكم كما يلي: يتم قياس الجهد V_{pv} والتيار I_{pv} ، ثم تُرسل هذه القيم إلى الشبكة العصبية، فتنتج الشبكة دورة العمل DANN. بعد ذلك يتم تحويل DANN إلى إشارة PWM، ثم تُستعمل هذه الإشارة في قيادة مفتاح المحول الرفع. ويؤدي تغيير دورة العمل إلى تعديل نقطة تشغيل اللوح الكهروضوئي، مما يسمح للنظام بالاقتراب من نقطة القدرة العظمى.



الشكل 11.4: خرج الشبكة DANN

يبين الشكل 11.4 تطور خرج الشبكة العصبية DANN أثناء تشغيل متحكم ANN-MPPT. نلاحظ أن قيمة دورة العمل تتغير عند لحظات تبدل ظروف التشغيل، ثم تستقر حول قيم شبه ثابتة. كما تبقى الإشارة ضمن مجال تشغيل مقبول، مما يدل على قدرة الشبكة العصبية على إنتاج دورة العمل المناسبة اعتماداً على القياسات الكهربائية V_{pv} و I_{pv} .



الشكل 12.4: إشارة PWM


يوضح الشكل 12.4 تكبيراً زمنياً لإشارة PWM الناتجة عن خرج الشبكة العصبية. تظهر الإشارة بين الحالتين 0 و 1، مما يؤكد أن قيمة DANN تم تحويلها بشكل صحيح إلى إشارة تحكم قابلة للاستعمال في قيادة مفتاح المحول الرفع.

يمثل إدماج الشبكة داخل Simulink مرحلة مهمة في التحقق من صلاحية المتحكم العصبي. فبعد أن أثبتت الشبكة قدرتها على تقريب D_{ref} أثناء التدريب، أصبح من الضروري اختبار أدائها داخل النموذج الديناميكي، حيث تتغير الإشارات الكهربائية مع الزمن. لذلك يتم في القسم التالي تحليل استجابة النظام بعد تشغيل متحكم ANN-MPPT، من خلال دراسة تغير التيار والجهد والقدرة.

7.4 نتائج المحاكاة

بعد إدماج الشبكة العصبية داخل نموذج Simulink، تم تشغيل النظام الكهروضوئي تحت السيناريو المختار من أجل تقييم استجابة متحكم ANN-MPPT. وتهدف هذه المرحلة إلى دراسة سلوك النظام بعد أن أصبحت دورة العمل ناتجة عن الشبكة العصبية، أي أن المتحكم أصبح يعتمد على القيم الكهربائية V_{pv} و I_{pv} لإنتاج D_{ANN} ، ثم تحويلها إلى إشارة PWM للتحكم في المحول الرفع.

تم تسجيل الإشارات الأساسية للنظام خلال زمن المحاكاة، والمتمثلة في تيار اللوح I_{pv} ، وجهد V_{pv} ، وقدرته P_{pv} . وتُعد هذه الإشارات مؤشرات مباشرة على أداء المتحكم، لأن نجاح عملية MPPT يظهر من خلال قدرة النظام على الاستجابة لتغير ظروف التشغيل، ثم الوصول إلى حالة استقرار نسبي بعد كل تغير في الإشعاع الشمسي ودرجة الحرارة.



الشكل 13.4: استجابة النظام مع ANN-MPPT

يوضح الشكل (13.4) تطور التيار I_{pv} والجهد V_{pv} والقدرة P_{pv} بعد تشغيل متحكم ANN-MPPT. نلاحظ ظهور تغيرات واضحة في الإشارات عند لحظات تبدل ظروف التشغيل، خاصة عند الأزمنة 3s و 6s و 9s، وهي اللحظات التي تتغير فيها قيم الإشعاع الشمسي ودرجة الحرارة في السيناريو المطبق. يبين الشكل أن التيار الكهروضوئي يتأثر بشكل واضح بتغير الإشعاع الشمسي، إذ ينخفض عند انخفاض الإشعاع ويرتفع عند زيادته. أما الجهد، فيظهر تغيراً أقل حدة مقارنة بالتيار، لكنه يتأثر بدوره بدرجة الحرارة وبنقطة التشغيل التي يفرضها المتحكم العصبي. ونتيجة لتغير الجهد والتيار معاً، تتغير القدرة P_{pv} وفقاً لكل حالة تشغيل.

كما يلاحظ أن الإشارات تمر بفترات انتقالية قصيرة بعد كل تغير في ظروف التشغيل، ثم تعود إلى الاستقرار حول قيم شبه ثابتة. ويشير هذا السلوك إلى أن متحكم ANN-MPPT قادر على تعديل دورة العمل D_{ANN} بما يسمح بإعادة توجيه نقطة التشغيل نحو مجال مناسب لاستخراج القدرة من اللوح الكهروضوئي.

تدل هذه النتائج على أن الشبكة العصبية، بعد تدريبها على القيم المرجعية المستخرجة من خوارزمية P&O-MPPT، استطاعت إنتاج دورة عمل مناسبة داخل نموذج المحاكاة. غير أن هذا التقييم يبقى مرتبطاً بالسيناريو المدروس وبمجال البيانات التي استُعملت في التدريب، لذلك سيتم في القسم التالي إجراء مقارنة مباشرة بين أداء المتحكم العصبي وخوارزمية P&O-MPPT.

8.4 المقارنة مع خوارزمية P&O


بعد تحليل استجابة النظام عند تشغيل متحكم ANN-MPPT، تم إجراء مقارنة بين أداء المتحكم العصبي وخوارزمية P&O-MPPT المعتمدة كمرجع. وتهدف هذه المقارنة إلى تقييم مدى قدرة الشبكة العصبية على تقريب سلوك الخوارزمية المرجعية داخل نموذج المحاكاة، خاصة من حيث القدرة المستخرجة ودورة العمل الناتجة.

تعتمد المقارنة على الإشارات المسجلة خلال زمن المحاكاة، حيث تم تحليل القدرة الكهروضوئية P_{pv} ودورة العمل في كل من حالة التحكم بخوارزمية P&O وحالة التحكم بالشبكة العصبية. وتُعد القدرة المستخرجة مؤشراً مباشراً على فعالية التتبع، لأن الهدف الأساسي من MPPT هو تشغيل اللوح قرب نقطة القدرة العظمى. كما تمثل دورة العمل مؤشراً مهماً على سلوك المتحكم، لأنها الإشارة التي تتحكم في المحول الرفع وتحدد نقطة تشغيل اللوح.

يمكن حساب القدرة الكهروضوئية في كل لحظة وفق العلاقة الآتية:

$$P_{pv} = V_{pv} \times I_{pv}$$

حيث تمثل V_{pv} جهد اللوح و I_{pv} تياره. وبناءً على هذه العلاقة، تتم مقارنة القدرة الناتجة في الحالتين من أجل معرفة مدى تقارب أداء المتحكم العصبي مع خوارزمية P&O-MPPT.



الشكل 14.4: مقارنة القدرة بين P&O و ANN

يوضح الشكل (14.4) مقارنة تطور القدرة الكهروضوئية بين خوارزمية P&O-MPPT ومتحكم ANN-MPPT خلال زمن المحاكاة. نلاحظ أن منحنى القدرة الناتج عن المتحكم العصبي يتقارب بشكل كبير مع منحنى القدرة الناتج عن خوارزمية P&O في أغلب فترات التشغيل، خاصة بعد انتهاء الفترات الانتقالية. كما يظهر تحسن واضح في بداية المحاكاة، حيث أعطى متحكم ANN قدرة أعلى نسبياً. وتؤكد هذه النتيجة قدرة الشبكة العصبية على مجازاة الخوارزمية المرجعية ضمن السيناريو المدروس.

الجدول 8.4: مقارنة القدرة.

النافذة	المجال الزمني (s)	P&O (W)	ANN (W)	الفرق (W)	الفرق (%)
1	2.2 – 2.9	36.287	38.585	2.2983	6.3337
2	3.5 – 5.9	13.475	13.475	0.000111	0.000824
3	6.8 – 8.9	44.731	44.731	0.000000	0.000000
4	9.8 – 11.9	25.615	25.615	-0.000001	-0.000005

يبين الجدول 8.4 مقارنة القدرة الوسيطة المستخرجة باستعمال خوارزمية P&O-MPPT ومتحكم ANN-MPPT خلال أربع نوافذ تشغيل مستقرة. نلاحظ أن المتحكم العصبي أعطى قدرة قريبة جداً من القدرة الناتجة عن الخوارزمية المرجعية في النوافذ الثانية والثالثة والرابعة، حيث كانت الفروق شبه معدومة. أما في النافذة الأولى، فقد سجل متحكم ANN-MPPT قدرة أعلى بفارق قدره 2.2983 W ، أي بنسبة 6.3337 %. وتدل هذه النتائج على أن الشبكة العصبية استطاعت مجازاة سلوك خوارزمية

P&O-MPPT ضمن مجال التشغيل المدروس، مع تحسن واضح في النافذة الأولى.

الجدول 9.4 : مقارنة الطاقة الكلية المستخرجة.


طريقة التحكم	الطاقة الكلية (J)	الملاحظة
P&O-MPPT	359.90	مرجع المقارنة
ANN-MPPT	366.46	أداء المتحكم العصبي
الفرق	6.5674	فرق الطاقة بين الطريقتين

يبين الجدول 9.4 بلوغ نسبة الفرق في الطاقة 1.824797 % لصالح متحكم ANN-MPPT. كما يوضح أن الطاقة الكلية المستخرجة باستعمال متحكم ANN-MPPT بلغت J 366.46، مقابل J 359.90 باستعمال خوارزمية P&O-MPPT، أي بفارق قدره J 6.5674 ونسبة تحسن تقارب 1.824797 %. وتشير هذه النتيجة إلى أن المتحكم العصبي استطاع تحقيق أداء قريب جداً من الخوارزمية المرجعية، مع تحسن طفيف في الطاقة المستخرجة ضمن السيناريو المدروس.

الجدول 10.4: مقارنة دورة العمل.

النافذة	المجال الزمني (s)	$D_{ref} / P\&O$	D_{ANN} / ANN	الفرق ΔD
1	2.2 – 2.9	0.33932	0.38703	0.047702
2	3.5 – 5.9	0.34378	0.34378	-0.0000004176
3	6.8 – 8.9	0.39810	0.39809	-0.000011938
4	9.8 – 11.9	0.40395	0.40395	0.0000008827

يبين الجدول 10.4 مقارنة دورة العمل الناتجة عن خوارزمية P&O-MPPT ودورة العمل الناتجة عن الشبكة العصبية. نلاحظ أن قيم D_{ANN} كانت مطابقة تقريباً للقيم المرجعية D_{ref} في النوافذ الثانية والثالثة والرابعة، حيث بقي الفرق صغيراً جداً. أما في النافذة الأولى، فقد ظهر فرق أكبر بين القيمتين، وهو ما يفسر التحسن المسجل في القدرة خلال هذه النافذة. وبصفة عامة، تؤكد النتائج أن الشبكة العصبية استطاعت إنتاج دورة عمل قريبة جداً من خرج خوارزمية P&O-MPPT ضمن أغلب نوافذ التشغيل.



الشكل 14.4: مقارنة دورة العمل بين ANN و P&O

يبين الشكل (14.4) مقارنة دورة العمل الناتجة عن خوارزمية P&O ودورة العمل الناتجة عن الشبكة العصبية أثناء المحاكاة. يظهر تقارب واضح بين D_{po} و D_{ann} في أغلب فترات التشغيل المستقرة، مع وجود بعض الاختلافات خلال اللحظات الانتقالية الناتجة عن تغير ظروف التشغيل. ويؤكد هذا التقارب أن الشبكة العصبية تعلمت إنتاج قيم قريبة من دورة العمل المرجعية، وهو ما يفسر تقارب القدرة المستخرجة بين المتحكمين.

9.4 خلاصة الفصل

تم في هذا الفصل تنفيذ وتقييم متحكم MPPT قائم على الشبكات العصبية الاصطناعية داخل نموذج كهروضوئي في بيئة MATLAB/Simulink. وقد انطلق العمل من بناء نموذج النظام الكهروضوئي، ثم تطبيق مجموعة من سيناريوهات التشغيل التي تمثل تغيرات مختلفة في الإشعاع الشمسي ودرجة حرارة الخلية. وسمحت هذه السيناريوهات بتوليد استجابات كهربائية متنوعة للوح الكهروضوئي، خاصة من حيث الجهد V_{pv} والتيار I_{pv} والقدرة P_{pv} .

اعتمدت مرحلة توليد البيانات على خوارزمية P&O-MPPT بوصفها خوارزمية مرجعية لإنتاج دورة العمل المناسبة. وبعد تسجيل الإشارات الناتجة عن المحاكاة، تم اختيار العينات المناسبة وبناء قاعدة بيانات نهائية مكونة من 600 عينة. وقد استعملت القيم الكهربائية V_{pv} و I_{pv} كمدخلين للشبكة العصبية، بينما اعتمدت دورة العمل المرجعية D_{ref} كمخرج تدريبي.

أظهرت نتائج التدريب أن الشبكة العصبية استطاعت تقريب القيم المرجعية بدقة عالية، حيث كانت قيمة متوسط مربع الخطأ MSE صغيرة جداً، وبلغ معامل الارتباط R قيمة قريبة جداً من الواحد. كما بينت منحنيات الأداء والانحدار وتوزيع الخطأ وجود توافق واضح بين خرج الشبكة D_{ann} والقيم المرجعية

D_{ref} ، مما يدل على جودة التدريب وقدرة الشبكة على تمثيل العلاقة بين القياسات الكهربائية ودورة العمل المناسبة.

بعد ذلك، تم إدماج الشبكة العصبية داخل نموذج Simulink لاختبارها كمتحكم ANN-MPPT. وقد أظهرت نتائج المحاكاة أن المتحكم العصبي قادر على توليد دورة عمل مناسبة والتحكم في المحول الرفع من خلال إشارة PWM. كما بينت استجابة الجهد والتيار والقدرة أن النظام استطاع التكيف مع تغيرات ظروف التشغيل، مع ظهور فترات انتقالية قصيرة تليها حالات استقرار نسبي.

وأظهرت المقارنة مع خوارزمية P&O-MPPT أن متحكم ANN-MPPT أعطى أداءً قريباً جداً من الخوارزمية المرجعية في أغلب نوافذ التشغيل، مع تحسن واضح في الطاقة الكلية المستخرجة ضمن السيناريو المدروس. فقد بلغت الطاقة المستخرجة باستعمال المتحكم العصبي 366.46 J مقابل 359.90 J باستعمال خوارزمية P&O-MPPT، أي بفارق قدره 6.5674 J ونسبة تحسن تقارب 1.824797% .

بصفة عامة، تؤكد نتائج هذا الفصل أن الشبكة العصبية المدربة استطاعت تقريب سلوك خوارزمية P&O-MPPT وإنتاج دورة عمل مناسبة ضمن مجال البيانات والسيناريوهات المعتمدة. ومع ذلك، تبقى هذه النتائج مرتبطة بمجال التدريب وظروف المحاكاة المستعملة، مما يفتح المجال مستقبلاً لتوسيع قاعدة البيانات، واختبار المتحكم العصبي تحت سيناريوهات أكثر تنوعاً، ثم الانتقال لاحقاً إلى التحقق التجريبي على منصة حقيقية.

الخاتمة العامة

الخاتمة العامة

تناولت هذه المذكرة موضوع تحسين تتبع نقطة القدرة العظمى في الأنظمة الكهروضوئية باستعمال شبكة عصبية اصطناعية، اعتماداً على خوارزمية P&O-MPPT بوصفها خوارزمية مرجعية لتوليد قاعدة البيانات التدريبية. وقد انطلقت الدراسة من عرض الأسس العامة للأنظمة الكهروضوئية، ثم التطرق إلى تقنيات تتبع نقطة القدرة العظمى، وبعد ذلك دراسة مبادئ الشبكات العصبية الاصطناعية، وصولاً إلى تنفيذ وتقييم متحكم ANN-MPPT داخل بيئة MATLAB/Simulink.

أظهر الفصل الأول أن أداء اللوح الكهروضوئي يتأثر مباشرة بالظروف البيئية، خاصة شدة الإشعاع الشمسي ودرجة حرارة الخلية، وهو ما يؤدي إلى تغير الجهد والتيار والقدرة المنتجة. كما تم توضيح أن منحني القدرة-الجهد يحتوي على نقطة قدرة عظمى تتغير بتغير ظروف التشغيل، مما يجعل تشغيل النظام عند نقطة ثابتة غير كافٍ لاستخراج أكبر قدرة ممكنة من اللوح.

أما الفصل الثاني، فقد ركز على مبدأ تتبع نقطة القدرة العظمى MPPT، ودور المحول المستمر-المستمر ودورة العمل في تعديل نقطة تشغيل اللوح الكهروضوئي. كما تم عرض خوارزمية P&O، باعتبارها من أكثر الخوارزميات التقليدية استعمالاً بسبب بساطتها وسهولة تنفيذها. ورغم بعض محدودياتها، خاصة التذبذب حول نقطة القدرة العظمى، فقد تم اعتمادها في هذه الدراسة كمرجع لتوليد دورة العمل المناسبة.

وفي الفصل الثالث، تم عرض الأسس النظرية للشبكات العصبية الاصطناعية، مع التركيز على التعلم الموجه، تدريب الشبكة، ومؤشرات تقييم الأداء. وقد تم توضيح أن الشبكة العصبية قادرة على تعلم العلاقة غير الخطية بين القياسات الكهربائية للوح الكهروضوئي ودورة العمل المناسبة. وبناءً على ذلك، تم اعتماد الجهد V_{pv} والتيار I_{pv} كمداخل للشبكة، بينما اشتملت دورة العمل المرجعية D_{ref} كمخرج تدريبي.

أما الفصل الرابع، فقد مثّل الجانب التطبيقي من المذكرة، حيث تم تنفيذ نموذج كهروضوئي في MATLAB/Simulink، ثم اعتماد سيناريوهات مختلفة للإشعاع الشمسي ودرجة الحرارة من أجل توليد بيانات متنوعة. بعد ذلك، تم استعمال خوارزمية P&O-MPPT لاستخراج دورة العمل المرجعية، ثم اختيار قاعدة بيانات نهائية مكونة من 600 عينة لتدريب الشبكة العصبية.

أظهرت نتائج التدريب أن الشبكة العصبية استطاعت تقريب دورة العمل المرجعية بدقة عالية، حيث بلغت قيمة متوسط مربع الخطأ MSE مقدار 0.000000007741، وبلغ متوسط الخطأ المطلق MAE قيمة 0.000053542161، في حين لم يتجاوز الخطأ الأعظمي 0.000280021240. كما بلغت قيمة

معامل الارتباط R مقدار 0.999995741207، وهو ما يدل على توافق شبه تام بين خرج الشبكة العصبية D_{ANN} والقيم المرجعية D_{ref} ضمن مجال بيانات التدريب.

وبعد إدماج الشبكة العصبية داخل نموذج Simulink، بينت نتائج المحاكاة أن متحكم ANN-MPPT قادر على إنتاج دورة عمل مناسبة والتحكم في المحول الرافع عبر إشارة PWM. كما أظهرت استجابة التيار والجهد والقدرة أن النظام استطاع التكيف مع تغيرات ظروف التشغيل، مع ظهور فترات انتقالية قصيرة تليها حالات استقرار نسبي.

كما بينت المقارنة بين متحكم ANN-MPPT وخوارزمية P&O-MPPT أن المتحكم العصبي أعطى أداءً قريباً جداً من الخوارزمية المرجعية في أغلب نوافذ التشغيل. وقد بلغت الطاقة الكلية المستخرجة باستعمال ANN-MPPT قيمة 366.46 J ، مقابل 359.90 J باستعمال P&O-MPPT، أي بفارق قدره 6.5674 J ونسبة تحسن تقارب 1.824797% . وتدل هذه النتيجة على أن الشبكة العصبية استطاعت مجازة خوارزمية P&O، مع تحقيق تحسن طفيف ضمن السيناريو المدروس.

انطلاقاً من هذه النتائج، يمكن القول إن استعمال الشبكات العصبية الاصطناعية يمثل حلاً واعداً في مجال تتبع نقطة القدرة العظمى، خاصة عندما يتم تدريبها على قاعدة بيانات مناسبة وممثلة لمجال التشغيل. فقد أثبتت الشبكة قدرتها على تعلم العلاقة بين V_{pv} و I_{pv} من جهة، و D_{ref} من جهة أخرى، ثم إنتاج دورة العمل D_{ANN} المناسبة داخل نموذج التحكم.

ومع ذلك، تبقى نتائج هذه الدراسة مرتبطة بمجال البيانات المستعملة في التدريب وبالسيناريوهات المعتمدة في المحاكاة. لذلك لا يمكن تعميم الأداء المحصل عليه على جميع ظروف التشغيل دون توسيع قاعدة البيانات واختبار المتحكم العصبي تحت حالات أكثر تنوعاً، مثل التغيرات السريعة جداً في الإشعاع، حالات التظليل الجزئي، وتغيرات الحمل.

كآفاق مستقبلية، يمكن توسيع هذا العمل من خلال زيادة عدد السيناريوهات المستعملة في توليد البيانات، وإدخال حالات التظليل الجزئي ضمن التدريب، وتجريب بنى مختلفة للشبكات العصبية من أجل تحسين التعميم. كما يمكن مقارنة المتحكم العصبي مع خوارزميات أخرى مثل Incremental Conductance أو Fuzzy Logic أو PSO. وأخيراً، يبقى الانتقال من المحاكاة إلى التطبيق التجريبي على منصة حقيقية خطوة مهمة للتحقق من أداء المتحكم ANN-MPPT في ظروف تشغيل واقعية.

المراجع

المراجع

- [1] J. A. Duffie and W. A. Beckman, *Solar Engineering of Thermal Processes*, 4th ed. Hoboken, NJ, USA: Wiley, 2013.
- [2] S. A. Kalogirou, *Solar Energy Engineering: Processes and Systems*, 2nd ed. Amsterdam, Netherlands: Academic Press, 2014.
- [3] R. A. Messenger and A. Abtahi, *Photovoltaic Systems Engineering*, 4th ed. Boca Raton, FL, USA: CRC Press, 2017.
- [4] A. E. Becquerel, “Mémoire sur les effets électriques produits sous l’influence des rayons solaires,” *Comptes Rendus de l’Académie des Sciences*, vol. 9, pp. 561–567, 1839.
- [5] A. Einstein, “Über einen die Erzeugung und Verwandlung des Lichtes betreffenden heuristischen Gesichtspunkt,” *Annalen der Physik*, vol. 17, no. 6, pp. 132–148, 1905.
- [6] D. M. Chapin, C. S. Fuller, and G. L. Pearson, “A new silicon p-n junction photocell for converting solar radiation into electrical power,” *Journal of Applied Physics*, vol. 25, no. 5, pp. 676–677, 1954.
- [7] M. A. Green, *Solar Cells: Operating Principles, Technology, and System Applications*. Englewood Cliffs, NJ, USA: Prentice-Hall, 1982.
- [8] A. Luque and S. Hegedus, Eds., *Handbook of Photovoltaic Science and Engineering*, 2nd ed. Chichester, UK: Wiley, 2011.
- [9] J. Nelson, *The Physics of Solar Cells*. London, UK: Imperial College Press, 2003.
- [10] S. M. Sze and K. K. Ng, *Physics of Semiconductor Devices*, 3rd ed. Hoboken, NJ, USA: Wiley, 2006.
- [11] M. G. Villalva, J. R. Gazoli, and E. R. Filho, “Comprehensive approach to modeling and simulation of photovoltaic arrays,” *IEEE Transactions on Power Electronics*, vol. 24, no. 5, pp. 1198–1208, 2009.
- [12] W. De Soto, S. A. Klein, and W. A. Beckman, “Improvement and validation of a model

- for photovoltaic array performance,” *Solar Energy*, vol. 80, no. 1, pp. 78–88, 2006.
- [13] J. A. Gow and C. D. Manning, “Development of a photovoltaic array model for use in power-electronics simulation studies,” *IEE Proceedings – Electric Power Applications*, vol. 146, no. 2, pp. 193–200, 1999.
- [14] H. L. Tsai, C. S. Tu, and Y. J. Su, “Development of generalized photovoltaic model using MATLAB/SIMULINK,” in *Proceedings of the World Congress on Engineering and Computer Science*, San Francisco, CA, USA, 2008.
- [15] G. Walker, “Evaluating MPPT converter topologies using a MATLAB PV model,” *Journal of Electrical and Electronics Engineering, Australia*, vol. 21, no. 1, pp. 49–56, 2001.
- [16] N. Mohan, T. M. Undeland, and W. P. Robbins, *Power Electronics: Converters, Applications, and Design*, 3rd ed. Hoboken, NJ, USA: Wiley, 2003.
- [17] R. W. Erickson and D. Maksimović, *Fundamentals of Power Electronics*, 2nd ed. New York, NY, USA: Springer, 2001.
- [18] M. H. Rashid, *Power Electronics: Circuits, Devices, and Applications*, 4th ed. Boston, MA, USA: Pearson, 2014.
- [19] T. Esum and P. L. Chapman, “Comparison of photovoltaic array maximum power point tracking techniques,” *IEEE Transactions on Energy Conversion*, vol. 22, no. 2, pp. 439–449, 2007.
- [20] D. P. Hohm and M. E. Ropp, “Comparative study of maximum power point tracking algorithms,” *Progress in Photovoltaics: Research and Applications*, vol. 11, no. 1, pp. 47–62, 2003.
- [21] N. Femia, G. Petrone, G. Spagnuolo, and M. Vitelli, “Optimization of perturb and observe maximum power point tracking method,” *IEEE Transactions on Power Electronics*, vol. 20, no. 4, pp. 963–973, 2005.
- [22] K. H. Hussein, I. Muta, T. Hoshino, and M. Osakada, “Maximum photovoltaic power tracking: An algorithm for rapidly changing atmospheric conditions,” *IEE Proceedings – Generation, Transmission and Distribution*, vol. 142, no. 1, pp. 59–64, 1995.

- [23] V. Salas, E. Olías, A. Barrado, and A. Lázaro, “Review of the maximum power point tracking algorithms for stand-alone photovoltaic systems,” *Solar Energy Materials and Solar Cells*, vol. 90, no. 11, pp. 1555–1578, 2006.
- [24] B. Subudhi and R. Pradhan, “A comparative study on maximum power point tracking techniques for photovoltaic power systems,” *IEEE Transactions on Sustainable Energy*, vol. 4, no. 1, pp. 89–98, 2013.
- [25] A. Safari and S. Mekhilef, “Simulation and hardware implementation of incremental conductance MPPT with direct control method using cuk converter,” *IEEE Transactions on Industrial Electronics*, vol. 58, no. 4, pp. 1154–1161, 2011.
- [26] K. Ishaque and Z. Salam, “A review of maximum power point tracking techniques of PV system for uniform insolation and partial shading condition,” *Renewable and Sustainable Energy Reviews*, vol. 19, pp. 475–488, 2013.
- [27] S. Haykin, *Neural Networks and Learning Machines*, 3rd ed. Upper Saddle River, NJ, USA: Pearson, 2009.
- [28] M. T. Hagan, H. B. Demuth, M. H. Beale, and O. De Jesús, *Neural Network Design*, 2nd ed. Stillwater, OK, USA: Martin Hagan, 2014.
- [29] C. M. Bishop, *Pattern Recognition and Machine Learning*. New York, NY, USA: Springer, 2006.
- [30] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. Cambridge, MA, USA: MIT Press, 2016.
- [31] M. H. Beale, M. T. Hagan, and H. B. Demuth, *Neural Network Toolbox User’s Guide*. Natick, MA, USA: MathWorks, 2017.
- [32] A. Mellit and S. A. Kalogirou, “Artificial intelligence techniques for photovoltaic applications: A review,” *Progress in Energy and Combustion Science*, vol. 34, no. 5, pp. 574–632, 2008.
- [33] A. Mellit, S. A. Kalogirou, L. Hontoria, and S. Shaari, “Artificial intelligence techniques for sizing photovoltaic systems: A review,” *Renewable and Sustainable Energy*

Reviews, vol. 13, no. 2, pp. 406–419, 2009.

[34] M. Veerachary, T. Senjyu, and K. Uezato, “Neural-network-based maximum-power-point tracking of coupled-inductor interleaved-boost-converter-supplied PV system using fuzzy controller,” *IEEE Transactions on Industrial Electronics*, vol. 50, no. 4, pp. 749–758, 2003.

[35] M. A. Elgendy, B. Zahawi, and D. J. Atkinson, “Assessment of perturb and observe MPPT algorithm implementation techniques for PV pumping applications,” *IEEE Transactions on Sustainable Energy*, vol. 3, no. 1, pp. 21–33, 2012.

[36] MathWorks, *MATLAB Documentation*. Natick, MA, USA: The MathWorks, Inc., 2017.

[37] MathWorks, *Simulink Documentation*. Natick, MA, USA: The MathWorks, Inc., 2017.

[38] MathWorks, *Deep Learning Toolbox Documentation*. Natick, MA, USA: The MathWorks, Inc., 2017.