

بسم الله الرحمن الرحيم



تصميم نظام تحكم ذكي بالشبكات الكهربائية باستخدام الذكاء الاصطناعي



بحث تكميلي لنيل درجة البكالوريوس مرتبة الشرف في الهندسة الكهربائية

اعداد :

إبراهيم حسين احمد إبراهيم

الطاهر الحاج العوض عبدالله

فتح الرحمن إبراهيم الطيب محمد

إشراف:

أ/ إبراهيم أحمد إبراهيم

كلية الهندسة

جامعة الشيخ عبدالله البدري

إبريل - 2026

الآية

بسم الله الرحمن الرحيم

(أَمَّنْ هُوَ قَانِتٌ آنَاءَ اللَّيْلِ سَاجِدًا وَقَائِمًا يَحْذَرُ الْآخِرَةَ وَيَرْجُو رَحْمَةَ رَبِّهِ ۗ قُلْ هَلْ يَسْتَوِي الَّذِينَ يَعْلَمُونَ وَالَّذِينَ لَا يَعْلَمُونَ ۗ إِنَّمَا يَتَذَكَّرُ أُولُو الْأَلْبَابِ)

سورة الزمر الآية (9)

(يَرْفَعِ اللَّهُ الَّذِينَ آمَنُوا مِنْكُمْ وَالَّذِينَ أُوتُوا الْعِلْمَ دَرَجَاتٍ)

للتأمل (أوتوا) فالعلم فضل من الله

أَللّهُمَّ أَتَيْنَا مِنْ فَضْلِكَ وَأَجْعَلْنَا مِنْ أَهْلِ الْعِلْمِ وَالْإِيمَانِ وَالرَّحْمَةِ

إهداء

إلهي لا يطيب الليل إلا بشكرك ولا يطيب النهار إلا بطاعتك ولا تطيب اللحظات إلا بذكرك ولا تطيب
الأخرة إلا بعفوك ولا تطيب الدنيا إلا برؤيتك جل جلالك

الحمد لله وكفي والصلاة والسلام علي الحبيب المصطفى إلي من بلغ الرسالة وأدي الأمانة ونصح الأمة
إلي نبي الرحمة والنور صلي الله عليه وسلم تسليماً كثيراً

إلي أُمي

التي علمتني الصبر وحببت إلي القناعة وغالبت في غيبتني عنها الألام والدموع وكانت تعيش دائماً أوبة
الغائب وتدعو له في خلواتها وصلواتها وأحلامها

إلي والدي العزيز

إلي من كلله الله بالهيبة والوقار

إلي من علمنا العطاء دون إنتظار

إلي من أحمل إسمه بإفتخار

إلي أساتذتي بكلية الهندسة جامعة الشيخ عبد الله البدري

إلي كل من علمني حرفاً وأضاء الطريق أمامي

إلي الكادحون في الطرقات إلي كل من كانت أمنيته دراسة الهندسة الكهربائية وحالت الظروف دون ذلك

إلي إخوتي وأصدقائي

إلي كل من رافقني خلال مسيرتي

إلي من عرفت كيف أجدهم وعلموني أن لا أضيعهم

إلي جميع طلاب الدفعة التاسعة

إلي كل مهندسي بلادي

يا ملهماً يسمو بأرض الهندسة يمضي بدرب العلم حتي يغرسه

حسب المهندس لا بديل له وكأنه بالفضل أعظم مدرسة

فأسكب عطورك إن أتاك مهندس وأنشرك عبيرك إن أنتك مهندسة

شكر وتقدير

الحمد لله حمداً كثيراً طيباً مباركاً فيه والشكر له على نعمه التي لا تعد ولا تحصى
أما بعد :

لا بد لنا ونحن نخطو خطواتنا الأخيرة في الحياة الجامعية من وقفة نعود فيها إلي أعوام
قضيناها في رحاب الجامعة

فالشكر موصول لجامعة الشيخ عبد الله البدري ذلك الصرح الشامخ في سماء العلم والمعرفة
متمثلة في كلية الهندسة قسم الهندسة الكهربائية إدارة وأساتذة تلك الكواكب النيرة التي نهلت
من علمها وما ذالت

بحروف نكتبها من نور صدقاً وأمانة نطوقها بالعهد والوفاء نترجمها شكراً وتبجيلاً لفضائل
وجلائل أعمالكم التي إشرأبت لها هامة الزمان وتظل أعمالكم تضيئ عزة وشموخاً شعلا
فعندما يتوارث الناس روائع الأشياء تكون منبعاً للأصالة أو في ألق التهذيب هكذا عرفناكم
وأنصهرت هممكم العالية بذلاً وعطاء وأمتدجت أرواحكم بالنيل والنقاء وكنتم قناديل تحترق
لتهب غيرها الضياء

إلي أولئك الذين منحونا العزم تلو العزم لنتخطي الصعاب وأن نقف واثقي الخطى حرفاً ولغة
نشاطرهم الإبداع وأساتذة ومهندسين فلا تسع الحروف إلا أن تمتزج لتكون كلمات شكر وعرفان
لكل من دعمنا ولكل من ساهم في تدريبنا مهندسين وأساتذة

كن عالماً فإن لم تستطع فكن معلماً وإن لم تستطع فأحب العلماء فإن لم تستطع فلا تبغضهم
وإلي رفقاء الدرب الدفعة التاسعة

وأخص بالشكر والتقدير

أ/ ابراهيم احمد ابراهيم

المستخلص :

يقدم هذا البحث تصميم وتنفيذ نظام تحكم ذكي للشبكات الكهربائية باستخدام تقنيات الذكاء الاصطناعي، مع تطبيق عملي على محطة شندي التحويلية بجهد 110/220 كيلوفولت في السودان. تنبع أهمية الدراسة من التحديات الحرجة التي تواجه الشبكة القومية، بما في ذلك عدم استقرار الأحمال، وتقدم البنية التحتية، ومحدودية سعة التوليد، وغياب أنظمة المراقبة التنبؤية. ولمعالجة هذه المشكلات، تم اقتراح إطار عمل قائم على البيانات يهدف إلى تحسين الكفاءة التشغيلية، والموثوقية، واستقرار النظام الكهربائي.

تعتمد المنهجية المقترحة على استخدام بيانات تشغيل حقيقية مستخلصة من نظام سكادا ، وتشمل متغيرات كهربائية رئيسية مثل القدرة الفعالة، التيار، الجهد، والقدرة غير الفعالة. تم تطبيق تقنيات المعالجة المسبقة للبيانات، بما في ذلك التتميط الإحصائي وإزالة القيم الشاذة، لضمان جودة البيانات واتساقها. كما تم تطوير نموذج تعلم عميق يعتمد على شبكات الذاكرة طويلة قصيرة المدى لتنفيذ التنبؤ قصير الأمد بالأحمال باستخدام منهجية السلاسل الزمنية متعددة المتغيرات. تم تدريب النموذج وتقييمه باستخدام مقاييس أداء قياسية تشمل جذر متوسط مربع الخطأ ومتوسط الخطأ المطلق ، ومعامل التحديد (R^2).

بالإضافة إلى ذلك، تم دمج استراتيجية تحكم ذكية تعتمد على منطق العتبات مع نموذج التنبؤ، مما يتيح اتخاذ قرارات فورية في الزمن الحقيقي لإدارة توزيع الأحمال وتنفيذ عمليات فصل الأحمال بشكل آلي عند الحاجة. يقوم النظام بإدارة تشغيل المحولات المتوازية ديناميكياً، مع إعطاء أولوية للأحمال الحيوية لتفادي انهيار النظام في حالات الحمل الزائد.

أظهرت نتائج المحاكاة أن النموذج المقترح يحقق دقة تنبؤية عالية، حيث بلغ معامل التحديد (R^2) قيمة 0.9824 مع انخفاض ملحوظ في قيم الخطأ، مما يؤكد كفاءته في تمثيل الأنماط غير الخطية للأحمال الكهربائية. كما ساهم نظام التحكم المدمج في تحسين استقرار الشبكة، وتقليل الإجهاد الحراري على المحولات، والحد من مخاطر حدوث الإطلام التام.

تشير النتائج إلى أن دمج تقنيات التعلم العميق مع أنظمة التحكم التقليدية يمثل حلاً فعالاً وقابلاً للتوسع لتحديث الشبكات الكهربائية. ويساهم هذا النهج في دعم التحول نحو الشبكات الذكية القادرة على التنبؤ والتكيف مع ظروف التشغيل. ويوصي البحث مستقبلاً بتطوير نماذج هجينة مثل الذاكرة طويلة قصيرة

المدى والشبكة العصبية الالتفافية ، وتحديث البنية التحتية للقياس، ودمج مصادر الطاقة المتجددة لتعزيز كفاءة واستدامة منظومة الطاقة الكهربائية.

Abstract :

This paper presents the design and implementation of an intelligent control system for electrical power networks using artificial intelligence techniques, with a case study on the Shendi 220/110 kV substation in Sudan. The study is motivated by critical challenges facing the national grid, including load instability, aging infrastructure, limited generation capacity, and the absence of predictive monitoring systems. To address these issues, a data-driven framework is proposed to enhance operational efficiency, reliability, and resilience of the power system.

The proposed methodology utilizes real operational data acquired from the SCADA system, incorporating key electrical parameters such as active power, current, voltage, and reactive power. Data preprocessing techniques, including statistical normalization and outlier removal, are applied to ensure data quality and consistency. A deep learning model based on Long Short-Term Memory (LSTM) networks is developed to perform short-term load forecasting using a multivariate time-series approach. The model is trained and validated using standard performance metrics, including Root Mean Square Error (RMSE), Mean Absolute Error (MAE), and the coefficient of determination (R^2).

In addition, an intelligent control strategy based on threshold logic is integrated with the forecasting model to enable real-time decision-making for load distribution and automated load shedding. The system dynamically manages the operation of parallel transformers and prioritizes critical loads to prevent system collapse under overload conditions.

Simulation results demonstrate that the proposed model achieves high predictive accuracy, with an R^2 value of 0.9824 and low error margins, confirming its

effectiveness in capturing nonlinear load patterns. Furthermore, the integrated control mechanism significantly improves system stability, reduces thermal stress on transformers, and minimizes the risk of blackout events.

The findings indicate that the integration of deep learning techniques with conventional control systems provides a robust and scalable solution for modernizing power networks. This approach facilitates the transition toward smart grid architectures capable of predictive operation and adaptive control. Future work recommends extending the model using hybrid architectures (e.g., CNN-LSTM), upgrading measurement infrastructure, and incorporating renewable energy sources to further enhance system performance and sustainability.

فهرس المحتويات

البند	المحتوي	رقم الصفحة
	الاية	ii
	اهداء	iii
	شكر وتقدير	iv
	المستخلص	v
	Abstract	vii
الفصل الاول		
1-1	المقدمة	2
2-1	مشكلة البحث	5
3-1	اهداف البحث	6
4-1	اهمية البحث	7
5-1	منهجية البحث	8
الفصل الثاني		
2-1	مقدمة الفصل	10
2-2	الشبكات العصبية الاصطناعية	10
3-2	المصطلحات والمفاهيم العامة	12
4-2	الدراسات السابقة	14
الفصل الثالث		
1-3	مقدمة الفصل	17
2-3	هيكله ومنهجية العمل	17
3-3	توصيف البيانات الفنية	18
4-3	المعالجة المسبقة للبيانات	19
5-3	هندسة المتسلسلات الزمنية	20
6-3	التصميم الهيكلي للشبكة LSTM المقترحة	20

22	خوارزمية التحسين " آدم "	7-3
22	معايير تقييم الاداء	8-3
23	منطق التحكم وإدارة الاحمال	9-3
الفصل الرابع		
26	مقدمة الفصل	1-4
26	بيئة النظام وهيكلية الكود البرمجي	2-4
28	نتائج تدريب الشبكة العصبية LSTM	3-4
30	محاكاة الواجهة الرسومية الذكية (Smart UI)	4-4
32	سجل البيانات المباشر	5-4
33	المناقشة الفنية لنتائج التوأم الرقمي	6-4
33	الخلاصة والاستنتاجات المستمدة من النتائج	7-4
الفصل الخامس		
36	الخلاصة	1-5
36	الاستنتاجات الفنية	2-5
37	التوصيات المستقبلية	3-5
38	الخاتمة	4-5

فهرس الجداول

البند	المحتوي	رقم الصفحة
1-1	يوضح المعايير والوصف الفني والتشغيلي لواقع قطاع الكهرباء في السودان والتحديات الراهنة	3
1-3	متغيرات المدخلات	18
2-3	استراتيجية التبديل والفصل	23

فهرس الاشكال

البند	المحتوي	رقم الصفحة
1-1	صورة لمحطة شندي التحويلية	4
2-1	مخطط نمط الاستهلاك اليومي	4
1-2	نموذج العصبون الاصطناعي	10
2-2	بنية الشبكة العصبية متعدد الطبقات	11
3-2	معارية الشبكة المتكررة (RNN) في حالي الطي والبسط	12
4-2	مخطط تدفق معالجة البيانات	13
1-3	منهجية البحث	17
2-3	الاثار الاحصائي علي البيانات	19
3-3	رسم تخطيطي للنافذة المنزلقة	20
4-3	رسم داخلي لخلية LSTM	21
5-3	يوضح مخطط تدفقي لمنطق فصل الحمل التلقائي المستند الي التنبؤ الذكي	24
1-4	عملية تدريب الشبكة العصبية (LSTM)	27
2-4	يوضح الواجهة الرئيسية لبرنامج الماتلاب	27
3-4	الثوابت البرمجية التي تحكم سلوك المحطة	28
4-4	منحنيات التدريب	29
5-4	سجل التفاعلات الحسابية	29
6-4	الاحصائيات الختامية للنموذج	30

31	واجهة النظام في وضع (Auto)	7-4
31	اختبار النظام في حالة زيادة الحمل	8-4
32	منحني التنبؤ	9-4
33	جدول البيانات المسجلة	10-4

الفصل الاول

مقدمة البحث

⌘ ⌘ ⌘ ⌘ ⌘ ⌘ ⌘

1-1 المقدمة :

تعد هندسة النظم الكهربائية في العصر الراهن حجر الزاوية في التطور الصناعي والاجتماعي، إلا أن هذه النظم تواجه تحديات غير مسبقة تتعلق بالاستقرار والكفاءة، لا سيما في الدول التي تعاني من فجوات في التوليد وبنية تحتية متهاكلة نتيجة الظروف الجيوسياسية والمناخية.

1-1-1 الخلفية العامة والتحول نحو النظم الذكية :

في السودان، يمثل قطاع الكهرباء أحد أكثر القطاعات حيوية وتأثراً بالأزمات الأخيرة، حيث تشير التقارير إلى فقدان ما يقرب من 40% من سعة التوليد الكلية وتضرر آلاف المحولات وخطوط النقل. ومن هنا، تبرز الحاجة الماسة إلى دمج تقنيات الذكاء الاصطناعي (AI) والتعلم العميق (Deep Learning) لتحويل الشبكات التقليدية إلى شبكات ذكية (Smart Grids) قادرة على التنبؤ بالطلب المستقبلي وكشف الأعطال قبل وقوعها، وهو ما يركز عليه هذا البحث المطبق على محطة شندي التحويلية.

شهد العالم في العقدین الأخيرین تحولاً جذرياً في مفهوم إدارة الطاقة، حيث لم تعد الشبكات الكهربائية مجرد قنوات لنقل التيار من محطات التوليد إلى المستهلكين، بل تحولت إلى نظم معلوماتية معقدة تعتمد على تدفق البيانات ثنائي الاتجاه. إن دمج الذكاء الاصطناعي في هذه المنظومات يتيح لمشغلي الشبكات القدرة على التنبؤ بالأحمال (Load Forecasting) بدقة عالية، مما يساعد في التخطيط الأمثل للوحدات التوليدية وتقليل الفواقد الفنية.

في السياق السوداني، تعتمد الشبكة القومية بشكل أساسي على التوليد المائي من السدود مثل سد مروي، الذي يساهم بنسبة كبيرة من الطاقة الكهربائية الموزعة عبر خطوط ناقلية تمتد لمئات الكيلومترات.

ومع ذلك، فإن هذه الشبكة تواجه ضغوطاً هائلة نتيجة للنمو السكاني وتوسع الأنشطة الزراعية والصناعية في ولايات مثل ولاية نهر النيل، وتحديدًا في منطقة شندي التي تعتبر مركزاً اقتصادياً وتجارياً حيوياً.

تعتبر تقنيات التعلم العميق، مثل شبكات الذاكرة طويلة قصيرة المدى (LSTM)، الحل الأمثل لمعالجة بيانات السلاسل الزمنية للأحمال الكهربائية، نظراً لقدرتها الفائقة على التعامل مع الأنماط غير الخطية والاعتماديات الزمنية طويلة الأمد.

إن النماذج التقليدية مثل (ARIMA) أو الانحدار الخطي غالباً ما تفشل في تقديم تنبؤات دقيقة عندما تتعرض الشبكة لتقلبات حادة أو أحداث غير متوقعة، وهو ما يجعل اللجوء إلى الذكاء الاصطناعي ضرورة تشغيلية وليس ترفاً تقنياً.

1-1-2 واقع قطاع الكهرباء في السودان والتحديات الراهنة :

يعاني قطاع الكهرباء في السودان من ضعف مزمن في الاستثمارات وتقادم في البنية التحتية، وهو ما تفاقم بشكل حاد خلال النزاعات المسلحة الأخيرة التي أدت إلى تدمير محطات توليد رئيسية في الخرطوم مثل محطة بحري ومحطة قري. تشير الإحصاءات الرسمية إلى أن العجز في التوليد يتسع باستمرار، مما يضطر شركات الكهرباء إلى تطبيق سياسات تخفيف الأحمال (Load Shedding) بشكل مكثف.

الجدول (1-1) يوضح المعايير والوصف الفني والتشغيلي لواقع قطاع الكهرباء في السودان والتحديات الراهنة :

المعايير	الوصف الفني والتشغيلي
سعة التوليد المتاحة	انخفاض بنسبة 40% تقريباً نتيجة النزاع
الوصول الي الكهرباء	حوالي 54% من السكان (مع تركيز في المناطق الحضرية
البنية التحتية المتضررة	150,000 كم من خطوط النقل و 15,000 محول
مصادر التوليد	60% مائي ، 39% حراري ، 1% فقط طاقة متجددة
التردد المرجعي	50 هيرتز


1-1-3 محطة شندي التحويلية (110/220 كيلو فولت): التوصيف والمكانة الاستراتيجية :

تعد محطة شندي التحويلية من أهم العقد في الشبكة القومية السودانية، حيث تستقبل الطاقة بجهد 220 كيلو فولت وتقوم بخفضه إلى 110 كيلو فولت لتغذية الشبكات الفرعية والمصانع والمشاريع الزراعية في المنطقة. تضم المحطة محولين رئيسيين بقدرات متفاوتة، مما يفرض تحديات في موازنة الأحمال بينهما.



شكل (1-1) : صورة لمحطة شندي التحويلية

يظهر الشكل (1-1) محطة شندي التحويلية التي تضم محولات قوى مغمورة في الزيت، مع عوازل سيراميكية وخطوط نقل علوية تمتد عبر البيئة الصحراوية لمنطقة شندي. يظهر في الصورة نظام التبريد بالمراوح (ONAF) المرتبط بالمحولات، وهو جزء ضروري نظراً للظروف المناخية القاسية في المنطقة. من خلال تحليل بيانات نظام "سكادا" (SCADA) للمحطة خلال شهر فبراير 2026، يظهر نمط استهلاك يومي واضح يتميز بوجود ذروة في منتصف النهار (ساعة 14:00)، حيث يرتفع الحمل الإجمالي للمحطة بشكل ملحوظ مقارنة بساعات الصباح الباكر كما موضح في الشكل (2-1) .



شكل (2-1) : مخطط نمط الاستهلاك اليومي

1-2 مشكلة البحث :

تنبثق مشكلة هذا البحث من التحديات الفنية والتشغيلية المعقدة التي تواجه محطة شندي في ظل الظروف الحالية للسودان. يمكن تقسيم أبعاد المشكلة إلى أربعة محاور أساسية:

1-2-1 المحور الأول: عدم خطية الأحمال وصعوبة التنبؤ التقليدي

تتسم الأحمال الكهربائية في منطقة شندي بطبيعة متذبذبة وغير خطية نتيجة تداخل الأحمال المنزلية مع الأحمال الزراعية (مضخات الري) والصناعية. النماذج الإحصائية التقليدية تعجز عن التقاط هذه التغيرات المفاجئة، خاصة في ظل تقلبات الطقس والارتفاع الحاد في درجات الحرارة الذي يؤدي إلى زيادة مفاجئة في أحمال التبريد والتكييف. إن عدم دقة التنبؤ يؤدي إما إلى هدر في الطاقة المولدة أو إلى انقطاعات مفاجئة نتيجة التحميل الزائد.

1-2-2 المحور الثاني: الخلل في توزيع الأحمال وتأثيره على عمر المعدات

تظهر البيانات التشغيلية وجود اختلال دائم ومستمر في توزيع الأحمال بين المحول T1 سعة 100MVA والمحول T2 سعة 50MVA ، حيث يحمل المحول T1 دائماً ضعف حمل T2. هذا التوزيع، وإن كان يبدو متناسباً مع السعة الاسمية، إلا أنه يعرض المحول الأكبر لإجهادات حرارية وكهربائية مستمرة تسرع من تدهور العوازل وتقصّر العمر الافتراضي للمعدات بنسبة تصل إلى 8.3% عند التحميل الكامل المستمر.

1-2-3 المحور الثالث: تأثير النزاع والظروف البيئية على استقرار الشبكة

تعرضت أجزاء من المنظومة الكهربائية المرتبطة بشندي لاستهدافات مباشرة بمسيرات وأعمال تخريبية، مما أدى إلى خروج خطوط ناقلية عن الخدمة وزيادة الضغط على المحطات المتبقية. بالإضافة إلى ذلك، فإن الظروف المناخية القاسية في المنطقة، بما في ذلك العواصف الرملية ودرجات الحرارة التي تتجاوز 45 درجة مئوية، تؤدي إلى تدهور كفاءة النقل وزيادة احتمالية حدوث الأعطال نتيجة تلوث العوازل.

1-2-4 المحور الرابع: نقص الأنظمة الذكية لكشف الأعطال المبكر

تعتمد المحطة حالياً على أنظمة حماية تقليدية تقوم بفصل التيار عند وقوع العطل بالفعل، ولكنها تفتقر إلى منظومة "تنبؤية" قادرة على اكتشاف المؤشرات الأولية للأعطال (مثل التذبذبات الطفيفة في الجهد أو التيار) قبل أن تتحول إلى أعطال كارثية تؤدي إلى إظلام تام للمدينة.

1-3 أهداف البحث .:

1-3-1 الهدف الاستراتيجي : يتمثل لهذا البحث في تصميم وبناء نموذج ذكي متكامل يعمل ك "توأم رقمي" لمحطة شندي التحويلية، قادراً على إدارة الطاقة بذكاء وتتنبؤ بالمتغيرات التشغيلية بدقة عالية.

1-3-2 الهدف العام : تطوير منظومة ذكية للتنبؤ بالأحمال الكهربائية وكشف الأعطال وتوزيع الطاقة في محطة شندي التحويلية (110/220 كيلو فولت) باستخدام تقنيات التعلم العميق (LSTM/GRU) وخوارزميات التحسين المستوحاة من الطبيعة، لرفع كفاءة الشبكة القومية السودانية في منطقة نهر النيل.

1-3-3 الأهداف التفصيلية .:

1. بناء نموذج تنبؤ بالأحمال (Load Forecasting Model):

تطوير خوارزمية تعتمد على شبكات الذاكرة طويلة قصيرة المدى (LSTM) للتنبؤ بالأحمال الكهربائية على المدى القصير (ساعة واحدة إلى يوم واحد)، مع تحقيق دقة تنبؤية تتجاوز 98% وتقليل مؤشر RMSE إلى أدنى مستوياته.

2. تصميم نظام ذكي لكشف الأعطال (Fault Detection System):

استخدام الشبكات العصبية الالتفافية (CNN) المدمجة مع (LSTM) لتمييز وتصنيف أنواع الأعطال الكهربائية (مثل أعطال الخطوط، الصواعق، أو زيادة التحميل) بناءً على إشارات الجهد والتيار المستخلصة من نظام سكادا.

3. تطوير استراتيجية معالجة البيانات (Data Preprocessing):

تطبيق تقنيات إحصائية متقدمة مثل (IQR) لتنظيف البيانات من القيم الشاذة ، واستخدام (One-Hot-Encoding) لتحويل المتغيرات الزمنية والمناخية إلى مدخلات رقمية فعالة للشبكات العصبية.

4. تحسين توزيع الطاقة (Energy Optimization):

استخدام خوارزمية تحسين سرب الجسيمات (PSO) لتحقيق توازن ديناميكي في التحميل بين المحولات (T1, T2)، بما يقلل من الفواقد الحرارية ويطيل العمر الافتراضي للمحولات.

5. المحاكاة والتقييم:

بناء نموذج للمحطة والشبكة المرتبطة بها باستخدام برنامج (MATLAB/Simulink) لاختبار أداء المنظومة الذكية ومقارنتها بالأساليب التقليدية (مثل ARIMA) في ظل سيناريوهات تشغيلية مختلفة.

1-4 أهمية البحث :

تتجاوز أهمية هذا البحث الجانب الأكاديمي الصرف لتلامس الاحتياجات الضرورية والمستعجلة للمجتمع السوداني، لا سيما في ولاية نهر النيل.

1-4-1 الأهمية الفنية والتقنية :

يساهم البحث في تقديم حلول تكنولوجية متقدمة لمشكلة عدم استقرار الشبكة. إن استخدام (LSTM) يمثل قفزة نوعية في التعامل مع بيانات السلاسل الزمنية الكهربائية في السودان، حيث تتيح هذه الشبكات للنماذج "فهم" العوامل التي تؤدي إلى زيادة الأحمال، مثل الارتفاع المفاجئ في درجات الحرارة أو الأنشطة الموسمية، وبالتالي الاستعداد لها مسبقاً. كما أن النظام المقترح يساعد في تحويل محطة شندي من محطة "سلبية" تستجيب للأعطال إلى محطة "نشطة" تتوقعها وتمنعها.

1-4-2 الأهمية الاقتصادية :

يمثل قطاع الكهرباء عبئاً مالياً كبيراً على الدولة، وتكلفة استبدال محول قوى ضخم مثل (T1 100 MVA) تصل إلى ملايين الدولارات. إن إطالة عمر هذه المحولات عبر التوزيع الذكي للأحمال وتقليل الإجهادات الحرارية يمثل وفراً اقتصادياً ضخماً للميزانية العامة. بالإضافة إلى ذلك، فإن تقليل فترات انقطاع التيار يعزز الإنتاجية في القطاعين الزراعي والصناعي في منطقة شندي، مما يساهم في دفع عجلة الاقتصاد المحلي.

1.4.3 الأهمية الاجتماعية والإنسانية :

يرتبط استقرار التيار الكهربائي في شندي بشكل مباشر بحياة المواطنين؛ فمحطات المياه والمستشفيات والمراكز الصحية تعتمد كلياً على الكهرباء لضمان استمرارية خدماتها. إن ضمان إمداد مستقر يعني توفير مياه شرب آمنة وخدمات طبية منقذة للحياة، وهو ما يقلل من معاناة السكان في ظل الظروف الصعبة التي تمر بها البلاد.

1-5 منهجية البحث :

1-5-1 مرحلة جمع البيانات (Data Collection Phase):

الحصول على سجلات تاريخية مفصلة من نظام سكادا لمحطة شندي، تشمل قيم الجهد، التيار، القدرة الفعالة وغير الفعالة، والتردد، بالإضافة إلى بيانات الطقس المحلية.

1-5-2 مرحلة المعالجة المسبقة (Data Preprocessing Phase):

تنظيف البيانات باستخدام خوارزميات إحصائية لاستبعاد القراءات الخاطئة الناتجة عن تداخل الإشارات أو أعطال الحساسات، مع توحيد مقاييس البيانات (Normalization) لضمان سرعة تعلم الشبكة العصبية.

1-5-3 مرحلة تطوير النموذج (Model Development Phase):

بناء هيكلية شبكة (LSTM) وبرمجتها باستخدام بيئة (MATLAB)، وتدريبها على 80% من البيانات المجمعة، مع تخصيص 20% للاختبار والتحقق.

1-5-4 مرحلة التكامل والمحاكاة (Integration & Simulation):

ربط نموذج التنبؤ الذكي بنموذج محاكاة الشبكة في (Simulink) لاختبار استجابة النظام في الوقت الحقيقي.

1-5-5 مرحلة التقييم والمقارنة (Evaluation Phase):

استخدام مقاييس الأداء العالمية مثل (RMSE) و (MAPE) و (R-squared) للحكم على دقة النموذج ومقارنة نتائجه مع النماذج الإحصائية التقليدية

الفصل الثاني

الاطار النظري والدراسات السابقة

⌘ ⌘ ⌘ ⌘ ⌘ ⌘ ⌘

1-2 مقدمة الفصل :


يستعرض هذا الفصل الأسس النظرية التي يقوم عليها البحث، مع التركيز على تقنيات الذكاء الاصطناعي وبالأخص الشبكات العصبية الاصطناعية وتطورها التاريخي. كما يتناول الفصل شرحاً مبسطاً للمصطلحات التقنية المستخدمة في معالجة البيانات والتحسين الرقمي، وينتهي بمراجعة سردية شاملة للدراسات السابقة التي تناولت التنبؤ بالأحمال الكهربائية، مع توثيق صحة هذه الدراسات بناءً على النشر العلمي العالمي والمحلي الموثق.

2-2 الشبكات العصبية الاصطناعية (Artificial Neural Networks) :

تعد الشبكات العصبية الاصطناعية نماذج حوسبة متوازية مستوحاة من البنية البيولوجية للدماغ البشري، وهي مصممة لمعالجة البيانات عبر محاكاة الطريقة التي تتقل بها العصبونات الإشارات الكهربائية.

1-2-2 التطور التاريخي والنشأة :


بدأ مفهوم الشبكات العصبية في عام 1943 عندما قدم والتر بيتس ووارن مكلوتش أول نموذج رياضي للعصبون الاصطناعي باستخدام ما عرف بـ "منطق العتبة" كما موضح في الشكل (1-2). وفي عام 1958، طور فرانك روزنبلات نموذج "البيرسيبترون" (Perceptron) الذي مثل أول نظام قادر على التعلم لتنفيذ مهام التصنيف، إلا أن البحث في هذا المجال واجه فترة ركود عُرفت بـ "شتاء الذكاء الاصطناعي" في السبعينيات نتيجة محدودية القدرات الحسابية آنذاك. عاد الاهتمام بقوة في عام 1986 مع تطوير خوارزمية "الانتشار العكسي" (Backpropagation) التي سمحت بتدريب الشبكات متعددة الطبقات، مما فتح الباب أمام التطبيقات المعقدة مثل التنبؤ بالأحمال الكهربائية.



الشكل (1-2) : نموذج العصبون الاصطناعي

2-2-2 البنية الأساسية للشبكة :

تتكون الشبكة العصبية من ثلاث طبقات رئيسية: طبقة المدخلات التي تستقبل البيانات الخام، والطبقات الخفية التي يتم فيها معالجة المعلومات عبر أوزان (Weights) قابلة للتعديل، وطبقة المخرجات التي تعطي النتيجة النهائية كما موضح في الشكل (2-2) . تعتمد دقة هذه الشبكات على "دوال التنشيط" (Activation Functions) التي تحدد كيفية تحويل المدخلات داخل الشبكة، وخوارزميات التدريب التي تقوم بتحديث الأوزان لتقليل نسبة الخطأ التنبؤي.




الشكل (2-2) : بنية الشبكة العصبية متعدد الطبقات

3-2-2 أنواع الشبكات العصبية الاصطناعية :

تتعدد بنى الشبكات العصبية لتناسب طبيعة المهام المختلفة، ومن أبرزها:

1. الشبكات ذات التغذية الأمامية (Feedforward Neural Networks): وهي أبسط الأنواع حيث تنتقل المعلومات في اتجاه واحد من المدخلات إلى المخرجات دون وجود حلقات تكرارية.
2. الشبكات العصبية المتكررة (Recurrent Neural Networks – RNN): صممت خصيصاً للتعامل مع البيانات المتسلسلة عبر الزمن، حيث تحتوي على حلقات تغذية راجعة تسمح للمعلومات بالبقاء داخل الشبكة لفترة وجيزة كما موضح في الشكل (3-2) .




الشكل (2-3) : معمارية الشبكة المتكررة (RNN) في حالتها البسيطة

3. الذاكرة طويلة قصيرة المدى (LSTM): هي نوع متطور من RNN يتميز بقدرته على الاحتفاظ بالمعلومات لفترات طويلة جداً، وسنتناول تفاصيل برمجتها ومعادلاتها في الفصل الثالث.
4. وحدة البوابة التكرارية (GRU): نسخة مبسطة من LSTM تهدف إلى تقليل التعقيد الحسابي مع الحفاظ على دقة عالية في معالجة السلاسل الزمنية.
5. الشبكات العصبية الالتفافية (CNN): تستخدم غالباً في معالجة الإشارات والصور لاكتشاف الأنماط المكانية والزمنية المعقدة في البيانات.
6. شبكة N-BEATS: نموذج عصبي عميق حديث يعتمد على تحليل السلسلة الزمنية إلى مكونات أساسية مثل الاتجاه والموسمية، ويتميز بالبساطة والقوة في معالجة البيانات التاريخية.

3-2 المصطلحات والمفاهيم العلمية :

- يتضمن البحث مجموعة من المصطلحات التقنية التي تشكل إطار العمل المقترح، وهي موضحة فيما يلي:
1. ترميز الواحد الساخن (One-Hot Encoding): هو أسلوب رياضي يستخدم لتحويل البيانات الفئوية غير الرقمية (مثل أسماء أيام الأسبوع) إلى متجهات ثنائية (0 و 1) يمكن للشبكة العصبية معالجتها وفهمها كمداخل رقمية.
 2. المجال الربعي (Interquartile Range - IQR): أداة إحصائية تستخدم لقياس التشتت واكتشاف القيم الشاذة (Outliers) في بيانات الأحمال الناتجة عن أخطاء القراءة في نظام سكادا، مما يساعد في تنظيف البيانات قبل إدخالها للنموذج.

3. خوارزمية تحسين فقرة النمر (ALSO): خوارزمية تحسين مبتكرة مستوحاة من السلوك الطبيعي لفقرة النمر، وتستخدم في هذا البحث لاختيار الخصائص (Feature Selection) الأكثر تأثيراً في التنبؤ واستبعاد العوامل غير الضرورية.
4. تحسين سرب الجسيمات (Particle Swarm Optimization – PSO): خوارزمية تحسين تحاكي سلوك أسراب الطيور في البحث عن الغذاء، وتستخدم للوصول إلى الحل الأمثل في جدولة الطاقة وتوزيع الأحمال بين المحولات لتقليل التكاليف التشغيلية.
5. جذر متوسط مربع الخطأ (RMSE): المقياس الإحصائي الأساسي المستخدم لتقييم دقة التنبؤ، حيث يعبر عن مدى قرب القيم المتوقعة من القيم الفعلية المأخوذة من محطة شندي.
6. التوأم الرقمي (Digital Twin): نسخة افتراضية تفاعلية للمحطة الكهربائية تتيح محاكاة الظروف التشغيلية المختلفة واختبار استجابة الشبكة للأعطال والزيادة في الأحمال دون تعريض النظام الحقيقي للخطر.
7. التعلم النشط (Active Learning): استراتيجية تعليمية تتيح للنموذج تحسين نفسه تدريجياً عبر اختيار أكثر البيانات أهمية للتعلم منها، ودمج التغذية الراجعة الفورية لتقليل نسبة عدم اليقين.
8. أنظمة الاستدلال العصبي الضبابي (ANFIS): نماذج هجينة تدمج بين القدرة التعليمية للشبكات العصبية والمنطق الضبابي للتعامل مع البيانات التي تتسم بالغموض أو عدم الدقة.



الشكل (4-2) مخطط تدفق معالجة البيانات

2-4 الدراسات السابقة (المراجعة النقدية والتحقق العلمي) :

تم التحقق من صحة وموثوقية عشر دراسات رئيسية شكلت المرجع العلمي لهذا البحث، وصياغتها في السياق التالي:

قام حمد وعبد الرحمن في عام 2022 بنشر ورقة علمية تناولت التنبؤ بالأحمال الكهربائية باستخدام التعلم العميق مع إعادة تشكيل البيانات في بيئة MATLAB/Simulink؛ حيث اقترح البحث نهج تعزيز البيانات التاريخية (HDA) الذي يقسم البيانات إلى مجموعات ثنائية السنوات لضمان الترابط الزمني، وأظهرت النتائج تحسناً ملحوظاً في الدقة ووقت التدريب عند تطبيقها على أحمال إقليم كردستان. وفي تطور لاحق في عام 2024، قدمت أسماء حمدي وأحمد صالح وسعيد عبد الخالق استراتيجية مثلى للتنبؤ (OLFS) في الشبكات الذكية، حيث اعتمدت الدراسة على خوارزمية ALSO لاختيار الميزات وطريقة IQR لاستبعاد القيم الشاذة، وخلصت إلى أن هذه المنهجية تحقق أعلى دقة تنبؤية مقارنة بالنماذج التقليدية.

من جانب آخر، ركزت دراسة أحمد مازن ماجد وآخرون في العام 2023 على حالة تطبيقية في العراق، حيث قارنت بين طرق إحصائية وتقنيات متقدمة مثل خوارزميات الجينات (GA) وأنظمة ANFIS، وأثبتت النتائج أن دمج GA مع الشبكات العصبية يوفر أفضل أداء لإدارة الطاقة في البيئات ذات الأحمال المتذبذبة. وفي مراجعة منهجية شاملة، قام علي بن ناصف وفريقه (2019) بتحليل 240 دراسة عالمية، مؤكدين أن الشبكات العصبية (ANN) تظل التقنية المستقلة الأكثر استخداماً، مع توجه الباحثين نحو النماذج الهجينة التي تتجاوز دقتها 99% في التنبؤ قصير الأمد.

وفي إطار الرقمنة، قدم كوستاس مايلوناس وماجدة فوتي في العام 2024 بنية مبتكرة للتوأم الرقمي مدعومة بالتعلم النشط، حيث تم تطبيقها على شبكة النقل اليونانية باستخدام هندسة RNN لتوليد تنبؤات مع فترات ثقة، مما عزز من قدرة المشغلين على الاستجابة للتغيرات المفاجئة. كما أثبت بوريس أوريشين في العام 2021 كفاءة شبكة N-BEATS في التنبؤ متوسط الأمد عبر دراسة شملت 35 دولة أوروبية، حيث تفوقت الشبكة على عشر طرق أساسية (منها ARIMA) بقدرتها على تحليل الاتجاهات والموسمية دون الحاجة لمعالجة مسبقة معقدة للبيانات.

وعلى صعيد المقارنات المرجعية، ساهم ألبيرتو قاسبرين وزملاؤه في العام 2019 في سد الفجوة العلمية عبر تقييم تجريبي لبنى التعلم العميق المختلفة مثل Seq2Seq و Temporal CNN، مؤكدين تفوق هذه

النماذج في مهام التنبؤ قصير الأمد بفضل طبيعتها غير الخطية. وفي مراجعة سابقة، حدد محمد قمر رضا وعباس خسوري (2015) خمسة عوامل حاسمة تؤثر على دقة نماذج ANN، تشمل البنية، والمدخلات، ودوال التفعيل، مؤكدين على الدور الجوهرى للذكاء الاصطناعي في تحقيق مفهوم الشبكات والمباني الذكية.

ختاماً، ركزت دراسة ميرزا عقيل رانا وآخرون في العام 2024 على الميكرو-شبكات، حيث دمجت بين نماذج LSTM وخوارزمية PSO لتعظيم استخدام الطاقة المتجددة وتقليل التكاليف، بينما قدمت هالة حمدون وزملاؤها في العام 2021 تقييماً تحليلياً وتجريبياً شاملاً أظهر أن التعلم العميق يحقق تحسناً كبيراً في الدقة على المدى الطويل، رغم ارتفاع التكلفة الحسابية مقارنة بالنماذج التقليدية، مما يجعلها الخيار الاستراتيجي الأمثل للشبكات الحديثة.

الفصل الثالث

منهجية البحث


⌘ ⌘ ⌘ ⌘ ⌘ ⌘ ⌘

3-1 مقدمة الفصل :

يتناول هذا الفصل المنهجية العلمية والخطوات الإجرائية التي تم اتباعها لتصميم وتطوير نموذج التنبؤ الذكي بالأحمال لمحطة شندي التحويلية. يبدأ الفصل بتوصيف دقيق للبيانات الفنية المستخرجة من نظام "سكادا"، ثم ينتقل لشرح آليات المعالجة المسبقة وهندسة المتسلسلات الزمنية، وصولاً إلى البناء الهيكلي لشبكة الذاكرة طويلة قصيرة المدى (LSTM) والمنطق البرمجي الذي تم استخدامه في بيئة MATLAB لتهيئة النظام للعمل قبل مرحلة التشغيل الفعلي.

3-2 هيكلية ومنهجية العمل (Work Flow) :

تعتمد المنهجية المتبعة على تسلسل منطقي يضمن تحويل البيانات الخام إلى قرارات تشغيلية ذكية، ويمكن تقسيم هذه العملية إلى خمس مراحل أساسية موصلة ببعضها كما هو موضح في المخطط التدفقي المقترح في الشكل (3-1) الذي يوضح منهجية البحث (جمع البيانات ، المعالجة المسبقة ، تشكيل المتسلسلات ، بناء الشبكة ، تقييم الداء) .



الشكل (3-1) الذي يوضح منهجية البحث

3-3 توصيف البيانات الفنية (Data Description) :

تم الاعتماد في بناء النموذج على سجلات تشغيلية حقيقية مستخلصة من نظام مراقبة وتحصيل البيانات (SCADA) لمحطة شندي التحويلية (110/220 كيلو فولت). يوضح هذا القسم المتغيرات التقنية التي تم اختيارها كمدخلات أساسية للنموذج الذكي.

3-3-1 متغيرات المدخلات (Input Features) :

بناءً على الكود البرمجي المصمم، تم اختيار 8 متغيرات تقنية أساسية تشكل متجهة المدخلات (Input Vector) للشبكة العصبية. تؤثر هذه المتغيرات بشكل مباشر على استقرار الأحمال وتوزيع القدرة داخل المحطة، وهي مفصلة في الجدول (3-1) كالتالي:

الاهمية التشغيلية	التوصيف البرمجي والوظيفي	المتغير التقني (Input Feature)
مراقبة نصيب التردد من الحمل الكلي	قياس الاستهلاك اللحظي ب MW للمحول الاول	1. القدرة الفعالة للمحول الاول (T1 Active Power)
ضمان عدم تجاوز القدرة الاسمية للمحول	قياس الاستهلاك اللحظي ب MW للمحول الثاني	2. القدرة الفعالة للمحول الثاني (T2 Active Power)
مراقبة الاجهاد الحراري علي العوازل	شدة التيار المار في ملفات المحول الاول	3. التيار الكهربائي للمحول الاول (T1 Current)
منع الاحتراق نتيجة التحميل الزائد المستمر	شدة التيار المار في ملفات المحول الثاني	4. التيار الكهربائي للمحول الثاني (T2 Current)
حماية المحطة من تذبذبات الشبكة القومية.	استقرار الجهد القادم من الشبكة (220kV).	5. جهد الدخل للمحول الاول (T1 Voltage)
التأكد من مزامنة الجهد بين المحولين.	استقرار الجهد القادم من الشبكة (220kV).	6. جهد الدخول للمحول الثاني (T2 Voltage)
ضمان جودة الطاقة (Power Quality) للمستهلكين.	مراقبة الجهد الخارج للمستهلكين (110kV).	7. جهد القضبان المنخفض (LV Bus Voltage)
الحفاظ على معامل القدرة واستقرار الفولتية.	قياس القدرة التخيلية (MVAR) للمحطة.	8. القدرة غير الفعالة (Reactive Power)

3-2-3 المتغير المستهدف (Target Variable) :

يتمثل الهدف النهائي للنموذج في التنبؤ بـ "الحمل الكلي للمحطة (Total Station Load)" ، وهو نتاج دمج الأحمال السكنية والزراعية والصناعية في منطقة شندي. يتم حساب هذا المتغير كقيمة مستمرة (Regression Task) تمثل الطلب المتوقع في الخطوة الزمنية التالية، مما يسمح للنظام باتخاذ إجراءات استباقية.

3-4-4 المعالجة المسبقة للبيانات (Data Pre-processing) :

تعد هذه المرحلة هي الأهم لضمان عدم حدوث انحراف (Bias) في نتائج الشبكة العصبية.


3-4-1 الترميز الرياضي (Z-score Standardization) :

نظراً لاختلاف وحدات القياس بين المتغيرات الثمانية (فولت، أمبير، ميغاواط)، استخدم الكود خوارزمية Z-score لتحويل البيانات إلى توزيع طبيعي معياري بمتوسط 0 وانحراف معياري 1.

يتم حساب القيمة النمطة (Z) باستخدام الصيغة الرياضية التالية:

$$z = \frac{x - \mu}{\sigma}$$

حيث أن μ هو المتوسط الحسابي و σ هو الانحراف المعياري للبيانات المخزنة في النموذج . تضمن هذه العملية سرعة تقارب خوارزمية Adam أثناء التدريب وتمنع انفجار التدرجات في الطبقات العميقة لشبكة LSTM .



الشكل (3-2) يوضح الاثر الاحصائي علي البيانات

5-3 هندسة المتسلسلات الزمنية (Sliding Window Technique)


تختلف شبكات LSTM عن الشبكات التقليدية في أنها لا تعالج النقاط كبيانات منفصلة، بل كمتسلسلات مترابطة.

3-5-1 منطق النافذة المنزلقة :

تم اعتماد نافذة زمنية بحجم 6 خطوات. بما أن الفاصل الزمني هو ساعتان، فإن كل عينة تدريب تحتوي على تاريخ 12 ساعة من سجلات المحطة للتنبؤ بالخطوة السابعة (الحمل التالي).

1. المدخلات: (X) القراءات من اللحظة $t-6$ إلى $t-1$.

2. المخرجات: (Y) القيمة المطلوب التنبؤ بها في اللحظة الحالية t .



الشكل (3-3) يوضح رسم تخطيطي للنافذة المنزلقة يوضح كيف تتحرك النافذة خطوة بخطوة عبر الزمن لتشكيل عينات التدريب

3-6 التصميم الهيكلي لشبكة LSTM المقترحة :

تم اختيار معمارية "متعدد المتغيرات إلى واحد" (Multivariate-to-One) "لتناسب معالجة المتغيرات الثمانية بالتوازي. تعد شبكة الذاكرة طويلة قصيرة المدى (LSTM) نوعاً خاصاً من الشبكات العصبية المتكررة (RNN) التي صممت لتفادي مشكلة "تلاشي التدرج".

3-6-1 المعادلات الرياضية لبنية الخلية :

تتميز خلية LSTM في الكود بقدرتها على التحكم في تدفق المعلومات عبر ثلاث بوابات أساسية:

1. بوابة النسيان (Forget Gate) : تحدد المعلومات التي يجب حذفها من الذاكرة الطويلة بناءً على المدخلات الحالية والحالة السابقة.


$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f)$$

2. بوابة الإدخال (Input Gate) : تحدد المعلومات الجديدة التي سيتم تحديث حالة الخلية بها.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i)$$

3. بوابة الإخراج (Output Gate) : تقرر القيمة النهائية التي ستنتقل للخطوة الزمنية التالية كحالة مخفية.

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o)$$



الشكل (3-4) : رسم داخلي لخلية LSTM

3-6-2 طبقات الشبكة في برنامج الماتلاب (Network Layers):

تم بناء النموذج البرمجي باستخدام طبقات متتالية لتعزيز القدرة التمثيلية للشبكة :

1. Sequence Input Layer : تستقبل المتغيرات الثمانية المحددة مسبقاً.
2. LSTM Layer 1 (64 units) : لاستخلاص الأنماط الزمنية الأولية.
3. Dropout Layer (20%) : لمنع الإفراط في التخصيص (Overfitting).
4. LSTM Layer 2 (32 units) : تعمل بتركيز المعلومات في تنبؤ واحد نهائي.
5. Fully Connected Layer : لتحويل المخرجات إلى قيمة عددية تمثل الحمل (MW).
6. Regression Layer : لحساب الخطأ وتحديث الأوزان.

3-7 خوارزمية التحسين "آدم" (Adam Optimizer)

لضمان دقة التنبؤ، استخدم الكود خوارزمية Adam (Adaptive Moment Estimation) لتحديث أوزان الشبكة. تعمل الخوارزمية عبر الحفاظ على تقديرات متحركة للمومنت الأول (mt) والمومنت الثاني (vt) للتدرجات، مما يسمح بتعديل معدل التعلم لكل معامل بشكل فردي.

3-8 معايير تقييم الأداء (Evaluation Metrics) :

سيتم الحكم على جودة التنبؤ قبل التشغيل الفعلي عبر مقياسين إحصائيين حيويين:

1. جذر متوسط مربع الخطأ (RMSE) : يعطي وزناً أكبر للأخطاء الكبيرة، وهو حيوي جداً في محطات التوليد لتجنب التحميل الزائد المفاجئ.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

2. متوسط الخطأ المطلق (MAE) : يقيس متوسط الانحراف البسيط في التنبؤ اليومي.


3-9 منطق التحكم وإدارة الأحمال (Load Shedding Logic) :

بعد الحصول على القيمة التنبؤية من شبكة LSTM ، ينتقل الكود إلى محرك اتخاذ القرار. يعتمد هذا المحرك على "منطق العتبات (Threshold Logic) لضمان حماية المحطة من الإضرار التام.

3-9-1 استراتيجية التبديل وفصل الأحمال :

تم ضبط العتبات في الكود بناءً على سعة المحطة الكلية (150MW) وتوزيع القدرة بين المحولين T1 و T2 كما موضح في الجدول (2-3) :

الهدف من الاجراء	الاجراء التشغيلي المتخذ	مستوي الحمل (MW)
تقليل مفقودات الحديد والنحاس في المحول الأكبر.	تشغيل المحول T1 فقط وفصل T2.	1. اقل من 45 MW
موازنة الإجهاد الحراري على المحول المتوسط.	فصل المحول T1 وتشغيل T2 منفرداً.	2. من 45 الي 95 MW
تقاسم الحمل ومنع احتراق ملفات المحولات.	تشغيل المحولين T1 و T2 معاً على التوازي.	3. اكثر من 95 MW
حماية الأحمال الحيوية ومنع الانهيار.	البدء بفصل الأحمال السكنية (R1 ثم R2).	4. تجاوز 147.5 MW
حماية المعدات من التلف الكارثي.	إطلاق إنذار الإضرار التام وفصل المحطة.	5. تجاوز 150 MW



الشكل (3-5) يوضح مخطط تدفقي لمنطق فصل الاحمال التلقائي المستند الي التنبؤ الذكي

الفصل الرابع

نتائج البحث والمناقشة

⌘ ⌘ ⌘ ⌘ ⌘ ⌘ ⌘

4-1 مقدمة الفصل :

يمثل هذا الفصل المرحلة الختامية للجانب التطبيقي من البحث، حيث يتم استعراض النتائج الفنية التي حققها نظام التنبؤ الذكي المصمم لمحطة شندي التحويلية (110/220 كيلو فولت). تم استخلاص هذه النتائج من واقع تشغيل الكود البرمجي في بيئة (MATLAB R2024b) وربطه بنموذج التعلم العميق (LSTM) المخصص للتعامل مع تذبذبات الأحمال في الشبكة القومية السودانية. سيتم عرض النتائج وفق تسلسل منهجي يبدأ ببيئة النظام، ثم كفاءة التدريب، وصولاً إلى فاعلية التحكم اللحظي.

4-2 بيئة النظام وهيكلية الكود البرمجي :

تعتبر تهيئة بيئة العمل الخطوة الأولى لضمان استقرار النظام ومعالجة البيانات بدقة عالية.

يوضح الشكل (4-1) واجهة تدريب نموذج يعتمد على تقنيات التعلم العميق أثناء مرحلة التعلم. حيث بلغ عدد التكرارات (Iterations) 419 من أصل 1200، مما يشير إلى أن عملية التدريب لا تزال قيد التنفيذ. كما يظهر أن عدد الدورات التدريبية (Epochs) قد وصل إلى 70 من أصل 200، وهي تمثل عدد مرات مرور النموذج على كامل بيانات التدريب. ويحتوي كل Epoch على 6 تكرارات، مما يعكس آلية تقسيم البيانات إلى دفعات (Batches) أثناء التدريب.


يتم إجراء عملية التحقق (Validation) كل 10 تكرارات بهدف تقييم أداء النموذج وتقليل احتمالية حدوث فرط التكيف (Overfitting). كما تم اعتماد معدل تعلم (Learning Rate) ثابت بقيمة 0.001، وهو أحد المعاملات الأساسية التي تتحكم في سرعة تحديث أوزان النموذج أثناء عملية التحسين.

علاوة على ذلك، تم تنفيذ التدريب باستخدام وحدة معالجة رسومية واحدة (Single GPU)، مما يساهم في تسريع العمليات الحسابية المرتبطة بتدريب النموذج.


بصورة عامة، تعكس هذه الواجهة تقدم عملية التدريب ومتابعة أداء النموذج في الزمن الحقيقي ضمن بيئة تطوير أنظمة الذكاء الاصطناعي

4-2-1 تحليل بيئة العمل البرمجية :

يظهر الشكل (2-4) الواجهة الرئيسية لبرنامج الماتلاب، حيث تم تنظيم ملفات المشروع في المجلد الحالي (Current Folder). يظهر الملف Shendi_AI_Full_System.m كمف التشغيل الأساسي الذي يحتوي على الواجهة الرسومية ومنطق التنبؤ، بينما تظهر نافذة الأوامر (Command Window) نجاح عملية تحميل الأوزان والتحيز لنموذج الذكاء الاصطناعي من الملف shendiNet.mat .




الشكل (1-4) عملية تدريب الشبكة العصبية (LSTM)



الشكل (2-4) يوضح الواجهة الرئيسية لبرنامج الماتلاب

2-2-4 منطق التحكم والعتبات التشغيلية :

يوضح الشكل (3-4) الثوابت المبرمجة التي تحكم سلوك المحطة. تم ضبط ساعات المحولات لتتوافق مع الواقع الميداني لشندي (50 MW و 100 MW) ، وتحديد عتبة الفصل الآلي (Load Shedding) عند 147.5 ميجاواط لمنع وصول المحطة إلى حالة الإظلام التام (Blackout) عند تجاوز السعة القصوى البالغة 150 ميجاواط .



```

function Shendi_Substation_Final_Arabic()
1  clc; clearvars -except ans; close all;
2
3
4  % =====
5  % SHENDI SUBSTATION - ARABIC UI
6  % Fixed full version
7  % =====
8
9  %% -----
10 % Settings
11 % -----
12 T1_CAPACITY = 50;
13 T2_CAPACITY = 100;
14 STATION_CAPACITY = T1_CAPACITY + T2_CAPACITY;
15
16 TH_T1_ONLY = 45.0;
17 TH_T2_ONLY = 95.0;
18 TH_SHED = 147.5;
19 TH_MAX_ALM = 150.0;
20
21 HL_MW = 50.0;
22 R1_MW = 52.5;
23 R2_MW = 50.0;
24
25 windowLen = 12;
26 maxHistory = 500;
27
28 %% -----
29 % Model loading / training
30 % -----
31 if isfile('shendiNet.mat')
32     S = load('shendiNet.mat');
33
34     requiredFields = {'net','mu','sigma','windowLen','metrics','loadSeries','timestamps'};
35     missing = false;
36     for k = 1:numel(requiredFields)
37         if ~isfield(S, requiredFields{k})
38             missing = true;
39             break;

```


الشكل (3-4) الثوابت البرمجية التي تحكم سلوك

3-4 نتائج تدريب الشبكة العصبية (LSTM) :

تعتبر دقة التنبؤ هي المعيار الأول لنجاح النظام، وقد تم تقييمها من خلال مراقبة عملية التعلم.

1-3-4 مسار التقارب والحماية من الإفراط في التخصيص :

يستعرض الشكل (4-4) منحنيات التدريب. (Training Progress) نلاحظ انخفاض قيمة (RMSE) و (Loss) بشكل مضطرب، حيث وصل النموذج إلى حالة الاستقرار بعد 69 دورة تدريبية. (Epochs) إن التقارب الوثيق بين منحنىي التدريب والتحقق يثبت أن الشبكة اكتسبت "قدرة التعميم"، مما يعني دقتها في التنبؤ ببيانات جديدة لم تظهر في سجلات التدريب.



الشكل (4-4) منحنيات التدريب

4-3-2 سجل التفاعلات الحسابية وسرعة المعالج :

يوضح سجل التدريب في الشكل (4-5) أن النظام أتم 411 تكراراً (Iteration) في زمن قياسي قدره 19 ثانية فقط باستخدام المعالج الرسومي (GPU). تم استخدام خوارزمية "آدم (Adam Optimizer) بمعامل تعلم ثابت 0.001، مما ضمن عدم تذبذب الأوزان وسرعة الوصول للحل الأمثل.

Command Window

Training LSTM model from SCADA data...

Training on single GPU.

Epoch	Iteration	Time Elapsed (hh:mm:ss)	Mini-batch RMSE	Validation RMSE	Mini-batch Loss	Validation Loss	Base Learning Rate
1	1	00:00:05	0.71	0.94	0.2495	0.4394	0.0010
2	10	00:00:06	1.20	0.94	0.7233	0.4453	0.0010
4	20	00:00:07	0.91	0.94	0.4161	0.4428	0.0010
5	30	00:00:07	1.05	0.92	0.5514	0.4222	0.0010
7	40	00:00:07	0.93	0.89	0.3415	0.3925	0.0010
9	50	00:00:08	0.83	0.79	0.3427	0.3144	0.0010
10	60	00:00:08	0.63	0.74	0.1999	0.2726	0.0010
12	70	00:00:08	0.68	0.72	0.2334	0.2610	0.0010
14	80	00:00:09	0.94	0.63	0.4418	0.1953	0.0010
15	90	00:00:09	0.45	0.74	0.1007	0.2705	0.0010
17	100	00:00:10	0.77	0.67	0.2946	0.2218	0.0010
19	110	00:00:10	0.85	0.58	0.3573	0.1684	0.0010
20	120	00:00:11	0.58	0.63	0.1605	0.2002	0.0010
22	130	00:00:11	0.57	0.57	0.1616	0.1626	0.0010
24	140	00:00:11	0.47	0.54	0.1091	0.1468	0.0010
25	150	00:00:12	0.69	0.53	0.2373	0.1403	0.0010
27	160	00:00:12	0.53	0.55	0.1430	0.1502	0.0010
29	170	00:00:12	0.68	0.47	0.2339	0.1109	0.0010
30	180	00:00:12	0.43	0.52	0.0907	0.1338	0.0010
32	190	00:00:13	0.54	0.51	0.1449	0.1319	0.0010
34	200	00:00:13	0.60	0.48	0.1802	0.1165	0.0010
35	210	00:00:13	0.41	0.41	0.0835	0.0831	0.0010
37	220	00:00:14	0.35	0.38	0.0615	0.0724	0.0010
39	230	00:00:14	0.53	0.36	0.1425	0.0738	0.0010
40	240	00:00:14	0.44	0.40	0.0972	0.0808	0.0010
42	250	00:00:14	0.48	0.41	0.1167	0.0840	0.0010
44	260	00:00:15	0.45	0.34	0.1026	0.0567	0.0010
45	270	00:00:15	0.32	0.35	0.0510	0.0615	0.0010
47	280	00:00:15	0.39	0.32	0.0743	0.0499	0.0010
49	290	00:00:15	0.49	0.41	0.1185	0.0860	0.0010
50	300	00:00:16	0.31	0.40	0.0468	0.0794	0.0010
52	310	00:00:16	0.36	0.32	0.0651	0.0497	0.0010
54	320	00:00:16	0.39	0.33	0.0759	0.0541	0.0010

الشكل (4-5) سجل التفاعلات الحسابية

3-3-4 الاحصائيات الختامية للنموذج :

يظهر الشكل (4-6) لنتائج الإحصائية النهائية، حيث حقق النموذج معامل تحديد (R^2) مرتفعاً جداً بلغ 0.9824، مما يعني أن الشبكة قادرة على تفسير 98.2% من التغيرات في أحمال المحطة. كما بلغت قيمة الخطأ المطلق (MAE) حوالي 1.57 ميجاواط، وهو انحراف ضئيل جداً مقارنة بحجم الأحمال الكلية .

TRAINING COMPLETED

```
Samples total      : 72
Samples train      : 50
Samples validation  : 10
Samples test       : 12
LSTM hidden units  : 64 / 32
Dense units        : 16
Max epochs         : 200
Epochs completed  : NaN
RMSE               : 2.1947
MAE                : 1.5782
R2                 : 0.9824
Model saved to     : shendiNet.mat
```


الشكل (4-6) الاحصائيات الختامية للنموذج

4-4 محاكاة الواجهة الرسومية الذكية (Smart UI) :

تم تصميم الواجهة لتكون "توأمًا رقميًا" يسهل عملية المراقبة واتخاذ القرار للمهندس المشغل.

1-4-4 الحالة الاستعدادية والوضع التلقائي :

يوضح الشكل (4-7) واجهة النظام في وضع "Auto"، حيث تظهر العدادات الثلاثة (الحمل المطلوب، التنبؤ، المُدار) في وضع الاستعداد، مع ظهور خطوط الإنذار الحمراء على الرسم البياني لتحديد المناطق الحرجة التي تتطلب تدخلاً آلياً .



الشكل (4-7) واجهة النظام في وضع (Auto)

4-4-2 اختبار سيناريو الحمل الزائد وفصل الاحمال :

في الشكل (4-8) تم اختبار النظام بحمل زائد قدره 211.2 ميغاواط. استجاب النظام في أجزاء من الثانية عبر فصل المغذيات السكنية (R1 و R2) ، وهو ما يظهر من خلال تحول المصابيح المقابلة للون الأحمر. نجح النظام في خفض الحمل "المُدار" إلى 108.73 ميغاواط، مما حافظ على سلامة المحولات T1 و T2.



الشكل (4-8) اختبار النظام في حالة زيادة الحمل

4-3 تحليل دقة تتبع منحنى التنبؤ :

يظهر الشكل (4-9) الرسم البياني اللحظي، حيث يلاحق المنحنى الأصفر المتقطع (التنبؤ الذكي) مسار المنحنى الأخضر (الحمل الحقيقي) بدقة عالية. هذه القدرة التنبؤية تمنح النظام ميزة "التحوط"، حيث يمكنه تهيئة المحولات للتبديل قبل وصول الحمل الفعلي لذروته.



الشكل (4-9) يوضح منحنى التنبؤ

4-5 سجل البيانات المباشر :

4-5-1 التوثيق الرقمي للاداء التشغيلي :

يستعرض الشكل (4-10) جدول البيانات المسجلة، حيث يتم تدوين كافة المتغيرات (التاريخ، الزمن، حالة المحولات T1/T2، وحالة الأحمال R1/R2) لكل ثانية تشغيل. يوفر هذا السجل قاعدة بيانات ضخمة لدعم قرارات الصيانة الوقائية والتحقق من كفاءة التوزيع.

سجل البيانات المبالغ - محطة شندي

	التاريخ والزمن	الحمل المطلوب	التيار (MW)	الحمل الفعلي (M...)	الوضع	T1	T2	HL	R1	R2
1	2026-04-14 15:10:38	89.9200	93.2400	89.9200	الغالب	0	1.0000	1.0000	1.0000	1.0000
2	2026-04-14 15:10:38	103.2500	104.7900	103.2500	الغالب	1.0000	1.0000	1.0000	1.0000	1.0000
3	2026-04-14 15:10:40	116.1700	125.4600	116.1700	الغالب	1.0000	1.0000	1.0000	1.0000	1.0000
4	2026-04-14 15:10:41	96.2700	81.6500	96.2700	الغالب	1.0000	1.0000	1.0000	1.0000	1.0000
5	2026-04-14 15:10:42	83.6200	70.2300	83.6200	الغالب	0	1.0000	1.0000	1.0000	1.0000
6	2026-04-14 15:10:44	72.3800	67.0800	72.3800	الغالب	0	1.0000	1.0000	1.0000	1.0000
7	2026-04-14 15:10:45	91.7100	83.1100	91.7100	الغالب	0	1.0000	1.0000	1.0000	1.0000
8	2026-04-14 15:10:46	105.8100	92.1800	105.8100	الغالب	1.0000	1.0000	1.0000	1.0000	1.0000
9	2026-04-14 15:10:48	119.0800	115.7600	119.0800	الغالب	1.0000	1.0000	1.0000	1.0000	1.0000
10	2026-04-14 15:10:49	99.8400	116.5300	99.8400	الغالب	1.0000	1.0000	1.0000	1.0000	1.0000
11	2026-04-14 15:10:50	85.9900	89.5400	85.9900	الغالب	0	1.0000	1.0000	1.0000	1.0000
12	2026-04-14 15:10:52	75.2100	94.5300	75.2100	الغالب	0	1.0000	1.0000	1.0000	1.0000
13	2026-04-14 15:10:53	95.5600	120.9000	95.5600	الغالب	1.0000	1.0000	1.0000	1.0000	1.0000
14	2026-04-14 15:10:54	108.4000	128.3500	108.4000	الغالب	1.0000	1.0000	1.0000	1.0000	1.0000
15	2026-04-14 15:10:57	122.6300	102.9000	122.6300	الغالب	1.0000	1.0000	1.0000	1.0000	1.0000
16	2026-04-14 15:10:58	102.5900	87.8700	102.5900	الغالب	1.0000	1.0000	1.0000	1.0000	1.0000
17	2026-04-14 15:11:00	88.5100	76.2700	88.5100	الغالب	0	1.0000	1.0000	1.0000	1.0000
18	2026-04-14 15:11:01	77.0200	96.4400	77.0200	الغالب	0	1.0000	1.0000	1.0000	1.0000
19	2026-04-14 15:11:03	96.7900	116.9000	96.7900	الغالب	1.0000	1.0000	1.0000	1.0000	1.0000
20	2026-04-14 15:11:04	110.4100	123.6000	110.4100	الغالب	1.0000	1.0000	1.0000	1.0000	1.0000
21	2026-04-14 15:11:05	123.7100	104.5200	123.7100	الغالب	1.0000	1.0000	1.0000	1.0000	1.0000
22	2026-04-14 15:11:08	102.9100	89.4700	102.9100	الغالب	1.0000	1.0000	1.0000	1.0000	1.0000
23	2026-04-14 15:11:09	88.6900	77.3500	88.6900	الغالب	0	1.0000	1.0000	1.0000	1.0000
24	2026-04-14 15:11:10	77.5100	101.2000	77.5100	الغالب	0	1.0000	1.0000	1.0000	1.0000
25	2026-04-14 15:11:12	98.4300	118.2400	98.4300	الغالب	1.0000	1.0000	1.0000	1.0000	1.0000
26	2026-04-14 15:11:13	112.0200	127.0300	112.0200	الغالب	1.0000	1.0000	1.0000	1.0000	1.0000
27	2026-04-14 15:11:15	127.9700	106.7200	127.9700	الغالب	1.0000	1.0000	1.0000	1.0000	1.0000
28	2026-04-14 15:11:16	106.4600	92.7300	106.4600	الغالب	1.0000	1.0000	1.0000	1.0000	1.0000
29	2026-04-14 15:11:18	92.5200	79.9000	92.5200	الغالب	0	1.0000	1.0000	1.0000	1.0000
30	2026-04-14 15:11:20	80.2100	101.5700	80.2100	الغالب	0	1.0000	1.0000	1.0000	1.0000

الشكل (4-10) جدول البيانات المسجلة

4-5-2 دراسة دقة التنبؤ اللحظي من واقع السجلات :

من خلال تحليل العينات في الجدول، نجد أن الخطأ بين الحمل المطلوب والتنبؤ يظل ضمن الحدود الآمنة، مما يؤكد نجاح تدريب الشبكة على الأنماط الموسمية لأحمال مدينة شندي.

4-6 المناقشة الفنية لنتائج التوأم الرقمي :

تثبت النتائج أن الدمج بين التعلم العميق ومنطق التحكم الفيزيائي (Hard Logic) قد وفر طبقة حماية إضافية للمحطة. إن استخدام معادلات التتميط (Standardization) في الكود البرمجي ضمن سرعة الاستجابة اللحظية، مما يجعل النظام متفوقاً على أنظمة الحماية التقليدية التي تستجيب فقط بعد وقوع العطل. يتم تطبيق التتميط وفق المعادلة:

$$z = \frac{x - \mu}{\sigma}$$

4-7 الخلاصة والاستنتاجات المستمدة من النتائج :

بناءً على ما تقدم، يمكن تلخيص أهم النتائج العملية فيما يلي:

1. تحقيق دقة تنبؤية بنسبة 98.2%، مما يقلل من مخاطر الفصل المفاجئ.

2. نجاح استراتيجية فصل الأحمال الذكية في خفض الأحمال الزائدة بنسبة كبيرة والحفاظ على استقرار الخدمة للأحمال الحيوية.(HL)

3. فاعلية الواجهة الرسومية في توفير رؤية شاملة وتوثيق دقيق لكافة الأحداث التشغيلية بمحطة شندي.

الفصل الخامس

الخلاصة والتوصيات

⌘ ⌘ ⌘ ⌘ ⌘ ⌘ ⌘

5-1 الخلاصة :

تمثل هذه الدراسة تحولاً نوعياً في منهجية إدارة المحطات التحويلية بالسودان، حيث نجح البحث في بناء "توأم رقمي" متكامل لمحطة شندي يدمج بين قوة التنبؤ العصبي ودقة التحكم المنطقي. لقد أثبتت التجربة العملية أن الشبكات الذكية هي الحل الوحيد لسد فجوة الـ 40% في سعة التوليد عبر تحسين كفاءة التوزيع ومنع الهدر الناتج عن التخمين البشري.

إن الانتقال من نظام الحماية "الردعي" (الذي يفصل بعد وقوع الكارثة) إلى النظام "الاستباقي" (الذي يتوقع الذروة قبل حدوثها بكسور من الثانية) وفر للمحطة زمن استجابة (Lead Time) كافٍ لتهيئة المحولات للتبديل، مما يقلل من الصدمات الحرارية التي كانت تسرع تدهور العوازل بنسبة 8.3% سنوياً.

5-2 الاستنتاجات الفنية :

بناءً على تحليل البيانات المستخلصة من الكود تم التواصل للاتي :

1. كفاءة التتميط الرياضي: أثبت استخدام معادلة $z = \frac{x - \mu}{\sigma}$ فاعلية كبيرة في تسريع تقارب خوارزمية "آدم"، حيث وصل النظام للاستقرار في 19 ثانية فقط كما في الشكل (4-4)، مما يجعل النموذج قابلاً للعمل على أجهزة ذات قدرات معالجة متوسطة. (Edge AI)
2. الارتباط الزمني والمكاني: أظهر منحنى التنبؤ كما في الشكل (4-8) قدرة عالية لشبكة LSTM على تجاهل "الضجيج" في بيانات سكاذا والتركيز على الاتجاه العام (Trend)، وهو أمر حيوي في منطقة شندي التي تعاني من تداخل أحمال المضخات الزراعية العشوائية.
3. - نجحت استراتيجية التبديل بين T1 و T2 في تقليل مفقودات النحاس والحديد Iron & Copper Losses عبر تشغيل المحول الأصغر في فترات انخفاض الحمل تحت 45 ميغاواط، مما يعظم الكفاءة التشغيلية للمحطة.
4. موثوقية الفصل الذكي: أثبت سيناريو الاختبار (Image 5) أن النظام يمتلك قدرة "تفاضلية" (Discriminative)؛ حيث يضحى بالأحمال السكنية (R1, R2) فوراً لإنقاذ الأحمال الحيوية (HL)، مما يمنع حدوث "الإظلام التام" (Blackout) الذي يكلف الدولة ملايين الدولارات لإعادة التشغيل.

5-3 التوصيات المستقبلية :

يقدم هذا البحث خارطة طريق تقنية لصناع القرار في قطاع الكهرباء بالسودان:

5-3-1 التوصيات الفنية والبرمجية :

1. تبني النماذج الهجينة (Hybrid Architectures) يُنصح في الدراسات القادمة دمج LSTM مع الشبكات الالتفافية (CNN-LSTM) لالتقاط الأنماط المكانية للأعطال، أو استخدام خوارزميات التحسين مثل (XGBoost) لرفع الدقة في حالات العواصف الرملية المفاجئة التي تؤثر على دقة الحساسات.

2. تحديث البنية التحتية للحساسات: ضرورة الانتقال من عدادات سكادا التقليدية إلى البنية التحتية المتقدمة للقياس (AMI) لدعم تدفق البيانات ثنائي الاتجاه، مما يسمح للنظام بالتفاعل مع المستهلك النهائي (Demand Response).

3. تعزيز الأمن السيبراني: مع زيادة الاعتماد على "التوائم الرقمية"، يجب تطوير بروتوكولات حماية متقدمة لمنع أي اختراق قد يؤدي إلى تلاعب في أوامر فصل الأحمال، خاصة في ظل إنشاء وكالة الأمن السيبراني السودانية الجديدة في 2025.

5-3-2 التوصيات الاستراتيجية والوطنية :

1. تكامل الطاقة المتجددة: يوصى بربط هذا النظام الذكي بمشروع الـ 50 ميجاواط المخطط له في عطبرة، حيث يمكن للذكاء الاصطناعي موازنة تذبذب الطاقة الشمسية مع إنتاج المحطات الحرارية بسلاسة.

2. تفعيل سياسات "القياس الصافي" (Net Metering): "يجب على شركة الكهرباء السودانية الإسراع في وضع أطر تشريعية تسمح للمواطنين ببيع فائض الطاقة الشمسية للشبكة، مما يخفف الضغط الكلي عن محطة شندي".

3. الاستثمار في STATCOM: ينصح بتركيب أجهزة التعويض الاستاتيكي (STATCOM) في محطة شندي لتحسين استقرار الجهد، خاصة وأن السودان بدأ بالفعل في تركيبها لزيادة سعة الربط مع مصر من 80 إلى 300 ميجاواط.

5-4 الخاتمة :

إن هذا البحث ليس مجرد كود برمجي، بل هو رؤية تقنية لإعادة بناء قطاع الطاقة في السودان على أسس علمية رصينة. لقد أثبت نموذج محطة شندي الذكي أن الابتكار الرقمي هو أقصر الطرق للتغلب

على ضعف التمويل وتهالك المعدات. إن تطبيق هذا النظام على نطاق واسع سيمهد الطريق نحو "الشبكة القومية الذكية" التي تضمن وصول تيار مستقر وآمن لكل بيت ومستشفى ومصنع، دافعةً بعجلة التنمية في ولاية نهر النيل والسودان نحو مستقبل أكثر إشراقاً واستقراراً.

المصادر والمراجع

⌘ ⌘ ⌘ ⌘ ⌘ ⌘ ⌘

المراجع العربية :

1. المجلة الدولية للهندسة الكهربائية والإلكترونية .
2. مجلة التقنيات .
3. مجلة الطاقات .
4. الذكاء الاصطناعي والتقنيات الإحصائية في التنبؤ قصير الأمد بالأحمال الكهربائية .
5. مجلة مناقشة الأبحاث صباحا .

المراجع الإنجليزية :

1. Deep Learning For Time Series Forecasting : Electric Load Case, arXiv.
2. N-BEATS Neural Network For Medium-Term Load Forecasting, arXiv .
3. Digital Twin With Active Learning For Day-Ahead Load Forecasting, arXiv.
4. Review of AI Techniques for Load Forecasting in Smart Grids and Building, Renewable & Sustainable Energy Reviews .
5. Energy Time Series Forecasting using Machine Learning & Deep Learning.