مجلة جامعة طرطوس للبحوث والدراسات العلمية _ سلسلة العلوم الهندسية المجلد (١٠) العدد (٨) ٢٠٢٦

Tartous University Journal for Research and Scientific Studies - engineering Sciences Series Vol. (10) No. (8) 2026

تقييم أداء خوارزمية شجرة القرار في التنبؤ بتوتر الانهيار للعوازل الملوثة

د. جورج اسبر*

د. جمال الناصير**

راما الختيار***

(تاريخ الإيداع ٢٠٢٦/٢/١١ . قُبِل للنشر في ٢٠٢٦/٥/٤)

ملخّص

تلعب العوازل الكهربائية دوراً حيوياً في حماية خطوط نقل الكهرباء، إلا أن تعرضها للملوثات البيئية مثل الأملاح الصناعية، رمال الصحراء، ورطوبة الجو يؤدي إلى انخفاض مقاومتها السطحية وزيادة احتمالية حدوث الانهيار الكهربائي. تهدف هذه الدراسة إلى تقييم كفاءة خوارزمية شجرة القرار (Decision Tree Regression) في التنبؤ بتوتر الانهيار للعوازل الملوثة في خطوط نقل الكهرباء. تم استخدام مجموعة بيانات مستمدة من التجارب المخبرية والنماذج الرياضية، حيث تم دمج القيم المخبرية المنشورة مع القيم المحسوبة باستخدام النموذج الرياضي، ثم تقسيم المجموعة الكلية عشوائياً إلى تدريب واختبار تضمنت متغيرات مثل كثافة الملح المترسب، عامل شكل العازل، طول المسار الزاحف، وارتفاع العازل، فيما كان المتغير الهدف هو توتر الانهيار. أظهرت النتائج على بيانات التدريب توافقاً عالياً بين القيم المتنبأ بها والقيم الفعلية، حيث بلغ معامل التحديد 0.995 وقيمة RMSE = 0.335، مما يدل على قدرة النموذج على تمثيل العلاقات غير الخطية بين المتغيرات بدقة. وعند تطبيق النموذج على بيانات الاختبار، حافظ على أداء جيد بمعامل تحديد R^2=0.966 و خطأ RMSE = 1.017 مؤكداً قدرة النموذج على التعميم خارج بيانات التدريب. يبرز البحث أن خوارزمية شجرة القرار توفر وسيلة فعالة للتنبؤ بتوتر الانهيار، مما يقلل الاعتماد على التجارب المخبرية المكلفة ويتيح اتخاذ قرارات صيانة مبكرة.

الكلمات المفتاحية: خطوط نقل الكهرباء، العوازل الملوثة، توتر الانهيار، شجرة القرار

* استاذ– قسم الطاقة الكهربائية– كلية الهندسة الميكانيكية والكهربائية– جامعة اللاذقية –اللاذقية– سورية.

George.lsber@yahoo.com

**استاذ – قسم الطاقة الكهربائية– كلية الهندسة الميكانيكية والكهربائية– جامعة دمشق–دمشق– سورية

jamal.nassier@damascusuniversity.edu.sy

***طالبة دراسات عليا (دكتوراه) – قسم الطاقة الكهربائية–كلية الهندسة الميكانيكية والكهربائية–جامعة اللاذقية –اللاذقية– سورية

rama.alkhtiar@latakia-univ.edu.sy

مجلة جامعة طرطوس للبحوث والدراسات العلمية _ سلسلة العلوم الهندسية المجلد (١٠) العدد (٨) ٢٠٢٦

Tartous University Journal for Research and Scientific Studies - engineering Sciences Series Vol. (10) No. (8) 2026

Evaluation of the Performance of the Decision Tree Algorithm in Predicting the Flashover Voltage of Contaminated Insulators

Dr. George Isber*
Dr. Jamal Alnassier**
Rama Alkhtiar***

(Received 11/2/2026. Accepted 4/5/2026)

□ ABSTRACT □

Electrical insulators play a vital role in protecting power transmission lines. However, their exposure to environmental pollutants such as industrial salts, desert sand, and atmospheric humidity leads to a reduction in surface resistance and an increased likelihood of electrical flashover. This study aims to evaluate the efficiency of the Decision Tree Regression algorithm in predicting the flashover voltage of contaminated insulators in power transmission lines. A dataset derived from laboratory experiments and mathematical models was used, where published experimental values were combined with values computed using a mathematical model. The entire dataset was then randomly split into training and testing subsets. The dataset included variables such as salt deposit density, insulator shape factor, creepage distance, and insulator height, while the target variable was the flashover voltage. The results obtained on the training data showed a high agreement between predicted and actual values, achieving a coefficient of determination (R^2) of 0.995 and an RMSE of 0.335, indicating the model's ability to accurately capture the nonlinear relationships among the variables. When applied to the test data, the model maintained good performance with an R^2 of 0.966 and an RMSE of 1.017, confirming its capability to generalize beyond the training data. This study highlights that the Decision Tree algorithm provides an effective tool for predicting flashover voltage, thereby reducing reliance on costly laboratory experiments and enabling early maintenance decisions.

Keywords: Power transmission lines, Contaminated insulators, Flashover voltage, Decision Tree.

***Professor - Department of Electrical Power - Faculty of Mechanical and Electrical Engineering - - Lattakia University - Lattakia – Syria. George.Isber@yahoo.com**
****** Professor - Department of Electrical Power - Faculty of Mechanical and Electrical Engineering - Damascus University - Damascus – Syria. jamal.nassier@damascusuniversity.edu.sy**
******* Postgraduate Student(PhD) - Department of Electrical Power - Faculty of Mechanical and Electrical Engineering - Lattakia University - Lattakia –Syria. rama.alkhtiar@latakia-univ.edu.sy**

مقدمة:

تلعب العوازل دوراً أساسياً في خطوط نقل الكهرباء، ويتأثر أداؤها بالملوثات البيئية مثل ملح البحر، الأملاح الصناعية والطرق، والرمال الصحراوية [5]. تتفاعل هذه الملوثات مع الرطوبة (مثل الندى أو الضباب أو الأمطار الخفيفة) لتكوين ظروف غير مواتية لعمل العوازل. إذ يمكن لوجود الجزيئات الإلكتروليتية والرطوبة أن يؤدي إلى تكوين طبقة رقيقة موصلة على سطح العازل، مما يقلل من مقاومة السطح ويسبب تدفق تيار تسريب. يؤدي هذا التيار إلى تسخين أومي للسطح وتشكيل شرائط جافة، الأمر الذي قد يؤدي إلى حدوث تفريغات جزئية. وإذا بلغت قيم التوتر الكهربائي أو تيار التسريب حدودًا حرجة، يمكن أن تنشأ ظاهرة الانهيار الكهربائي [5,2,8]

توجد عدة تقنيات للحد من هذه الظاهرة، مثل التنظيف الدوري للعوازل الملوثة. ومع ذلك، فإن عدم تنفيذ برامج الغسيل والصيانة بشكل منتظم يزيد من التكاليف بشكل كبير. لمواجهة هذا التحدي، يتم تحديد توتر الانهيار للعوازل الملوثة مسبقاً [7]

تم تطوير عدة طرق لتقدير توتر الانهيار، إلا أن التجارب المخبرية تستغرق وقتاً طويلاً وتزيد من تكلفة النظام. وللتغلب على هذه المشكلة، اقترح بعض الباحثين نماذج رياضية تعتمد على النمذجة الفيزيائية باستخدام دارات مكافئة كهربائية، أو على الانحدارات الرياضية باستخدام تقنيات الذكاء الاصطناعي للتنبؤ بتوتر الانهيار للعوازل الملوثة. وقد ازدادت أهمية الأبحاث المتعلقة بتلوث العوازل بشكل ملحوظ مع ارتفاع توترات خطوط النقل، بهدف فهم سلوك الانهيار الكهربائي للعوازل الملوثة ذات التوتر العالي وتحديد الآليات الفيزيائية التي تتحكم في هذه الظاهرة [7]

أكد الباحثون في المرجع [4] فعالية استخدام الذكاء الاصطناعي، حيث تم تقدير توتر انهيار عازل Cap–Pin Glass الملوث بدقة عالية باستخدام المنطق الضبابي والشبكات العصبية في MATLAB.

وأشار الباحثون في المرجع [10] إلى أن الميزة الأساسية في الدراسة كانت اعتبار شكل العازل كعامل مهم في حساب توتر الانهيار للعوازل الملوثة. وبناءً عليه، قدموا نموذجًا ديناميكيًا لحساب توتر الانهيار للعوازل الملوثة المغذاة بالتيار المستمر، وقارنوا النتائج مع البيانات التجريبية والنظرية السابقة، محققين نتائج مرضية. كما أكد الباحثون في المرجع [11] أن توتر انهيار العازل الملوث يتأثر بتغير عامل شكل العازل.

في دراسة [3]، استخدم الباحثون نظام الاستدلال الضبابي العصبي التكيفي (ANFIS) لتقدير توتر الانهيار الحرجي للعوازل الملوثة، مستفيدين من البيانات التجريبية والنموذج الرياضي، وحقق النموذج دقة عالية في التنبؤ. في الدراسة [1]، استخدم الباحثون شجرة القرار (Decision Tree) كإحدى خوارزميات التعلم الآلي التي تم تقييمها للتنبؤ بمعلمات الانهيار للعوازل البوليمرية في ظروف ملوثة. وقد أظهرت النتائج قدرة هذه الخوارزمية على التعامل مع العلاقات غير الخطية في البيانات، وهي سمة معروفة لخوارزميات شجرة القرار. ركزت الدراسة المذكورة على عوازل سيليكون مسطحة باستخدام متغيرات الإدخال التالية: الرطوبة، درجة الحرارة، كثافة رواسب الملح المكافئة القابلة للذوبان، وكثافة الترسبات غير القابلة للذوبان، بينما كان متغير الخرج هو توتر الانهيار.

تجدر الإشارة إلى أن الدراسة السابقة لم تتضمن عامل شكل العازل كمتغير إدخال، وهو عامل هندسي مؤثر في أداء العوازل الملوثة. لذلك، إن هذه الدراسة تهدف إلى توسيع نطاق تطبيق نموذج شجرة القرار ليشمل عوازل

ذات أشكال هندسية متنوعة ومعقدة، من خلال إدخال عامل شكل العازل كمتغير مستقل رئيسي، وذلك للتقريب من ظروف التشغيل الحقيقية لأنواع العوازل المستخدمة في شبكات النقل. مع التركيز على تقييم أداء نموذج شجرة القرار في التنبؤ بتوتر الانهيار ومقارنته مع البيانات التجريبية باستخدام مؤشرات أداء قياسية، وذلك للتحقق من دقته وفعاليته في هذا السياق التطبيقي الموسع.

أهمية البحث وأهدافه:

تكتسب هذه الدراسة أهميتها من تطوير نموذج قائم على خوارزمية شجرة القرار للتنبؤ بتوتر الانهيار للعوازل الملوثة مما يسهم في تحسين الأداء التشغيلي لأنظمة نقل الطاقة الكهربائية وتقليل المخاطر الناتجة عن الأعطال. يوفر النموذج إمكانية التنبؤ الموثوق لتوتر الانهيار، مما يدعم اتخاذ قرارات صيانة مبكرة ويحسن استقرار الشبكة الكهربائية. كما يقلل الاعتماد على التجارب المخبرية المكلفة والطويلة، مما يوفر الوقت والجهد، ويساهم في تحسين كفاءة اختيار المواد والتصاميم المناسبة للعوازل لتعزيز أداء النظام الكهربائي بشكل عام.

طرائق البحث ومواده:

اعتمدت الدراسة على البيانات المستمدة من النتائج المخبرية في الدراسات السابقة والنموذج الرياضي للعازل الملوث، وذلك لتدريب خوارزمية شجرة القرار المقترحة.

تضمنت بيانات الدخل (Inputs) :

- ارتفاع العازل (H)
- طول المسار الزاحف للعازل (L)
- عامل شكل العازل (F)
- القطر المكافئ للعازل (Dm)
- كثافة رواسب الملح المكافئة(C)

أما الخرج:

- توتر الانهيار للعازل الملوث

تم استخدام هذه المعطيات لتدريب النموذج وتقييم أداء شجرة القرار في التنبؤ بتوتر الانهيار.

النموذج الرياضي للعازل الملوث:

يتألف أبسط نموذج لدراسة العوازل في ظروف التلوث، والمعروف باسم نموذج Obenhaus ، من قوس ابتدائي زاحف يربط بين المنطقة الجافة ومقاومة المنطقة الملوثة على العازل [3]. يعرف توتر الانهيار Uc بأنه التوتر المطبق عبر العازل عندما يكون القوس الجزئي تم تطويره إلى كامل العازل ويعطى بالعلاقة (١) وفق المراجع [3] ,[2]:

$$Uc = \frac{A}{n+1}(L + \pi \times n \times Dm \times F \times K) \times (\pi \times A \times Dm \times \sigma_s)^{-\left(\frac{n}{n+1}\right)} \dots\dots\dots (1)$$

حيث:

σ_S : الناقلية السطحية [$\frac{1}{\Omega}$]

A,n : ثوابت القوس

Dm: القطر الأعظمي لقرص العازل [cm]

F: عامل الشكل للعازل ويعطى بالمعادلة (٢) وفق المراجع [3] ,[2]:

$$F = \int_0^L \frac{dl}{\pi \times D(l)} \dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots (2)$$

يمثل $D(l)$ قطر العازل المتغير على طول المسار الزاحف للعازل L

تعطى الناقلية السطحية بالعلاقة (٣) وفق المراجع [3] ,[2]:

$$\sigma_s = (369.05 \times C + 0.42) \times 10^{-6} \dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots (3)$$

حيث:

C: كثافة الملح المكافئة المترسبة على العازل [mg/cm^2]

K: معامل مقاومة طبقة التلوث مع الآخذ بعين الاعتبار تركيز التيار عند نقطة أسفل القوس. يعطى هذا العامل بالنسبة للعازل القبعي بالعلاقة (٤) وفق المراجع [3] ,[2]:

$$K = 1 + \frac{\mathrm{n}+1}{2 \times \pi \times \mathrm{F} \times \mathrm{n}} \times \mathrm{Ln}\left(\frac{\mathrm{L}}{2 \times \pi \times \mathrm{R} \times \mathrm{n}}\right) \dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots (4)$$

حيث R نصف قطر الانفراغ ويعطى بالمعادلة (٥) وفق المراجع [3] ,[2] :

$$R = 0.46 \times\times (\pi \times A \times Dm \times \sigma_s)^{\frac{1}{2(n+1)}} \dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots (5)$$

النموذج الرياضي أعلاه هو نتيجة للتجارب على أنواع محددة من العوازل والملوثات المحددة على سطحها.

هناك العديد من القيم لثوابت القوس A و n في الدراسات المرجعية. تم أخذها من دراسة سابقة [7] في عام ٢٠٢٣ وهي:

A=130.4122 و n=0.3401 حيث تم تحديد القيم المثلى لها باستخدام خوارزميتي:

Particle Swarm Optimization (PSO), Whale Optimization Algorithm (WOA)

في هذا البحث تم أخذ القيم التالية لكثافة الملح المترسب المكافئة C [3]:

0.02,0.03,0.04,0.05,0.06,0.13,0.16,0.23,0.28,0.34,0.37, 0.49,0.52,0.55

تعطى بيانات العوازل الملوثة المستخدمة في حساب توتر الانهيار وفق المعادلة (1) بالجدول الآتي [3]:

جدول (1) بيانات العوازل الملوثة المستخدمة في حساب توتر الانهيار

Dm(cm)	H(cm)	L(cm)	F
26.8	15.9	33.0	0.79
26.8	15.9	40.6	0.86
25.4	16.5	43.2	0.90
25.4	14.6	31.8	0.72
29.2	15.9	47.0	0.92
27.9	15.6	36.8	0.76
32.1	17.8	54.6	0.96
28.0	17.0	37.0	0.80
25.4	14.5	30.5	0.74
20.0	16.5	40.0	1.29

إضافة إلى البيانات التجريبية من مرجع [3].

خوارزمية شجرة القرار (Decision Tree Algorithm):

تُعد شجرة القرار للانحدار (Decision Tree Regression) إحدى خوارزميات التعلم الآلي المراقب التي تُستخدم للتنبؤ بقيم عددية مستمرة. في هذه الدراسة، في هذه الدراسة، تم تطبيق خوارزمية شجرة القرار للانحدار، والتي أثبتت الدراسات السابقة [1] فعاليتها في التنبؤ بمعلمات الانهيار، وذلك للاستفادة من قدرتها على تمثيل العلاقات غير الخطية بين المتغيرات. تعتمد الخوارزمية على تقسيم مجموعة البيانات بشكل تكراري إلى مجموعات فرعية أكثر تجانساً، وذلك من خلال اختيار المتغير وقيمة العتبة التي تؤدي إلى تقليل الخطأ بين القيم الفعلية والقيم المتنبأ بها للمتغير الهدف. يتم تقييم جودة كل تقسيم من خلال معيار تخفيض الانحراف المعياري (Standard Deviation Reduction – SDR) وفقاً للمعادلة الرياضية التالية[9] :

$$SDR = Sd(T) - \sum_{i} \frac{Ti}{T} \times Sd(Ti) \dots\dots\dots\dots\dots\dots\dots\dots\dots\dots\dots (6)$$

حيث تمثل $Sd(T)$ الانحراف المعياري للقيم في العقدة الأصلية، و T عدد العينات فيها، و Ti عدد العينات في العقدة الفرعية i و $Sd(Ti)$ الانحراف المعياري للقيم فيها. تستمر عملية التقسيم حتى الوصول إلى عقد نهائية تمثل القيم المتوقعة لتوتر الانهيار.

من المزايا العملية لخوارزمية شجرة القرار [6]:

١- سهلة الفهم والتفسير مما يجعله أداة عملية لدعم قرارات الصيانة للمهندسين.

٢- تتطلب القليل من عملية إعداد البيانات مقارنة مع النماذج الأخرى.

وصف مجموعة البيانات والمتغيرات المستخدمة:

١- تم تحميل بيانات التدريب من ملف Excel ضمن بيئة Google Colab بعد ذلك تم تحديد المتغيرات المدخلة وهي القطر الأعظمي لقرص العازل Dm وارتفاع العازل H وعامل شكله F و

طول المسار الزاحف للعازل L كثافة الملح المكافئة المترسبة على العازل C بينما تم اختيار توتر الانهيار (FOV)ليكون المتغير الهدف الذي يسعى النموذج إلى التنبؤ به.

٢- تثبيت العشوائية لضمان ثبات النتائج

لضمان الحصول على نفس النتائج عند كل تشغيل، تم تثبيت قيمة العشوائية (Random State = 42) لكل من مكتبة NumPy ونموذج شجرة القرار، مما يجعل عملية تقسيم البيانات وبناء النموذج قابلة لإعادة الإنتاج.

٣- إزالة القيم المتطرفة (Outliers Removal):

قبل بدء عملية التعليم، تم تنظيف البيانات من القيم المتطرفة باستخدام طريقة z-score حيث تم حساب قيمة z-score لكل متغير، واعتُبرت القيم التي يكون مقدار z-score لها أكبر من 3 قيماً متطرفة وتم استبعادها، وذلك بهدف:

- تقليل تأثير القيم الشاذة على عملية التعلم
- تحسين دقة النموذج واستقراره

٤- تطبيع البيانات (Data Normalization):

تم تطبيق التطبيع باستخدام Standard Scalerلتحويل المتغيرات المدخلة إلى نطاق قياسي بمتوسط صفري وانحراف معياري يساوي واحد. يساعد هذا الإجراء على:

- تسهيل عملية التعلم
- تحسين أداء النموذج
- منع هيمنة متغير على آخر بسبب اختلاف المقاييس

٥- تقسيم البيانات إلى تدريب واختبار:

تم تقسيم البيانات بعد معالجتها إلى:

- 70% بيانات تدريب
- 30% بيانات اختبار

وهي نسبة شائعة في التعلم الآلي لتحقيق توازن بين وفرة بيانات التدريب ودقة تقييم التعميم.

باستخدام الدالة train_test_split مع تثبيت قيمة العشوائية، وذلك لتقييم أداء النموذج على بيانات غير مستخدمة أثناء التدريب.

٦- إعداد نموذج شجرة القرار:

تم استخدام نموذج Decision Tree Regressor من مكتبة Scikit-learn، وهو نموذج غير خطي قادر على تمثيل العلاقات المعقدة بين المتغيرات المدخلة والمتغير الهدف من خلال سلسلة من القواعد المنطقية.

٧- تحسين بارامترات النموذج باستخدام Grid Search:

للحصول على أفضل أداء ممكن، تم استخدام تقنية Grid Search مع التحقق المتقاطع-Cross) Validation)لاختبار عدة مجموعات من بارامترات شجرة القرار، شملت:

- عمق الشجرة (max_depth)
- عدد العينات اللازمة لتقسيم العقدة (min_samples_split)
- عدد العينات في الورقة النهائية (min_samples_leaf)
- معامل التقليم (ccp_alpha)

وبعد عملية البحث، تم التوصل إلى أفضل مجموعة بارامترات كما يلي:

- max_depth = 6
- min_samples_split = 2
- min_samples_leaf = 1
- ccp_alpha = 0.001

٨- تدريب نموذج شجرة القرار:

باستخدام أفضل البارامترات التي تم الحصول عليها، تم تدريب نموذج شجرة القرار على بيانات التدريب. يقوم النموذج ببناء الشجرة من خلال:

- تقسيم البيانات عند كل عقدة
- اختيار أفضل تقسيم يقلل من الخطأ التربيعي
- الاستمرار حتى الوصول إلى شروط الإيقاف المحددة بالبارامترات

بعد التدريب، بلغ عدد العقد الكلي في الشجرة 99 عقدة، منها 50 عقدة طرفية (ورقة).

٩- التنبؤ وتقييم الأداء:

بعد إتمام عملية التدريب، تم استخدام النموذج للتنبؤ بقيم FOV لكل من بيانات التدريب والاختبار، ثم تم تقييم الأداء باستخدام المقاييس التالية[8]:

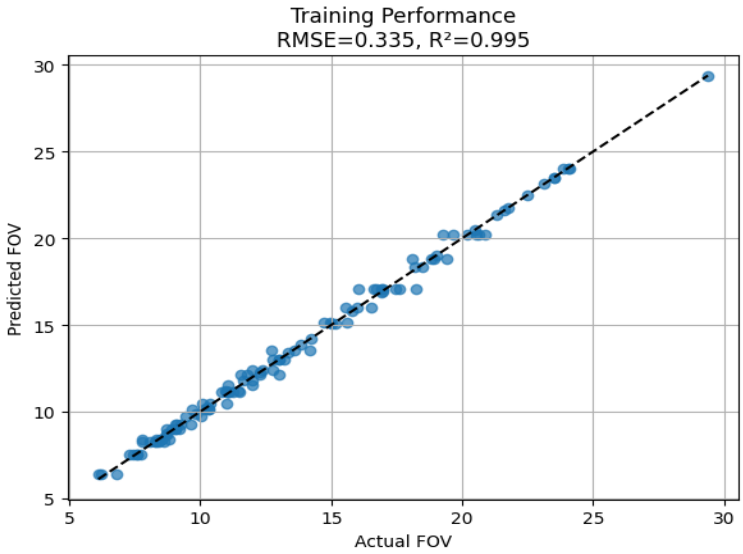
- جذر متوسط مربع الخطأ Root Mean Squared Error (RMSE) : يعبر هذا المقياس عن متوسط مقدار الخطأ بين القيم المتنبأ بها والقيم الفعلية، حيث تشير القيمة المنخفضة إلى دقة أعلى في التنبؤ.
- معامل التحديد(R^2) : مقياس يوضح نسبة التباين في المتغير الهدف التي يفسرها النموذج، حيث تتراوح قيمته بين ٠ و ١، وتشير القيمة الأعلى إلى قدرة أفضل للنموذج على تفسير البيانات.

١٠- بيئة التنفيذ:

تم تنفيذ النموذج باستخدام لغة Python ضمن بيئة Google Colab، مما يتيح تشغيل الكود دون الحاجة إلى تثبيت أي برامج إضافية على الحاسب المحلي. تم الاعتماد على مكتبة Scikit-learn لبناء نموذج شجرة القرار وتحسينه لأجل مهمة التنبؤ بقيمة توتر الانهيار.

النتائج والمناقشة:

بعد تدريب واختبار الخوارزمية حصلنا على النتائج التالية، حيث يبين الشكل (1) التالي أداء الخوارزمية على بيانات التدريب (تم شرح بيانات التدريب بالتفصيل في قسم وصف مجموعة البيانات والمتغيرات المستخدمة).



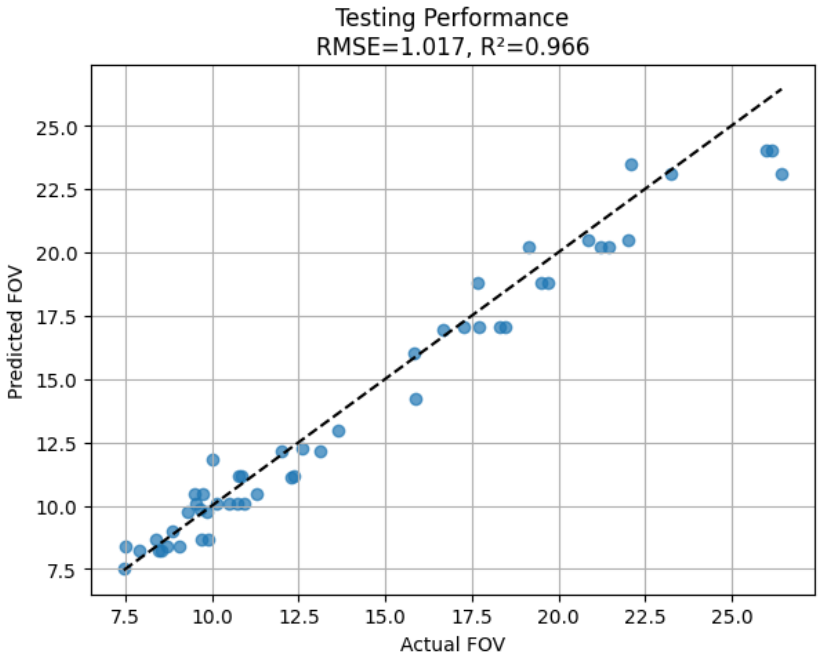
الشكل (1) أداء الخوارزمية على بيانات التدريب

يُظهر الشكل أعلاه مخطط التوافق (Parity Plot) العلاقة بين القيم المتنبأ بها والقيم الفعلية لتوتر الانهيار، حيث تمثل الدوائر الزرقاء نتائج التنبؤ للنموذج. يلاحظ تمركز غالبية النقاط بالقرب من الخط المثالي(y = x) ، مما يدل على توافق عالٍ بين القيم المتوقعة والقيم الحقيقية، ويشير إلى قدرة النموذج على تمثيل السلوك الحقيقي لتوتر الانهيار بدقة عالية ضمن نطاق القيم التجريبية المدخلة.

تعكس القيمة المرتفعة لمعامل التحديد ($R^2 = 0.995$) أن النموذج يفسر ما يقارب ٩٩,٥% من التباين الكلي في بيانات التدريب، وهو مؤشر قوي على كفاءة النموذج في التقاط العلاقات غير الخطية بين المتغيرات المدخلة والمتغير الهدف. في الوقت نفسه، يشير الانخفاض الملحوظ في قيمة الجذر التربيعي لمتوسط مربع الخطأ (RMSE = 0.335)إلى أن الفروقات بين القيم المتنبأ بها والقيم الفعلية محدودة، مما يعكس مستوى عالٍ من الدقة في التنبؤ.

تُبرز هذه النتائج قدرة نموذج شجرة القرار على استخلاص الأنماط الأساسية من البيانات وتمثيلها بشكل فعال دون فقدان معلومات جوهرية. كما تدل القيم الإحصائية المحققة على أن النموذج يتمتع بقدرة جيدة على التعلم، مع احتمالية منخفضة لحدوث انحرافات كبيرة في التنبؤ، مما يجعله أداة موثوقة لتقدير توتر الانهيار في التطبيقات الهندسية والبحثية المشابهة.

ويبين الشكل (2) أداء النموذج على بيانات الاختبار :



الشكل (2) أداء الخوارزمية على بيانات الاختبار

يُظهر الشكل أعلاه توزع القيم المتنبأ بها مقابل القيم الفعلية لتوتر الانهيار على بيانات الاختبار، حيث تتركز معظم النقاط بالقرب من الخط القطري المثالي، مما يدل على توافق جيد بين القيم المتوقعة والحقيقية. وقد حقق النموذج قيمة معامل تحديد مرتفعة بلغت $R^2 = 0.966$، إلى جانب قيمة $RMSE = 1.017$، وهو ما يعكس قدرة النموذج على تقديم تنبؤات دقيقة نسبياً على بيانات غير مستخدمة في عملية التدريب.

تشير هذه النتائج إلى أن النموذج يتمتع بقدرة جيدة على التعميم، حيث حافظ على مستوى عالٍ من الدقة عند تطبيقه على بيانات الاختبار، دون ظهور مؤشرات واضحة على فرط التعلّم. ويعكس هذا الأداء كفاءة الخوارزمية في استخلاص العلاقات الأساسية بين المتغيرات المدخلة وتوتر الانهيار.

وعليه، يمكن اعتبار النموذج أداة واعدة لدعم عمليات التنبؤ بتوتر الانهيار، مع إمكانية استخدامه كمكمل أو بديل أولي للاختبارات التجريبية التقليدية، الأمر الذي قد يسهم في تقليل الجهد الزمني والتكاليف المرتبطة بالتجارب المخبرية خاصة في مراحل التصميم والدراسة الأولية.

الاستنتاجات:

- أظهرت هذه الدراسة فعالية استخدام خوارزمية شجرة القرار (Decision Tree Regression) في التنبؤ بقيمة توتر الانهيار للعوازل بنسبة دقة ٩٩,٥% (تدريب) و ٩٦,٦% (اختبار) اعتماداً على مجموعة من المتغيرات الفيزيائية والهندسية. حيث حقق النموذج دقة عالية، كما انعكس ذلك في القيم المرتفعة لمعامل التحديد وانخفاض قيم الخطأ، مما يدل على قدرة النموذج على تمثيل العلاقات غير الخطية بين المتغيرات المدخلة والمتغير الهدف بكفاءة.
- بيّنت نتائج التدريب والاختبار وجود توافق جيد بين القيم المتنبأ بها والقيم الفعلية، مع احتفاظ النموذج بقدرة جيدة على التعميم عند تطبيقه على بيانات غير مستخدمة أثناء التدريب، مما يشير إلى استقرار النموذج وموثوقيته.
- أظهرت تقنية تحسين البارامترات باستخدام Grid Search دوراً مهماً في تعزيز أداء النموذج، حيث أسهمت عملية اختيار العمق الأمثل للشجرة ومعاملات التقليم في تقليل الخطأ وتحسين دقة التنبؤ دون الوقوع في مشكلة فرط التعلّم.
- تؤكد النتائج المتحصل عليها إمكانية توظيف نماذج التعلم الآلي القائمة على أشجار القرار كأدوات مساعدة في تقدير توتر الانهيار، مما قد يقلل من الاعتماد على الاختبارات المخبرية التقليدية المكلفة ويختصر الوقت والجهد في مراحل التحليل والتصميم.

التوصيات:

- توسيع استخدام نماذج التعلم الآلي: يُوصى باعتماد نماذج شجرة القرار ونماذج التعلم الآلي الأخرى في دراسات العوازل الكهربائية، لما لها من قدرة عالية على تحليل البيانات المعقدة وتحسين دقة التنبؤ.
- مقارنة النموذج مع خوارزميات أخرى: يُستحسن إجراء دراسات مقارنة مستقبلية تشمل نماذج أكثر تقدماً مثل الانحدار المعزز (Gradient Boosting) (تقنية تعلم آلي متقدمة تعتمد على تصحيح الأخطاء بشكل متتابع لتحسين دقة التنبؤ) والشبكات العصبية، بهدف تقييم الأداء النسبي واختيار النموذج الأنسب لكل تطبيق.
- التحقق الميداني للنموذج: من الضروري إجراء تجارب ميدانية إضافية للتحقق من كفاءة النموذج في الظروف العملية، وتحديثه بشكل دوري اعتماداً على البيانات الجديدة لضمان استمرارية الدقة والموثوقية.

المراجع:

[1] ARSHAD, J.A., AHMAD, J., TAHIR, A., STEWART, B.G., NEKAHI, A. 2020, *Forecasting Flashover Parameters of Polymeric Insulators under Contaminated Conditions Using the Machine Learning Technique.* Energies, Vol. 13, No. 15, pp 3889.

[2] BESSEDIK, S.A., DJEKIDEL, R. 2016, *Improved least squares support vector machines to estimate flashover voltage of insulators.* Conference, April 2016.

[3] BESSEDIK, S.A., HADI, H. 2013, *Prediction of flashover voltage of insulators using adaptive neuro-fuzzy inference system.* Journal of Electrical Engineering, Jan. 2013.

[4] BOUREK, Y., M'ZIOU, N., BENGUESMIA, H. 2017, *Prediction of flashover voltage of high-voltage polluted insulator using artificial intelligence.* Transactions on Electrical and Electronic Materials.

[5] HUSSEIN, A., GHASIM, Y., SALIH, S. 2011, *Effect of industrial pollution on different types of high voltage insulators.* Journal of Engineering and Development, Vol. 15, No. 1, pp 108.

[6] JIJO, B., ABDULAZEEZ, A. 2021, *Classification Based on Decision Tree Algorithm for Machine Learning.* Journal of Applied Science and Technology Trends, Vol. 02, No. 01, pp 20-28.

[7] KHERFANE, S., KHERFANE, R.L., MOUSSA, M.A., TOUAL, B. 2023, *Determining critical flashover voltage for various contaminated insulators using a hybrid approach of whale optimization and particle swarm optimization.* Advanced Engineering Science, Vol. 55, No. 2, pp 260-274.

[8] NIAZI, M.T.K., ARSHAD, AHMAD, J., ALQAHTANI, F., BAOTHAM, F.A.B., ABU-AMARA, F. 2020, *Prediction of critical flashover voltage of high voltage insulators leveraging bootstrap neural network.* Electronics, Vol. 9, No. 10, pp 1620.

[9] RATHORE, S.S., KUMAR, S. 2016, *A Decision Tree Regression based Approach for the Number of Software Faults Prediction.* ACM SIGSOFT Software Engineering Notes, Vol. 41, No. 1, pp 1-6.

[10] SUNDARARAJAN, R., GORUR, R.S. 2003, *Dynamic arc modeling of pollution flashover of insulators under DC voltage.* IEEE Transactions on Electrical Insulation, Vol. 28, No. 2, pp 200.

[11] WETZER, J.M., WOUTERS, P.A.A.F. 1993, *The effect of insulator charging on breakdown and conditioning.* IEEE Transactions on Electrical Insulation, Vol. 28, No. 4, pp 681.