

## Prediction of Flashover Voltage on Contaminated Insulators Using Machine Learning

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

(Received 27 / 10 / 2024. Accepted 22 / 12 / 2024)

### □ ABSTRACT □

Electrical insulators are a crucial component of electrical power transmission systems, and the issue of insulator pollution is one of the most significant challenges facing electrical networks. Pollution leads to electrical breakdowns, causing power outages and substantial financial losses. Therefore, accurately predicting the Flashover voltage of polluted insulators is essential for improving insulator design and ensuring high operational efficiency and reliability of power systems. The use of artificial intelligence techniques significantly contributes to enhancing the accuracy of predicting the Flashover voltage of polluted insulators, reducing associated burdens, and improving the reliability and safety of electrical power systems. In this research, the Random Forest algorithm, one of the most prominent machine learning algorithms, was used to predict the Flashover voltage of polluted insulators. Data was cleaned and processed in a Python environment, where the algorithm demonstrated high accuracy in predicting breakdown voltage, achieving a low Root Mean Square Error (RMSE) compared to previous studies related to this field. These findings highlight the role of artificial intelligence as an effective and reliable tool for estimating Flashover voltage and reducing the need for costly and complex laboratory experiments. This approach contributes to enhancing the reliability of electrical networks, lowering operational costs associated with maintenance and testing, and opening new horizons for applying machine learning techniques to improve the performance of electrical systems and address similar challenges.

**Keywords:** High voltage insulators, Polluted insulators, flashover voltage , Random Forest Algorithm

**Copyright**  :Tishreen University journal-Syria, The authors retain the copyright under a CC BY-NC-SA 04

\* Professor - Department of Electrical Power - Faculty of Mechanical and Electrical Engineering - Tishreen University - Lattakia – Syria. [George.Isber@yahoo.com](mailto:George.Isber@yahoo.com)

\*\* Professor - Department of Electrical Power - Faculty of Mechanical and Electrical Engineering - Damascus University - Damascus – Syria. [jamal.nassier@damascusuniversity.edu.sy](mailto:jamal.nassier@damascusuniversity.edu.sy)

\*\*\* Postgraduate Student(PhD) - Department of Electrical Power - Faculty of Mechanical and Electrical Engineering - Tishreen University - Lattakia – Syria. [rama.alkhtiar@tishreen.edu.sy](mailto:rama.alkhtiar@tishreen.edu.sy)

## التنبؤ بتوتر انهيار العوازل الملوثة باستخدام تعلم الآلة

د. جورج اسبر\*

د. جمال الناصير\*\*

راما الختير\*\*\*

(تاريخ الإيداع 27 / 10 / 2024. قُبِلَ للنشر في 22 / 12 / 2024)

### □ ملخص □

تشكل العوازل الكهربائية عنصراً مهماً في أنظمة نقل الطاقة الكهربائية، وتعد مشكلة تلوث العوازل واحدة من أبرز التحديات التي تواجه الشبكات الكهربائية. حيث يؤدي التلوث إلى حدوث انهيارات كهربائية، مما يسبب انقطاعات في التغذية الكهربائية وخسائر مالية كبيرة. لذا، يُعد التنبؤ الدقيق بتوتر الانهيار للعوازل الملوثة أمراً بالغ الأهمية لتحسين تصميم العوازل وضمان كفاءة التشغيل والموثوقية العالية لأنظمة الطاقة. يُسهم استخدام تقنيات الذكاء الاصطناعي بشكل كبير في تحسين دقة التنبؤ بتوتر انهيار العوازل المعرضة للتلوث، ويقلل من الأعباء المترتبة على ذلك، مما يعزز من موثوقية وأمان نظام الطاقة الكهربائية. استخدمنا خوارزمية الغابة العشوائية في تحديد توتر الانهيار المتوقع للعوازل الملوثة، وهي إحدى أهم خوارزميات تعلم الآلة. قمنا بتنظيف البيانات ومعالجتها في بيئة Python، حيث حققت الخوارزمية دقة عالية في توقع توتر الانهيار وبلغ جذر متوسط مربع الخطأ (RMSE) قيمة صغيرة مقدارها بالمقارنة مع أبحاث سابقة ذات صلة بموضوع البحث.

تُبرز هذه النتائج دور الذكاء الاصطناعي كأداة فعالة وموثوقة لتقدير توتر الانهيار وتقليل الحاجة إلى التجارب المخبرية المكلفة والمعقدة. يساهم هذا النهج في تعزيز موثوقية الشبكات الكهربائية، وتقليل التكاليف التشغيلية المرتبطة بالصيانة والاختبارات، وفتح آفاق جديدة لتطبيق تقنيات تعلم الآلة في تحسين أداء الأنظمة الكهربائية ومعالجة التحديات المماثلة.

الكلمات المفتاحية: عوازل التوتر العالي، تلوث العوازل، توتر الانهيار، خوارزمية الغابة العشوائية

حقوق النشر : مجلة جامعة تشرين- سورية، يحتفظ المؤلفون بحقوق النشر بموجب الترخيص



CC BY-NC-SA 04

\* استاذ- قسم الطاقة الكهربائية- كلية الهندسة الميكانيكية والكهربائية- جامعة تشرين- اللاذقية- سورية.

[George.Isber@yahoo.com](mailto:George.Isber@yahoo.com)

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

[jamal.nassier@damascusuniversity.edu.sy](mailto:jamal.nassier@damascusuniversity.edu.sy)

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

[rama.alkhtiar@tishreen.edu.sy](mailto:rama.alkhtiar@tishreen.edu.sy)

## مقدمة:

تلعب العوازل في خطوط نقل الطاقة الكهربائية دوراً أساسياً، حيث توفر مسارات عزل في خطوط النقل والتوزيع ويعتبر تعرضها لظروف بيئية مختلفة عاملاً حاسماً في أنظمة تشغيل الطاقة الكهربائية.

حيث تتعرض العوازل للملوثات الآتية [1] :

- ملح البحر.
- المنتجات الصناعية التي تحوي على ملح قابل للذوبان.
- أملاح الطرق.
- الرمال الصحراوية.

تشكل هذه الملوثات، مع الرطوبة (كالندى أو الضباب أو الأمطار الخفيفة)، ظروفاً غير مواتية لعمل العوازل. يمكن أن يؤدي وجود الجزيئات الإلكترونية والرطوبة إلى تشكيل طبقة رقيقة عالية التوصيل على سطح العازل مما يقلل من مقاومة السطح ويسبب تدفق تيار تسريب. يؤدي هذا التيار إلى تسخين أومي للسطح وتكوين شرائط جافة، مما قد يسبب تفريغات جزئية. وإذا وصلت قيم التوتر والتيار التسريب إلى قيم حرجة معينة، يمكن أن تبدأ ظاهرة الانهيار الكهربائي [1,2,3]

هناك عدة تقنيات لتقليل هذه الظاهرة، تشمل التنظيف الدوري للعوازل الملوثة. ومع ذلك، إذا لم يتم تنفيذ برنامج الغسيل والصيانة بشكل موثوق، فإن التكلفة تزداد بشكل كبير. للتصدي لهذا التحدي بشكل مسبق، يتم تحديد توتر الانهيار للعوازل الملوثة [4]

تم تطوير عدة طرق لتقدير توتر الانهيار، إلا أن التجارب المخبرية تستغرق وقتاً وتزيد من تكلفة النظام. لتفادي هذه المشكلة، اقترح بعض الباحثين نماذج رياضية تعتمد على النمذجة الفيزيائية باستخدام دارات مكافئة كهربائية أو على انحذارات رياضية باستخدام تقنيات الذكاء الاصطناعي للتنبؤ بتوتر انهيار على العوازل الملوثة. حيث زادت أهمية الأبحاث المتعلقة بتلوث العوازل بشكل كبير مع ارتفاع توتر خطوط النقل. ومن أجل تحديد سلوك الانهيار الكهربائي للعوازل الملوثة ذات التوتر العالي وتحديد الآليات الفيزيائية التي تحكم هذا الظاهرة [4]

أكد الباحثون في المرجع [5] على أهمية استخدام طرق الذكاء الاصطناعي في دراسة توتر انهيار العازل الملوثة باعتبارها طرق بسيطة وناجحة. في هذا البحث، حددوا توتر انهيار العازل الملوثة نوع cap-pin glass باستخدام المنطق الضبابي والشبكة العصبية الاصطناعية في بيئة MATLAB. حيث دخل الخوارزميات الناقلية وكمية التلوث في كل منطقة من العازل، وخرجها توتر انهيار العازل. نتج عن المقارنة بين النتائج التي تم الحصول عليها من الخوارزميات والنتائج المخبرية دقة هذه الطرق.

استخدم الباحثون في المرجع [6] شبكة عصبية اصطناعية متعددة الطبقات Feed Forward Neural Network (FFNN) مع خوارزمية الانتشار الخلفي لحساب توتر انهيار العوازل البورسلانية الملوثة صناعياً. أظهرت النتائج أن النموذج المقترح باستخدام الشبكة العصبية الاصطناعية يقدم نتائج أفضل مقارنة بالنماذج التحليلية المقترحة سابقاً.

في المرجع [7]، تم اعتماد نموذج Obenhaus لإجراء نمذجة رياضية ديناميكية لتحديد توتر انهيار الحرج اعتماداً على الناقلية، طول القوس، عرض طبقة التلوث على عازل زجاجي. إضافة لذلك، تم إجراء تجارب في المخبر وفق لمعيار IEC للتحقق من الطريقة المقترحة، وأشارت النتائج إلى توافق جيد.

تتبع الباحثون في المرجع [8] بتوتر انهيار العوازل الملوثة باستخدام شبكة عصبية (ANN) مُحسنة بالخوارزمية الجينية (GA) بناءً على كثافة الملح المترسبة والكثافة الرمادية، وقد حصلوا على نتائج جيدة. ذكر الباحثون في المرجع [9] أن الميزة الأساسية في هذا البحث هي أنه تم الأخذ بالاعتبار شكل العازل باعتباره يلعب دوراً أساسياً في حساب توتر الانهيار للعوازل الملوثة. لذلك، قدموا نموذجاً ديناميكياً لحساب توتر الانهيار للعازل الملوث والمغذى بالتيار المستمر، وقارنوا النتائج مع النتائج التجريبية والنظرية للباحثين السابقين وتوصلوا إلى نتائج مرضية. كما أكد الباحثون في المرجع [10] على أن توتر انهيار العازل الملوث يتغير بتغير عامل شكل العازل. ذكر الباحثون في مرجع [11] أن خوارزمية الغابة العشوائية تعتبر مصنفاً مثالياً مقارنة بأنواع أخرى من خوارزميات تعلم الآلة. سنقوم في هذا البحث باستخدام خوارزمية الغابة العشوائية من أجل حساب توتر الانهيار للعوازل الملوثة بالاستفادة من بارامترات محددة للعازل كبيانات دخل، بما في ذلك عامل شكل العازل.

### أهمية البحث وأهدافه:

تأتي أهمية البحث من خلال استخدام أحد الخوارزميات المتقدمة في مجال تعلم الآلة وبالتالي:

- 1- توفير الوقت والجهد: تُعد التجارب المخبرية التقليدية لتحديد توتر الانهيار للعوازل مكلفة وتستغرق وقتاً طويلاً. يمكن لنماذج الذكاء الاصطناعي مثل خوارزمية الغابة العشوائية أن تقلل من الحاجة إلى هذه التجارب المرهقة، مما يوفر الوقت والموارد البشرية.
- 2- تقليل التكاليف الاقتصادية: من خلال الاعتماد على النماذج الرياضية وتقنيات الذكاء الاصطناعي، يمكن تقليل التكاليف المرتبطة بالصيانة الدورية والتجارب المخبرية المكلفة في مختبرات التوتر العالي. مما يساهم في تحسين كفاءة الإنفاق على صيانة أنظمة نقل الطاقة.

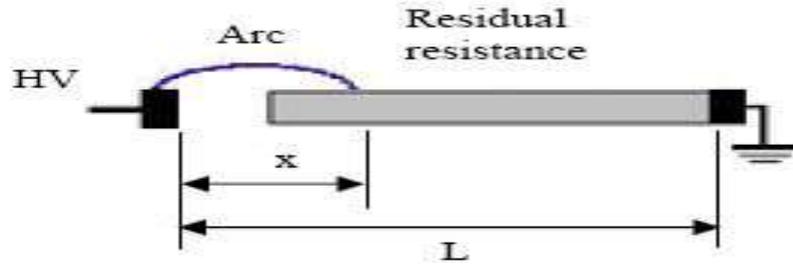
يهدف تحسين موثوقية النظام الكهربائي حيث التنبؤ الدقيق بتوتر الانهيار للعوازل الملوثة يمكن أن يساعد في تحسين موثوقية أنظمة نقل الطاقة الكهربائية عن طريق منع الأعطال قبل حدوثها، وبالتالي تحسين استقرار الشبكة الكهربائية.

### طرائق البحث ومواده:

اعتمدنا في هذه الدراسة على البيانات المستمدة من النتائج المخبرية التي تم الحصول عليها من دراسات سابقة والنموذج الرياضي للعازل الملوث. من أجل تدريب الخوارزمية المقترحة حيث دخل الخوارزمية ارتفاع العازل (H)، طول المسار الزاحف للعازل (L) عامل الشكل للعازل (F)، القطر المكافئ للعازل (Dm) كثافة رواسب الملح المكافئة (C) وخرجها توتر الانهيار للعازل الملوث.

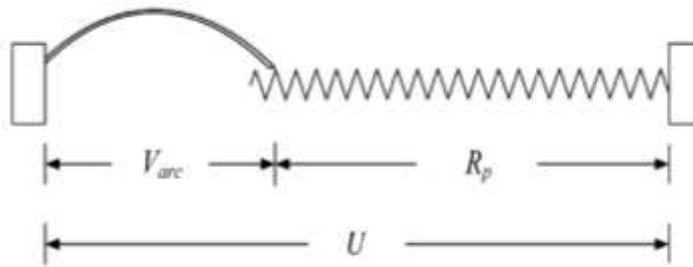
### النموذج الرياضي للعازل الملوث:

يتألف أبسط نموذج للعازل في ظروف التلوث والمعروف باسم نموذج Obenhaus، والذي يمكن من خلاله شرح وتقدير عملية الانهيار على سطحه الملوث، من قوس ابتدائي زاحف يربط بين المنطقة الجافة ومقاومة المنطقة الملوثة على العازل. يبين الشكل (1) نموذج Obenhaus للعازل الملوث [12]



الشكل (1) نموذج Obenhaus للعازل الملوث

يبين الشكل (2) الدارة المكافئة للعازل تحت ظروف التلوث [12]:



الشكل (2) الدارة المكافئة للعازل تحت ظروف التلوث

حيث:

$V_{arc}$ : توتر القوس

$R_p$ : مقاومة طبقة التلوث.

$x$ : طول القوس،  $L$ : طول المسار الزاحف للعازل

وتعطي علاقة التوتر  $U_c$  وهو التوتر المطبق عبر العازل عندما يكون القوس الجزئي تم تطويره إلى كامل العازل، ويعطى بالعلاقة [12,13]:

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

حيث:

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

$A, n$ : ثوابت القوس

$Dm$ : القطر الأعظمي لقرص العازل [cm]

$F$ : عامل الشكل للعازل ويعطى بالعلاقة [12,13]:

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

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

تعطى الناقلية السطحية بالعلاقة [12,13]

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

حيث:

C: كثافة الملح المكافئة المترسبة على العازل [mg/cm<sup>2</sup>]

K: معامل مقاومة طبقة التلوث مع الآخذ بعين الاعتبار تركيز التيار عند نقطة أسفل القوس. يعطى هذا العامل بالنسبة للعازل القبعي بالعلاقة التالية [12,13]:

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

حيث R نصف قطر الانفراج ويعطى بالعلاقة:

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

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 ونتيجة لذلك، يمكن للنموذج الرياضي أعلاه أن يُطبق بدقة مرضية على أنواع محددة من العوازل والملوثات. تعطى بيانات العوازل الملوثة المستخدمة في حساب توتر الانهيار وفق القانون السابق بالجدول الآتي:

الجدول (1) بارامترات العوازل المستخدمة لحساب توتر الانهيار رياضياً [13]

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

في هذا البحث تم أخذ القيم التالية لكثافة الملح المترسب المكافئة C [13] :

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

وتعطى البيانات التجريبية بالجدول (2) [13]:

الجدول (2) البيانات التجريبية

Dm [cm]	H [cm]	L [cm]	F	C [mg/cm <sup>2</sup> ]	Fov [kV]
25.4	14.6	27.9	0.68	0.13	12.0
25.4	14.6	27.9	0.68	0.16	11.1

25.4	14.6	27.9	0.68	0.23	8.7
25.4	14.6	27.9	0.68	0.28	9.1
25.4	14.6	27.9	0.68	0.34	7.5
25.4	14.6	27.9	0.68	0.37	7.8
25.4	14.6	27.9	0.68	0.49	6.2
25.4	14.6	30.5	0.70	0.52	6.8
25.4	14.6	30.5	0.70	0.02	22.0
25.4	14.6	30.5	0.70	0.05	16.0
25.4	14.6	30.5	0.70	0.10	13.0
25.4	14.6	30.5	0.70	0.16	11.0
25.4	14.6	43.2	0.92	0.22	10.0
25.4	14.6	43.2	0.92	0.05	19.0
25.4	14.6	43.2	0.92	0.10	15.0
25.4	14.6	43.2	0.92	0.16	13.0
25.4	14.6	43.2	0.92	0.22	12.0
25.4	14.6	43.2	1.38	0.30	10.5
22.9	16.6	43.2	1.38	0.03	20.9
22.9	16.6	43.2	1.38	0.04	19.4
22.9	16.6	43.2	1.38	0.05	18.3
22.9	16.6	43.2	1.38	0.06	16.9
22.9	16.6	43.2	1.38	0.10	15.8
22.9	16.6	43.2	1.38	0.20	13.6

إضافة للبيانات التجريبية من مرجع [12].

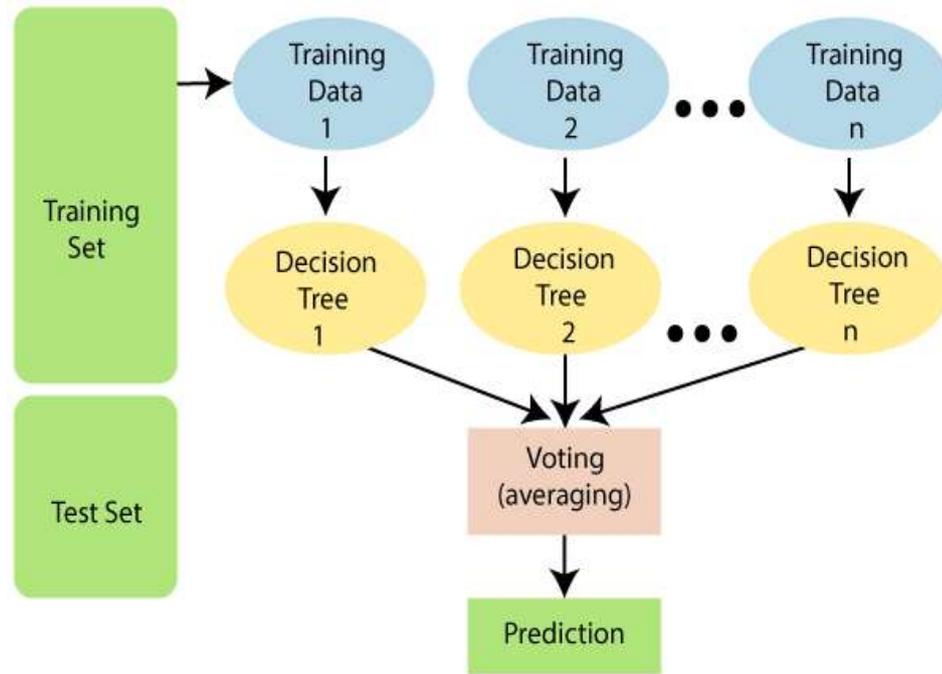
ثوابت القوس وهي  $A=130.4122$  و  $n=0.3401$ . تم أخذها من دراسة سابقة [4] في عام 2023 والتي حدد الباحثون فيها القيم المثلى لها باستخدام خوارزميتي:

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

خوارزمية الغابة العشوائية ((Random Forest Algorithm (RF))

إن خوارزمية الغابة العشوائية هي تقنية تجميع تم تقديمها لأول مرة في عام 2001 من قبل Breiman، وتستخدم في مجال تعلم الآلة لأجل مهام التصنيف وإيجاد القيمة الرقمية المتوقعة. تعتمد هذه الخوارزمية على مبدأ المعالجة على التوازي، إذ تقوم بتدريب عدة أشجار قرار باستخدام مجموعات بيانات فرعية مختلفة بشكل متوازي في إطار التعلم المراقب. عادةً ما تكون دقة التنبؤ عند استخدام شجرة قرار واحدة منخفضة نسبياً بسبب التباين العالي، ولكن عند

استخدام الغابة العشوائية، يتم تحسين الأداء من خلال تدريب عدد كبير من أشجار القرار. كل شجرة قرار تنتج توقعها الخاص، وفي حالة التصنيف، يتم تحديد النتيجة النهائية بناءً على قرار الأغلبية من هذه الأشجار [11]. أما في حالة التنبؤ بقيمة رقمية، وهي الحالة التي استخدمت فيها هذه الخوارزمية في بحثي، فإن الخوارزمية تقوم بحساب متوسط نتائج الأشجار المختلفة لتقديم التوقع النهائي. هذا الأسلوب يساعد في تقليل التباين وزيادة دقة التنبؤات بالمقارنة مع استخدام شجرة قرار واحدة. يبين الشكل (3) مبدأ عمل خوارزمية الغابة العشوائية:



الشكل (3) مبدأ عمل خوارزمية الغابة العشوائية

من مزايا الغابة العشوائية: تعمل بكفاءة لأجل مجموعة كبيرة من البيانات وتعطي دقة تنبؤ عالية.

**التنبؤ بتوتر الانهيار باستخدام RF:**

تم تنفيذ خوارزمية الغابة العشوائية للتنبؤ بتوتر انهيار العوازل الملوثة. تم تدريب الخوارزمية باستخدام البيانات المأخوذة من النموذج الرياضي (140 عينة تدريب)، في حين تم اختبارها على البيانات التجريبية الحقيقية المأخوذة من دراسات سابقة كما ذكرنا سابقاً (38 عينة). تم تخزين البيانات في ملف بصيغة Excel لاستخدامها في تدريب واختبار الخوارزمية. تمت عملية تعليم الخوارزمية بالتفصيل وفق التالي:

**عملية تعليم الغابة العشوائية:**

1. **تجميع البيانات وتحديد المتغيرات:**

قمنا بجمع بيانات التدريب من ملف Excel وتحديد المتغيرات المدخلة (D, H, L, C, F) والمتغير الهدف وهو توتر الانهيار (FOV).

## 2. إزالة القيم المتطرفة:

قبل بدء عملية التعليم، تم تنظيف البيانات بإزالة القيم المتطرفة باستخدام طريقة z-score حيث تُعتبر القيم التي يكون z-score الخاص بها أكبر من 3 قيمةً متطرفة ويتم استبعادها لضمان دقة أفضل.

## 3. تطبيع البيانات:

تم استخدام المحول القياسي (Standard Scaler) لتطبيع البيانات، حيث يتم تحويل القيم المدخلة إلى نطاق قياسي لتسهيل عملية التدريب.

## 4. إعداد وتكوين النموذج:

قمنا بضبط بارامترات الغابة العشوائية لتحقيق الأداء الأمثل. حصلنا على أفضل أداء عند:

n\_estimators: عدد الأشجار في الغابة (1000 شجرة)

max\_features: عدد الميزات المستخدمة في كل تقسيم (auto)

max\_depth: عمق الأشجار 50 مستوى

min\_samples\_split: عدد العينات المطلوبة لتقسيم العقدة 2 عينة.

min\_samples\_leaf: عدد العينات المطلوبة في الورقة النهائية 1 عينة.

## 5. بناء الغابة العشوائية:

تتكون الغابة العشوائية من مجموعة من أشجار القرار. كل شجرة تُبنى باستخدام عينة عشوائية من بيانات التدريب. تتعلم كل شجرة بشكل مستقل عن الأشجار الأخرى وتقوم بالتنبؤ بالقيمة المستهدفة بناءً على الميزات المدخلة.

## 6. تكرار عملية التعليم:

تم تدريب كل شجرة باستخدام عينة من البيانات. بالنسبة لكل عينة، تقوم الشجرة بإجراء تقسيمات متتابعة على الميزات لاختيار أفضل تقسيم يقلل من الخطأ. تم تحسين النموذج من خلال بناء أشجار متعددة وتجميع نتائجها.

## 7. حفظ النموذج المدرب:

بعد تدريب النموذج، تم حفظه لاستخدامه لاحقاً في عملية التنبؤ على بيانات الاختبار.

تم تنفيذ الخوارزمية باستخدام لغة البرمجة Python ضمن بيئة Google Colab مما يلغي الحاجة إلى تثبيت أي برنامج آخر على جهاز الحاسب المحلي ذو القدرة المحدودة. تم استخدام تقنية Random Forest Regressor من مكتبة تعلم الآلة سايكيت ليرن لبناء الغابة العشوائية لأجل مهمة تحديد قيمة التوتر.

## معايير تقييم الأداء:

تم استخدام المعايير الآتية:

1- جذر المتوسط التربيعي للخطأ (Root Mean Square Error) :

يُعرف اختصاراً بـ RMSE، هو مقياس يستخدم لقياس مدى دقة نموذج التنبؤ أو التقدير. يعبر RMSE عن متوسط حجم الأخطاء بين القيم المتوقعة من النموذج والقيم الفعلية في مجموعة البيانات. والذي يعطى بالمعادلة [14]:

$$RMSE = \sqrt{\frac{1}{N} \times \sum_{i=1}^N (FP_{Ai} - FP_{Pi})^2 \dots \dots \dots (6)}$$

FP<sub>Ai</sub>: القيمة الفعلية للبيانات عند النقطة i

$FP_{Pi}$ : القيمة المتنبأ بها بواسطة النموذج عند النقطة  $i$

$N$ : عدد نقاط البيانات أو العينات

حيث كلما كانت قيمة RMSE قريبة من الصفر كلما كان أفضل.

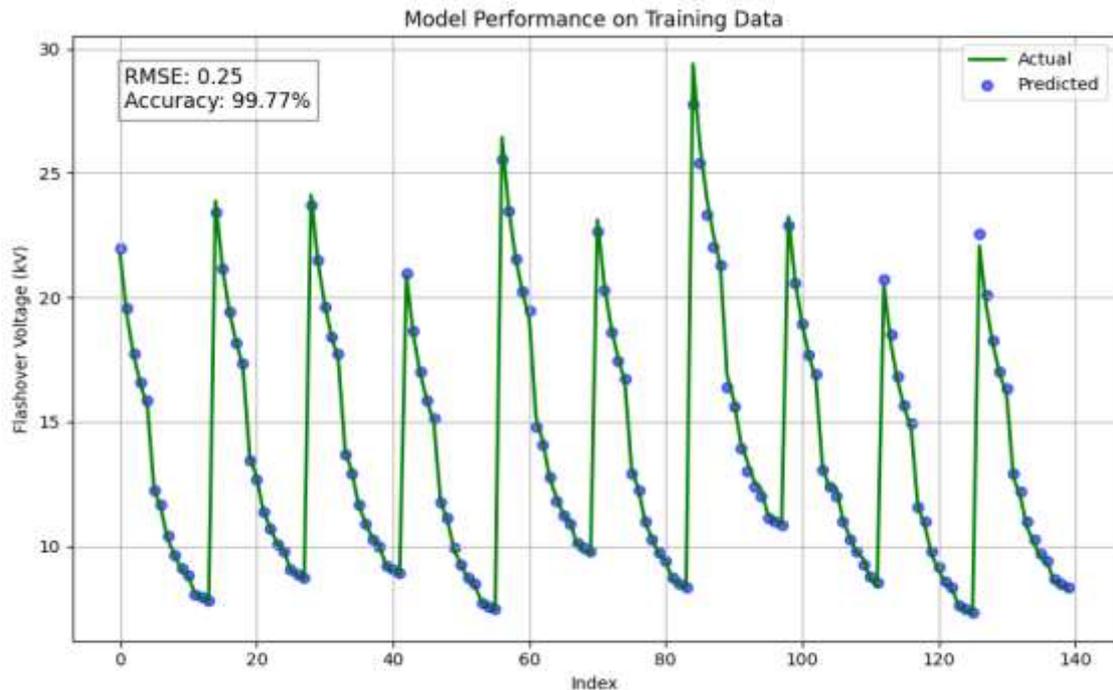
2- معامل التحديد أو مقياس درجة الملائمة  $R^2$  (Coefficient of Determination) [13]:

هو مقياس يستخدم لتقييم جودة التنبؤات التي يقدمها النموذج التنبؤي حيث يحدد مدى قدرة النموذج على تفسير التباين في القيم الفعلية. كلما اقتربت قيمته من 1 كان أفضل. يعطى بالمعادلة:

$$R^2 = 1 - \frac{\sum_{i=1}^N (FP_{Ai} - FP_{Pi})^2}{\sum_{i=1}^N (FP_{Ai} - \overline{FP_{Ai}})^2} \dots \dots \dots (7)$$

### النتائج والمناقشة:

بعد تدريب واختبار الخوارزمية حصلنا على النتائج التالية، حيث يبين الشكل (4) التالي أداء الخوارزمية على بيانات التدريب.



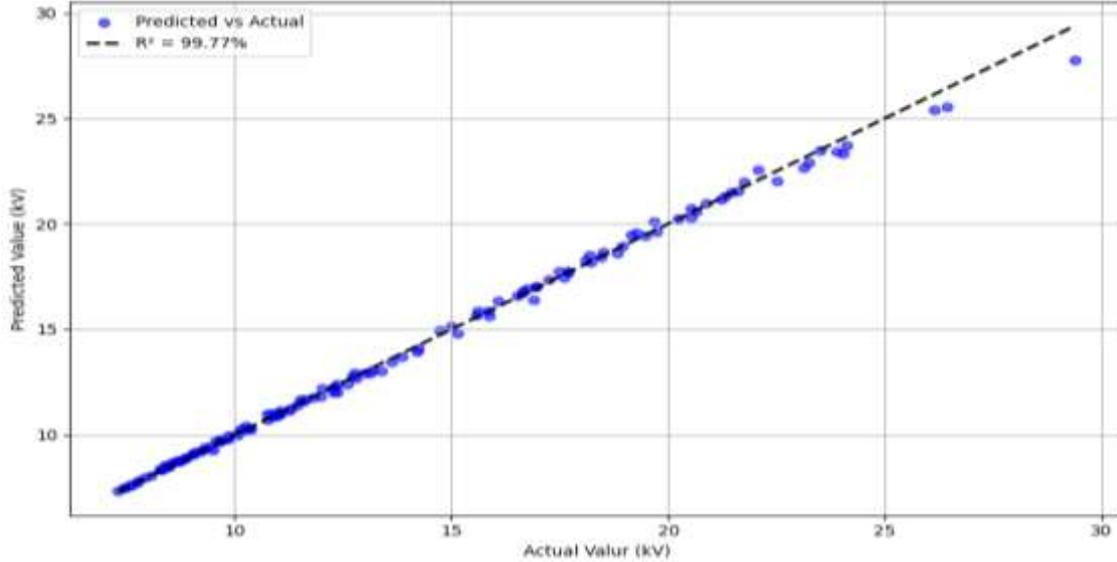
الشكل (4) أداء خوارزمية الغابة العشوائية على بيانات التدريب

تمثل في الشكل (4) الخطوط الخضراء القيم الحقيقية للتوتر، بينما تمثل الدوائر الزرقاء القيم المتنبأ بها بواسطة النموذج. كما يظهر في الرسم، هناك تطابق كبير بين القيم الحقيقية والقيم المتنبأ بها، مما يشير إلى دقة النموذج في تعلم الأنماط الموجودة في البيانات.

حصلنا على قيمة عالية لمقياس الملائمة والمشار إليها على الرسم بـ accuracy مقدارها 99.77%، و قيمة RMSE مقدارها 0.25، مما يدل على أن الفروقات بين القيم الفعلية والمتنبأ بها كانت قليلة جداً. هذه النتائج تؤكد أن النموذج يمتلك قدرة عالية على محاكاة السلوك الفعلي لتوتر الانهيار تحت ظروف. مختلفة سيتبع هذا الشرح تحليل

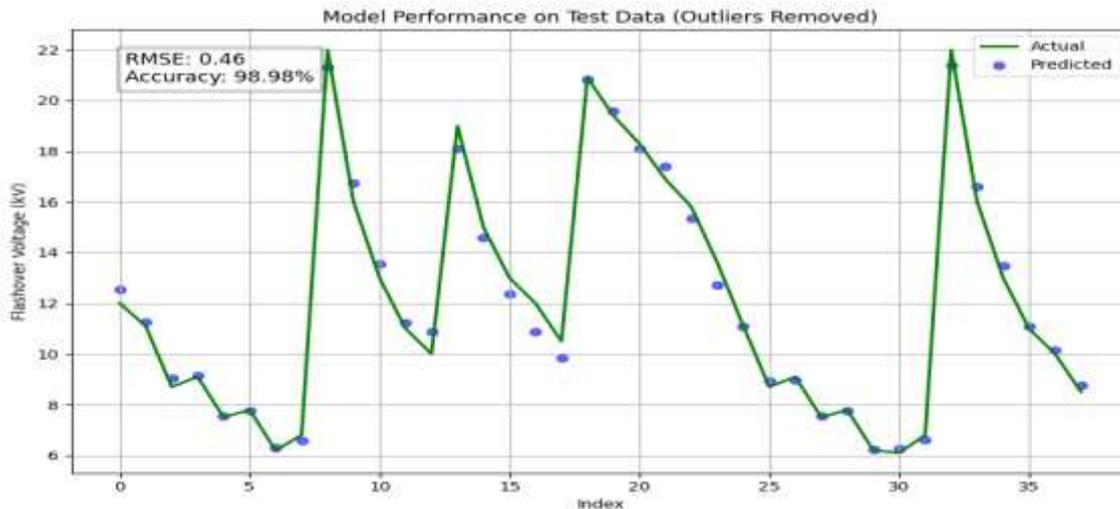
أداء النموذج على بيانات الاختبار في الشكل (6) حيث سيوفر المزيد من التوضيح حول دقة النموذج. بفضل هذه الدقة العالية، يمكن للنموذج أن يكون أداة فعالة لتقدير توتر الانهيار دون الحاجة إلى إجراء اختبارات تجريبية مكلفة أو معقدة.

يبين الشكل (5) العلاقة بين القيم الحقيقية والمتوقعة على بيانات التدريب



الشكل (5) العلاقة بين القيم الحقيقية والمتوقعة على بيانات التدريب

يبين الشكل (5) العلاقة بين القيم الحقيقية للتوتر والقيم المتنبأ بها بواسطة النموذج، حيث تُظهر الدوائر الزرقاء التنبؤات المتحققة مقابل القيم الفعلية، وهو ما يعكس الأداء الفائق للنموذج. يتضح من الرسم أن هناك تطابقاً ملحوظاً بين القيم المتنبأ بها والقيم الحقيقية، مما يدل على دقة النموذج في محاكاة السلوك الفعلي لتوتر الانهيار تحت ظروف مختلفة. تشير قيمة معامل التحديد ( $R^2$ ) البالغة 99.77% إلى أن النموذج يفسر نسبة كبيرة من التباين في البيانات، بينما تعكس قيمة الجذر التربيعي للخطأ (RMSE) البالغة 0.25 الفروقات البسيطة بين القيم المتوقعة والفعلية. هذه النتائج تبرز قدرة النموذج على التعلم من البيانات واستخلاص الأنماط مما يجعله أداة موثوقة لتقدير توتر الانهيار. سيتبع هذا الشرح تحليل أداء النموذج على بيانات الاختبار في الشكل (7)، حيث سيوفر نظرة إضافية على دقة النموذج. يبين الشكل (6) أداء الخوارزمية على بيانات الاختبار.

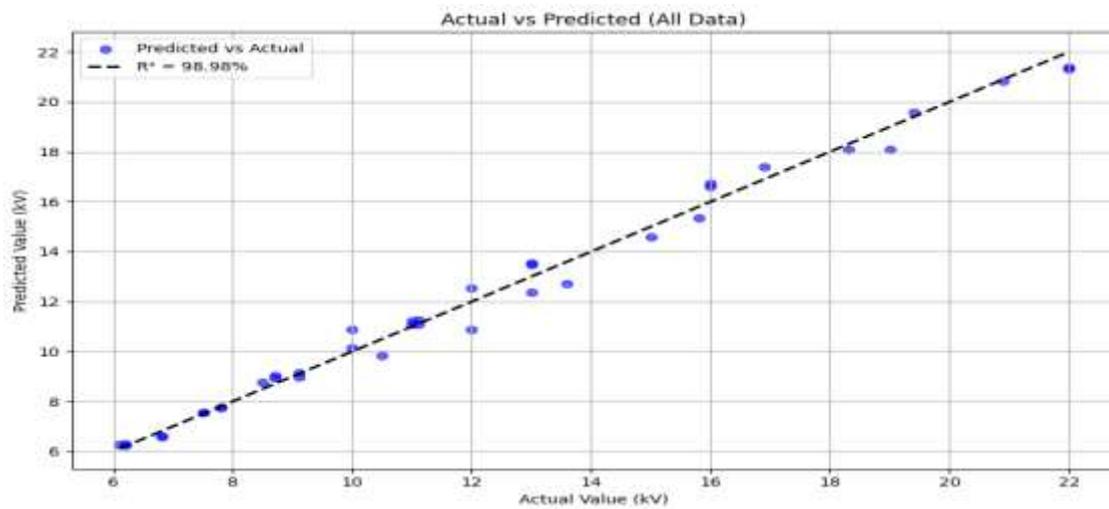


الشكل (6) أداء الخوارزمية على بيانات الاختبار

نلاحظ من الشكل (6) مدى دقة الخوارزمية في التوقع على بيانات الاختبار، حيث حققت قيمة عالية لمقياس درجة الملائمة وقدرها 98.98% ونسبة خطأ صغيرة مقدارها 0.46. تشير هذه النتائج إلى قدرة النموذج على التعميم بشكل جيد على البيانات الجديدة، مما يعكس فعاليته في التعرف على الأنماط الموجودة.

بالمقارنة مع الدراسات السابقة، تفوق النموذج الحالي على أداء خوارزمية ANFIS، التي أظهرت قيمة RMSE مقدارها 0.47 لنفس قاعدة البيانات في الدراسة [13]. كما أن تلك الدراسة قد ذكرت تفوق ANFIS على الشبكات العصبية الاصطناعية والمنطق الضبابي. بناءً على ذلك، فإن النموذج الحالي ليس فقط أفضل من ANFIS بل يظهر أيضاً قدرة متفوقة مقارنة بتلك الخوارزميات الأخرى، مما يجعله أداة واعدة لتقدير توتر انهيار العوازل الملوثة في شبكات النقل.

يبين الشكل (7) العلاقة بين القيم الحقيقية والمتوقعة لأجل بيانات الاختبار:



الشكل (7) العلاقة بين القيم الحقيقية والمتوقعة لأجل بيانات الاختبار

نلاحظ من الشكل (7) أن النقاط موزعة بشكل قريب من الخط القطري، هذا يشير إلى أن النموذج يقدم توقعات دقيقة ويعكس مدى دقة الخوارزمية في التنبؤ بالنتائج بناءً على بيانات الاختبار. مما يفتح المجال لاستخدامه كبديل فعال لاختبارات التوتر التقليدية، ويقلل من التكاليف والوقت في التجارب المخبرية.

## الاستنتاجات والتوصيات:

### الاستنتاجات:

- أثبتت الدراسة فعالية استخدام خوارزمية الغابة العشوائية في تحسين دقة التنبؤ بتوتر انهيار العوازل الملوثة مقارنة بالأساليب التقليدية والخوارزميات الأخرى، مثل ANFIS والشبكة العصبية الاصطناعية والمنطق الضبابي.
- تعزز هذه الخوارزمية من موثوقية النظام الكهربائي وتقلل من الحاجة إلى إجراء التجارب المخبرية المكلفة.
- أظهرت النتائج توافقاً جيداً بين النموذج المقترح والبيانات التجريبية، مما يثبت إمكانية الاعتماد على الذكاء الاصطناعي في هذا المجال لتقليل التكاليف والوقت.

**التوصيات:**

- التوسع في استخدام تقنيات الذكاء الاصطناعي: ينبغي على المهندسين والباحثين تبني استخدام تقنيات الذكاء الاصطناعي، مثل الغابة العشوائية لتحسين أداء العوازل الكهربائية وتقليل مخاطر الانهيار.
- تطوير نماذج رياضية أكثر تعقيداً تتضمن تأثيرات متعددة للظروف البيئية المختلفة على أداء العوازل، مما يساهم في تحسين دقة التنبؤات.
- القيام بالتنظيف الدوري للعوازل وصيانتها بشكل منتظم ضرورة لا غنى عنها للحفاظ على كفاءتها ومنع حدوث الانهيارات.
- توفير برامج تدريب مستمرة للمهندسين والفنيين العاملين في مجال الكهرباء حول أحدث التقنيات والنماذج المستخدمة في التنبؤ بتوتر الانهيار وكيفية تطبيقها بشكل فعال.
- إجراء دراسات ميدانية إضافية للتحقق من كفاءة النماذج المستحدثة وتحديثها بناءً على نتائج هذه الدراسات لضمان دقة وموثوقية أعلى.

**References:**

- [1] A. Hussein, Y. Ghasim, and S. Salih, "Effect of industrial pollution on different types of high voltage insulators," *Journal of Engineering and Development*, vol. 15, no. 1, pp. 108, Mar. 2011.
- [2] Bessedik SA, Djekidel R, et al. Improved least squares support vector machines to estimate flashover voltage of insulators. Conference. April 2016.
- [3] M. T. K. Niazi, Arshad, J. Ahmad, F. Alqahtani, F. A. B. Baotham, and F. Abu-Amara, "Prediction of critical flashover voltage of high voltage insulators leveraging bootstrap neural network," *Electronics*, vol. 9, no. 10, p. 1620, 2020
- [4] S. Kherfane, R. L. Kherfane, M. A. Moussa, and B. Toual, "Determining critical flashover voltage for various contaminated insulators using a hybrid approach of whale optimization and particle swarm optimization," *Gongcheng Kexue Yu Jishu/Advanced Engineering Science*, vol. 55, no. 2, pp. 260-274, Sep. 2023, doi: 10.5281/zenodo.4651203. [Online].
- [5] Y. Bourek, N. M'Ziou, and H. Benguesmia, "Prediction of flashover voltage of high-voltage polluted insulator using artificial intelligence," *Transactions on Electrical and Electronic Materials*. [Online]. Available: <https://doi.org/10.1007/s42341-018-0010-3>. 2017
- [6] A. Author, "Flashover Analysis in High Voltage Insulator Using By ANN," *\*International Journal of Innovative Science and Research Technology\**, vol. 2, no. 11, pp. 131-136, Nov. 2017. Available: [www.ijisrt.com](http://www.ijisrt.com)
- [7] A. A. Salem, R. Abd-Rahman, M. S. Kamarudin, H. Ahmad, N. A. M. Jamail, N. A. Othman, M. T. Ishak, M. N. R. Baharom, and S. Al-Ameri, "Proposal of a dynamic numerical approach in predicting flashover critical voltage," *International Journal of Power Electronics and Drive System (IJPEDS)*, vol. 10, no. 2, pp. 602-610, Jun. 2019, doi: 10.11591/ijped.v10.i2.602-610.
- [8] Zhao, l. Prediction of Pollution Flashover Voltage of Insulators Based on Genetic Algorithm. 2020 International Symposium on Advances in Informatics, Electronics and Education (ISAIEE 2020)
- [9] Sundararajan R, Gorur RS. Dynamic arc modeling of pollution flashover of insulators under DC voltage. *IEEE Trans Electr Insul*. 2003;28(2):200.
- [10] Wetzler JM, Wouters PAAAF. The effect of insulator charging on breakdown and conditioning. *IEEE Trans Electr Insul*. 1993;28(4):681.

- [11] Mehdi A, Hussain A, Haider W, Hassan SJ, Saad M, Kim CH. *Classification of Power System Faults Using Random Forests*. . 2020;957–8.
- [12] B. Zegnini, M. Belkheiri, and M. Djillali, "Modeling flashover voltage (FOV) of polluted HV insulators using artificial neural networks (ANNs)," in *\*Proc. IEEE Conference\**, Dec. 2009. Available: <https://www.researchgate.net/publication/224091474>
- [13] S. A. Bessedik and H. Hadi, "Prediction of flashover voltage of insulators using adaptive neuro-fuzzy inference system," *\*Journal of Electrical Engineering\**, Jan. 2013. Available: <https://www.researchgate.net/publication/288104937>.
- [14] Ahmad J, Tahir A. Forecasting Flashover Parameters of Polymeric Insulators under Contaminated Conditions Using the Machine Learning Technique. *Energies* 2020, 13, 3889; doi:10.3390/en13153889