

UNIVERSITAT POLITÈCNICA DE VALÈNCIA

PROGRAMA DE DOCTORADO INGENIERÍA Y PRODUCCIÓN INDUSTRIAL

DEPARTAMENTO DE INGENIERÍA ELÉCTRICA

INSTITUTO DE TECNOLOGÍA ELÉCTRICA



**Contribución al mantenimiento
de aisladores de alta tensión en
servicio basado en medidas de
corrientes de fuga**

Tesis Doctoral

José Manuel Bueno Barrachina

Director: Vicente Luis Fuster Roig

Codirectora: Yiyao Ye Lin

València, Julio de 2023

Resumen

Los aisladores eléctricos de alta tensión desempeñan un papel fundamental en las redes aéreas de transporte y distribución de energía eléctrica. En caso de un fallo de funcionamiento pueden incidir de forma importante en la continuidad del suministro eléctrico, dando lugar a importantes impactos socio-económicos. Las descargas disruptivas por deposición de contaminación en la superficie de los aisladores son una de las amenazas a la fiabilidad de la red eléctrica, constituyendo un reto para proyectistas e ingenieros de mantenimiento de la red eléctrica. En la actualidad, no existen métodos realmente eficaces para la monitorización continua de los niveles de contaminación en la superficie de los aisladores durante la operación normal, por lo tanto, se recurre al mantenimiento periódico de los mismos para garantizar la continuidad del suministro eléctrico. El desarrollo de una herramienta que permitiera esta monitorización en tiempo real proporcionaría información muy valiosa para el mantenimiento preventivo de los aisladores eléctricos de alta tensión y/o el seguimiento del estado superficial de los mismos.

La segunda aproximación se centra en la predicción a corto plazo de la corriente de fugas, permitiendo detectar comportamientos anómalos al compararla con la corriente de fugas real. El modelo desarrollado en esta tesis podría utilizarse para crear un sistema on-line de preaviso, que permita anticipar las consecuencias negativas de la climatología y/o depósitos de contaminación a corto y medio plazo cuando el efecto del envejecimiento es irrelevante, constituyendo potencialmente una herramienta de gran utilidad para diseñar un plan estratégico de mantenimiento preventivo de los aisladores eléctricos de alta tensión y minimizar las descargas disruptivas que provoquen fallos inesperados de la red eléctrica, aumentando así la fiabilidad y resiliencia de la red eléctrica.

Para ello, partiendo de registros simultáneos de la corriente de fuga en 7 aisladores y las variables ambientales de larga duración,

monitorizadas durante 30 meses, se ha analizado la relación subyacente entre la corriente de fuga cruda o en bruto (la medida) y las variables ambientales, utilizando la correlación de Spearman. Mediante el análisis de correlación parcial, se ha determinado que la relación entre la corriente de fuga cruda y la temperatura, dirección y velocidad del viento se debe principalmente a su influencia sobre la humedad relativa. Asimismo, se ha determinado la relación causa - efecto de estas variables ambientales con la corriente de fuga mediante el análisis de causalidad condicional de Granger. Con el modelo de vectores autorregresivos, se ha establecido el número óptimo de muestras anteriores de las variables ambientales para predecir la corriente de fuga. A continuación, se ha cancelado la influencia de la humedad relativa en la corriente de fuga mediante un filtrado adaptativo y se ha diseñado un filtro específico basado en niveles de umbral adaptativos, calculado por métodos estadísticos para eliminar los picos anómalos de corriente dispersos como los de alta densidad (en el tiempo), hallando así, al filtrar los picos anómalos, la corriente de fuga debida a la polución depositada en el aislador (PLC). El método propuesto reduce considerablemente la correlación entre la corriente de fuga y la humedad relativa (0.826 ± 0.051 frente a 0.019 ± 0.014). La señal resultante presentó una correlación muy débil con otras variables ambientales (<0.03), lo cual confirma que las relaciones entre la corriente de fuga y la temperatura, la dirección y la velocidad del viento se atribuyen principalmente a su influencia en la humedad relativa. La PLC presenta una suave fluctuación cuasi-anual en el tiempo de magnitud similar a las obtenidas en las pruebas de laboratorio. Esta técnica podría usarse para monitorizar en tiempo real la PLC en los aisladores eléctricos y así mejorar la continuidad del suministro eléctrico y reducir los costos de mantenimiento.

Asimismo, la corriente de fuga es un reflejo integral de la climatología y estado superficial del aislador y es una medida objetiva de todo el proceso completo del desarrollo de la descarga disruptiva por contaminación. Por tanto, la monitorización de la corriente de fuga es la medida más eficaz para mantenerse en la zona de seguridad y prevenir las descargas disruptivas por contaminación. En la literatura

se han propuesto distintas técnicas de regresión para predecir la corriente de fuga a partir de las variables ambientales: regresión multivariable lineal (MVR), redes neuronales y/o máquinas de soportes vectoriales. Sin embargo, debido a la complejidad de la interacción dinámica entre las variables ambientales y la corriente de fuga, se han obtenido resultados aceptables en registros de corta duración con poca capacidad de generalización. Por tanto, en esta tesis se han desarrollado modelos robustos y suficientemente precisos de predicción de la corriente de fuga en base a las variables ambientales en registros de larga duración. El modelo debe ser capaz de predecir la corriente de fuga en tiempo real durante la operación normal de los aisladores eléctricos y además debe adaptarse fácilmente a otras subestaciones, constituyendo una herramienta ingenieril que permite proporcionar información valiosa para anticipar las consecuencias negativas de la climatología y/o la contaminación. Todo ello con el objetivo de minimizar las descargas disruptivas y los cortes imprevistos de suministro eléctrico, aumentando así la fiabilidad y resiliencia de la red eléctrica.

Para ello, se han desarrollado y comparado 5 modelos de regresión para predecir la corriente de fuga a partir de las muestras actuales o las últimas 21 muestras de variables ambientales: MVR, soporte vectorial para regresión (SVR), 2SL-CNN (redes neuronales convolucionales (CNN) basadas en 2 capas convolucionales estándares), 2IL-CNN (CNN basado en 2 capas convolucionales con arquitectura inception) y 4IL-CNN (CNN basado en 4 capas convolucionales con arquitectura inception). Los modelos basados con las últimas 21 muestras presentaron significativamente mejores rendimientos que los basados en muestras actuales, sugiriendo que la climatología pasada aporta información valiosa para pronosticar la corriente de fuga. Asimismo, se ha contrastado la no-linealidad de la interacción entre las variables ambientales y la corriente de fuga, ya que la técnica MVR obtuvo un rendimiento significativamente inferior que los otros modelos no-lineales. Los resultados experimentales sugieren que la compleja interacción dinámica no-lineal entre las variables ambientales y la corriente de fuga puede capturarse

mediante el aprendizaje en cascada de la arquitectura inception que permite extraer simultáneamente la información local y regional (en distintos instantes de tiempo) cada vez más extensa. Tanto el modelo 2IL-CNN ($R^2: 0.89 \pm 0.06$) como el 4IL-CNN ($R^2: 0.94 \pm 0.03$) obtuvieron rendimientos sustancialmente superiores al modelo 2SL-CNN ($R^2: 0.73 \pm 0.11$), y este a su vez ligeramente superior que SVR ($R^2: 0.70 \pm 0.13$), siendo estas diferencias estadísticamente significativas. A pesar del complejo proceso de humedecido con depósitos de contaminación en los aisladores de silicona, el modelo 4IL-CNN es válido para predecir la corriente de fuga tanto en aisladores cerámicos con o sin recubrimientos de silicona como aisladores de silicona, y además fácilmente adaptable a otras subestaciones.

Abstract

High-voltage electrical insulators play a fundamental role in overhead power transmission and distribution networks. In the malfunction event, they can significantly affect the continuity of the electricity supply, giving rise to significant socio-economic impacts. Disruptive discharges due to the deposition of contamination on the surface of the insulators are one of the threats to the reliability of the electrical network, constituting a challenge for designers and maintenance engineers of the electrical network. Currently, there are no truly effective methods for continuous monitoring of the contamination levels on the insulator surface during normal operation, therefore, periodic maintenance is used to guarantee the continuity of the electrical supply. The development of a tool that would allow this monitoring in real time would provide very valuable information for the preventive maintenance of high-voltage electrical insulators and/or the monitoring of their surface condition.

The second approach focuses on the short-term prediction of the leakage current, allowing the detection of anomalous behaviours when comparing it with the actual leakage current. The model developed in this thesis could be used to create an online pre-warning system, which allows anticipating the negative consequences of the weather and/or pollution deposits in the short and medium term when the effect of aging is irrelevant, potentially constituting a tool very useful for designing a strategic preventive maintenance plan for high - voltage electrical insulators and minimizing disruptive discharges that cause unexpected failures in the electrical network, thus increasing the reliability and resilience of the electrical network.

To do this, based on simultaneous recordings of the leakage current in 7 insulators and the long-term environmental variables, monitored for 30 months, the underlying relationship between the crude or raw leakage current (the measurement) and the environmental variables has been analysed, using Spearman's

correlation. Through partial correlation analysis, it has been determined that the relationship between raw leakage current and temperature, direction and wind speed is mainly due to its influence on relative humidity. Likewise, the cause-effect relationship of these environmental variables with the leakage current has been determined through Granger's conditional causality analysis. With the autoregressive vector model, the optimal number of previous samples of the environmental variables to predict the leakage current has been established. Next, the influence of relative humidity on the leakage current has been cancelled by adaptive filtering and a specific filter has been designed based on adaptive threshold levels, calculated by statistical methods to eliminate scattered anomalous current peaks such as those of high density (in time), thus finding, by filtering the anomalous peaks, the leakage current due to the pollution deposited on the insulator (PLC). The proposed method considerably reduces the correlation between leakage current and relative humidity (0.826 ± 0.051 vs. 0.019 ± 0.014). The resulting signal presented a very weak correlation with other environmental variables (< 0.03), confirming that the relationships between leakage current and temperature, wind direction and speed are mainly attributed to their influence on relative humidity. The PLC presents a smooth quasi - annual fluctuation in time of magnitude similar to those obtained in laboratory tests. This technique could be used to monitor the PLC in electrical insulators in real time to improve continuity of power supply and reduce maintenance costs.

Likewise, the leakage current is an integral reflection of the climatology and surface state of the insulator and is an objective measure of the entire process of the development of the disruptive discharge due to contamination. Therefore, monitoring the leakage current is the most effective measure to stay in the safety zone and prevent disruptive discharges due to contamination. Different regression techniques have been proposed in the literature to predict leakage current from environmental variables: multivariable linear regression (MVR), neural networks and/or support vector machines. However, due to the complexity of the dynamic interaction between

environmental variables and leakage current, acceptable results have been obtained in short duration records with little generalizability. Therefore, in this thesis robust and sufficiently accurate models have been developed for the prediction of leakage current based on environmental variables in long-term records. The model must be capable of predicting the leakage current in real time during the normal operation of the electrical insulators and must also be easily adapted to other substations, constituting an engineering tool that allows providing valuable information to anticipate the negative consequences of the weather and/or or pollution. All this with the aim of minimizing disruptive discharges and unforeseen power outages, thus increasing the reliability and resilience of the electrical network.

For this, 5 regression models have been developed and compared to predict the leakage current from the current samples or the last 21 samples of environmental variables: MVR, support vector for regression (SVR), 2SL-CNN (convolutional neural networks (CNN) based on 2 standard convolutional layers), 2IL-CNN (CNN based on 2 convolutional layers with inception architecture) and 4IL-CNN (CNN based on 4 convolutional layers with inception architecture). Models based on the last 21 samples performed significantly better than those based on current samples, suggesting that past climatology provides valuable information for forecasting leakage current. Likewise, the non-linearity of the interaction between the environmental variables and the leakage current has been contrasted, since the MVR technique obtained a significantly lower performance than the other non-linear models. The experimental results suggest that the complex non-linear dynamic interaction between environmental variables and leakage current can be captured by cascade learning of the inception architecture that allows simultaneously extracting local and regional information (at different time instants) each time. more extensive. Both the 2IL-CNN ($R^2: 0.89\pm 0.06$) and the 4IL-CNN ($R^2: 0.94\pm 0.03$) models obtained substantially higher performance than the 2SL-CNN model ($R^2: 0.73\pm 0.11$), and this in turn slightly higher than SVR ($R^2: 0.70\pm 0.13$), these differences being statistically significant. Despite the complex wetting process with contamination deposits in

silicone insulators, the 4IL-CNN model is valid for predicting leakage current in both ceramic insulators with or without silicone coatings and silicone insulators, and is also easily adaptable to other substations.

Resum

Els aïlladors elèctrics d'alta tensió tenen un paper fonamental a les xarxes aèries de transport i distribució d'energia elèctrica. En cas d'una fallada de funcionament poden incidir de manera important en la continuïtat del subministrament elèctric, donant lloc a importants impactes socioeconòmics. Les descàrregues disruptives per deposició de contaminació a la superfície dels aïlladors són una de les amenaces a la fiabilitat de la xarxa elèctrica, constituint un repte per a projectistes i enginyers de manteniment de la xarxa elèctrica. En l'actualitat, no hi ha mètodes realment eficaços per a la monitorització contínua dels nivells de contaminació a la superfície dels aïlladors durant l'operació normal, per tant, es recorre al manteniment periòdic dels mateixos per garantir la continuïtat del subministrament elèctric. El desenvolupament d'una eina que permetés aquest monitoratge en temps real proporcionaria informació molt valuosa per al manteniment preventiu dels aïlladors elèctrics d'alta tensió i/o el seguiment de l'estat superficial.

La segona aproximació se centra en la predicció a curt termini del corrent de fugides, permetent detectar comportaments anòmals en comparar-la amb el corrent de fuites real. El model desenvolupat en aquesta tesi podria utilitzar-se per crear un sistema on-line de preavís, que permeti anticipar les conseqüències negatives de la climatologia i/o dipòsits de contaminació a curt i mitjà termini quan l'efecte de l'envelliment és irrellevant, i constitueix potencialment una eina de gran utilitat per dissenyar un pla estratègic de manteniment preventiu dels aïlladors elèctrics d'alta tensió i minimitzar les descàrregues disruptives que provoquin errors inesperats de la xarxa elèctrica, augmentant així la fiabilitat i resiliència de la xarxa elèctrica.

Per això, partint de registres simultanis del corrent de fugida en 7 aïlladors i les variables ambientals de llarga durada, monitoritzades durant 30 mesos, s'ha analitzat la relació subjacent entre el corrent de fugida crua o en brut (la mesura) i les variables ambientals, utilitzant

la correlació de Spearman. Mitjançant l'anàlisi de correlació parcial, s'ha determinat que la relació entre el corrent de fugida crua i la temperatura, la direcció i la velocitat del vent es deu principalment a la seva influència sobre la humitat relativa. Així mateix, s'ha determinat la relació causa-efecte d'aquestes variables ambientals amb el corrent de fugida mitjançant l'anàlisi de causalitat condicional de Granger. Amb el model de vectors autoregressius, s'ha establert el nombre òptim de mostres anteriors de les variables ambientals per predir el corrent de fugida. A continuació, s'ha cancel·lat la influència de la humitat relativa al corrent de fugida mitjançant un filtratge adaptatiu i s'ha dissenyat un filtre específic basat en nivells de llindar adaptatius, calculat per mètodes estadístics per eliminar els pics anòmals de corrent dispersos com els de alta densitat (en el temps), trobant així, en filtrar els pics anòmals, el corrent de fugida degut a la pol·lució dipositada a l'aïllador (PLC). El mètode proposat redueix considerablement la correlació entre el corrent de fugida i la humitat relativa (0.826 ± 0.051 davant 0.019 ± 0.014). El senyal resultant va presentar una correlació molt feble amb altres variables ambientals (< 0.03), la qual cosa confirma que les relacions entre el corrent de fugida i la temperatura, la direcció i la velocitat del vent s'atribueixen principalment a la seva influència en la humitat relativa. La PLC presenta una suau fluctuació quasi-anual en el temps de magnitud similar a les obtingudes a les proves de laboratori. Aquesta tècnica podria utilitzar-se per monitoritzar en temps real la PLC als aïlladors elèctrics i així millorar la continuïtat del subministrament elèctric i reduir els costos de manteniment.

Així mateix, el corrent de fugida és un reflex integral de la climatologia i estat superficial de l'aïllador i és una mesura objectiva de tot el procés complet del desenvolupament de la descàrrega disruptiva per contaminació. Per tant, el monitoratge del corrent de fugida és la mesura més eficaç per mantenir-se a la zona de seguretat i prevenir les descàrregues disruptives per contaminació. A la literatura s'han proposat diferents tècniques de regressió per predir el corrent de fugida a partir de les variables ambientals: regressió multivariable lineal (MVR), xarxes neuronals i/o màquines de suports

vectorials. Tot i això, a causa de la complexitat de la interacció dinàmica entre les variables ambientals i el corrent de fuga, s'han obtingut resultats acceptables en registres de curta durada amb poca capacitat de generalització. Per tant, en aquesta tesi s'han desenvolupat models robusts i suficientment precisos de predicció del corrent de fugida en base a les variables ambientals en registres de llarga durada. El model ha de ser capaç de predir el corrent de fugida en temps real durant l'operació normal dels aïlladors elèctrics i a més s'ha d'adaptar fàcilment a altres subestacions, constituint una eina enginyeria que permet proporcionar informació valuosa per anticipar les conseqüències negatives de la climatologia i/ o la contaminació. Tot això amb l'objectiu de minimitzar les descàrregues disruptives i els talls imprevistos de subministrament elèctric, augmentant així la fiabilitat i la resiliència de la xarxa elèctrica.

Per això, s'han desenvolupat i comparat 5 models de regressió per predir el corrent de fugida a partir de les mostres actuals o les darreres 21 mostres de variables ambientals: MVR, suport vectorial per a regressió (SVR), 2SL-CNN (xarxes neuronals convolucionals (CNN) basades en 2 capes convolucionals estàndards), 2IL-CNN (CNN basat en 2 capes convolucionals amb arquitectura inception) i 4IL-CNN (CNN basat en 4 capes convolucionals amb arquitectura inception). Els models basats amb les darreres 21 mostres van presentar significativament millors rendiments que els basats en mostres actuals, suggerint que la climatologia passada aporta informació valuosa per pronosticar el corrent de fugida. Així mateix, s'ha contrastat la no-linealitat de la interacció entre les variables ambientals i el corrent de fugida, ja que la tècnica MVR va obtenir un rendiment significativament inferior que els altres models no-lineals. Els resultats experimentals suggereixen que la complexa interacció dinàmica no-lineal entre les variables ambientals i el corrent de fugida es pot capturar mitjançant l'aprenentatge en cascada de l'arquitectura inception que permet extreure simultàniament la informació local i regional (en diferents instants de temps) cada cop més extensa. Tant el model 2IL-CNN ($R^2: 0.89 \pm 0.06$) com el 4IL-CNN ($R^2: 0.94 \pm 0.03$) van obtenir rendiments substancialment superiors al model 2SL-CNN ($R^2:$

0.73±0.11), i aquest lleugerament superior que SVR (R^2 : 0.70±0.13), sent aquestes diferències estadísticament significatives. Tot i el complex procés d'humit amb dipòsits de contaminació als aïlladors de silicona, el model 4IL-CNN és vàlid per predir el corrent de fugida tant en aïlladors ceràmics amb o sense recobriments de silicona com aïlladors de silicona, ia més fàcilment adaptable a altres subestacions.

Agradecimientos

Agradezco a mis directores, la paciencia demostrada para poder terminar esta Tesis.

Agradezco la energía que me han dado mis hijos para poder acabar con esta Tesis.

Del mismo modo, agradezco a mi esposa, las veces que me ha invitado a dejar la Tesis, sabiendo que con lo cabezota que soy, lo único que hacía es trabajar más.

También quiero agradecer a mi mentor, el señor Cavallé, quien me inspiró el cariño por la Ingeniería Eléctrica.

Siguiendo en la línea del agradecimiento, no me puedo olvidar de mis compañeros César y Saturnino, con los que tanto he discutido.

Finalmente, agradezco al resto de las personas que me han acompañado durante este tiempo y que sin ellos esta Tesis no existiría.

Índice

CAPÍTULO I: INTRODUCCIÓN.....	5
1. Impacto socio-económico de la red eléctrica	3
2. Red eléctrica	10
3. Aisladores eléctricos.....	13
3.1. Impacto de los aisladores eléctricos de alta tensión.....	13
3.2. Descarga disruptiva en los aisladores eléctricos de alta tensión	17
3.3. Monitorización del nivel de depósitos de contaminación	21
3.4. Corriente de fuga como medio de diagnóstico	27
3.5. Predicción de la corriente de fuga.....	38
CAPÍTULO II: JUSTIFICACIÓN Y OBJETIVOS.....	43
CAPÍTULO III: MATERIALES Y MÉTODOS.....	49
4. Configuración de los ensayos	51
5. Análisis de datos	54
5.1. Descripción estadística de los datos	54
5.2. Relación entre las variables ambientales y la corriente de fuga.....	54
5.3. Estimación de la corriente de fuga asociada a los depósitos de contaminación en aisladores de alta tensión.....	60
5.4. Desarrollo de modelos de predicción de la corriente de fuga en aisladores de alta tensión en base a las variables ambientales.....	64

CAPÍTULO IV: RESULTADOS	95
6. Resultados	97
6.1 Descripción estadística de los datos	97
6.2 Relación entre la corriente de fuga y las variables ambientales	102
6.3 Estimación de la PLC en aisladores de alta tensión	106
6.4 Predicción de la corriente de fuga en base a los variables ambientales	118
CAPÍTULO V: DISCUSIÓN.....	161
7. Discusión	163
7.1. Relación entre la corriente de fuga y las variables ambientales	163
7.2. Estimación de la PLC mediante filtro adaptativo	168
7.3. Predicción de la corriente de fuga a partir de variables ambientales	170
7.4. Limitaciones del estudio y líneas futuras	177
CAPÍTULO VI: CONCLUSIONES	181
PUBLICACIONES	189
BIBLIOGRAFÍA.....	197

*El universo no conspira contra ti, pero
tampoco se desvía para alinear tu camino.*

Tim Ferriss

**CAPÍTULO I:
INTRODUCCIÓN**

1. Impacto socio-económico de la red eléctrica

En la sociedad actual la energía eléctrica ha invadido todas las esferas de la actividad humana: la industria, el transporte, la comunicación, el sector servicios, residencial, etc. Esto radica en que la electricidad una forma de energía muy versátil, controlable y la que permite una distribución más simple y eficiente. En el punto de uso, tiene un rendimiento elevado, comparado con otras fuentes de energía y no contamina. La Figura 1 muestra el uso energético por sectores de España y Europa en 2019. La industria es uno de los grandes consumidores de la energía, representando alrededor del 54% de la energía total mundial [1] y un 25.6% en Europa. En la referencia de International Energy Outlook 2016 (IEO2016), se proyecta el consumo de energía del sector industrial mundial aumentará en un promedio de 1.2%/año, de 222 billones de unidades térmicas británicas (Btu) en 2012 a 309 billones de Btu en 2040. El sector industrial puede clasificarse en tres tipos distintos de industria: fabricación intensiva en energía, manufactura no intensiva en energía y no manufactura. La energía se utiliza en el sector industrial para una amplia gama de fines, como proceso, ensamblaje, producción de vapor, calor y refrigeración e iluminación y climatización para edificios. Además de la electricidad en la industria, se utilizan otras de fuentes de energía como gas natural, derivados del petróleo, carbón y térmica renovable. En la Figura 2 se muestra el uso de energía por tipo de fuentes del sector industrial de EEUU desde 1950 a 2020. Se puede apreciar que la energía eléctrica representa aproximadamente un 15% del total energía consumida en industria, además con una tendencia creciente.

Asimismo, todas las instalaciones modernas de comunicación se basan en el uso de la electricidad, por ejemplo, teléfono, radio, televisión, internet o sistemas de Internet of Things entre otros. La electricidad también juega un papel importante en el sector del transporte, desde el transporte ferroviario para interconectar las grandes áreas urbanas, tranvía y metro en las ciudades al incremento de los vehículos eléctricos. Asimismo, la energía eléctrica es fundamental para los sectores servicios y residencial, desde la

iluminación, la climatización de los edificios, electrodomésticos, etc [2].

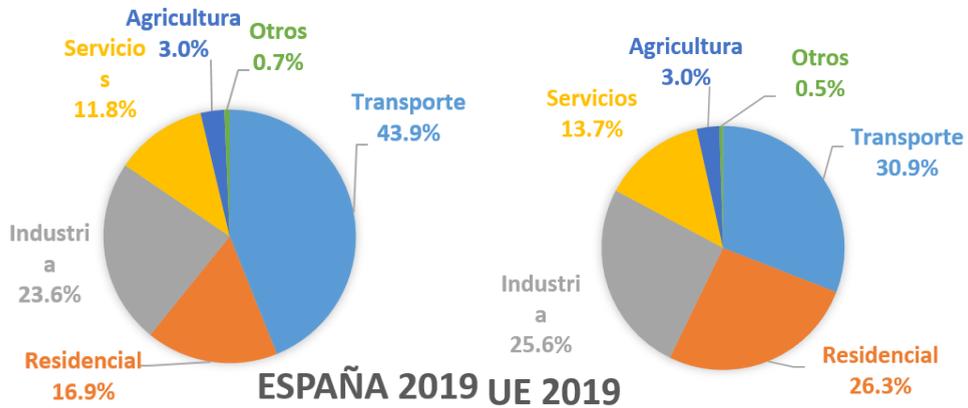


Figura 1. Uso de energía por sectores en España y Europeo (elaborado a partir de [2]).

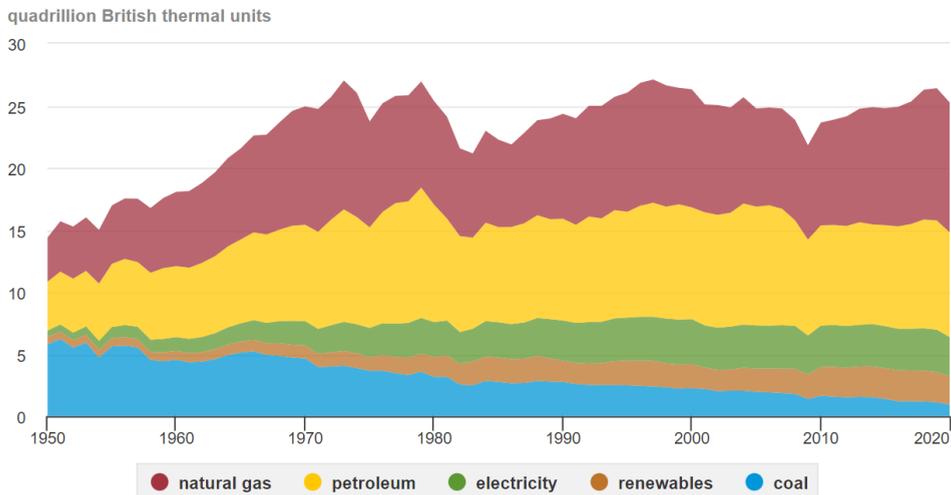


Figura 2. Sector energético en la industria de EEUU desde 1950-2020 [3].

La energía eléctrica es fundamental para el funcionamiento ‘normal’ de nuestra sociedad, y puede considerarse como un indicador del crecimiento económico tanto en los países desarrollados como en los países en desarrollo. Esto es debido a que conforme aumentan los ingresos medios, se tiende a utilizar energías de mayor calidad, más

productivas, más limpias y más flexibles, especialmente la electricidad.

Por consiguiente, el sistema eléctrico constituye un pilar estratégico para la economía y el desarrollo de los países [4]. De hecho, la seguridad del suministro se considera un importante objetivo de la política energética en muchos países del mundo. Junto con la eficiencia y sostenibilidad, la Unión Europea incluye la seguridad de suministro de energía como uno de los tres pilares de la política de energía [5,6]. La seguridad del suministro eléctrico hace referencia a corto plazo a la capacidad de generación para llegar a una carga real y soportar las perturbaciones inesperadas como cortocircuitos eléctricos y otro tipo de faltas. A medio plazo, la seguridad del suministro eléctrico se refiere a una óptima gestión de recursos para suministrar electricidad de manera eficiente con las capacidades de generación ya existentes. A largo plazo, la seguridad del suministro eléctrico tiene como objeto cumplir demanda con la capacidad disponible, instalada y/o esperada.

Existen distintas causas que amenazan la seguridad del suministro eléctrico, las cuales se pueden agrupar en tres categorías: peligros naturales, peligros técnicos y riesgos sociales. Anualmente, se cifran en miles de millones las pérdidas por fallos de suministro eléctrico por la sobrecarga del sistema frente a las olas de calor o frío extremo [7,8], y/o daños irreversibles sobre las infraestructuras eléctricas por la climatología. También se pueden producir cortes de suministro por fallos técnicos relacionados con la falta de un mantenimiento apropiado de la red eléctrica de transporte. Es pertinente en este aspecto recordar la famosa frase de Thomas Reid, filósofo escocés del siglo XVIII, que escribió *“una cadena es tan fuerte como lo sea el más débil de los eslabones que la componen”*. Los riesgos sociales hacen referencia al cambio de las conductas de consumo eléctrico que podrían ocasionar sobrecargas en el sistema, provocando así interrupciones de suministro. A este respecto determinadas políticas, como la de favorecer patrones de recarga concretos para vehículos eléctricos, pueden servir para cubrir el gran desajuste histórico entre las horas punta y las horas valle [9,10]. Hay que tener en cuenta que

la introducción, cada vez mayor, de generación renovable no gestionable, conlleva la necesidad de cambiar patrones de consumo, favoreciendo que este se desplace a los momentos en que se genera la energía, incluso contando con sistemas de almacenamiento.

Los distintos países implementan estrategias para poder solventar posibles fallos en el sistema eléctrico. En general se consideran cinco apartados para hacer frente a los citados riesgos: prevención, preparación, intervención, reacondicionamiento y reconstrucción [11]. Aun así, se han experimentado en los últimos años interrupciones de suministro que han afectado a un gran número de usuarios, algunos ejemplos son California en 2000 y 2001, Noruega en 2002, Francia y Alemania en 2003, Sudáfrica en 2008 y 2009, o Japón en 2011 [5].

Las consecuencias del corte de suministro eléctrico son particularmente importantes para la mayoría de las sociedades, muy dependientes de la disponibilidad de electricidad, y pueden generar elevados mayores costes económicos y sociales. Aunque es muy difícil de obtener una estimación precisa del impacto socio-económico de un corte de suministro, porque depende en gran medida el método de estimación. No obstante, se pueden agrupar las consecuencias del mismo en tres grandes categorías [5]:

- Impacto económico directo. Incluye la pérdida de productividad, pérdidas de ventas, coste de reiniciar el proceso, daños en equipamientos, deterioro de las materias primas.
- Impacto económico indirecto. Engloba tanto el coste de los ingresos que se posponen, aumentando el tiempo de retorno de inversión, como el coste financiero de la pérdida de participación en el mercado.
- Impacto social. Comprende desde incomodidades debido a la parada de electrodomésticos, iluminación, climatización y servicios TIC en el trabajo o en casa, a la pérdida de tiempo libre, o el riesgo para la seguridad y la salud, siendo en éstos últimos muy difícil el valorar cuál es su coste económico equivalente.

Además, no todas las interrupciones de suministro tienen las mismas consecuencias. Los impactos sociales e económicos indirectos son mayores cuando se tratan de cortes de suministro inesperados [5]. Asimismo, los de duración prolongada tienen principalmente impactos económicos directos. Linares y Rey utilizaron el método de función de producción que consiste en determinar el ratio entre una medida económica (por ejemplo, producto interior bruto o valor agregado bruto agregado) y una medida del consumo de electricidad (por ejemplo, kWh) para estimar los costes de los cortes de suministro por sector- Con ello se pretendía determinar el valor de una unidad de electricidad, también conocido como valor de pérdida carga (VoLL) [12]. Se observaron grandes diferencias entre sectores (ver Figura 3). Destacar que servicios y residencial son los sectores con el VoLL más alto por el corte de suministro, representando estos el segundo y tercer gran consumidor de electricidad en España, y generando alrededor de un tercio del valor de cada uno. En cambio, el VoLL era mucho más bajo para los otros sectores. Por ejemplo, en el sector del metal, uno de los más importantes consumidores de electricidad (11% del consumo total), su VoLL era incluso ocho veces inferior.

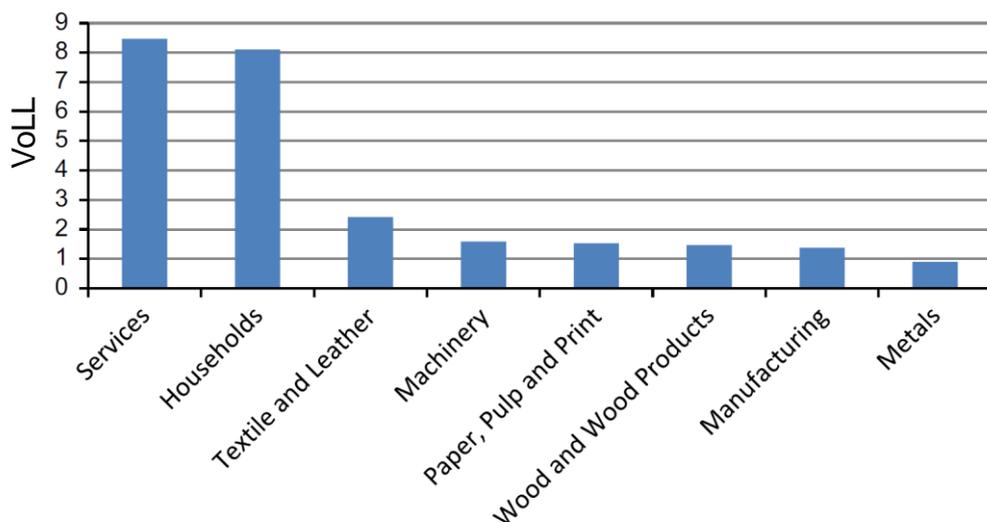


Figura 3. VoLL en sectores donde la electricidad es esencial [5].

Hay que tener en cuenta también que el valor de la carga perdida cambia a lo largo del día, es decir, tanto la actividad económica como el consumo de electricidad presentan fluctuaciones a lo largo del día. Consecuentemente el impacto del corte de suministro eléctrico también varía dependiendo de la hora del día (Figura 4). Se puede apreciar que tanto los sectores servicios como residencial son muy dependientes por hora, alcanzando en horas punta valores que duplican a los de las horas valle. En cambio la actividad en el sector industrial presenta mucho menos fluctuación a lo largo del día, por tanto el coste del corte de suministro eléctrico permanece relativamente constante todo el día [5].

Ante el aumento de la demanda de la energía eléctrica, y que al mismo tiempo una parte significativa de los métodos vigentes de producción de energía no son sostenibles, ni por razones medioambientales ni de recursos, las compañías eléctricas se enfrentan actualmente a los mayores desafíos de la historia. Entre ellos, la generación de energía limpia y sostenible, tanto de forma centralizada como distribuida. La integración de las nuevas tecnologías de la información, que permita una gestión óptima de los recursos. Y en este contexto, la garantía de la calidad de la energía con la máxima resiliencia y fiabilidad de la red eléctrica, previniendo así los posibles cortes de suministro eléctrico y al mismo tiempo debiendo mantener el coste de producción, transporte y distribución de la energía eléctrica suficientemente reducido.

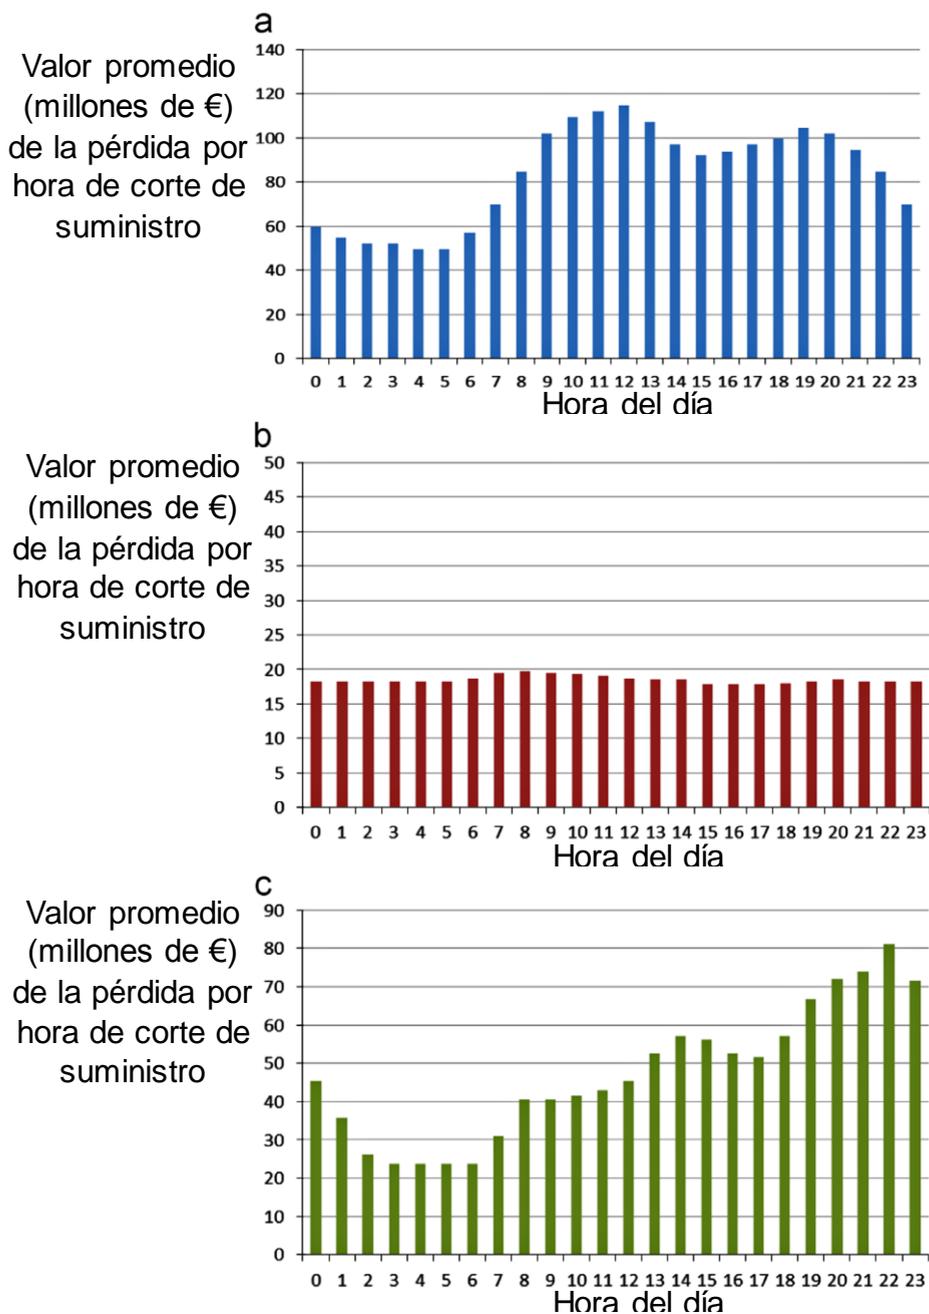


Figura 4. Valor promedio (millones de euros) de la pérdida por hora de corte de suministro por sectores. (a) Servicio. (b) Industria. (c) Hogar [5].

2. Red eléctrica

La red eléctrica es una de las redes más complejas jamás diseñada por la humanidad, fruto de las aportaciones científicas y tecnológicas que se han ido acumulando a lo largo de los años, y con una presencia muy importante en grandes áreas del planeta. La red eléctrica en el hemisferio norte del planeta es masiva en escala y alcance, estando constituida por decenas de miles de grandes centrales eléctricas y millones de kilómetros de conductores.

Hay tres partes principales de la cadena de suministro de electricidad: generación, transporte (líneas eléctricas de mayor tensión y longitud), distribución (líneas eléctricas de media y baja tensión para el suministro local de electricidad).

Desde los inicios de la distribución de energía eléctrica quedó clara la ventaja que suponía el empleo de tensiones elevadas, y ello ha configurado el sistema de “generación – transporte – distribución – utilización” que sigue empleado en la actualidad. Por un lado, al elevar la tensión en las líneas se consigue disminuir la caída de tensión relativa, lo que permite transportar la energía eléctrica a mayores distancias. Por otro lado, para una misma sección de conductor se incrementa la potencia que circula, lo que redundará en una reducción sustancial de la cantidad de material conductor utilizado.

Para pasar de las tensiones empleadas para transmitir la energía eléctrica, a las tensiones más reducidas utilizadas en los dispositivos eléctricos finales, es necesario disponer de subestaciones y centros de transformación. Con ello se configura una red con diversos escalones de tensión.

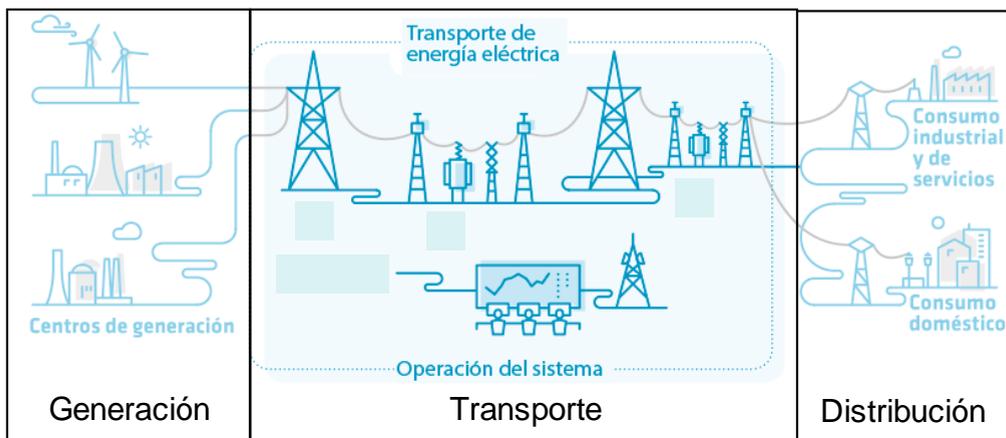


Figura 5: Sistema eléctrico Español [13].

En el mayor nivel de tensión se sitúa el transporte de energía, que representa los componentes de la red mallada de transmisión de larga distancia. Esto incluye componentes como grandes nodos de interconexión, subestaciones y, por supuesto, el conjunto de líneas eléctricas, que son aéreas en su mayor parte, con algunos tramos subterráneos. En España, los valores típicos de tensión para este tipo de redes son 220 kV y 400 kV, aunque puede incluir algunas líneas de tensiones inferiores. Tradicionalmente, esta parte del sistema está bajo el control del operador del sistema de transmisión. En algunos países, un organismo nacional o un “supercuerpo” de empresas de servicios públicos opera ese dominio, como es el caso de España, donde Red Eléctrica Española (REE) se encarga del transporte de la energía y de la operación del sistema.

En cambio, la distribución proporciona toda la infraestructura para llevar energía al usuario final (consumidor). Esta parte del sistema también incluye equipos transformadores que son necesarios para reducir el voltaje a medida que la energía se transporta al consumidor. Los consumidores no domésticos generalmente obtienen su energía a voltajes más altos, por ejemplo, 20 kV. El consumidor doméstico y pequeño terciario generalmente se alimenta en baja tensión.

Actualmente, la red de transporte en España está compuesta por más de 43.600 km de líneas, más de 5.400 posiciones de subestaciones y

más de 85.000 MVA de capacidad de transformación [13]. Estos activos configuran en la actualidad una red mallada, fiable y segura, que ofrece unos altos índices de calidad de servicio y que cumple una serie de funciones críticas [14].

- Garantizar el equilibrio y la seguridad del sistema eléctrico nacional.
- Transferencia neta de energía entre distintas subestaciones de la red, pudiendo invertirse el sentido del flujo de energía en función de las circunstancias.
- Minimización de pérdidas.
- Mantenimiento en todos los puntos de la red de los parámetros básicos (frecuencia, tensión) dentro de los límites aceptables.
- Utilización de los medios de producción óptimos en función de la topología de la demanda en cada momento.

Una red funcional y confiable es esencial para el desarrollo económico estable de un país. Por lo tanto, los gobiernos brindan orientación en forma de programas de protección de infraestructura crítica (CIP) [11] y en forma de recomendaciones escritas SIGP ENISA [15,16] sobre cómo operar de forma segura las nuevas generaciones de redes llenas de tecnologías de la información.

Una parte importante de esa red es aérea, formada por líneas aéreas y subestaciones de intemperie. El aislamiento se consigue mediante el empleo de aisladores eléctricos de diversos tipos, teniendo el estado de los mismos una influencia muy importante en la fiabilidad del sistema.

3. Aisladores eléctricos

3.1. Impacto de los aisladores eléctricos de alta tensión

Tal como se ha indicado en el apartado anterior, el transporte de energía desde las centrales generadoras hasta las subestaciones de distribución se realiza en alta tensión. Por tanto, es necesario un sistema de aislamiento de alta tensión eficiente y coordinado para poder transmitir de forma segura y confiable la energía eléctrica.

El principal dieléctrico utilizado en las redes de alta tensión es el aire a presión atmosférica. El aire es un buen material aislante, siempre que la tensión eléctrica se mantenga por debajo de la tensión umbral de ionización o tensión disruptiva del aire. Sin embargo, el aire no tiene propiedades mecánicas para soportar los elevados esfuerzos a los que están sometidos los conductores (peso propio, tensiones longitudinales, esfuerzos transversales entre otros). Los aisladores eléctricos se utilizan para realizar la doble función de soportar mecánicamente y aislar eléctricamente las líneas, así como toda la aparamenta eléctrica presente en las subestaciones o en las propias líneas.

Los primeros aisladores utilizados fueron de vidrio y porcelana (materiales cerámicos). Estos materiales dominaron el mercado de los aisladores durante muchos años, desde el principio de las redes eléctricas. Por tanto, se han realizado muchas investigaciones sobre el desempeño de los materiales aislantes cerámicos y en la actualidad los principios de aplicación están bien establecidos [17].

Desde los años 60 del siglo XX, con el objetivo de mejorar el rendimiento de los aisladores en entornos contaminados, reducir los costes de fabricación y operativos, y reducir la susceptibilidad al vandalismo, se han desarrollado nuevos aisladores de materiales no cerámicos. Estos incluyen aislantes cicloalifáticos de resina epoxi y aislantes poliméricos compuestos (como goma de silicona, goma de etileno – propileno, etc. [17]). Estos aisladores compuestos

generalmente constan de un núcleo de fibra de vidrio con un recubrimiento polimérico, que presentan propiedades hidrofóbicas (repelente de agua). Los aisladores de goma de silicona (Silicone Rubber, SiR) y elastoméricos termoplásticos (TPE) son dos materiales de tercera generación entre los polímeros ampliamente utilizados para fabricar aisladores para exteriores [18]. Gracias a su baja humectabilidad, algunos aisladores poliméricos funcionan muy bien en entornos extremadamente contaminados [19]. Por estas propiedades, los aisladores poliméricos se han utilizado con éxito en multitud de países, y se están volviendo cada vez más populares. Sin embargo, períodos prolongados de exposición a la contaminación, puede ocasionar la degradación del material que conlleva a la pérdida de hidrofobicidad, dando lugar a una mayor corriente fuga [20].

En aplicaciones de aparamenta en intemperie, se siguen utilizando los aisladores cerámicos debido a sus propiedades mecánicas [21]. En ocasiones se emplean estos aisladores con recubrimiento de silicona vulcanizada a temperatura ambiente (RTV) para mejorar sus propiedades hidrófobas, y consecuentemente el rendimiento del aislador [22]. El uso de aislantes de porcelana vidriada resistivos / semiconductores, que inhiben la formación de una capa húmeda, disminuyendo así la actividad de las descargas parciales, corona y de banda seca, también está aumentando su uso en áreas muy contaminadas [23].

El SiR vulcanizado a alta temperatura (High-temperature vulcanised - HTV) es el principal tipo de material no cerámico aislante utilizado en líneas de transporte de energía eléctrica en España. En otros países, algunas compañías eléctricas utilizan otros materiales poliméricos, por ejemplo, en la red de transporte de tensión de 66 kV - 132 kV, se pueden encontrar aisladores no cerámicos de HTV monómero de etileno propileno dieno (EPDM) y caucho *alloy*. En las redes de distribución de 11 y 22 kV se pueden encontrar también aisladores no cerámicos de resina epoxi cicloalifática y de caucho *alloy* [24].



Figura 6. Aisladores de porcelana, vidrio y SIR, y Pórticos subestación transformadora 132/20 kV.

Las últimas investigaciones se centran en el desarrollo de nanocompuestos que están hechos de una matriz anfitriona a base de polímero y partículas de tamaño nanométrico [25]. En comparación con los compuestos convencionales, los nanocompuestos tienen mejores propiedades mecánicas y eléctricas que incluyen una mayor resistencia a la ruptura, una mayor permitividad (depende del tipo de nanocargas) y una mejor resistencia a la descarga superficial [25]. No obstante, hay una falta generalizada de caracterización de estos nuevos materiales a largo plazo en instalaciones reales [25].

El coste del aislador puede ser tan bajo como el 5% del coste total de la transmisión [26] pero su desempeño es crítico. El fallo de un solo aislador de alta tensión puede causar una interrupción de suministro, con efecto en gran cantidad de usuarios [27]. Los fallos mecánicos de los aisladores pueden provocar la caída del conductor, que es un riesgo importante para la seguridad. La descarga disruptiva de los

aisladores es una de las principales razones que ponen en peligro el funcionamiento seguro de la red eléctrica. En 2010, la red eléctrica Egipcia sufrió varias interrupciones debido a los depósitos de contaminación [28]. El daño causado por la niebla salina a las líneas de transmisión y distribución de Tailandesa tiene una larga historia [28]. En Taiwán se produjo una descarga disruptiva a fines de 1992 hasta el comienzo de 1993 debido a lluvias prolongadas y el sistema de transmisión por encima de 69 kV resultó en un total de 63 accidentes de línea [28]. En 1990, debido a la continua niebla, lluvia y nieve, cinco subestaciones de 220 kV y 7 subestaciones de 110 kV en la red eléctrica de Henan fallaron parcial y totalmente, lo que provocó un corte de energía en un área extensa. En 2001, se produjeron lluvias intensas y nevadas con una densa niebla en la mayor parte del norte de China que provocó un corte suministro a gran escala. En este accidente de descarga disruptiva, 238 líneas de transmisión que van desde 66 kV a 500 kV y 34 subestaciones se dispararon 972 veces [29].

Si bien es cierto que el fabricante suele proporcionar hojas características que indican el rendimiento según las pruebas estándares internacionales, estas son difíciles de trasladar a las condiciones locales de cada instalación. Las compañías eléctricas llevan años realizando programas de investigación para estudiar el rendimiento de los aisladores eléctricos en las condiciones locales, que engloba tanto los ensayos de laboratorio para la caracterización del proceso de envejecimiento, la tensión crítica disruptiva en función de los depósitos de contaminación, como la evaluación y supervisión del rendimiento de los aisladores en los bancos de ensayo de la propia instalación y/o durante la operación normal. La presente tesis está desarrollada dentro del marco de uno de estos programas de investigación.

3.2. Descarga disruptiva en los aisladores eléctricos de alta tensión

Durante la vida útil del aislador, se somete a numerosos estreses, tanto eléctricos, como mecánicos y ambientales, siendo el estrés ambiental (contaminación) el que tiene un alto impacto en la confiabilidad del aislador [27]. En general, se puede categorizar en dos tipos de contaminación: la contaminación sólida no soluble (NSDD) que se humedece rápidamente con la humedad y niebla; y la deposición electrolítica soluble (SDD). Ambos tipos de depósitos de contaminación aumentan la conductividad superficial del aislador.

Los aisladores eléctricos de alta tensión en subestaciones exteriores se exponen rutinariamente a sustancias contaminantes como el polvo, los productos químicos, la contaminación del tráfico y las sales minerales, que se acumulan en las superficies expuestas formando depósitos de contaminación [30,31]. En las instalaciones costeras, los aisladores eléctricos están especialmente afectados por contaminantes solubles y diferentes sales, principalmente cloruro de sodio (NaCl). La niebla salina del mar o el material sólido cargado de sal impulsado por el viento, como la arena, se acumula en la superficie del aislador. En climas desérticos, están expuestos a fuertes vientos y tormentas de arena, con partículas de arena que se mueven rápidamente y que erosionan y agrietan los aisladores eléctricos [27]. La deposición contaminante es normalmente de mayor tamaño de grano y mayor contenido de sal. Además de NaCl, otras sales y sulfatos como CaSO_4 , KNO_3 , Na_2SO_4 suelen estar presentes [27]. En otras ocasiones, el hielo se deposita en la superficie del aislador y se derrite formando película de agua mezclada con contaminación [27]. La contaminación está fuertemente correlacionada con las condiciones locales del área, el mecanismo de transferencia incluye el clima (viento, lluvia, humedad), la ubicación del sitio, instalaciones vecinas (plantas químicas), entre otras [27]. En otras palabras, las condiciones meteorológicas juegan un papel importante en la tasa de depósitos de contaminación y comportamiento eléctrico de los aisladores. De hecho se ha determinado la existencia de una relación

considerable entre la ESDD y la descarga disruptiva (que se definirá más adelante) con las variables ambientales [32–34].

Cuando la superficie contaminada del aislador está seca, la corriente de fuga debida a la conducción óhmica es muy reducida. Sin embargo, cuando se combina con la humedad causada por una ligera lluvia, la niebla, o el rocío, puede formar una capa conductora en la superficie y desencadenar un arco eléctrico a través del conocido proceso de descarga disruptiva (flashover) por contaminación [26,35] en el que la corriente de fuga comienza a fluir a través de esta capa conductora húmeda y calienta la superficie por efecto Joule. Si el proceso se prolonga en el tiempo, puede hacer que el campo eléctrico aumente localmente debido a la aparición de áreas secas (dry bands [36]) lo que puede iniciar descargas parciales que finalmente desencadenen la descarga disruptiva [36], esto podría dañar irreversiblemente el recubrimiento del aislante y causar fallos en la línea eléctrica (ver Figura 7). La banda seca es uno de los requisitos previos para que ocurra la descarga disruptiva [37]. En la Figura 8 se muestra la descarga parcial en banda seca y la descarga disruptiva en los aisladores cerámicos.



Figura 7. Daños producidos en la superficie de un aislador polimérico por el efecto de Dry bands [38].



Figura 8. Proceso de descarga disruptiva en aislador cerámico. Izquierda: Descargas parciales [39]. Derecha: Descarga disruptiva del aislador cuando la corriente de fuga incrementa por encima de su límite debido a los depósitos de contaminación (extraído de [27]).

El proceso de descarga disruptiva por contaminación puede reducirse sustancialmente mediante el uso de materiales poliméricos y/o diferentes tratamientos superficiales con recubrimiento de los mismos. En los aisladores de silicona o recubrimiento de silicona que tienen un alto grado de hidrofobicidad, el mecanismo de humedecido debido a la lluvia o niebla sufre cierta variación. Gracias a la hidrofobicidad de los materiales poliméricos, se forman gotas de agua en la superficie del aislador y no formando película de agua como es el caso de aislador cerámico. La existencia de gotas de agua no necesariamente genera corriente de fuga, debido al aislamiento eléctrico en los espacios de aire entre gotas. Con el aumento de la conductividad de las gotas como resultado de los depósitos de contaminación, los campos eléctricos en las uniones triples entre la gota, el aire y la superficie del aislador superan un punto crítico que provoca la aparición de la descarga corona entre gotas [40] (ver Figura 9B). La descarga corona puede causar la degradación de la superficie del aislador disminuyendo su hidrofobicidad por la oxidación inducida debido al bombardeo de electrones [41]. La reducción hidrófoba deforma las gotas en forma semiovaladas. Por tanto, el campo eléctrico en la unión triple aumenta, presentando irregularidades y la reducción de la hidrofobicidad se acentúa. A través de una serie de gotas deformadas, comienza a fluir la corriente de fuga, dando lugar a la aparición de la descarga en las bandas secas entre gotas [41] (ver Figura 9B), que puede desencadenar la descarga disruptiva (ver Figura 9C). El calor generado durante este proceso provoca la rotura de las uniones químicas en las superficies de los aisladores poliméricos, creando una superficie hidrófila más grande, dando lugar a una corriente de fuga elevada. La exposición sostenida a las descargas en las bandas secas pueden provocar degradaciones graves que reducen la vida útil y el rendimiento de los aisladores poliméricos [41]. Sin embargo, la hidrofobicidad de los aisladores poliméricos se recupera en condiciones secas incluso si están cubiertos de contaminación y sometidos a daños en la superficie [42–45]. El rendimiento de los aisladores poliméricos depende en gran medida de la estabilidad de la hidrofobicidad y la velocidad de recuperación, las cuales están relacionadas con el grado de daño [41].

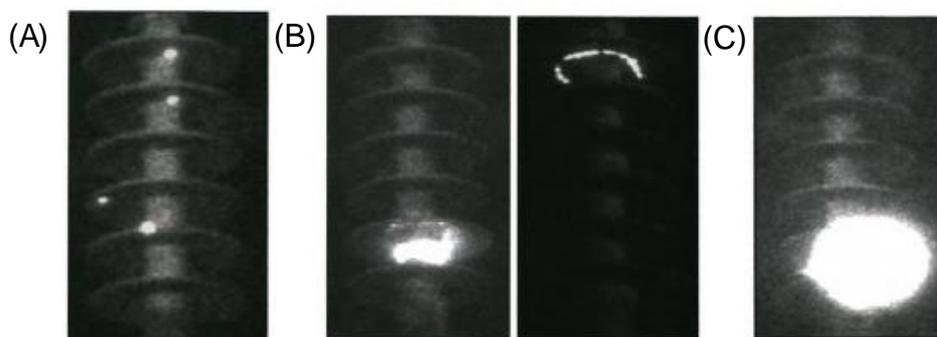


Figura 9. Proceso de descarga disruptiva en aisladores de silicón. (A) Descarga corona. (B) Descarga en banda seca. (C) Descarga disruptiva [38].

A medida que la capa protectora envejece, la hidrofobicidad se reduce y la banda seca aumenta, produciendo descargas parciales.

En consecuencia, la fiabilidad de la red eléctrica se ve continuamente afectada por los depósitos de contaminación de los aisladores [37]. Este tipo de problema es uno de los más comunes de la red eléctrica. Es necesario la monitorización del nivel de depósitos de contaminación en la superficie de los aisladores para la prevención de descargas disruptivas en cualquier condición climática, lo cual es de gran interés para el diseño de las líneas eléctricas de transmisión [46]. En general, la revisión y el mantenimiento regulares de los aisladores y el reemplazo de los aisladores defectuosos suelen ser medidas habituales en los programas de mantenimiento de la red eléctrica. En este contexto, la limpieza periódica de los aisladores podría reducir el impacto negativo de los depósitos de contaminación [47]. Sin embargo, si la limpieza y el mantenimiento del aislador no se establece en el tiempo de forma adecuada, el coste aumenta drásticamente. Por tanto, se requiere un sistema fiable con un coste sostenible (en el tiempo) para prevenir la descarga disruptiva y aumentar la fiabilidad y resiliencia de la red eléctrica.

3.3. Monitorización del nivel de depósitos de contaminación

Tal como se ha mencionado en el apartado anterior, es importante conocer el nivel de depósitos de contaminación para determinar el riesgo de aparición de la descarga disruptiva. Los métodos

comúnmente empleados para medir el nivel de contaminación son: ESDD/NSDD, corriente de fuga, gradiente de la tensión crítica de descarga disruptiva de contaminación. Si bien es cierto que las ESDD/NSDD constituyen una medida directa de la contaminación, la medida de las mismas requiere la interrupción del sistema de energía [28]. Por tanto, solo es factible realizar medidas discretas en instantes de tiempo programados y no se monitoriza de forma continua en tiempo real en los aisladores eléctricos de alta tensión de las líneas de transmisión. En cambio, éste constituye uno de los métodos comúnmente empleados en los ensayos de laboratorio [48].

La tensión crítica disruptiva es la tensión aplicada en bornes del aislador que permite ionizar el aire circundante ocasionando la descarga disruptiva. La tensión crítica disruptiva en condiciones de servicio depende de parámetros como la polaridad de la tensión [49], el tipo y tamaño de depósitos de contaminación [50,51], la regularidad del humedecido, la conductividad de la superficie, el viento, la longitud, el perfil y diámetro del aislador [50] y el espesor de la capa contaminante [52]. La Figura 10 muestra la tensión crítica disruptiva en función de ESDD en aisladores de silicona vulcanizado a alta temperatura. Se puede apreciar que la tensión crítica disminuye conforme va aumentando el nivel de ESDD y NSDD (depósitos de contaminación). Asimismo, se ha observado que tanto la humedad como la temperatura pueden variar sobre la tensión crítica de descarga disruptiva. Se ha determinado que un incremento en la salinidad de 20 a 80 g/l disminuye la tensión crítica disruptiva 0.73 - 1.1 kV/cm [53]. Bajo una salinidad de 80 g/l, un incremento de la humedad del 75% al 95% da lugar a una reducción de la tensión disruptiva entre 0.08 a 0.27 kV/cm [53]. Los experimentos relacionados con la tensión crítica disruptiva requieren mucho tiempo y presentan obstáculos adicionales, como el alto coste y la necesidad de equipos especiales [47], y no se puede aplicar en tiempo real durante la operación normal.

Estudios anteriores, han realizado pruebas de laboratorio para determinar la relación entre los niveles de depósito de sales solubles y no solubles [54,55] con las corrientes de fuga en condiciones de trabajo predefinidas [56,57] para obtener información valiosa sobre el

riesgo de inicio del arco eléctrico. Sin embargo, en aplicaciones reales se deposita en la superficie aislante una mezcla de sedimentos cuya composición varía con el tiempo, lo que dificulta la determinación de los depósitos de contaminación a partir de la corriente de fuga y sus posibles consecuencias negativas en el aislador. Actualmente no existe ningún método eficaz para medir directa o indirectamente los depósitos de contaminación en aplicaciones en tiempo real, lo que sería muy útil en la realización de mantenimiento [56] y/o el seguimiento del estado de los recubrimientos aislantes (por ejemplo, vulcanización a temperatura ambiente, RTV) y su vida útil para las compañías eléctricas.

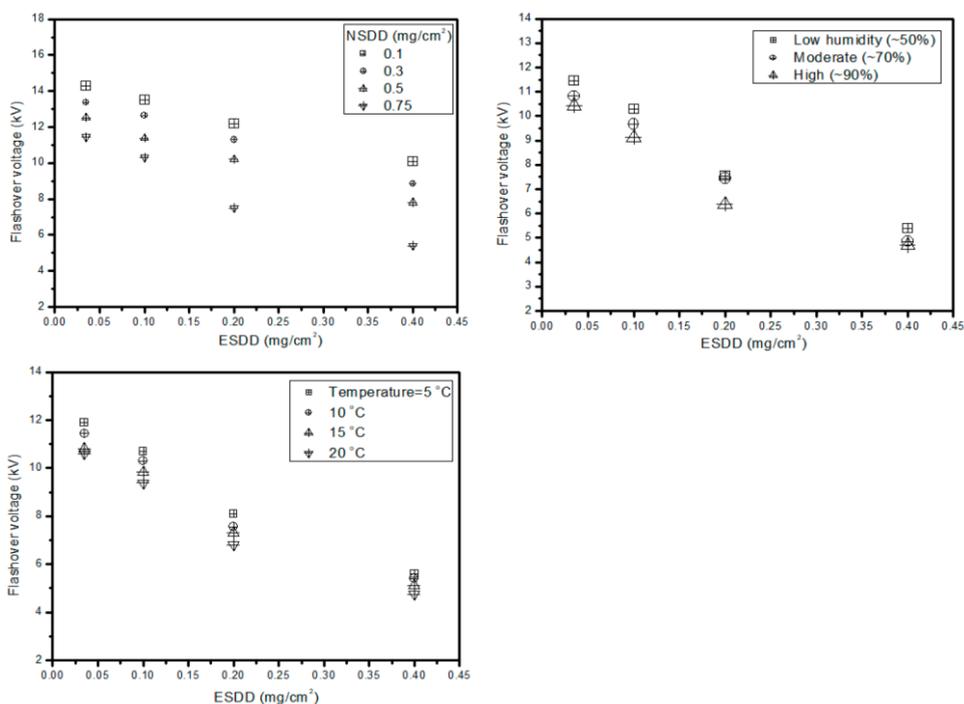


Figura 10. Tensión de descarga disruptiva en función de ESDD, NSDD, y su influencia en función de la temperatura y humedad en aisladores de silicona vulcanizado a alta temperatura (extraído de [58]).

A diferencia de los otros métodos que analizan la ESDD y NSDD, se puede monitorizar la corriente de fuga de forma continua sin manipular el aislador. La monitorización continua de la corriente de fuga podría

utilizarse para medir indirectamente el nivel de depósito de contaminación en los aisladores debido a la relación subyacente entre estos dos factores, siendo ésta la técnica más adecuada para dicho propósito. Abeysekara *et al.* analizaron la corriente de fuga en aisladores de vidrio para diferentes niveles de depósito salino y encontraron que el valor de curtosis de la corriente de fuga aumentó con la deposición salina ($k = 2.93$ para aisladores limpios frente a $k=12.33$ y 22.11 para depósitos salinos de 10 y 40 g/l, respectivamente) [56]. Se descubrió que la resistencia superficial del aislante era inversamente proporcional a la densidad equivalente del depósito de sal [59], mientras que Fierro-Chávez sugirió que la ESDD era proporcional a la corriente de fuga [60,61]. Sahli *et al.* propusieron un modelo de regresión múltiple para estimar la conductividad de la superficie aislante a partir de diferentes composiciones contaminantes, obteniendo una R^2 del 99% [62]. Otros autores también han demostrado que el nivel de contaminación influyó en gran medida en la corriente de fuga y condujo a una menor tensión de descarga disruptiva [62–64]. Por tanto, la monitorización de la corriente de fuga juega un papel importante para evaluar la severidad de la contaminación en los aisladores [65], lo cual permite programar el mantenimiento preventivo de los mismos o diseñar algunas medidas efectivas para reducir los depósitos de contaminación, todo ello con el objeto de minimizar las posibles descargas disruptivas [66], y los cortes imprevistos del suministro eléctrico.

A pesar de la contrastada relación entre la corriente de fuga y los depósitos de contaminación, la medida de la corriente de fuga registrada en tiempo real en los aisladores eléctricos no sólo depende de los depósitos de contaminación, sino también de las variables ambientales, que fluctúan con el tiempo [55,67]. Varios estudios han determinado la relación entre la corriente de fuga y la humedad relativa [59,68–70], siendo la función que mejor describe su comportamiento una ecuación exponencial (ver Figura 11 derecha). En cambio, hay cierta controversia sobre la influencia de la temperatura ambiente en la corriente de fuga en la superficie del aislador (ver Figura 11 izquierda). Algunos autores sugirieron que los

cambios de temperatura tuvieron un efecto menor en las corrientes de fuga [67,71]. Waluyo *et al.* encontraron que la corriente de fuga disminuye moderadamente a medida que aumenta la temperatura en registro simultáneo de 30 días, siendo la función que mejor describe su comportamiento una ecuación exponencial negativa [70]. Otros autores sugieren que tanto la temperatura como la humedad relativa juegan un rol importante en el proceso de humedecido [72]. La diferencia entre la temperatura del aislador y el punto de rocío ambiental afecta directamente la magnitud de la corriente de fuga. Si el aire local cerca del aislador tiene un punto de rocío más alto que el de la atmosfera general, los aisladores son más susceptibles a humedecerse [72].

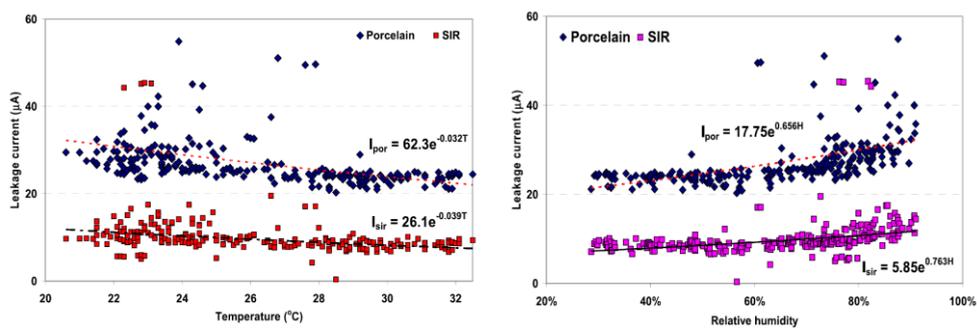


Figura 11. Gráfica de dispersión de la corriente de fuga vs. Temperatura (izquierda) y humedad relativa (derecha) (extraído de [70]).

En cuanto a la velocidad del viento, Ahmad encontró que la corriente de fuga aumenta conforme incrementa la velocidad del viento (2 - 8 m/s) [71]. Salam *et al.* encontraron que la corriente de fuga aumentaba a medida que incrementaba la velocidad del viento en el rango de 2 - 4 m/s y la han modelado como una función potencia [63]. En las instalaciones costeras, la alta velocidad y dirección del viento son especialmente relevantes a lo largo de la costa, donde la tasa de acumulación de solución salina, la tasa de difusión y penetración y la distancia del mar son factores estrechamente relacionados [73,74]. Hussain *et al.* analizaron el efecto del viento y distancia de la costa sobre la contaminación en la superficie de los aisladores [64], modelando tanto la concentración salina y la deposición salina en la superficie del aislador, como una función exponencial negativa,

teniendo en cuenta los distintos factores: los vientos oceánicos, la distancia entre el aislador y la orilla del mar, la difusión y penetración de la solución salina y el asentamiento gravitacional de la solución salina en los aisladores exteriores [64]. El ratio de deposición de contaminación en la superficie del aislador incrementa conforme aumenta la velocidad del viento y disminuye con la distancia entre el aislador y la orilla del mar. Asimismo, cuando el aislador está expuesto perpendicularmente a la dirección del viento, la densidad de contaminación aumenta con la velocidad del viento en el lado de barlovento y disminuye en el lado de sotavento, tanto en la superficie inferior como en la superior de las casetas de protección contra la intemperie del aislante [73] (ver Figura 12 derecha) . En cambio, la deposición de la contaminación en las caras superior e inferior eran prácticamente iguales, además con poca variación respecto a la velocidad del viento, cuando el aislador está expuesto en paralelo con la dirección del viento

Cuando la velocidad del viento es superior a 10 m/s, la deposición de contaminación tiende a ser constante por el efecto de arrastre y limpieza del aislador [73]. Velocidad de viento por encima de 12 m/s puede incluso deformar y dañar los aisladores poliméricos [73]. La densidad de contaminación a lo largo de la distancia de fuga del aislador fue discontinua y no uniforme.

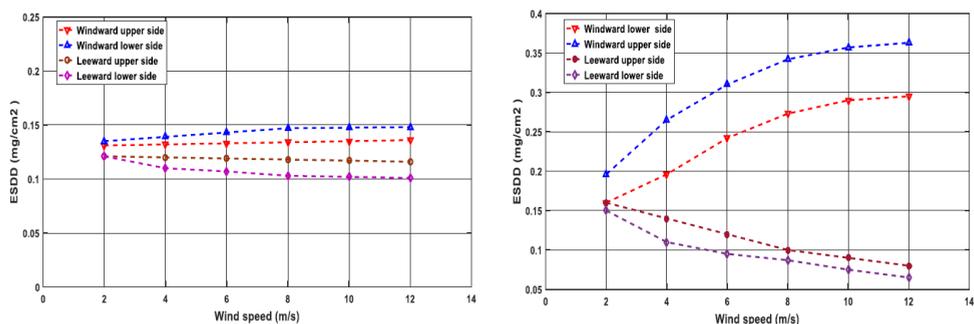


Figura 12. Relación entre la severidad de contaminación y la velocidad de viento cuando el aislador está en paralelo (izquierda) y perpendicular (derecha) con la dirección del viento [73].

Otros factores que influyen considerablemente en la corriente de fuga en la superficie del aislador son la lluvia, llovizna, niebla fría y el tratamiento superficial del aislador entre otros. La lluvia favorece las corrientes de fuga más altas tanto en aisladores cerámicos como

poliméricos (silicona), mientras que la condición de llovizna contribuye a mayor corriente de fuga en los aisladores de silicona, esto se debe, como se ha comentado, a la heterogeneidad de la formación de gotas de agua en la superficie del aislador, que es dependiente del material del aislador [70]. En niebla fría, la corriente de fuga aumenta en mayor proporción que en lluvia, dado que la tasa de humedecido es lenta y con mayor absorción en la deposición [73]. Otros estudios hallaron que la corriente de fuga aumentaba cuando los aisladores pierden su hidrofobicidad [68,69,75–77].

3.4. Corriente de fuga como medio de diagnóstico

Se denomina corriente de fuga a la que circula por un aislador entre sus dos extremos, el conectado a tensión y el dispuesto en el apoyo o herrajes y que está conectado finalmente a tierra. En general tiene dos componentes: una capacitiva debido a su propia disposición en el campo eléctrico; y otra de conducción superficial, de carácter resistivo, que es la más interesante desde el punto de vista de la contaminación. Esta última componente es muy superior a la capacitiva en cuanto hay una cierta humedad ambiental y contaminación superficial. En aisladores altamente deteriorados puede haber una tercera componente relacionada con la corriente conducida por el núcleo del aislador.

Como se ha visto en el apartado anterior, la corriente de fuga no solo depende de la deposición de la contaminación, sino de una serie de factores ambientales. Hasta ahora no se han desarrollado técnicas en tiempo real, que permitan estimar la corriente de fuga asociada a los depósitos de contaminación (Pollution associated leakage current, PLC) durante las operaciones normales en los aisladores eléctricos de alta tensión.

En la literatura, se han realizado algunos estudios que intentan determinar el nivel umbral de sustancias contaminantes solubles y/no solubles que desencadenan la descarga en la banda seca con el fin de prevenir arcos eléctricos [37,78–81]. Dada la dificultad de monitorizar continuamente la ESDD y NSDD sin interrumpir el

sistema, la implantabilidad de estas técnicas en la práctica es muy limitada.

En cambio, la corriente de fuga de los aisladores es un reflejo integral de la climatología, depósitos de contaminación, tensión aplicada y deterioro superficial [54,82], y puede reflejar objetivamente todo el proceso superficial que lleva a la descarga disruptiva [28]. La corriente de fuga se considera como uno de los parámetros más significativos para la prevención de la descarga disruptiva, ya que proporciona información sobre todas las etapas de este mecanismo e indica cómo de cerca está la cadena del aislador de sufrir una descarga disruptiva.[83] Por tanto, la corriente de fuga proporciona información relevante sobre el estado del aislador eléctrico y se considera el parámetro predictivo dinámico más eficaz.

Si bien es cierto que es muy difícil de predecir con exactitud la corriente de fuga a la que ocurre la descarga disruptiva [84], el incremento de la magnitud de la corriente de fuga a lo largo del tiempo, significa que la probabilidad de descarga disruptiva es más alta [80]. Primero, la corriente de fuga aumenta rápidamente antes de la descarga disruptiva. Cuando ocurre la descarga disruptiva, la corriente es la de cortocircuito. Los estudios teóricos y experimentales han demostrado que existe un valor crítico de corriente de fuga (I_{max}) por encima de un valor umbral en el que la probabilidad de descarga disruptiva aumenta drásticamente [85–87]. Verma definió la corriente que fluye en un semiperíodo antes de la descarga disruptiva como la corriente de fuga máxima [87] I_{max} . Holtzhausen y Du Toit [88] y Holtzhausen y Vosloo [89] sugirieron mantener el valor de corriente de fuga pico por debajo del 25% de la I_{max} para minimizar las descargas disruptivas. En los aisladores de vidrio, se puede establecer experimentalmente la I_{max} utilizando los métodos de niebla salina. Específicamente se somete a la cadena de aisladores de vidrio a una serie de tres pruebas consecutivas de una hora de duración por salinidad, registrando la corriente de fuga máxima por prueba. Los niveles de salinidad se incrementan gradualmente hasta alcanzar el nivel de salinidad no soportable que se considera que ocurre cuando hay más de una descarga disruptiva. En la Figura 13 se muestra un

ejemplo de las características de corriente de fuga en ensayos de descarga disruptiva en aisladores de vidrio.

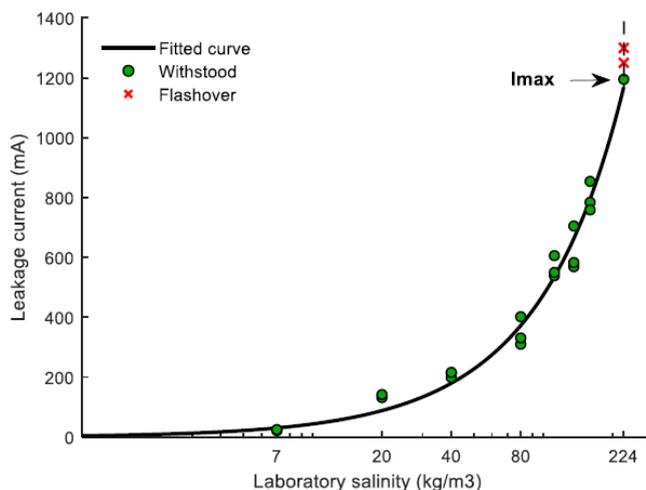
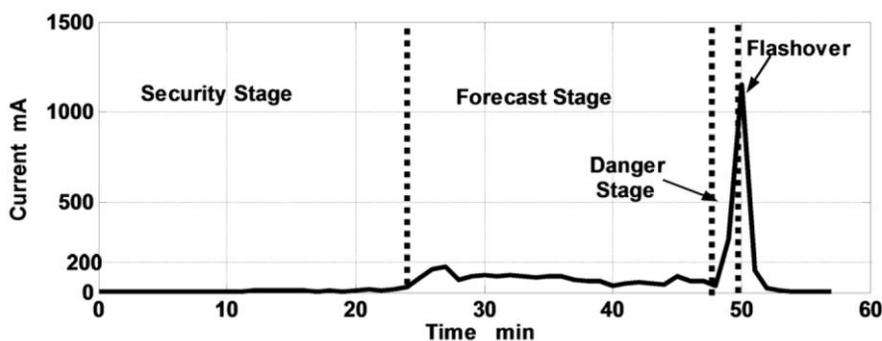


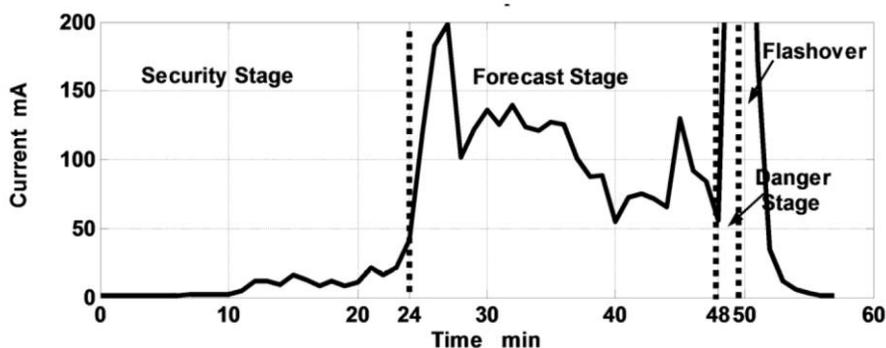
Figura 13. Características de corriente de fuga de aisladores de vidrio [83].

Considerando el valor eficaz de la corriente de fuga, se han definido tres zonas de descarga de contaminación: zona de seguridad, zona de pronóstico y zona de peligro [27]. En clima seco, se considera segura hasta los 5 mA. En condiciones húmedas, se han observado picos de corriente de hasta 50 mA, considerándolos seguros para la operación [27]. A partir de 150 mA-200 mA, se considera zona de peligro de acuerdo con la guía de clasificación de corriente de fuga [37]. En aisladores de alta tensión, puede producirse la aparición de la descarga disruptiva si la corriente de fuga se mantiene por encima del valor límite durante más de 48 minutos [37]. En cambio, la descarga disruptiva no se produce si la corriente de fuga disminuye por debajo del umbral. La Figura 14 reproduce la corriente de fuga durante el proceso completo de la descarga disruptiva por contaminación en un aislador cerámico. Estudios anteriores indicaron que la mejor forma de prevenir la descarga disruptiva es monitorizar la corriente de fuga en la zona de seguridad, y establecer un plan estratégico para determinar cuándo y donde limpiar los aisladores muy contaminados o reemplazar los defectuosos [37]. En la ¡Error!

No se encuentra el origen de la referencia. se muestra la forma de onda de la corriente de fuga desde la zona de seguridad, zona de pronóstico, antes y después de la ocurrencia de descarga disruptiva. Las formas de onda de la corriente de fuga son básicamente ondas sinusoidales o triangulares en la zona de seguridad. En la zona de pronóstico, tienen una gran cantidad de pulsos y picos de alta frecuencia (spikes individuales), a menudo acompañados de paso por cero. En cambio, en la zona de peligro, las formas de onda vuelven a mostrar formas sinusoidales similares pero con un incremento importante de la corriente de fuga [37].



(a) Current plot -- overview



(b) Current plot -- magnified

Figura 14. Corriente de fuga (en valor eficaz) durante el proceso completo (a) de la descarga disruptiva de contaminación en un aislador cerámico [37]. (b) Una vista ampliada.

Por tanto, la monitorización continua de la corriente de fuga es fundamental para diseñar una estrategia efectiva adaptada a las condiciones climatológicas de cada instalación para el mantenimiento apropiado de los aisladores eléctricos de alta tensión, todo ello con el objeto de mantenerse dentro de la zona de seguridad de funcionamiento, minimizando así las posibles descargas disruptivas, y los cortes imprevistos del suministro eléctrico. Más aún, el desarrollo de un modelo robusto y preciso de predicción de la corriente de fuga podría ser una herramienta muy valiosa para las compañías eléctricas ya que permite anticipar las consecuencias negativas de la climatología y/o la contaminación y diseñar medidas preventivas efectivas aumentando la fiabilidad y resiliencia de la red eléctrica. Asimismo, también permitiría la optimización de recursos tanto humanos como materiales para el mantenimiento de la red eléctrica.

Las investigaciones de las últimas décadas se centran en el estudio de la corriente de fuga en los ensayos de laboratorio para determinar el riesgo de aparición de la descarga disruptiva [90–95], con especial énfasis en el análisis de la forma de onda de la misma. Se ha determinado que existe una relación exponencial negativa entre la tensión de descarga disruptiva y un nuevo indicador de corriente I^* que refleja tanto la forma del aislador y la máxima corriente de fuga bajo humedad saturada. Con ello, se puede estimar la tensión de descarga disruptiva bajo humedad saturada a partir de la corriente de fuga adquirida [95] bajo humedad no-saturada.

Mediante el análisis de la transformada de Fourier, se ha confirmado, en pruebas de laboratorio, que la distorsión armónica de la corriente de fuga en el ancho de banda de 150 - 600 Hz está asociada con los depósitos de contaminación en la superficie del aislador, constituyendo un nuevo indicador de las condiciones críticas del aislador y por tanto está asociado con una alta probabilidad de ocurrencia de la descarga disruptiva [90,92–94] . Asimismo a partir de los datos obtenidos en los ensayos de laboratorio, se ha utilizado la transformada discreta de Wavelet para extraer la magnitud de la corriente de fuga a distintas escalas y por tanto el ratio de distorsión

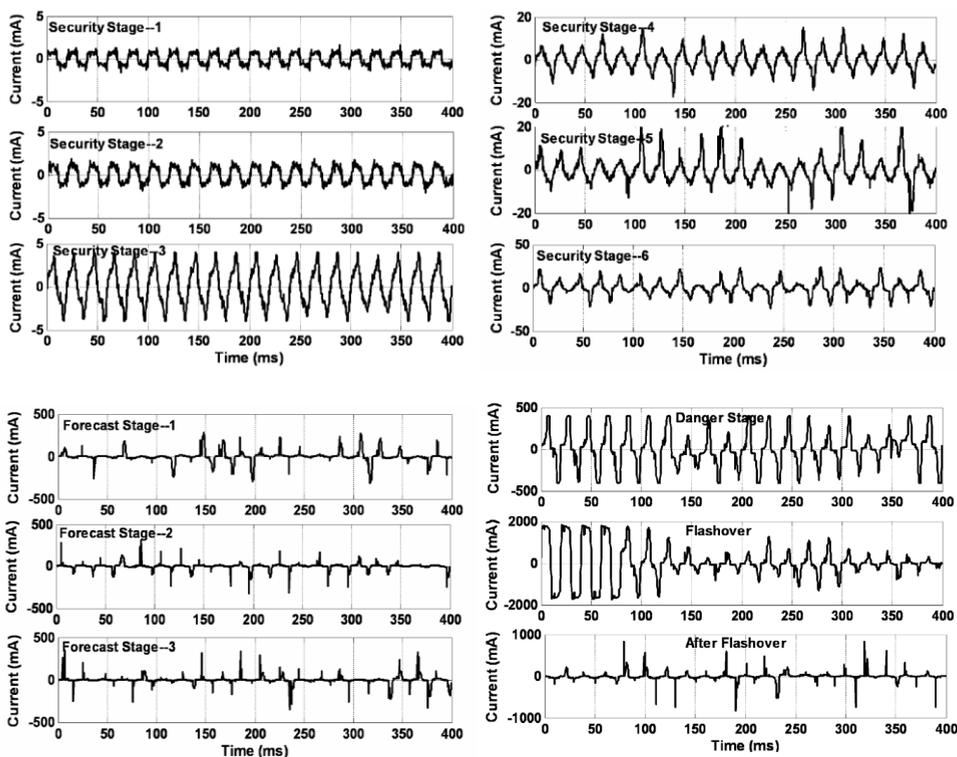


Figura 15. Forma de onda de la corriente de fuga en la zona de seguridad, zona de pronóstico, zona de peligro.

armónica, y posteriormente se ha utilizado el algoritmo de Fuzzy c - means para determinar el nivel de contaminación en 4 categorías [96].

Zhao *et al.* analizaron la relación de la tensión de descarga disruptiva con los depósitos de contaminación y el nivel de hidrofobicidad del aislador (HC1-HC7 de más a menos hidrofóbico) (ver Figura 16) [91]. Asimismo, caracterizaron el cambio de morfología de la corriente de fuga en función de depósitos de contaminación y nivel de hidrofobicidad del aislador. La Figura 17 muestra la forma de onda de la corriente de fuga con diferentes ESDD al aplicar U50 (50% de la tensión crítica de descarga disruptiva) en un aislador con nivel de hidrofobicidad HC6. En ella se puede apreciar la aparición de descarga parcial con una morfología de señal alterada para altas concentraciones de ESDD. Específicamente, han empleado las

siguientes características que describen la forma de onda de la corriente de fuga: entropía de los pulsos (S) que mide la complejidad de los mismos (ver Figura 18), máxima amplitud de pulso (I_h), que refleja la fuerza de descarga en la superficie del aislador (ver Figura 19), ratio de energía (K, ver Figura 20) de alta frecuencia (100-1000 Hz) respecto al de baja frecuencia (0-100 Hz), que mide el grado de distorsión de la forma de onda de la corriente de fuga y la energía total (E, ver Figura 21). Han determinado la relación de estos parámetros con la ESDD y la hidrofobicidad. Posteriormente utilizaron la técnica de regresión con soporte vectorial (SVR) para la predicción de la tensión de descarga disruptiva a partir de la corriente de fuga, obteniendo un error relativo inferior al 13% [91].

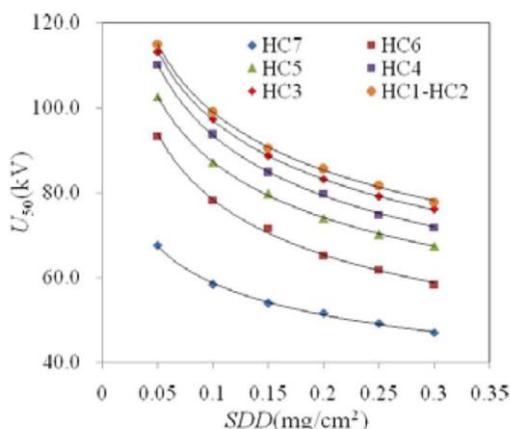


Figura 16. Tensión de descarga disruptiva en función de ESDD y hidrofobicidad [91].

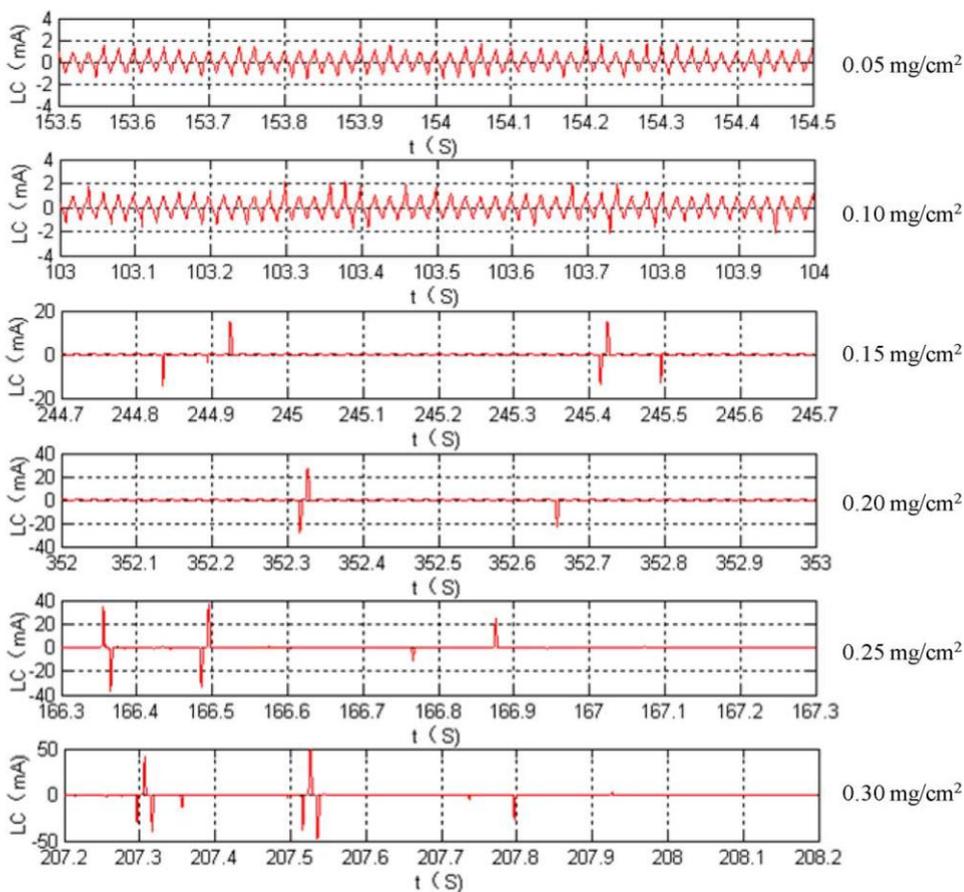


Figura 17. Forma de onda típica de la corriente de fuga con diferente ESDD aplicando U50 (50% de la tensión crítica de descarga disruptiva) para un aislador con nivel de hidrofobicidad HC6 [91].

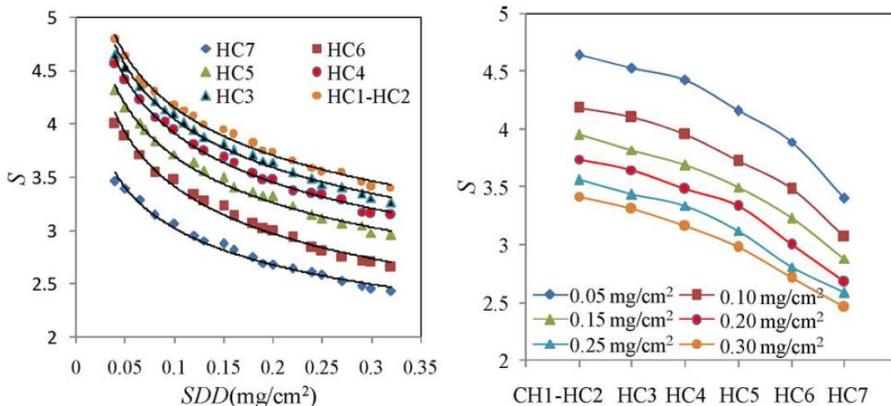


Figura 18. Entropía de los pulsos de la corriente de fuga con ESDD y la hidrofobicidad en ensayo de descarga disruptiva en aislador compuesto FXBW4-35/70 [91].

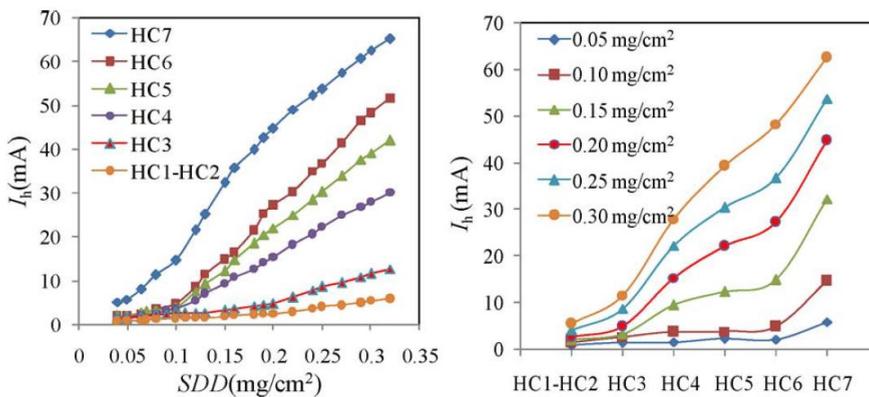


Figura 19. Máxima amplitud de pulso de la corriente de fuga con ESDD y la hidrofobicidad en ensayo de descarga disruptiva en aislador compuesto FXBW4-35/70 [91].

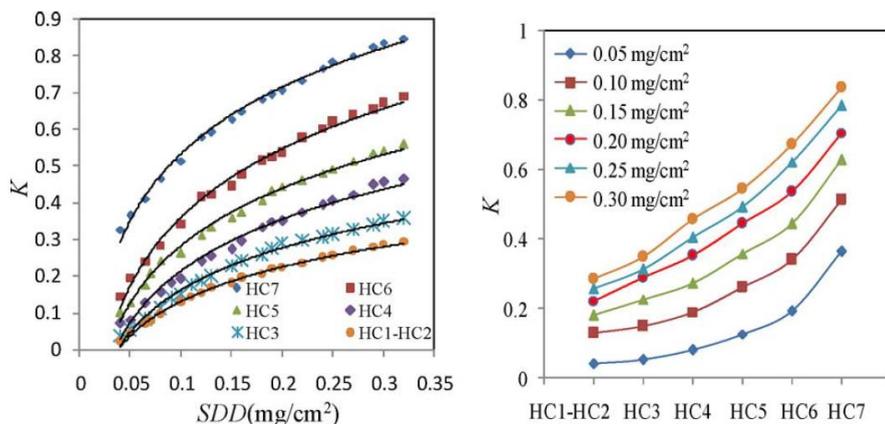


Figura 20. Ratio de energía de alta frecuencia respecto a baja frecuencia (K) de la corriente de fuga con ESDD y la hidrofobicidad en ensayo de descarga disruptiva en aislador compuesto FXBW4-35/70 [91].

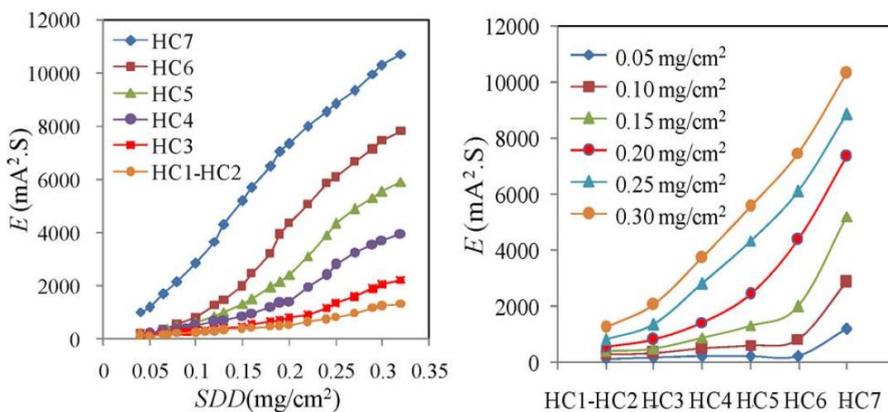


Figura 21. Energía (E) de la corriente de fuga con ESDD y la hidrofobicidad en ensayo de descarga disruptiva en aislador compuesto FXBW4-35/70 [91].

La dimensión fractal también se ha utilizado para caracterizar la corriente de fuga en pruebas de laboratorio en la zona de seguridad, zona de pronóstico y zona de peligro para distintos niveles de contaminación [97]. La media y desviación típica de la dimensión fractal no presentaron grandes diferencias en la zona de seguridad

para los distintos niveles de contaminación. Sin embargo, en la zona de pronóstico, un menor valor de promedio y una mayor desviación del fractal se asocia a una contaminación más severa, sugiriendo que la dimensión fractal de la forma de onda de la corriente de fuga como un nuevo indicador para la prevención de la descarga disruptiva [97].

Asimismo, se han propuesto las redes neuronales artificiales (ANN) para predecir el nivel de contaminación a partir de las características de la corriente de fuga: valor promedio y máximo, desviación típica [37,98–100], tensión aplicada al aislador entre otras. Físicamente, el valor medio de la corriente de fuga refleja el nivel de contaminación de diferentes cadenas de aisladores en la misma condición de funcionamiento [98]. El grosor y el ancho de las bandas secas se pueden reflejar a través de la magnitud y el número de pulsos de corriente [98]. Otros autores proponen evaluar el rendimiento del aislador en base al número de pulsos, el valor pico y la carga acumulada de la corriente de fuga [101,102]. Dadashizadeh ha propuesto un modelo de redes neuronales artificiales para predecir la tensión de descarga disruptiva a partir de ESDD, grado de heterogeneidad de contaminación, edad, corriente fundamental y distorsión armónica, obteniendo un error relativo <6.4% [103].

Partiendo de una combinación de datos de ensayos de laboratorio y de datos estimados a partir de un modelo matemático para el cómputo de la tensión crítica disruptiva [104], se ha desarrollado un modelo basado en redes neuronales artificiales para la predicción de la tensión crítica disruptiva, obteniendo un R^2 de 0.98 utilizando como variables predictoras las características geométricas del aislador, diámetro, altura, distancia de fuga, factor de forma, y la densidad de depósito de sales equivalente (ESDD) [47].

A pesar de los resultados prometedores, el análisis de forma de onda de la corriente de fuga sigue presentando algunas dificultades técnicas para medir los depósitos de contaminación o predecir el riesgo de descarga disruptiva en aplicaciones en tiempo real. Esto es debido a varios factores. Primero, el cambio morfológico de la corriente de fuga debido a los depósitos de contaminación en la zona de seguridad es muy sutil y mucho menos pronunciado que en la zona

pronóstico. Por otro lado es difícil diferenciar la distorsión armónica debida a los depósitos de contaminación de aquella asociada a la propia red durante las operaciones normales [105]. Asimismo, el análisis de la forma de onda de la corriente de fuga requiere la adquisición de datos a alta frecuencia (>2000 Hz), lo cual aumenta drásticamente el coste computacional. En cambio, el valor eficaz de la corriente de fuga es una medida más fiable, ya que está menos influenciada por la distorsión armónica. Además, no requiere una alta frecuencia de muestreo de la misma. Por dicho motivo, el valor eficaz de la corriente de fuga constituye una medida eficaz para monitorizar el estado de los aisladores eléctricos de alta tensión.

3.5. Predicción de la corriente de fuga

Tal como se mencionó en el apartado anterior, el desarrollo de un modelo robusto y preciso de predicción de la corriente de fuga permite anticipar los impactos negativos de la climatología y/o depósitos de contaminación, constituyendo una herramienta de gran utilidad para diseñar una estrategia efectiva adaptada a cada instalación con el mínimo de recursos humanos y materiales necesarios, aumentando así la fiabilidad y resiliencia de la red eléctrica. Dada la relación que presenta la corriente de fuga con las distintas variables ambientales, se han realizado numerosos estudios que intentan predecir la corriente de fuga a partir de las variables ambientales. Destacar que la relación entre las variables ambientales y la corriente de fuga, así como los depósitos de contaminación varía en función del lugar de instalación, y por tanto se ha de determinar *in situ* dicha relación, siendo muy difícil obtener un modelo generalizable válido para distintas instalaciones.

Xia *et al.* realizaron 157 ensayos de laboratorio en cámara climática con distinta composición de depósitos de contaminación (NSDD de 2.0 mg/cm^3 y ESDD en cinco escalones 0.05 , 0.1 , 0.15 y 0.20 mg/cm^3) en aisladores de vidrio, y midieron la humedad relativa, tensión aplicada al aislador ($20\text{-}30 \text{ kV}$) y la corriente de fuga [106]. Con ello, construyeron un modelo de regresión exponencial y un modelo basado

en ANN. Independientemente de la corriente de fuga, el modelo exponencial obtuvo mejor rendimiento que el modelo basado en ANN, obteniendo un error relativo de 13.8% para corrientes de fuga inferiores a 10 mA y 2.2% para corrientes de fuga superiores a 10 mA [106].

Vosloo ha desarrollado un modelo de regresión para predecir la corriente de fuga diaria de aisladores de porcelana a partir de las variables ambientales (temperatura, humedad, dirección y velocidad del viento), índice de radiación ultravioleta, lluvia, conductividad máxima diaria. En un periodo de 7 días, han obteniendo un R^2 que varía entre 0.43 y 0.88 para el modelo lineal, 0.56 y 0.95 para el modelo no-lineal [107]. Zhao *et al.* han confirmado que se puede utilizar la misma ecuación de regresión exponencial para predecir la corriente de fuga semanal a partir de variables ambientales, mientras que los coeficientes de regresión deben ajustarse dinámicamente en función de los depósitos de contaminación en aisladores, en registros de larga duración (periodo de observación 8 meses) [108]. Asimismo, se ha desarrollado un modelo de regresión exponencial para la predicción de la corriente de fuga de tres tipos de aisladores a partir de temperatura, humedad, dirección y velocidad del viento, precipitación y presión atmosférica registrados durante 28 días, obteniendo un $R^2 = 0.606, 0.633, \text{ y } 0.678$ para el aislador cerámico, híbrido y polimérico respectivamente [66].

Otros autores han propuesto la regresión multivariable lineal para predecir la corriente de fuga en los aisladores de un banco de transformadores de una subestación de 275kV en periodo de 43 días, donde las variables predictoras son temperatura, humedad, presión, velocidad del viento, precipitación, y han obtenido un R^2 de 0.674 [71]. Castillo-Sierra *et al.* han implementado una regresión multivariable lineal para predecir la corriente de fuga empleando como variables predictoras temperatura, humedad relativa, dirección y velocidad del viento y radiación solar [109]. Han entrenado el modelo con datos reales medidos *in situ* de 14 días y obtuvieron un error absoluto promedio de 6.14% y R^2 de 0.938. Sin embargo se ha encontrado diferencias estadísticamente significativa entre la corriente de fuga

registrada y la predicción en el grupo de validación [109]. Además, la regresión multivariable lineal también se ha utilizado para modelar la ESDD utilizando como variables predictoras la temperatura, humedad, precipitación, presión dirección y velocidad del viento. Obtuvieron resultados similares a la ESDD medida en un horizonte temporal de 30 días, aunque no proporcionan ningún dato cuantitativo de la bondad del modelo [110].

Los estudios más recientes han utilizado técnicas de procesado más avanzadas para modelar la compleja interacción no-lineal de la corriente de fuga con las variables ambientales. Bahramiazar desarrolló un modelo de predicción de corriente de fuga basado en ANN en base a las distintas variables ambientales (temperatura, humedad, dirección y velocidad del viento y radiación ultravioleta), obteniendo un R^2 de 0.98, donde el tiempo total de registro fue de 20 horas [111]. Basándose en el registro simultáneo de 60 días de la corriente de fuga, temperatura, humedad, velocidad del viento y radiación ultravioleta, se ha propuesto el uso de las redes neuronales prealimentadas multicapas para predecir la corriente de fuga, obteniendo un error absoluto promedio en el grupo de test de 9.11% [46]. Gao *et al.* han propuesto redes neuronales de retropropagación para predecir la corriente de fuga utilizando la diferencia de temperatura entre aire y aislador, humedad y precipitación. Sin embargo, sus modelos solo son capaces de ajustarse a los datos reales cuando la corriente de fuga es grande. Para magnitudes pequeñas, hubo una desviación importante entre la predicción y el valor medido [112]. Otros autores han propuesto la máquina de soporte vectorial (SVM) para clasificar niveles categóricos de la corriente de fuga utilizan como variables predictoras humedad, precipitación, velocidad del viento y temperatura de rocío, alcanzando una exactitud de 87% [113].

Asimismo, se ha propuesto la función de riesgo de valor extremo, teoría de predicción de la pequeña probabilidad de eventos de alto riesgo para pronosticar el valor de corriente de fuga estimando la función de densidad de probabilidad de los datos actuales [114].

De Santos *et al.* presentó un método nuevo para predecir la corriente de fuga a partir de dirección y velocidad del viento, dirección del polvo, lluvia, temperatura, humedad, y radiación solar [83]. Registraron los picos máximos positivos y negativos superiores a 10 mA en intervalos de 5 minutos. Se basa en la estimación del coeficiente de polución con la dirección y velocidad del viento y el medidor de depósito de polvo direccional, para obtener así el índice de polución como el incremento promedio de las conductividades debido a los depósitos de contaminación omnidireccionales. Asimismo, se estima el coeficiente de lavado teniendo en cuenta las precipitaciones. Con ello, se estima el índice de acumulación de contaminantes (CPI) que estima los depósitos de contaminación soluble en la cadena del aislador que tiene en cuenta ambos fenómenos. Para el desarrollo del modelo de regresión, se ha utilizado el algoritmo de bosque aleatorio (*random forest*). Utilizando sólo el CPI y humedad como variables predictoras, han logrado un R^2 de 0.91, 0.812 y 0.801 en el grupo de validación para aisladores no cubiertos, medio-cubiertos de silicona y completamente cubiertos de silicona respectivamente. Al incluir en el modelo la temperatura y radiación solar como variable predictora, el R^2 del grupo de validación incrementó ligeramente: 0.947, 0.860 y 0.869 para aisladores no cubiertos, medio-cubiertos de silicona y completamente cubiertos de silicona respectivamente.

No cuentes los días, haz que los días cuenten.

Muhammad Alí

**CAPÍTULO II:
JUSTIFICACIÓN Y OBJETIVOS**

Los aisladores eléctricos de alta tensión desempeñan un papel fundamental de la red de transporte y distribución de energía eléctrica, pudiendo provocar una catástrofe imprevista de corte de suministro eléctrico, generando graves consecuencias socio-económicas. Independientemente de la localización geográfica, las descargas disruptivas por contaminación amenazan continuamente la fiabilidad de la red eléctrica, constituyendo uno de los mayores retos para los diseñadores y los ingenieros de mantenimiento de la red eléctrica. Actualmente no existe ninguna herramienta ingenieril que permita la monitorización continua del nivel de depósito de contaminación en la superficie de aislador durante la operación normal, siendo necesario la interrupción de la red para realizar la medida de la misma. Por lo que se recurre el mantenimiento periódico de los aisladores eléctricos de alta tensión para garantizar la continuidad del servicio y minimizar los fallos imprevistos del suministro eléctrico. El desarrollo de una herramienta que permita monitorizar de forma continua el nivel de depósitos de contaminación durante la operación normal sería de gran utilidad para el mantenimiento preventivo de los aisladores eléctricos de alta tensión y/o el seguimiento del estado de los recubrimientos aislantes de los mismos para la compañía eléctrica.

Dado que la relación subyacente entre los depósitos de contaminación y la corriente de fuga, se puede monitorizar la corriente de fuga para determinar indirectamente el nivel de depósitos de contaminación. En este contexto, se ha contrastado en la literatura que la corriente de fuga registrada en los aisladores eléctricos depende de una serie de factores ambientales, como temperatura, humedad, dirección y velocidad del viento entre otros. Por tanto, es necesario eliminar la influencia de las variables ambientales de la corriente de fuga para determinar la corriente de fuga asociada a los depósitos de contaminación (PLC) como medida indirecta de la contaminación, para minimizar las descargas disruptivas.

Asimismo, tal como se ha mencionado en el apartado anterior, la corriente de fuga refleja completa y objetivamente todo el proceso del desarrollo de la descarga disruptiva por contaminación y se considera en la actualidad como la medida más eficaz para mantenerse en la

zona de seguridad y prevenir las descargas disruptivas. Por tanto, el desarrollo de un modelo robusto y preciso de predicción de la corriente de fuga podría ser una herramienta muy práctica para anticipar las consecuencias negativas de la climatología y/o la contaminación y diseñar un plan estratégico de medidas preventivas adaptado a cada instalación para evitar las descargas disruptivas, aumentando así la fiabilidad y resiliencia de la red eléctrica. Dada la compleja interacción dinámica entre las variables ambientales y la corriente de fuga, hasta la fecha de hoy, en la literatura se han intentado desarrollar modelos de predicción basados en regresión multivariantes, redes neuronales y/o máquinas de soportes vectoriales a partir de las variables ambientales, obteniendo buen resultado para registros de muy corta duración, pero con poco éxito en registros de larga duración y siendo poco generalizables. Si bien es cierto que el modelo basado en la estimación del índice de acumulación de contaminantes que tiene en cuenta tanto la acumulación de la polución y el índice de lavado ha obtenido resultados prometedores para la predicción de corriente de fuga [83], el método no es fácilmente trasladable a otras instalaciones.

El objetivo general de esta tesis doctoral es desarrollar una nueva tecnología de información que permita diseñar el plan estratégico de mantenimiento, adaptada a cada instalación, que minimice los fallos imprevistos de la red de transporte y distribución de energía eléctrica, aumentando así la fiabilidad y resiliencia de la red eléctrica con el mínimo de recursos humanos y materiales posibles.

El objetivo general se desglosa en 3 objetivos específicos:

- Determinar la relación subyacente entre la corriente de fuga y las variables ambientales
- Desarrollar una técnica de procesamiento para estimar la PLC en tiempo real para aisladores a la intemperie durante la operación normal, mediante la eliminación de la influencia de las variables ambientales
- Desarrollar modelos robustos y precisos de predicción en tiempo real de la corriente de fuga en los aisladores de alta tensión a partir de variables ambientales durante la operación

normal, que permita crear un nuevo sistema on-line de preaviso que anticipe las posibles consecuencias negativas de la climatología y/o depósitos de contaminación entre otros.

Todo ello, con el objetivo de desarrollar nuevas herramientas ingenieriles para diseñar un plan estratégico de mantenimiento adaptado a cada instalación que permita mejorar la continuidad y la calidad del servicio, y minimizar las descargas disruptivas que provoquen fallos inesperados en la red eléctrica.

*Tanto si crees que eres capaz
como si crees que no eres capaz,
en ambos casos estás en lo cierto.*

Henry Ford

**CAPÍTULO III:
MATERIALES Y MÉTODOS**

4. Configuración de los ensayos

En esta tesis se realizaron *in situ* las medidas de corriente de fuga de 7 aisladores instalados en un panel de pruebas en una subestación a la intemperie de la costa mediterránea, con un alto nivel de contaminación salina. El clima de la zona es mediterráneo, con inviernos suaves, húmedos, y veranos cálidos, largos y secos. El lugar donde se instalaron los aisladores tiene aproximadamente unas 3.000 horas de radiación solar al año, lo que hace que este sitio sea adecuado para probar materiales poliméricos, como recubrimientos de silicona, en condiciones de alta radiación ultravioleta [83]. Sus principales características eran las siguientes:

Tabla 1. Características de los aisladores ensayados.

Número de aislador	Material base del aislador	Recubrimiento del aislador
1	Porcelana	Tipo A (Medium silicone proportion + filler) Fabricante 1
2	Porcelana	Tipo B (High silicone proportion + filler)
3	Porcelana	Sin recubrimiento
4	Porcelana	Tipo C (Medium silicone proportion + filler) Fabricante 2
5	Porcelana	Tipo D (Medium silicone proportion + filler) Fabricante 3
6	Porcelana	Tipo E (Medium silicone proportion + filler) Fabricante 4
7	Compuesto de silicona	Sin recubrimiento

Los aisladores 1 - 6 eran aisladores eléctricos cerámicos de alta tensión para subestaciones con diferentes recubrimientos RTV de silicona, excepto el número 3 que no tenía recubrimiento. El número 7 era un aislador de polímero compuesto. Todos los aisladores estaban conectados a la misma fase de un embarrado de 20 KV (Ver Figura 22).



Figura 22. Aisladores en el montaje ensayado.

La Figura 23 muestra un diagrama de bloques de la configuración experimental. Los aisladores a ensayar se montaron en otro aislador auxiliar en la estructura del poste para derivar las corrientes de fuga al sistema de medición. Para medir tanto la corriente superficial como la corriente capacitiva, que varía según los depósitos de contaminación, se conectó un cable de cobre aislado a la unión entre ambos aisladores, a través del cual circulaba la corriente de fuga al sistema de medición. El cable de cobre aislado estaba conectado a una placa con resistencias de medida con su correspondiente protección de corrientes de cortocircuito mediante un descargador de sobretensiones a tierra, siendo los rangos de medición desde los $600 \mu\text{A}$ hasta los $4000 \mu\text{A}$.

Se ha medido la tensión en los terminales de resistencia mediante un circuito de acondicionamiento de señal con una salida de bucle de corriente de 4-20 mA, que estaba eléctricamente aislado para proteger el resto del equipo de medición. Teniendo en cuenta el ancho de banda de la señal de interés ($<800 \text{ Hz}$), se calculó el valor eficaz de forma continua cada 250 ms. El bucle de corriente de 4-20 mA estaba conectado a la entrada del procesador de datos comercial CR1000X (Campbell Scientific Company) especialmente diseñado para condiciones extremas al aire libre. Se obtuvo el valor promedio de la señal en ventanas de 5 minutos y se almacenó en una tarjeta microSD utilizando un software de lenguaje de programación

CR Basic para su posterior procesamiento y para reducir el coste computacional.

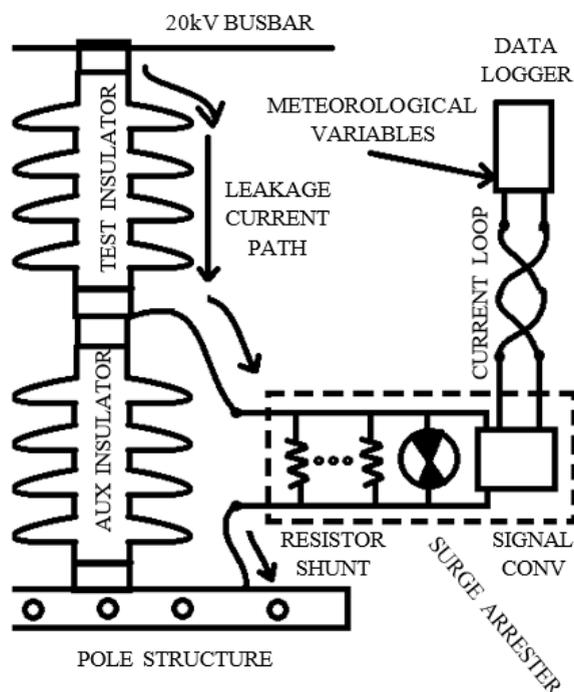


Figura 23. Esquema del montaje experimental.

Además de la corriente de fuga en los 7 aisladores, también se han registrado las distintas variables ambientales que podrían influir sobre la medida de la corriente de fuga incluyendo: temperatura, humedad relativa y dirección y velocidad del viento a una frecuencia de muestreo de 1 muestra cada 5 minutos a través de una estación meteorológica METSENS600. Ésta última es compatible y fácilmente integrable con cualquier procesador de datos Campbell Scientific a través de un puerto SDI-12. Dado que en condiciones normales, la acumulación de contaminantes en la superficie de los aisladores es un proceso a largo plazo y puede variar de meses a años [115], por lo que se estableció el período de estudio en 30 meses para cubrir diferentes estaciones, todas las etapas relevantes de depósitos de contaminantes así como el efecto de auto-lavado natural por la lluvia. Específicamente se extendió de febrero de 2015 a agosto de 2017.

5. Análisis de datos

5.1. Descripción estadística de los datos

Primero, se ha realizado el análisis estadístico de la corriente de fuga adquirida en cada aislador, así como el de las distintas variables ambientales, excepto de la dirección del viento. Este análisis permite determinar, que aislador presenta mayor corriente de fuga, y en cuál de ellos se ha registrado menor corriente de fuga. Por otro lado, también permite entender mejor el entorno donde se han instalado los aisladores. Para cada variable bajo análisis, se han representado las gráficas de cajas y bigotes para realizar un análisis visual de la distribución de datos. Asimismo, se han obtenido el valor máximo, mínimo, rango, promedio, percentiles 10, 25, 50, 75 y 90. El rango se define como la diferencia entre el valor máximo y mínimo. El percentil indica el valor de la variable por debajo del cual se encuentra un porcentaje dado de observaciones. Asimismo, se ha calculado el valor promedio diario de cada variable (ambiental y corriente de fuga) para determinar la posible variación estacional.

Con el fin de determinar si existe alguna dirección de viento predominante en función de la estación anual, se ha calculado el porcentaje de tiempo en el que sopla el viento de este ($[0^\circ, 90^\circ]$), norte ($[90^\circ, 180^\circ]$), oeste ($[180^\circ, 270^\circ]$) y sur ($[270^\circ, 360^\circ]$) de cada mes, así como del total de datos.

5.2. Relación entre las variables ambientales y la corriente de fuga

Para evaluar la relación no lineal subyacente entre las variables ambientales y la corriente de fuga cruda o en bruto (adquirida sin procesar) se ha utilizado el coeficiente de correlación de Spearman, que mide la fuerza y la dirección de la relación no lineal monótonica entre dos variables. Cómo puede haber una relación entre las diferentes variables ambientales, que podría enmascarar su relación

con la corriente de fuga [45,46], para determinar la relación intrínseca de estas variables con la corriente de fuga, también se calculó el coeficiente de correlación parcial de Spearman entre la corriente de fuga cruda y las variables ambientales que hayan obtenido una correlación media - moderada por encima de 0.20 al controlar el efecto de las otras variables. Por ejemplo, cuando se analiza la correlación parcial de la corriente de fuga con la velocidad del viento, esto puede indicar la relación entre estas variables mediante la eliminación de posibles interacciones humedad-velocidad del viento, dirección del viento y velocidad del viento y temperatura-velocidad del viento. También se llevaron a cabo ajustes de mínimos cuadrados para determinar la relación subyacente entre la corriente de fuga cruda y las diferentes variables ambientales utilizando las funciones lineales, exponenciales y polinómicas de 2º orden.

Por otro lado, se ha analizado la relación causa – efecto entre las variables ambientales y la corriente de fuga en aisladores de alta tensión, mediante la causalidad condicional de Granger. Ésta técnica sirve para revelar la relación subyacente oculta no identificada en el análisis de correlación parcial. Asimismo, puede determinar la dependencia temporal de la serie temporal de datos.

En el contexto de la causalidad de Granger, se dice que la variable Y (temperatura, humedad relativa, dirección o velocidad del viento) no es causa de la variable X (corriente de fuga de un determinado aislador), si y sólo si, X depende exclusivamente su propio pasado y es independiente del pasado de Y . Es decir, los valores pasados de Y no proporcionan información sobre el valor actual de X más allá de la propia información contenida en el pasado de X [116]. En cambio, si el pasado de Y transmite información sobre el futuro de X por encima y más allá de toda la información contenida en el pasado de X , entonces se dice que Y es causa de X [116]. Matemáticamente, se desarrolla primero un modelo de vectores autorregresivos para la predicción de la corriente de fuga en base a las p muestras anteriores de su propia información del pasado, donde p es el orden del modelo (ver ecuación 1). A continuación, se

construye otro modelo de vectores autorregresivos para la predicción de la corriente de fuga en base a p muestras anteriores de su propia información del pasado y la variable ambiental (temperatura, humedad, dirección o velocidad del viento) (ver ecuación 2).

$$X_t = \sum_{k=1}^p A'_{xx,k} \cdot X_{t-k} + \varepsilon'_{x,t} \quad (1)$$

$$X_t = \sum_{k=1}^p A_{xx,k} \cdot X_{t-k} + \sum_{k=1}^p A_{xy,k} \cdot Y_{t-k} + \varepsilon_{x,t} \quad (2)$$

Donde X_t es la corriente de fuga de un determinado aislador bajo análisis, Y_t podría ser cualquiera de las 4 variables ambientales o el conjunto de las variables ambientales, $A'_{xx,k}$ y $A_{xx,k}$ son coeficientes de regresión que representan la dependencia de X sobre su propio pasado, $A_{xy,k}$ representa la dependencia de X sobre el pasado de Y . $\varepsilon'_{x,t}$ y $\varepsilon_{x,t}$ son los errores residuales no predecibles del modelo, también denominado como ruido del proceso, con la matriz de covarianza $\Sigma'_{xx} = \text{cov}(\varepsilon'_{x,t})$ y $\Sigma_{xx} = \text{cov}(\varepsilon_{x,t})$.

La mejora de la predicción de la corriente de fuga por incluir alguna variable ambiental, significa que el error residual del nuevo modelo de regresión ($\varepsilon_{x,t}$ de la ecuación 2) debe ser inferior al modelo anterior ($\varepsilon'_{x,t}$ de la ecuación 1), es decir, debe haber una reducción en la matriz de covarianza de ruido del modelo de vectores autorregresivos [116]. En tal caso, se dice que dicha variable ambiental es causa de la corriente de fuga. Por tanto, la causalidad de Granger se define como:

$$F_{Y \rightarrow X|Z} = \ln \frac{|\Sigma'_{XX}|}{|\Sigma_{XX}|} \quad (3)$$

La causalidad de Granger definida en la ecuación (3) tiene el inconveniente de que si existen dependencias conjuntas entre X e Y y un tercer conjunto de variables, por ejemplo Z , entonces se pueden generar causalidades espurias [116]. En otras palabras, si no

hay una influencia causal directa $Y \rightarrow X$ pero existe una tercera variable Z que influye sobre ambas variables ($Z \rightarrow X$ y $Z \rightarrow Y$), entonces se puede dar lugar a una falsa causalidad $Y \rightarrow X$. En nuestra aplicación, puede haber una interacción o relación subyacente 'oculta' entre las distintas variables ambientales [70], que daría lugar a una falsa causalidad entre la variable ambiental y la corriente de fuga.

Para determinar la interacción real entre cada variable ambiental y la corriente de fuga, se analizó la causalidad condicional de Granger controlando el efecto de las otras variables ambientales [116]. La causalidad condicional de Granger pretende determinar la inferencia de la causalidad de Y a X eliminando cualquier efecto conjunto de Z [116]. Su formulación matemática es análoga a la causalidad de Granger. Para cada aislador, se desarrolló primero un modelo de vectores autorregresivos para la predicción de la corriente de fuga en base a las p (orden del modelo) muestras anteriores de las variables condicionadas o controladas y su propia información del pasado (ver ecuación 4). Por ejemplo, si se pretende determinar si la humedad relativa es causa de la corriente de fuga, entonces se construye primero el modelo de vectores autorregresivos con las p muestras anteriores de la información pasada de la temperatura, dirección y velocidad del viento (englobada en la variable Z_t) y la propia corriente de fuga. Posteriormente, se construyó un nuevo modelo de vectores autorregresivos incluyendo la información pasada de la humedad relativa Y_t (ver ecuación 5)

$$X_t = \sum_{k=1}^p A'_{xx,k} \cdot X_{t-k} + \sum_{k=1}^p A'_{xz,k} \cdot Z_{t-k} + \varepsilon'_{x,t} \quad (4)$$

$$X_t = \sum_{k=1}^p A_{xx,k} \cdot X_{t-k} + \sum_{k=1}^p A_{xy,k} \cdot Y_{t-k} + \sum_{k=1}^p A_{xz,k} \cdot Z_{t-k} + \varepsilon_{x,t} \quad (5)$$

Del mismo modo, se entiende que existe una relación causa – efecto si la inclusión de una determinada variable, por ejemplo, la humedad relativa (ecuación 5), permite mejorar la predicción de la corriente de

fuga, conociendo la información de las otras variables ambientales. La causalidad condicional de Granger $F_{Y \rightarrow X|Z}$ se define de forma análoga:

$$F_{Y \rightarrow X|Z} = \ln \frac{|\Sigma'_{XX}|}{|\Sigma_{XX}|} \quad (6)$$

En este contexto, $F_{Y \rightarrow X|Z}$ puede interpretarse como el grado en que el pasado de Y ayuda a predecir X , más allá del grado en el que X ya está predicho por su propio pasado y el pasado de Z .

Tal y como se indicó anteriormente, se ha determinado la relación causa-efecto de las distintas variables ambientales con la corriente de fuga de cada aislador. En primer lugar, se ha de estimar el orden óptimo del modelo de vectores autorregresivos. El orden del modelo de vectores autorregresivos contiene la información sobre la dependencia temporal de los datos y puede determinar el número de muestras anteriores a utilizar para mejorar el rendimiento del modelo de predicción de la corriente de fuga. Físicamente, este fenómeno podría relacionarse con el efecto de deposición de la humedad y secado de la superficie del aislador [117,118]. En esta tesis se ha utilizado el criterio de información Bayesiana (BIC) para determinar el orden óptimo de los modelos de vectores autorregresivos (VAR) para lograr el compromiso entre la precisión del modelo (primer término de la ecuación 7) y la complejidad de modelo (segundo término de la ecuación 7) evitando así el sobreajuste de una secuencia de datos finitos.

$$BIC(p) = \ln |\Sigma(p)| + \frac{\ln(T)}{T} pM^2 \quad (7)$$

Donde Σ es la estimación de la matriz de covarianza del ruido de orden p que corresponde al error de predicción del modelo de vectores autorregresivos de M -series temporales ($M=5$), T es el número total de muestras utilizado para ajustar el modelo.

Después de hallar el orden óptimo, el siguiente paso es obtener estimaciones de los parámetros del modelo que maximicen la función de verosimilitud para los respectivos modelos VAR (de manera equivalente, minimizar el error del modelo). Existen varias técnicas que producen estimaciones asintóticamente equivalentes a la estimación de la función de verosimilitud, en particular mínimos cuadrados ordinarios (MCO) [119] y varias extensiones multivariantes de recursión Durbin (frecuentemente se le denomina algoritmos LWR) [120]. En esta tesis, se han utilizado específicamente los algoritmos LWR para determinar los coeficientes de regresión de los distintos modelos.

Asimismo, se ha analizado la significancia estadística de la causalidad estimada [116], donde la hipótesis nula es cero causalidad vs. la hipótesis alternativa de que existe una causalidad distinta de cero entre las variables bajo análisis. Específicamente, se aplica la teoría estándar de muestras grandes aplicadas al estimador de causalidad de Granger en el dominio del tiempo. Bajo la hipótesis nula de cero causalidad, el estimador de causalidad de Granger normalizado por el tamaño muestral $(m-p)F_{Y \rightarrow X|Z}$ debe presentar una distribución χ^2 o una distribución F asintótica en función de si se trata de variables de interés X multivariantes o univariantes. En cambio, bajo la hipótesis alternativa, el estimador normalizado debe presentar una distribución χ^2 no central o una distribución F no central asintótica. Específicamente, en esta tesis se ha aplicado el test F porque se pretende conocer la relación causa-efecto entre las distintas variables ambientales y la corriente de fuga de un determinado aislador (variables de interés X son univariantes) de forma independiente.

Asimismo, tal como se planteó el estudio, se podría obtener un orden óptimo del modelo diferente para cada aislador. Por tanto, se ha utilizado el orden óptimo promedio de los 7 aisladores para el desarrollo de modelos de predicción de corriente de fuga a partir de las variables ambientales.

5.3. Estimación de la corriente de fuga asociada a los depósitos de contaminación en aisladores de alta tensión

En este apartado, se describe detalladamente el método para estimar la corriente de fuga asociada a los depósitos de contaminación en aisladores de alta tensión. Dado que se puede esperar una correlación estrecha entre estos dos factores [121], se procedió a cancelar primero la influencia de la humedad relativa en la corriente de fuga.

En este contexto, el filtro convencional es ineficaz ya que el ancho de banda de la señal de humedad relativa es desconocido y puede variar con el tiempo. Asumimos que la corriente de fuga cruda $e[k]$ es una mezcla desconocida de corriente de fuga modulada por humedad relativa $r_0[k]$, corriente de fuga asociada a los depósitos de contaminación y otras $d[k]$. En este contexto, se podría esperar que $r_0[k]$, que representa la variación de la corriente de fuga asociada a la humedad relativa, se correlacione con la humedad relativa registrada ($r_1[k]$). Por lo tanto, se decantó por utilizar el filtrado adaptativo para cancelar la influencia de la humedad relativa en la corriente de fuga utilizando la humedad relativa registrada como señal de ruido de referencia $r_1[k]$ (véase la Figura 24). En este contexto, se utilizó un filtro adaptativo para estimar la fuente de ruido $\widetilde{r_1[k]} = h[k]r_1[k]$. La salida del sistema cancelador de ruido adaptativo $x[k]$ es la estimación de la señal de interés $d[k]$ más la fuente de ruido $r_0[k]$, y luego se resta la fuente de ruido estimada $\widetilde{r_1[k]}$. Si $r_0[k]$ y $\widetilde{r_1[k]}$ son lo suficientemente similares, se puede obtener una mejor estimación de la señal de interés. Para ello, la salida del sistema $x[k]$ debe minimizarse en términos del mínimo cuadrado medio de la potencia de la siguiente manera:

$$x[k] = d[k] + r_0[k] - \widetilde{r_1[k]} \quad (8)$$

Haciendo el cuadrado de la ecuación (8) y teniendo en cuenta la condición de que la fuente de señal $d[k]$ no esté relacionada con la señal de ruido $r_0[k]$ y $\widetilde{r_1[k]}$ se obtiene

$$E[x^2] = E[d^2] + E[(r_0 - \tilde{r}_1)^2] \quad (9)$$

La mejor estimación por mínimo cuadrado de la señal $d[k]$ se puede lograr minimizando $E[(r_0 - \tilde{r}_1)^2]$.

$$E[x^2] = E[d^2] \quad (10)$$

Se ha utilizado el algoritmo LMS (Least-Mean-Square algorithm) para obtener el filtro deseado mediante la búsqueda de los coeficientes de filtro para producir el LMS de la salida del sistema $x[k]$. El coeficiente de filtro se inicializaba en cero y se actualizaba para cada muestra de la siguiente manera

$$h[k + 1] = h[k] + \mu x^*[k] \cdot r_1[k] \quad (11)$$

Donde $h[k] = (h_0[k], h_1[k], \dots, h_{p-1}[k - p + 1])^T$ es el coeficiente de filtro en la muestra k , p es el orden del filtro, y μ es el tamaño del paso. En esta tesis, se ha establecido el orden de filtro en 20 y tamaño de paso $\mu=10^{-6}$.

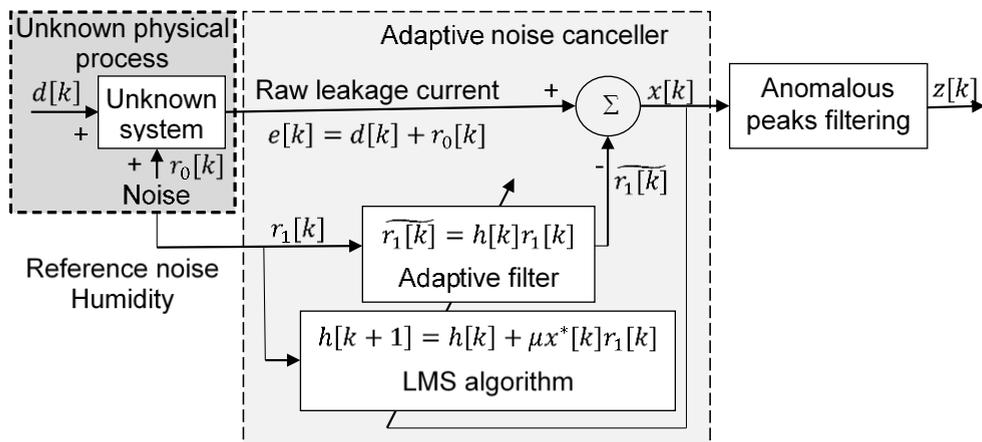


Figura 24. Diagrama del análisis de datos para estimar la corriente de fuga debida a la suciedad.

Después de cancelar la influencia de la humedad relativa en las corrientes de fuga, en la salida de la señal $x[k]$ suelen estar presentes picos de corriente anómalos. Estos picos anómalos pueden estar asociados con otros factores externos [122], por ejemplo, cortes de

energía o condiciones ambientales adversas extremas como lluvia y/o heladas. A continuación, se procedió a eliminar estos picos de corriente anómalos mediante un filtro especialmente diseñado basado en la información de la señal de interés. Los picos de corriente generalmente presentaban una amplitud mucho mayor que el PLC, que debería presentar variaciones suaves, pero no variaciones abruptas con el tiempo. Este filtro consistió en dos fases. En una fase inicial, se aplicó el nivel de umbral adaptativo $Threshold_1[n]$ a una ventana móvil de 1 mes con 50% de solapamiento, siendo éste calculado como el promedio de los niveles umbrales de las últimas 3 ventanas de análisis y la señal resultante se denominó como $y[k]$.

$$Threshold_1[n] = \frac{Thr[n] + Thr[n-1] + Thr[n-2]}{3} \quad (12)$$

$$Thr[n] = \mu[n] \pm b \cdot \sigma[n] = \mu[n] \pm 2\sigma[n] \quad (13)$$

Donde $Thr[n]$, $Thr[n-1]$ and $Thr[n-2]$ fueron los niveles umbral de las últimas 3 ventanas de análisis, que se calcularon a partir de la media μ y la desviación estándar σ de la señal $x[k]$ en la ventana de análisis. Tanto la longitud de la ventana (1 mes), el número de ventanas a considerar, como el coeficiente b , se determinaron experimentalmente para cancelar los picos anómalos en la medida de lo posible utilizando un criterio conservador manteniendo la información de interés.

En la segunda fase se pretenden eliminar los picos de corriente que no fueron cancelados en la fase anterior debido a la alta densidad de variaciones anómalas con el tiempo. Basándose en el hecho de que el PLC varía gradualmente con el tiempo, se implementó la función derivada acumulativa de 2 puntos para acentuar la variación abrupta de la corriente de fuga (véase ecuación 14). La señal resultante se elevó al cuadrado para acentuar aún más la variación abrupta de la corriente de fuga. Finalmente se aplicó un segundo nivel de umbral

adaptativo $Threshold_2[n]$ en ventana móvil de esta última señal $H[k]$, obteniendo así la corriente de fuga remanente $z[k]$.

$$H[k] = (|y[k] - y[k-1]| + |y[k-1] - y[k-2]|)^2 \quad (14)$$

$$Threshold_2[n] = \mu[n] \pm c \cdot \sigma[n] \quad (15)$$

Donde $y[k]$ es la señal de salida de la primera fase del filtro de picos anómalos, $\mu[n]$ y $\sigma[n]$ son respectivamente la media y desviación estándar de la señal $H[k]$ en la ventana de análisis. En este caso, el mejor resultado se obtuvo para una ventana móvil de 2 meses con solapamiento del 50%. A diferencia de la fase anterior, el nivel de umbral se calcula únicamente con las estadísticas de la ventana de análisis actual sin tener en cuenta las ventanas de análisis anteriores. El coeficiente c se determinó experimentalmente para cada aislador, con el objetivo de cancelar los picos anómalos de corriente en la medida de lo posible. Una vez más, utilizamos un criterio conservador para establecer este coeficiente c preservando al mismo tiempo la información de interés.

Para evaluar la eficacia de eliminar la influencia de las variables ambientales, se calculó el coeficiente de correlación de Spearman de la corriente de fuga remanente rectificadas $|z[k]|$ para cada aislador con diferentes variables ambientales para comparar con las obtenidas con la corriente de fuga cruda.

Con el fin de determinar la susceptibilidad de los distintos aisladores a la acumulación de sustancias contaminantes, se computó y comparó tanto la media, desviación estándar y valor máximo de la corriente de fuga remanente rectificadas $|z[k]|$ de los mismos.

5.4. Desarrollo de modelos de predicción de la corriente de fuga en aisladores de alta tensión en base a las variables ambientales

En este apartado se detalla la metodología utilizada para el diseño y evaluación del rendimiento de modelos de predicción de la corriente de fuga en aisladores de alta tensión a partir de las variables ambientales.

5.4.1. Partición de datos

Para evitar el sobre-entrenamiento del modelo y con el objeto de obtener un modelo de regresión robusto y generalizable para los nuevos datos entrantes, se ha dividido el total de la base de datos en tres conjuntos de forma aleatoria con la técnica de 'holdout': entrenamiento (70%), validación (15%) y test (15%) (ver Figura 25). Se han utilizado los grupos de entrenamiento y validación para desarrollar el modelo, optimizando los hiperparámetros del algoritmo y el grupo de test, que se utiliza para determinar la capacidad de generalización real para los nuevos datos entrantes nunca vistos por el modelo. Con el fin de minimizar el sesgo debido a la aleatoriedad de la técnica de 'holdout', se ha generado un total de 10 carpetas para determinar el rendimiento promedio y su variabilidad. Destacar que todos los modelos que se han desarrollado en esta tesis han sido diseñados y evaluados con las mismas carpetas, de manera que las diferencias en el rendimiento del modelo se han debido exclusivamente a los modelos de predicción y no a la partición aleatoria de datos.

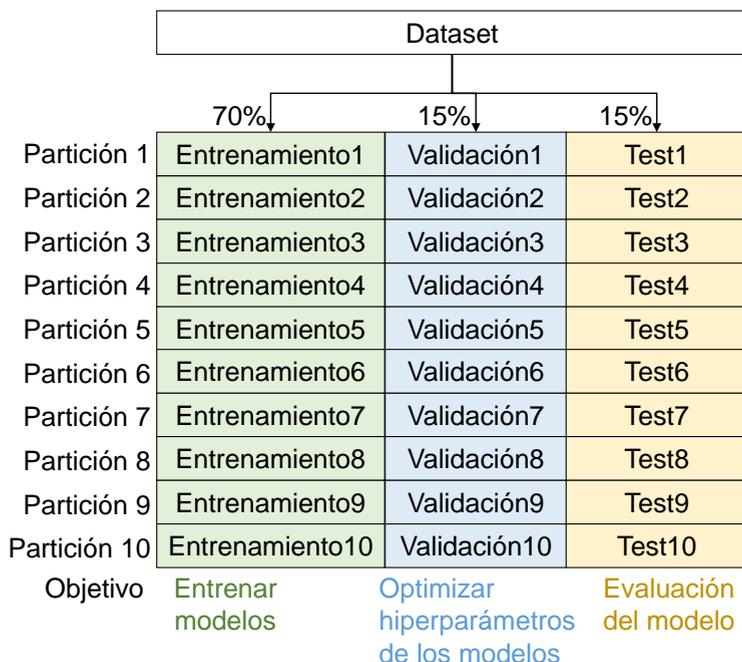


Figura 25. Hold-out para el diseño y evaluación de los modelos.

5.4.2. Variables predictoras

Tal como se mencionó anteriormente, se pretenden desarrollar modelos de predicción de la corriente de fuga a partir de las variables ambientales. Por tanto, se utilizarán los siguientes datos como variables predictoras: temperatura, humedad relativa, dirección y velocidad del viento. Dado que puede existir un efecto retardado de las distintas variables predictoras en la corriente de fuga debido al efecto de deposición y secado entre otros [117,118], se desarrollarán para cada técnica de regresión dos modelos de predicción utilizando solo las muestras actuales (ver Figura 26A) o utilizando las P muestras anteriores de las variables predictoras (las últimas P+1 muestras teniendo en cuenta la muestra actual). En este último caso, si la técnica de regresión permite procesar información bidimensional, entonces se han estructurado los datos de entrada como se muestra en la Figura 26B. En caso contrario, se reformó los datos de entrada en un vector de características como se muestra en la Figura 27. Recordar que P es el orden óptimo promedio de los 7 aisladores

hallado en el análisis de la causalidad condicional de Granger (ver apartado 5.3).

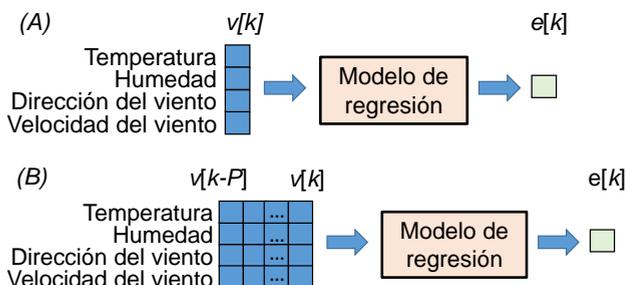


Figura 26. Variables predictoras o características de entrada $v[k]$ para la predicción de la corriente de fuga en el instante de tiempo k ($e[k]$) de un determinado aislador. (A) Solo las muestras actuales. (B) P muestras anteriores y la muestra actual.

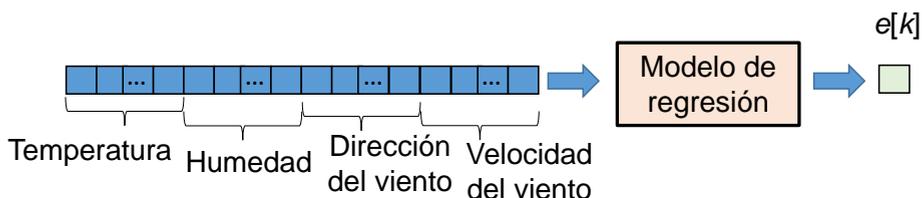


Figura 27. Transformación necesaria de las características de entrada para las técnicas de regresión que solo admiten entradas unidimensionales cuando se utilizan las últimas $P+1$ muestras.

5.4.3. Regresión multivariable lineal (MVR)

Para cada aislador, se ha realizado un modelo global de regresión multivariable lineal para la predicción de la corriente de fuga ($e_i[k]$, donde $i=1...7$, $k=1...N$) a partir de los variables ambientales (v): temperatura $v_1[k]$, humedad relativa $v_2[k]$, dirección $v_3[k]$ y velocidad del viento $v_4[k]$. Tal como se indicó en el apartado 5.2, se desarrollaron dos modelos de regresión utilizando solo la información de la muestra actual (ecuación 16) o las últimas $P+1$ muestras (ecuación 17). Dado que MVR solo admite características de entrada unidimensionales, se han de transformar las últimas $P+1$ muestras de las 4 variables ambientales en un vector de dimensión $1 \times (4 \cdot P + 4)$ para el desarrollo del modelo como se puede apreciar en la Figura 27.

$$e_i[k] = \beta_0 + \beta_1 v_1[k] + \dots + \beta_4 v_4[k] + \varepsilon_i \quad \forall i = 1 \dots 7, k = 1 \dots N \quad (16)$$

$$e_i[k] = \beta_0 + \sum_{p=0}^P \beta_{1p} v_{1p}[k-p] + \dots + \sum_{p=0}^P \beta_{4p} v_{4p}[k-p] + \varepsilon_i \quad \forall i = 1 \dots 7, k = 1 \dots N \quad (17)$$

Donde la anotación i e k hace referencia al aislador y la muestra de la serie temporal, ε es el término del error de estimación.

Dado que no hay que ajustar los hiperparámetro en el modelo, se pueden determinar los pesos de ponderación de cada característica utilizando los datos de entrenamiento, posteriormente se han aplicado al grupo de validación y test para determinar el rendimiento del modelo.

5.4.4. Soporte vectorial para la regresión

Dada la naturaleza de la interacción no-lineal entre las variables ambientales y la corriente de fuga, se ha realizado un modelo global de regresión para cada aislador mediante la utilización de la técnica máquina de soporte vectorial para la regresión (Support Vector Regression, SVR). La técnica de SVR es una aplicación específica de la máquina de soporte vectorial o de vectores de soporte (SVM) para la regresión de datos.

SVM consiste en la transformación no lineal (función *kernel*) de las características de entrada, que no son separables linealmente en su espacio original, a un espacio de mayor dimensión en el que los datos son linealmente separables. La idea es entonces encontrar un hiperplano que maximice la distancia entre clases (Figura 29 izquierda). La técnica SVM es ampliamente utilizada para resolver tareas de clasificación en múltiples campos de aplicación: reconocimiento facial [123], clasificación de imágenes [124], reconocimiento de textos escritos a mano, detección precoz de patologías en medicina [125,126]. Del mismo modo, para una regresión no lineal, se propone el uso de la función *kernel* para trasladar los datos a un espacio de mayor dimensión en el que se ajuste mejor a una línea recta gracias a la transformación no lineal. La Figura 28 muestra el diagrama de bloques básico de la predicción de

la corriente de fuga basado en las variables ambientales mediante técnicas no-lineales.

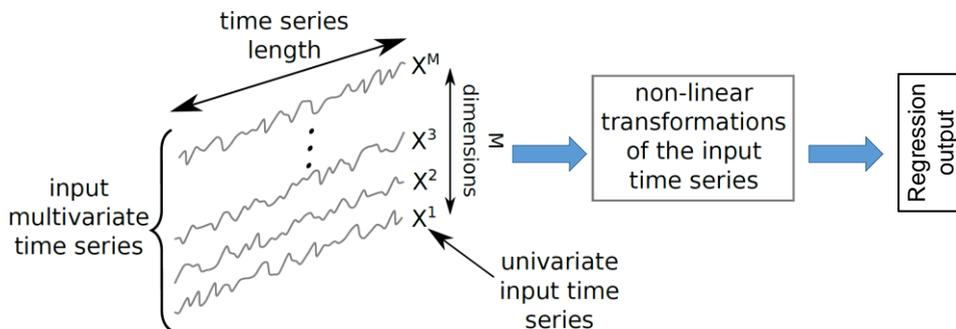


Figura 28. Diagrama de flujo de la regresión no-lineal para la predicción de corriente de fuga basado en variables ambientales mediante técnicas no-lineales (figura extraída de [127] y modificada por el autor).

La diferencia con SVM, es que en SVR el hiperplano es la línea recta en el espacio multi-dimensional en la que mejor se ajustan los datos, es decir, tiene el mayor número de puntos alojado sobre él o dentro de un margen de error (Figura 29 derecha). En el espacio de características originales, el hiperplano puede tomar cualquier forma geométrica gracias a la transformación no lineal mediante la función kernel (Figura 30).

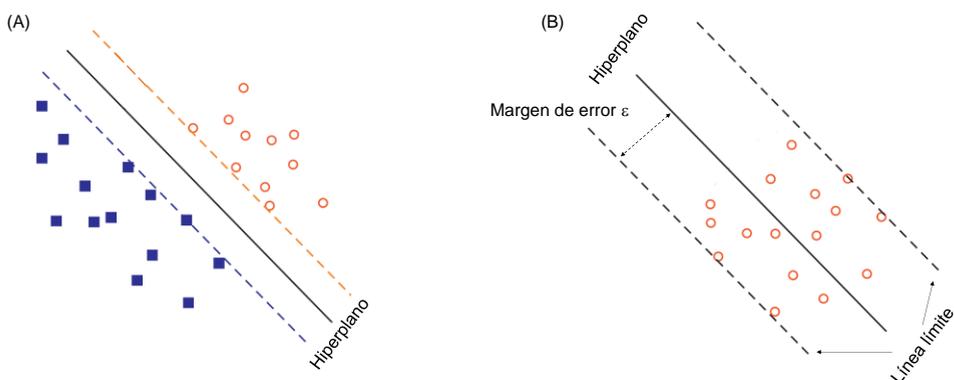


Figura 29. Representación en el espacio multidimensional (después de la transformación mediante la función kernel) para ilustrar la diferencia entre SVM (A) y SVR (B) (imagen extraída de [128] y modificada por el autor).

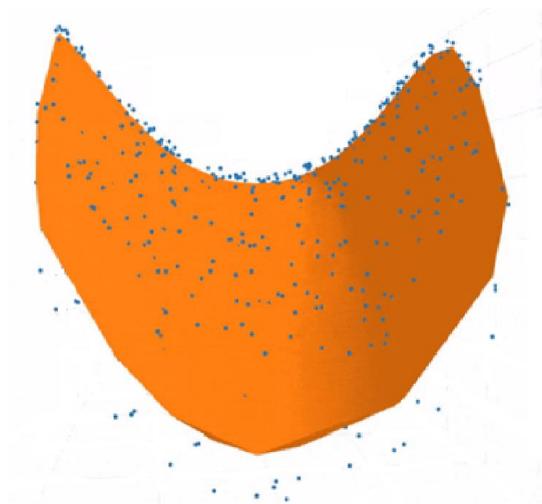


Figura 30. Ilustración del hiperplano en un espacio multidimensional de características originales en el que se ajusta los datos en SVR.

En la Figura 31 se muestra la arquitectura de la técnica de SVR, donde la primera capa consiste en la transformación no-lineal de las características mediante la función *kernel*, y la capa de salida simplemente es una regresión lineal en el espacio transformado.

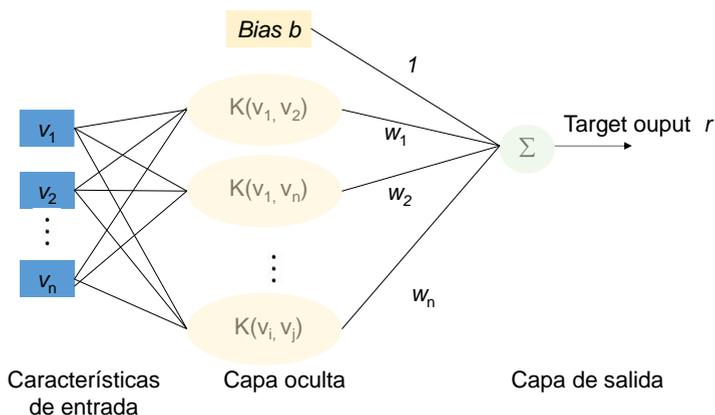


Figura 31. Arquitectura de la técnica de SVR.

Las funciones kernel más utilizadas son la función lineal, polinómica o función de base radial. En esta tesis, se ha utilizado específicamente la función kernel de base radial al tratarse de uno de los kernels no

lineales más utilizados. Matemáticamente, la función de base radial se puede expresar mediante la siguiente ecuación:

$$K(v, v') = \exp \frac{\|v-v'\|^2}{2\sigma^2} = \exp^{-\gamma\|v-v'\|^2} \quad (18)$$

Donde v y v' son dos muestras representadas como vectores de características en el espacio original. El parámetro γ puede considerarse como la inversa del radio de influencia (σ) de las muestras seleccionadas por el modelo como vectores de apoyo. El parámetro γ define hasta dónde alcanza la influencia de un solo ejemplo de entrenamiento. Los valores bajos de γ significan "lejos" y valores altos significan "cerca". Si el parámetro γ es demasiado grande, el radio del área de influencia de los vectores de soporte solo incluye el vector de soporte en sí, lo cual podría dar lugar un modelo demasiado flexible, generando así el problema del sobreentrenamiento. En cambio, cuando el parámetro γ es muy pequeño, la región de influencia de cualquier vector de apoyo seleccionado incluiría todo el conjunto de entrenamiento, dando lugar a un modelo demasiado restringido, que no puede capturar la complejidad o la "forma" de los datos. Normalmente el parámetro γ se determina experimentalmente para la aplicación específica.

A diferencia de otros modelos de regresión que intentan minimizar el error entre el valor real y su predicción, el SVR intenta encontrar un hiperplano (línea recta en el espacio transformado de alta dimensionalidad, y curvada en el espacio original) óptimo, con un error de estimación por debajo de un margen ε (ver Figura 29B). El margen de error ε es la distancia entre el hiperplano y la línea límite (*boudary line*). SVR proporciona la flexibilidad de definir cuánto error es aceptable en el modelo y encontrará una línea apropiada (o hiperplano en dimensiones más altas) para ajustarse a los datos. La Figura 32 muestra el concepto básico de SVR para la regresión de datos no-lineales.

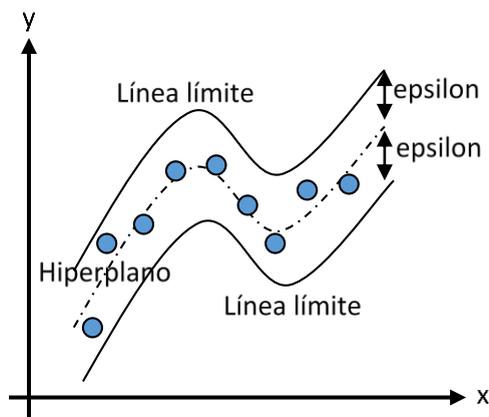


Figura 32. Ilustración conceptual básico de SVR, representado en el espacio original de características.

La función objetivo del SVR no es minimizar el error cuadrático entre el dato real y la predicción, sino minimizar la l2-norma del vector de coeficientes sujeto al error absoluto de predicción, para que sea igual o inferior al margen de error ε [129]. En el entrenamiento del modelo, se puede determinar el margen de error óptimo para mejorar el rendimiento del modelo, logrando una predicción de mayor precisión de la corriente de fuga a partir de las variables ambientales.

$$\begin{aligned} & \text{Minimizar } \frac{1}{2} \|w\|^2 \\ & \text{Sujeto a: } |e - (wK(v, v') + b)| \leq \varepsilon \end{aligned} \quad (19)$$

Donde r es la corriente de fuga de un determinado aislador, w corresponde a los pesos de cada característica en el espacio transformado de alta dimensión, b es el punto de intercepción de la línea recta, ε es el margen de error, $K(v, v')$ es la función kernel, específicamente se ha utilizado función de base radial. El problema de optimización descrito anteriormente se resuelve computacionalmente mediante la formulación dual de Lagrange.

El algoritmo resolverá la función objetivo de la mejor manera posible, pero en aplicaciones reales algunos de los datos pueden quedar fuera

del margen de error. En otras palabras, se debe tener en cuenta la posibilidad de estimar los datos con errores mayores que ε . Para ello, se introduce el concepto de regularización C en el SVR. Para cualquier error mayor que ε , se denota su desviación del margen como ξ . La Figura 33 muestra conceptualmente el SVR con el parámetro de regularización C . Por tanto, se reformula la función objetivo para minimizar el efecto de los puntos anómalos fuera del margen.

$$\begin{aligned} & \text{Minimizar } \frac{1}{2} \|w\|^2 + C \sum_{n=1}^N (\xi_n + \xi_n^*) \\ & \text{Sujeto a: } |e - (wK(v, v') + b)| \leq \varepsilon \\ & \quad \xi_n > 0, \text{ y } \xi_n^* > 0 \end{aligned} \quad (20)$$

Donde ξ_n y ξ_n^* son cualquier punto fuera del margen de error, w corresponde a los pesos de cada característica en el espacio transformado de alta dimensión, b es el punto de intercepción de la línea recta. La ecuación (20) también se puede reformular de la siguiente manera:

$$\begin{aligned} & \text{Minimizar } \frac{1}{2} \|w\|^2 + C \sum_{n=1}^N L[r - (wK(v, v') + b)] \\ & \text{Donde: } L = \begin{cases} 0 & \text{si } |e - (wK(v, v') + b)| < \varepsilon \\ e - (wK(v, v') + b) & \text{otros casos} \end{cases} \end{aligned} \quad (21)$$

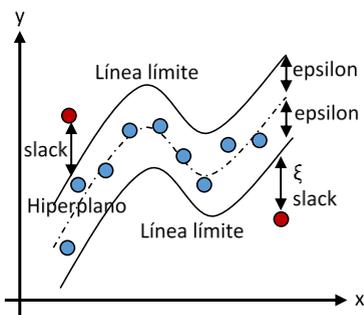


Figura 33. Ilustración de SVR con parámetro de regularización. Variable de 'Slack' es el parámetro de regularización.

En otras palabras, el parámetro de regularización C es lo que define la importancia de los datos con un error de estimación anormalmente alto. En la práctica el parámetro de regularización C se ha de determinar experimentalmente y debe ser un compromiso entre la complejidad del modelo y el error empírico. Del mismo modo, se debe buscar y optimizar el margen de error ϵ para la aplicación específica.

En esta tesis, se han desarrollado dos modelos para estimar la corriente de fuga de cada aislador mediante la técnica de SVR. El primero utiliza exclusivamente la información de las muestras actuales de las variables ambientales (ver Figura 26A), y el segundo modelo emplea la información de las últimas $P+1$ muestras de las misma (ver Figura 27). En cada modelo, se ha optimizado tanto el parámetro γ de la función *kernel*, el parámetro de regularización C y margen de error ϵ entre otros mediante la técnica de hold-out de 10 carpetas. Posteriormente se ha determinado el rendimiento del modelo para los datos de entrenamiento, validación y test.

5.4.5. Redes neuronales convolucionales

5.4.5.1. Antecedentes

El aprendizaje profundo (*Deep Learning*) es el último logro de la era del aprendizaje automático, en la actualidad presenta habilidades casi humanas y en muchas aplicaciones [130]. Hay diferentes arquitecturas de red, siendo las redes neuronales convolucionales (*Convolutional Neural Network, CNN*) una de las arquitecturas más extendidas [131]. El primer modelo de CNN fue desarrollado por Yann LeCun en 1990 [132] y se demostró su superioridad sobre la base de

datos de números manuscritos del MNIST de referencia. No tuvo demasiado éxito durante más de 1 década por el alto coste computacional necesario para entrenar el modelo. La aplicación de CNN en el área de clasificación de imágenes a gran escala tuvo su punto de inflexión en 2012 gracias al desarrollo del modelo AlexNet por Krizhevsky et al. [133]. Este modelo consiste en CNN de 8 capas (5 convolucional-pooling layers y 3 fully connected layers) que logró una tasa de error del 16.4% en la base de datos de referencia de ImageNet [134] y esto fue aproximadamente un 10% más bajo que el obtenido con el aprendizaje automático tradicional utilizando SVM. Actualmente, Deep learning y especialmente CNN ha obtenido resultados muy prometedores en reconocimiento facial [135], clasificación de imágenes [136], reconocimiento de textos escritos a mano [137], procesamiento de lenguaje natural [138], ingeniería biomédica [139].

CNN es una arquitectura de aprendizaje multicapa que permite extraer automáticamente las características relevantes utilizando capas convolucionales y submuestreos en cascada con la mínima interacción humana o conocimiento experto, siendo éstas utilizadas posteriormente por múltiples capas completamente conectadas (*fully connected layers*) en cadenas para resolver la tarea de clasificación [131]. Destacar que en general, CNN requiere una gran cantidad de datos (de orden de decenas de miles) de entrenamiento para extraer las características relevantes con un mínimo de interacción humana.

La técnica de CNN estaba originalmente pensada para la clasificación de imágenes o vídeos con de datos de entrada bidimensionales. Por ello, se le denomina 2D-CNN porque el *kernel* se desplaza en 2 dimensiones. La Figura 34 muestra el flujograma básico de un CNN para clasificar una imagen de 24x24 en escala de grises en dos categorías. En este ejemplo, la arquitectura de red consiste en dos capas de convolución (*convolution layers*) y dos capas de submuestreo (*subsampling or pooling layers*) que se detallarán más adelante. La salida de la última capa de submuestreo se procesa con una única *fully-connected layer* y seguida de la capa de salida que

produce el resultado de la clasificación. La capa de convolución consiste en aplicar los filtros de ponderación (w) con un tamaño de kernel de ($K_x=4$, $K_y=4$). Dado que la convolución tiene lugar dentro de los límites de la imagen, la dimensión del mapa de características se reduce por tanto en (K_x-1 , K_y-1) píxeles del ancho y alto, respectivamente. En este ejemplo, se aplica simultáneamente 4 y 6 filtros de ponderación en la primera y segunda capa respectivamente. Por ello, la salida de la primera capa de convolucional son 4 matrices de 21 x 21, mientras que la segunda capa de convolución obtiene 6 matrices de tamaño 4x4 en su salida. Los factores de submuestreo (S_x , S_y) se establecen de antemano en cada capa de *pooling*, en el ejemplo de la Figura 34, $S_x=S_y=3$ para la primera capa y $S_x=S_y=4$ en la segunda capa. Hay que tener en cuenta que estos valores se seleccionaron deliberadamente para que las salidas de la segunda capa de *pooling* (es decir, la entrada a la capa *fully-connected*) fueran escalares de dimensión 1x1. La capa de salida consta de dos neuronas correspondientes al número de clases en las que se categoriza la imagen.

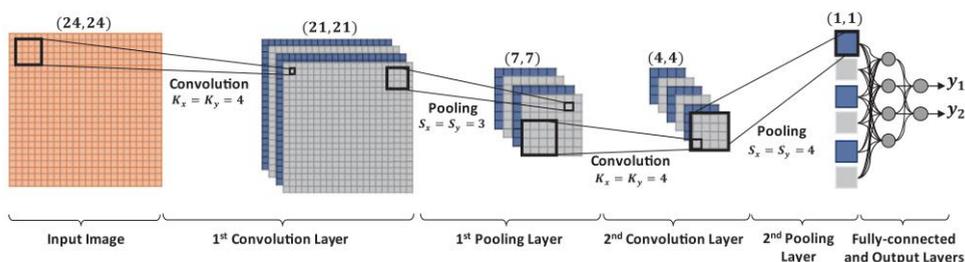


Figura 34. Ilustración de un ejemplo de CNN con 2 capas convolucionales y una capa completamente conectada [130].

Tal y como se ha mencionado anteriormente, la convolución es una de las capas fundamentales de CNN para la extracción de características. La Figura 35 muestra un ejemplo de convolución de 2D-CNN con el tamaño de *kernel* $K=3$ y un desplazamiento de 1 posición en ambas dimensiones. Primero se realiza el producto del *kernel* con los pesos de ponderación y la imagen de entrada. Dado que la imagen de entrada es de 7x7, entonces se subdivide en

pequeñas matrices del mismo tamaño (tensor de entrada) que el de *kernel* (3x3) para realizar el producto, y el resultante de la suma de este producto es la convolución del tensor de entrada con el *kernel*. Posteriormente se va desplazando en ambas dimensiones para obtener la salida del filtro, en este caso, de dimensión 5x5.

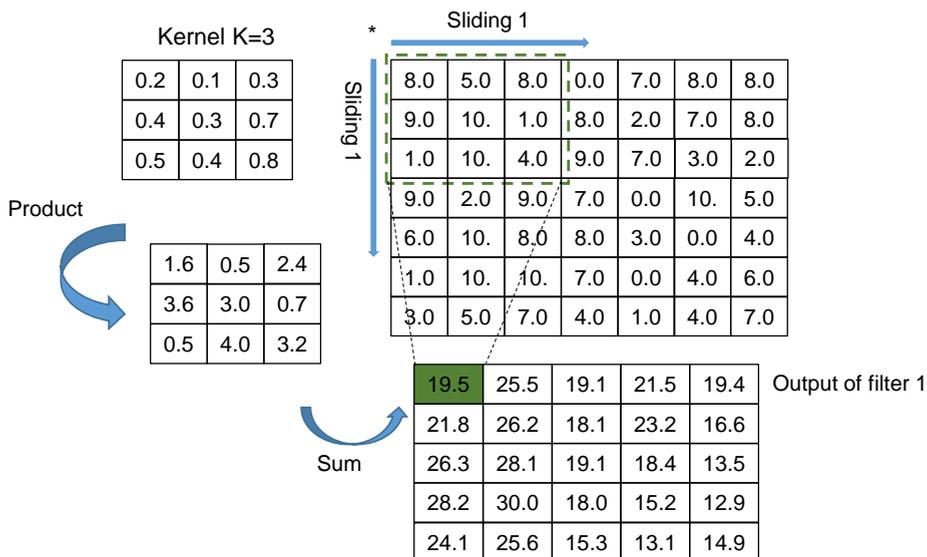


Figura 35. Ilustración del proceso de convolución en 2D-CNN con el tamaño del kernel K=3, desplazamiento de 1 posición en ambas dimensiones (solo efecto ilustrativo, los datos son ficticios). En la imagen se muestra con detalle el producto de la convolución de la sub-imagen (remarcado en verde) con el kernel.

El proceso de entrenamiento de un modelo CNN con respecto a la capa de convolución consiste en identificar los *kernels* óptimos para una tarea determinada en función de un conjunto de datos de entrenamiento. Los pesos de ponderación de los *kernels* son los únicos parámetros que se aprenden automáticamente durante el proceso de entrenamiento en la capa de convolución. En cambio, el tamaño de los *kernels*, el número de *kernels*, y el desplazamiento son hiperparámetros que deben configurarse antes de que comience el proceso de entrenamiento [140].

Las salidas de la convolución se procesan entonces por una función de activación no lineal que sirve para determinar qué neurona o

característica convolucionada se activará y cuál no. Actualmente la función de activación no lineal más utilizada en CNN es la unidad lineal rectificadora (ReLU) [140,141]. Matemáticamente se puede describir en la ecuación 22. La Figura 36 muestra la representación gráfica de la misma.

$$f(u) = \max(0, u) \quad (22)$$

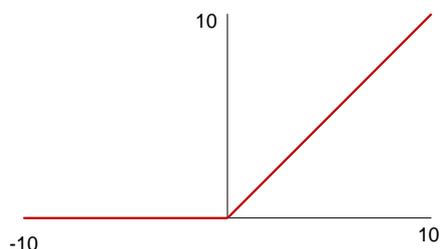


Figura 36. Representación gráfica de la función de activación no lineal ReLU [141].

La principal ventaja de utilizar la función ReLU sobre otras funciones de activación es que no activa todas las neuronas o características convolucionadas al mismo tiempo. Esto significa que las neuronas se desactivarán para valores de entradas negativas. Dado que solo se activa un cierto número de neuronas, la función ReLU es mucho más eficiente desde el punto de vista computacional en comparación con las funciones sigmoide y tangente hiperbólica que permiten una representación matemática del comportamiento de una neurona biológica [141]. En la práctica, las redes con ReLU tienden a mostrar un mejor rendimiento de convergencia que las redes sigmoideas. A diferencia de las funciones sigmoide y tangente hiperbólica que presentan el problema de la dificultad de entrenar el modelo cuando el gradiente que se pasa a la red subyacente se vuelve muy pequeño para la entrada, que es muy grande o muy pequeña, ReLU no presenta el problema de difusión del gradiente al no estar saturado [141].

La capa de submuestreo normalmente consiste en hallar el valor máximo o el promedio del tensor de entrada de dimensión prefijada que depende del factor de submuestreo, por lo que se le denomina

“Max-pooling” y “Average pooling” respectivamente. La Figura 37 muestra un ejemplo del proceso de submuestreo con factor de submuestreo en ambas dimensiones. Su objetivo es reducir la dimensionalidad de las características preservando la información relevante de las mismas. La capa de submuestreo además de disminuir el número de parámetros que requiere entrenar, introduce la invariancia traslacional a pequeños cambios y distorsiones [140]. Al eliminar la información ruidosa en los datos, extrayendo la información relevante, se puede evitar el sobreentrenamiento y acelerar los cálculos y por tanto reducir el tiempo de entrenamiento del modelo [142]. Destacar que no hay ningún parámetro que requiera entrenamiento en ninguna de las capas de submuestreo, mientras que el tamaño del filtro y el desplazamiento son hiperparámetros que se deben configurarse antes de que comience el proceso de entrenamiento [140].

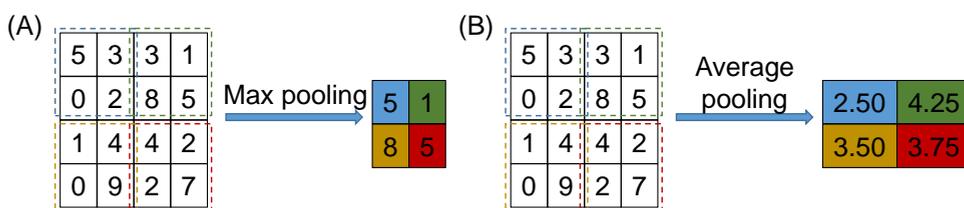


Figura 37. Ilustración del proceso del submuestreo mediante Max pooling (A) y Average pooling (B) con factor de submuestreo de 2 en ambas dimensiones. (solo efecto ilustrativo, los datos son ficticios)

El aplanamiento (*flattening*) y las *fully connected layers* (también llamado *dense connected layers*) son las últimas etapas de CNN. El aplanamiento consiste en convertir los datos de la salida de la última capa de submuestreo en un único vector de características para poder conectarse con las *fully connected layers*. En el ejemplo de la Figura 38, la última capa de submuestreo es de dimensión 3x3, y se convierte en un vector de 9x1 después del aplanamiento. Las *fully connected layers* son aquellas capas, donde todas las entradas de una capa, están conectadas a cada unidad de activación de la siguiente capa, mediante un peso “aprendible” durante el proceso de entrenamiento. En el ejemplo de la Figura 38 tiene una única capa oculta con 4

unidades de activación, donde cada unidad de activación es la suma ponderada de las 9 características de entrada y el término de intercepción. De nuevo, cada *fully connected layer* va seguida de una función de activación no lineal, como ReLU, como se describe anteriormente.

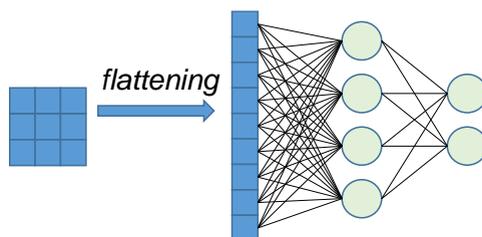


Figura 38. Ilustración del flattening y fully connected layers.

Generalmente las CNN se entrenan de manera supervisada por el algoritmo de retropropagación (*backpropagation*). Durante cada iteración de la retropropagación, se van actualizando iterativamente los parámetros de CNN desde la salida hacia la entrada hasta que se cumpla un cierto criterio de parada, utilizando la dirección de máxima gradiente. Entre los parámetros de CNN, caben citar los pesos de la convolución y los pesos de las neuronas de las capas completamente conectadas. En la Tabla 2 se muestra el listado de parámetros e hiperparámetros a configurar en una CNN.

Tabla 2. Lista de parámetros e hiperparámetros en una CNN. un parámetro es una variable que se optimiza automáticamente durante el proceso de entrenamiento y un hiperparámetro es una variable que debe configurarse de antemano [140].

	Parameters	Hyperparameters
Convolution layer	Kernels	Kernel size, number of kernels, stride, padding, activation function
Pooling layer	None	Pooling method, filter size, stride, padding
Fully connected layer	Weights	Number of weights, activation function
Others		Model architecture, optimizer, learning rate, loss function, mini-batch size, epochs, regularization, weight initialization, dataset splitting

Asimismo, se ha desarrollado una versión modificada de 2D-CNN para procesar datos de entrada unidimensionales, por ejemplo, textos o series temporales, denominado 1D-CNN [143–147] para distintas

aplicaciones: reconocimiento de voz automático [148], detección de daños estructurales basado en vibraciones en infraestructuras civiles [149], ingeniería biomédica [143]. La Figura 39 muestra un ejemplo de 1D-CNN para 3 capas convolucionales y 2 *fully connected layers* para resolver problema de regresión, que es el problema al que se enfrenta la presente tesis.

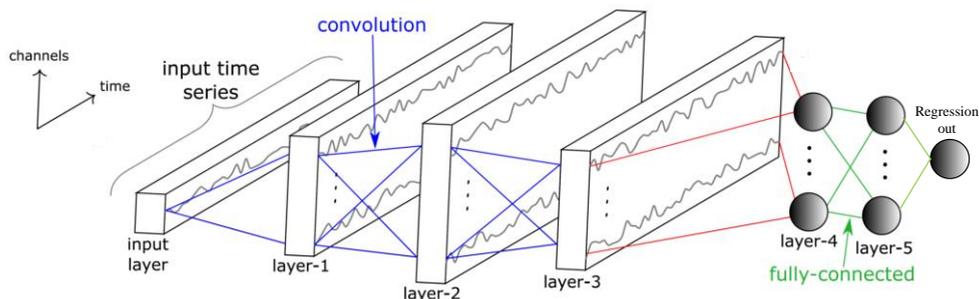


Figura 39. Ilustración de 1D-CNN basado 3 capas convolucionales y 2 full-connected layers para resolver problema de regresión (figura extraída de [127] modificada por el autor).

La principal diferencia con 2D-CNN reside en la capa convolucional (ver Figura 40). Partiendo de las series temporales multivariadas (número de serie temporal $n=8$, en el ejemplo de la figura), la convolución del *kernel* con los datos solo se desplaza en la dimensión del tiempo, esto obliga a que el tamaño de *kernel* coincida con el número de señales, en este caso, $K \times 8$. Específicamente el ejemplo de la figura ilustra la convolución de un kernel 2×8 con la serie temporal multivariable.

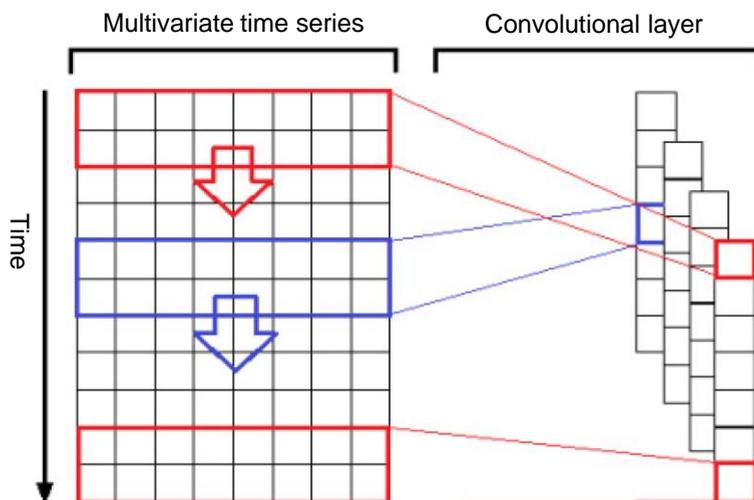


Figura 40. Capa convolucional de 1D-CNN con tamaño de kernel $K=2$, se han aplicado 4 filtros kernel simultáneamente [150].

5.4.5.2. Aplicación a corrientes de fuga

Tal como se mencionó anteriormente, se pretende desarrollar para cada técnica de regresión dos modelos de predicción de la corriente de fuga a partir de las muestras actuales y las últimas $P+1$ muestras de las variables ambientales. La Figura 41 muestra el proceso de la convolución con las últimas $P+1$ muestras de variables ambientales para el tamaño de $kernel\ K=1$. Dado que hay 4 variables ambientales de entrada, el tamaño de kernel es de 4×1 . A la izquierda se muestra el detalle de la operación del producto y suma de la convolución con un determinado filtro $kernel$, y a la derecha se muestra el resultado de la convolución simultánea con n filtros kernel.

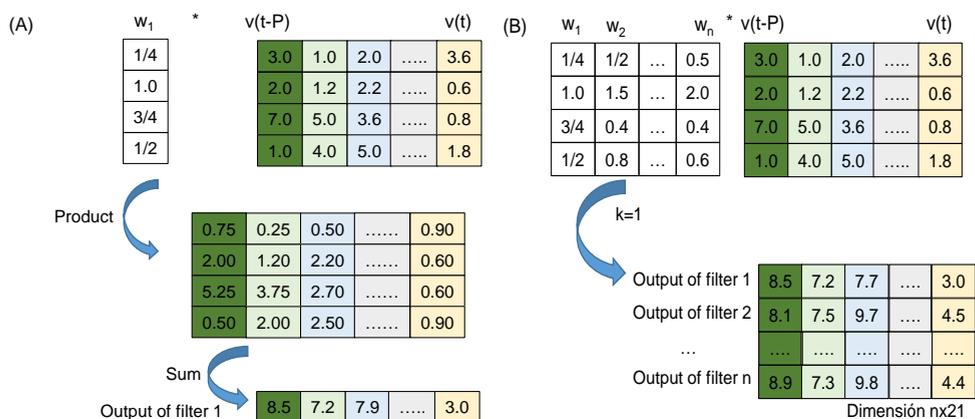


Figura 41. (A) Ilustración del proceso de convolución para kernel de tamaño $K=1$. $v(t-P)$, ..., $v(t)$ representan las últimas $P+1$ muestras de las variables ambientales: temperatura, humedad, dirección y velocidad del viento. w_1 corresponde a los pesos ponderados de cada variable ambiental de un determinado filtro del kernel. (B) Resultado de la aplicación simultánea de n filtros del kernel. (solo efecto ilustrativo, los datos son ficticios).

La Figura 42 muestra el proceso de la convolución con las últimas $P+1$ muestras de variables ambientales para el tamaño de kernel $K=3$.

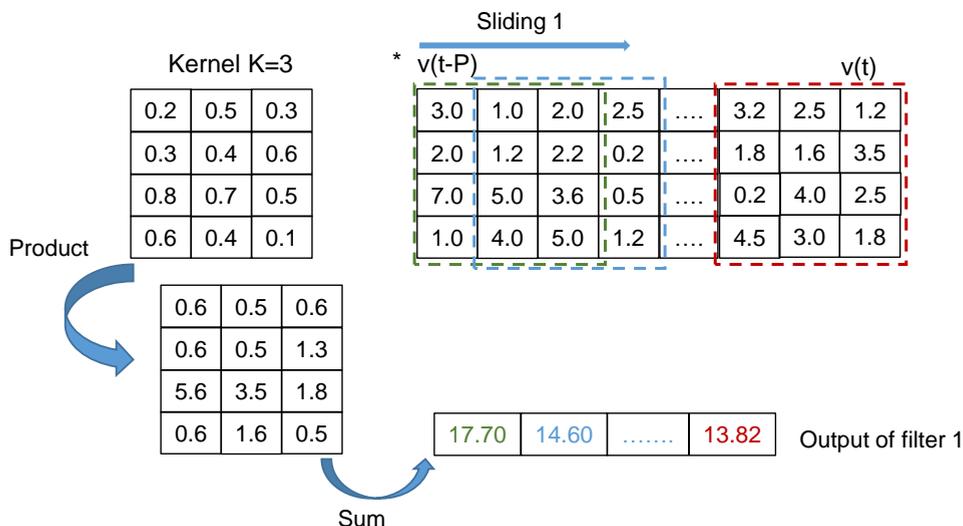


Figura 42. Ilustración del proceso de convolución y submuestreo con un kernel $K=3$. $v(t-P)$, ..., $v(t)$ representan las últimas $P+1$ muestras de las variables ambientales: temperatura, humedad, dirección y velocidad del viento (solo efecto ilustrativo, datos ficticios). Solo se muestra en detalle la operación de producto y suma la primera submatriz remarcado en verde.

En el caso de que el tamaño del kernel sea mayor que 1, entonces se presenta el problema del efecto de borde ya que la convolución debe tener lugar dentro de los límites de la serie temporal (*valid padding*), es decir, la dimensión del mapa de características a la salida de la capa convolucional se reduce en $(K-1)$ suponiendo que el desplazamiento es 1, donde K es el tamaño del *kernel*. Para ello, se ha propuesto la técnica de *same padding*, que consiste en añadir vectores de ceros a los tensores de entrada en los bordes, para alinear el centro del *kernel* en el elemento más externo del tensor de entrada y mantener la misma dimensión en el mapa de características a través de la operación de convolución. Consecuentemente se garantiza la integridad de los datos al procesarlos [151]. En la Figura 43 se muestra la diferencia entre *same padding* y *valid padding* para 1D-CNN con 4 características de entrada.

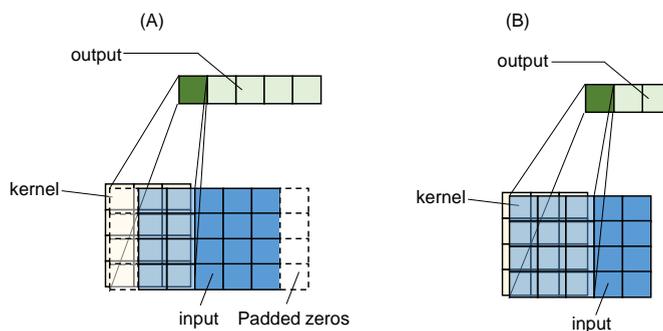


Figura 43. Modos de padding para 1D-CNN con 4 características de entrada (sombreado azul de dimensión 4×5 , solo efecto ilustrativo) y un kernel de tamaño $K=3$ (sombreado ocre) y un desplazamiento de 1, donde cada fila de la matriz de entrada corresponde a la información de la temperatura, humedad, dirección y velocidad de viento, cada columna corresponde a las 4 variables ambientales de un determinado instante dato. (A) *Same padding*. (B) *Valid padding*.

En esta tesis, se han ensayado 3 arquitecturas de red de 1D-CNN. La primera arquitectura se basa en dos capas convolucionales estándares, por lo que de aquí en adelante se denominará 2SL-CNN. Dado que se trata de 1D-CNN para regresión, la primera dimensión del *kernel* en la capa convolucional, viene predefinida por el número de características de entrada: temperatura, humedad, dirección y velocidad del viento. En esta tesis, se ha preestablecido el tamaño del

kernel de 4×1 y 4×3 en función de si se utiliza las muestras actuales o las últimas $P+1$ muestras de variables ambientales, y el desplazamiento del *kernel* en el tiempo en las dos capas convolucionales a 1. Además, se utilizaron un total de 128 filtros en las dos capas convolucionales y en la función de activación ReLU. Mencionar que el tamaño de Kernel 4×5 obtuvo resultados similares cuando se utilizan las últimas $P+1$ muestras de variables ambientales para la predicción de la corriente de fuga. Para el caso de utilizar las $P+1$ muestras como características de entrada, se ha utilizado la técnica de *same padding* para preservar la dimensión del mapa de características por lo que la convolución de cada filtro *kernel* con los datos de entrada obtiene un vector $P+1$ muestras. El resultado de la segunda convolución se ha utilizado como entrada de las *fully connected layers* a través del proceso de aplanamiento. En este caso, se ha utilizado dos *fully connected layers* con 200 y 100 neuronas respectivamente, ambas con la función de activación ReLU. Finalmente, la capa de salida regresiva que proporciona la predicción de la corriente de fuga está formada por una neurona con activación lineal. Destacar que tanto el número de filtros, como el número de neuronas en las capas de redes neuronales densas, son determinados experimentalmente para lograr un compromiso entre la precisión de modelo y el coste computacional. Las Figura 44 y Figura 45 muestran las arquitecturas de red de 2SL-CNN cuando se utiliza las muestras actuales y las $P+1$ muestras de las variables ambientales para la predicción de corriente de fuga respectivamente.

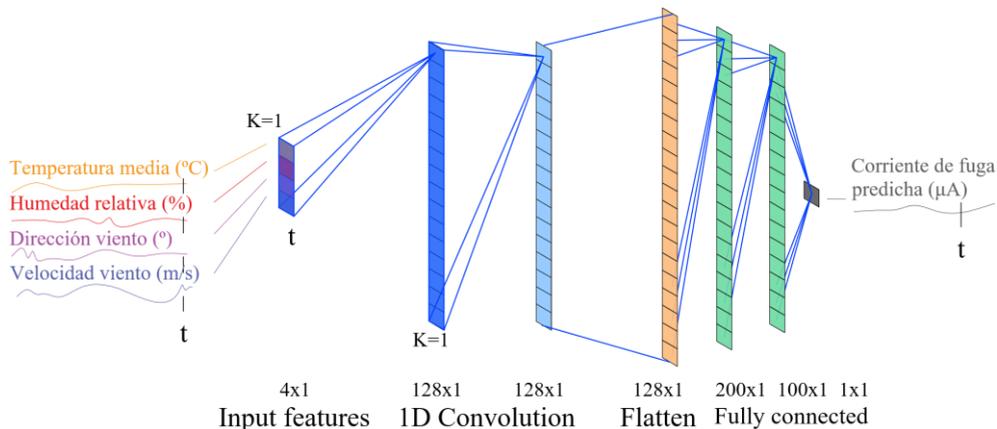


Figura 44 Arquitectura de CNN basado en 2 capas convolucionales estándar (2 standard layers CNN, 2SL-CNN) para la predicción de corriente de fuga utilizando las muestras actuales de variables ambientales.

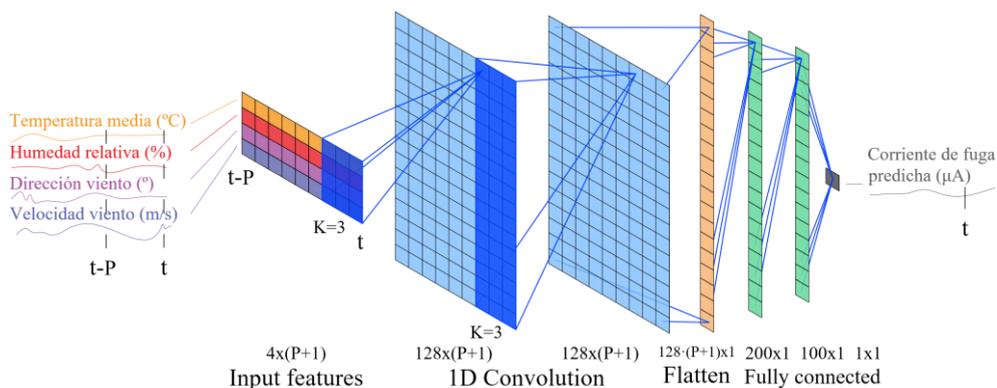


Figura 45. Arquitectura de CNN basado en 2 capas convolucionales estándar (2 standards layers CNN, 2SL-CNN) para la predicción de corriente de fuga utilizando las últimas $P+1$ muestras de variables ambientales.

Asimismo, se ha ensayado una variante de CNN basada en arquitectura *inception*. La arquitectura *inception* fue introducida por el GoogLeNet, el ganador del concurso Imagenet de reconocimiento visual a gran escala [152], y el principal objetivo de esta arquitectura era lograr una alta precisión con un bajo coste computacional [153]. Szegedy *et al.* demostró la posibilidad de desarrollar clasificadores de imágenes más precisos, incluso con 12 veces menos parámetros que la arquitectura ganadora de Krizhevsky *et al.* de 2012 [133]. Asimismo, se ha demostrado la superioridad de la arquitectura *inception* respecto

al estado de arte en el campo de visión artificial, obteniendo el 3.5% de error en el Top-5 del conjunto de validación y 17.3% de error en Top-1 del conjunto de validación [154]. La idea básica de la convolución consiste en determinar la estructura local de los datos de entrada, así como su distribución espacial. Suponemos que cada celda de las capas inferiores (las cercanas a la entrada) corresponde a alguna característica relevante (por ejemplo, borde) de una determinada región de la imagen de entrada. La convolución con un determinado filtro kernel, contiene la distribución espacial de esa característica (imagen de borde). Los bancos de filtros contienen por tanto la distribución espacial de distintas características relevantes, por ejemplo, borde, color, gradiente de orientación entre otros. En general, la convolución con kernel $K=1$, se utiliza para determinar la estructura local de los datos de entrada [155]. También existen características más complejas, que deben tener en cuenta la información de celdas vecinas, que requieren la convolución con filtros kernel de mayor tamaño ($K=3$, $K=5$). En general, el número de características complejas tiende a disminuir con regiones de imagen cada vez más grande [153]. Por tanto, éstas requieren una representación dispersa en la mayoría de las regiones de entrada [156].

La arquitectura *Inception* consiste en convolucionar simultáneamente los datos de entrada con distinto tamaño del *kernel* en cada capa ($K=1$, $K=3$ y $K=5$), y se propone una convolución con kernel $K=1$ antes de las convoluciones computacionalmente costosas ($K=3$ y especialmente $K=5$), para reducir el coste computacional gracias a la función de activación ReLU, que se aplica con la convolución, permitiendo lograr una representación dispersa de los datos. Finalmente se combinan todas las salidas de los bancos de filtro concatenándolos para formar la entrada de la siguiente etapa. Con ello, se logra tener la información local y regional en el mismo mapa de características. La aplicación sucesiva de la arquitectura *inception* permite extraer información de regiones cada vez más grandes. En la

Figura 46 se muestra la arquitectura inception original propuesta por Szegedy *et al.* para el procesamiento de imágenes.

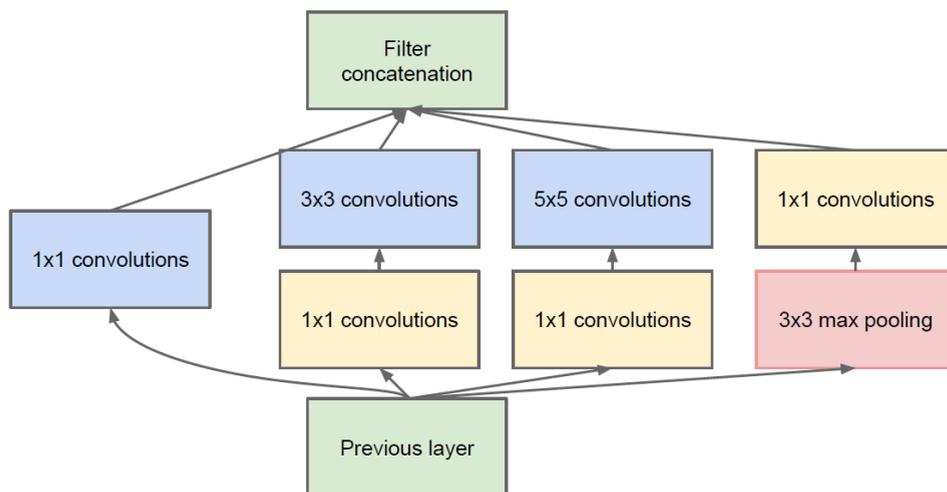


Figura 46. Arquitectura inception propuesta por Szegedy *et al.* [153].

La arquitectura *inception* fue adaptada rápidamente en múltiples aplicaciones. Halawa *et al.* sugirió que la arquitectura *inception* mejora la exactitud de reconocimiento facial, para prevenir las incidencias criminales, con cámaras CCTV (circuito cerrado de televisión) [157]. Yang *et al.* propuso la arquitectura *inception* para mitigar el problema de escala y aspecto de ratio, para la detección de textos de escena multiorientados [158]. La arquitectura *inception*, en combinación con el submuestreo deformable para adaptarse a múltiples orientaciones, demostró su superioridad tanto en eficacia como en eficiencia con respecto al estado de arte [158]. Se ha confirmado que la CNN con arquitectura inception permite mejorar tanto la exactitud (hasta >16% que otras técnicas) como tiempo de calibración, en aplicaciones de Interfaz cerebro-computador, específicamente en deletreadores basados en potenciales evocados visuales [159].

Dado que las capas de convolución inception estaban originalmente pensadas para procesamiento de imágenes con entradas bidimensionales, en esta tesis se ha adaptado la capa inception a 1D-CNN para regresión, cuando se utilizan las últimas P+1 muestras

como características de entrada. La arquitectura *inception* consiste en 3 flujos convolucionales en paralelo, donde la capa previa es común a todas ellas. El primer flujo consiste únicamente en una convolución simultánea con 64 filtros, con un tamaño de *kernel* $K=1$. De nuevo, se ha aplicado *same padding* para preservar la dimensionalidad del mapa de características y la función de activación *ReLU*. El segundo flujo consiste en 2 capas convolucionales en cascada, con el tamaño de *kernel* $K=1$ y $K=3$, en la primera y segunda capa respectivamente. De nuevo, se ha configurado el número de filtros, que se aplican simultáneamente, en 64 filtros en ambas capas. Del mismo modo, se ha aplicado la técnica de *same padding* y función de activación *ReLU*. El tercer flujo es muy similar al segundo, con dos capas convolucionales en cascada con el tamaño de *kernel* $K=1$ y $K=5$, en la primera y segunda capa respectivamente. Mencionar que la salida de cada flujo es de dimensión $64 \times (P+1)$. Después, los 3 flujos convergen para formar una única salida de dimensión $192 \times (P+1)$ a través de una concatenación. En la práctica se puede repetir N veces la arquitectura *Inception* en cascada para lograr una red de mayor profundidad, extrayendo las características relevantes tanto locales como de horizontes temporales lejanos. Con salida de la última capa convolucional, basada en arquitectura *inception*, se formó a un vector de características de $(192 \times (P+1)) \times 1$, a través de aplanamiento. A continuación, se han utilizado dos capas de redes neuronales densas (*fully Connected layers*) como cabezal regresor con 200 y 100 neuronas respectivamente, ambas con la función de activación *ReLU*. Finalmente, la salida regresiva que proporciona la predicción de la corriente de fuga, está formada por una neurona con activación lineal. Destacar que no se ha utilizado la capa de submuestreo, por la baja dimensionalidad de las características de entrada como se verá más adelante. Tanto el número del filtro, como números de neuronas en las capas de redes neuronales densas son determinados experimentalmente para lograr un compromiso entre precisión de modelo y el coste computacional.

En esta tesis, se han ensayado 2 modelos de regresión basados en arquitectura *inception* para la predicción de la corriente de fuga, a

partir de las últimas P+1 muestras de variables ambientales, donde la única de diferencia entre ambos modelos es el número de capas convolucionales basadas en arquitectura *inception*. Específicamente se ha ensayado 2 capas y 4 capas convolucionales basadas en arquitectura *inception*, de aquí en adelante se les denominará como 2IL-CNN y 4 IL-CNN respectivamente. Asimismo, se ha adaptado la arquitectura *inception* para datos de entrada unidimensionales cuando sólo se utilizan las muestras actuales como características de entrada. En la Figura 47 y en la Figura 48 se muestra el flujograma de las CNN con arquitectura *inception* (IL-CNN) para la predicción de la corriente de fuga, donde las características de entrada son las muestras actuales y las últimas P+1 muestras de variables ambientales respectivamente.

Para entrenar el modelo se utilizó el optimizador Adam [160], donde la función de pérdida es el R^2 de la regresión. Se ha utilizado un tamaño de lote (batch size) de 128 muestras. Asimismo, se ha utilizado la técnica de “early stopping” en el grupo de validación, para evitar el sobreentrenamiento del modelo, que consiste en detener el algoritmo si en 15 iteraciones sucesivas no logra mejorar la función objetivo (R^2 del grupo de validación).

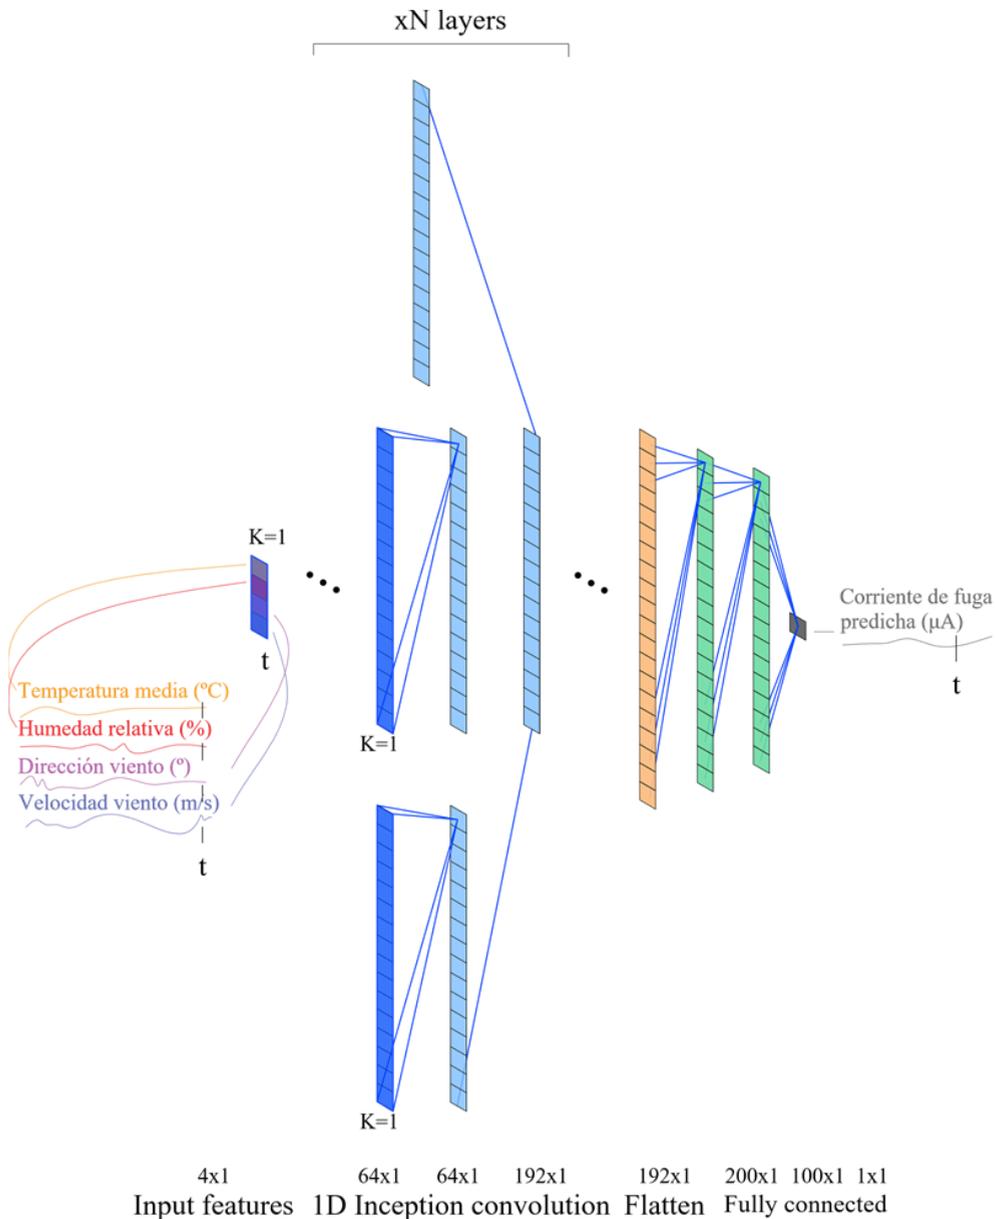


Figura 47. Diagrama de flujo de la red neuronal convolucional basado en N capas de arquitectura Inception para la predicción de corriente de fuga, donde las características de entrada son las muestras actuales de variables ambientales.

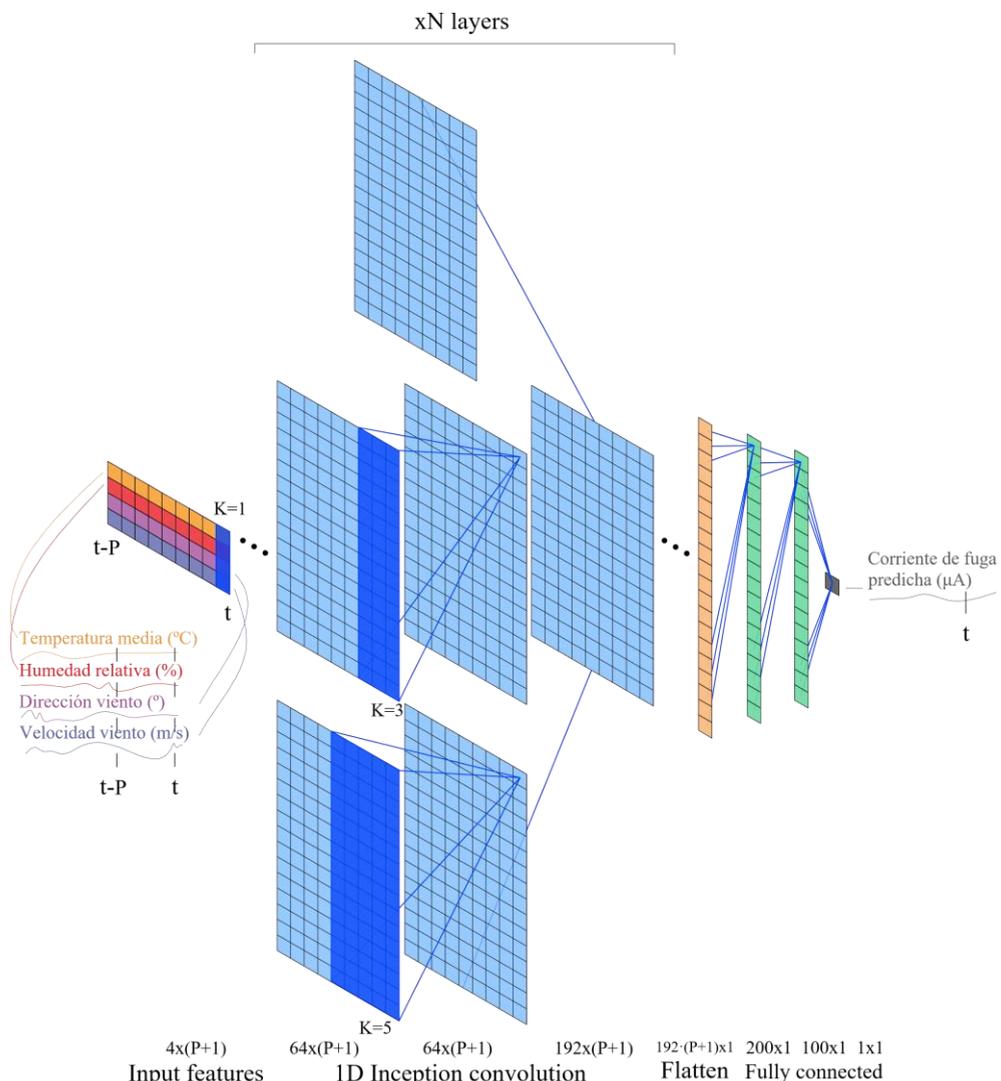


Figura 48. Diagrama de flujo de la red neuronal convolucional basada en N capas de arquitectura Inception para la predicción de corriente de fuga, donde las características de entrada son las últimas $P+1$ muestras de variables ambientales.

5.4.6. Evaluación del rendimiento de los modelos

Con el objeto de determinar el rendimiento del modelo, se han calculado las métricas comúnmente utilizadas en la regresión: coeficiente de determinación R^2 , error cuadrático medio normalizado

(NRMSE) y error absoluto medio (NMAE). En primer lugar, dado que R^2 se encuentra en el rango entre 0 y 1, cuanto mayor es el R^2 , más precisa es la predicción. Asimismo, en esta tesis, se ha optado por normalizar los indicadores del error para que sean comparables entre los distintos aisladores, es decir, que sean independientes de la magnitud de la corriente de fuga. Tras la normalización, tanto el NRMSE como el NMAE se encuentran en el rango entre 0 y 100, una predicción perfecta obtendría valores de 0 en estas métricas.

$$R_i^2 = 1 - \frac{\sum_{k=1}^N (e_i[k] - \hat{e}_i[k])^2}{\sum_{k=1}^N (e_i[k] - \bar{e}_i)^2} \quad \text{Donde } \bar{e}_i = \frac{1}{N} \sum_{k=1}^N e_i[k], \forall i = 1 \dots 7; \quad (23)$$

$$NRMSE_i = \frac{\frac{1}{N} \sum_{k=1}^N (e_i[k] - \hat{e}_i[k])^2}{\frac{1}{N} \sum_{k=1}^N (e_i[k])^2} \cdot 100 (\%) \quad (24)$$

$$NMAE_i = \frac{\frac{1}{N} \sum_{k=1}^N |e_i[k] - \hat{e}_i[k]|}{FS_i} \cdot 100 (\%) \quad (25)$$

Donde FS_i es el rango de la corriente de fuga registrada de cada aislador $e_i[k]$, $\forall i = 1 \dots 7$, que se define como la diferencia entre el valor máximo y mínimo. La anotación de \bar{e}_i hace referencia al valor promedio de la corriente fuga registrada de cada aislador i , $\forall i = 1 \dots 7$, mientras que $\hat{e}_i[k]$ es la predicción de la corriente de fuga del aislador i estimada por cada modelo.

Asimismo, independientemente de la técnica que se ha utilizado para la predicción de la corriente fuga (MVR, SVR, 2SL-CNN, 2IL-CNN y 4IL-CNN), para cada aislador así como para el total de los 7 aisladores, se ha analizado la diferencia significativa de las distintas métricas entre los grupos de entrenamiento, validación y test (C1 de

la Tabla 3), mediante la prueba del rango con signo de Wilcoxon (Wilcoxon signed Rank test, $\alpha=0.05$) tanto para las muestras actuales como para cuando se utilizan las últimas P+1 muestras. Este test estadístico es una prueba no paramétrica para muestras emparejadas, y es una alternativa a las pruebas t de Student, cuando no se puede asumir la distribución normal de los datos. Además, se ha determinado la significancia estadística entre los modelos obtenidos utilizando las muestras actuales y las últimas P+1 muestras (C2 de la Tabla 3), tanto en los grupos de entrenamiento, validación y test. De nuevo se ha utilizado la prueba del rango con signo de Wilcoxon.

Tabla 3. Análisis estadístico aplicado a cada aislador y el total de los 7 aisladores. Este análisis se realiza en cada una de las técnicas utilizadas para la predicción de la corriente de fuga (MVR, SVR, 2SL-CNN, 2IL-CNN, y 4IL-CNN).

Métrica	Características de entrada	Entrenamiento	Validación	Test
R ²	Muestra actual			
	Últimas P+1 muestras	C2 ↓	C1 ↓	↓
NRMSE	Muestra actual			
	Últimas P+1 muestras	C2 ↓	C1 ↓	↓
NMAE	Muestra actual			
	Últimas P+1 muestras	C2 ↓	C1 ↓	↓

Finalmente, se han comparado los rendimientos del modelo en el grupo de test obtenido, con las distintas técnicas para cada aislador y para el conjunto de los 7 aisladores analizados (ver C3 de Tabla 4). Para ello, se ha utilizado el test Friedman ($\alpha=0.05$) que es una alternativa no paramétrica a la prueba ANOVA de una vía, cuando los datos son dependientes (pareados). Se trata de una extensión de la prueba del rango con signo de Wilcoxon para más de dos grupos. En el caso de que el test Friedman indique que hay diferencia significativa entre las técnicas, se empleará de nuevo la prueba del rango con signo de Wilcoxon entre cada pareja de técnicas, para determinar su significancia estadística.

Tabla 4. Test Friedman aplicado a cada métrica del modelo (R^2 , NRMSE y NMAE) para el análisis comparativo de las distintas técnicas.

Métrica	MVR	SVR	2LS-CNN	2IL-CNN	4IL-CNN
R^2	←————— C3 —————→				
NRMSE	←————— C3 —————→				
NMAE	←————— C3 —————→				

*Veinte años más tarde estarás más
decepcionado por las cosas que no
hiciste que por las que hiciste.*

Mark Twain

**CAPÍTULO IV:
RESULTADOS**

6. Resultados

6.1 Descripción estadística de los datos

La Figura 49 muestra la evolución temporal de las distintas variables ambientales en bruto. En la Figura 50 se muestra las gráficas de cajas y bigotes de las mismas, excepto la dirección del viento. La Tabla 5 muestra los parámetros estadísticos de las variables ambientales, excepto la dirección del viento. La temperatura presenta una fluctuación anual entre 0°C y 40°C. Las máximas temperaturas se alcanzan en los meses 5-6, 17-18 y 29-30 que corresponde a los meses de julio y agosto, y la temperatura mínima fue registrada en los meses 0, 12 y 24 que corresponde al mes de febrero del periodo analizado. La humedad relativa no presenta una evolución temporal clara, pero se evidencia la fluctuación de la misma y el ambiente húmedo de la subestación en la que se instalaron los aisladores (percentil 50 de 74%). La velocidad del viento en general no es excesivamente alta (<18.1 m/s, percentil 50 1.51 m/s y percentil 90 3.74 m/s), y presenta una variación estacional anual, alcanzando su mínima en los meses 10 y 22.

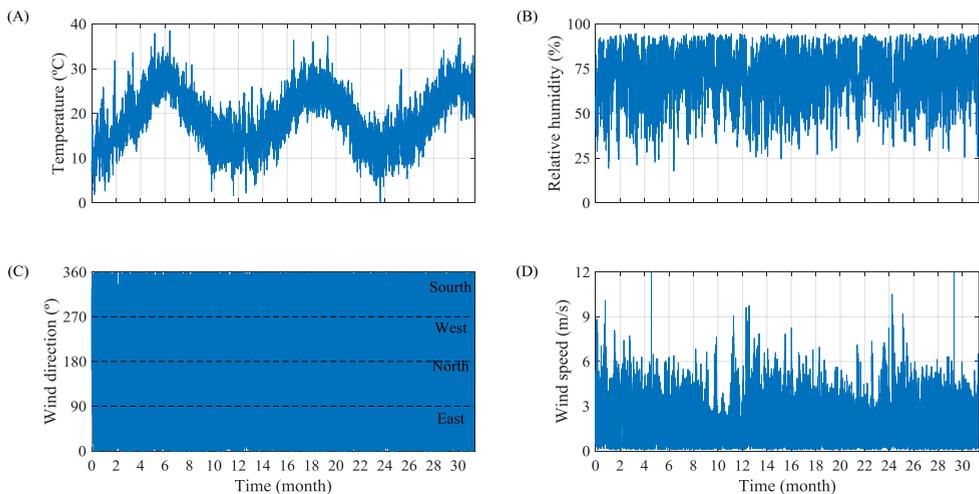


Figura 49. Evolución temporal de las distintas variables ambientales. (A) Temperatura. (B) Humedad relativa. (C) Dirección del viento. (D) Velocidad del viento.

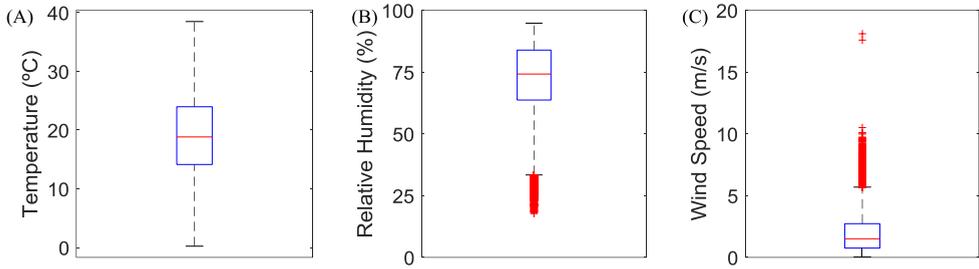


Figura 50. Gráficas de cajas y bigotes de la temperatura, humedad relativa y velocidad del viento.

Tabla 5. Estadística de las variables ambientales, excepto la dirección del viento.

	Temperatura (°C)	Humedad (%)	Velocidad del viento (m/s)
Máximo	38.48	94.80	18.1
Mínimo	0.23	17.73	0.04
Rango	38.25	77.07	18.06
Promedio	18.99	72.52	1.86
Percentil 10	10.84	52.74	0.44
Percentil 25	14.14	63.69	0.76
Percentil 50	18.83	74.21	1.51
Percentil 75	23.97	83.90	2.73
Percentil 90	27.4	89.40	3.74

Como cabe esperar, la evolución temporal de la dirección del viento (Figura 49) no parece aportar información alguna. En cambio, el indicador general del porcentaje de tiempo en el que sopla el viento de este, norte, oeste y sur, así como su evolución temporal mensual (Figura 51A), revela información de la climatología local donde se instalaron los aisladores. Primero, no existe una dirección del viento predominante. Aproximadamente el 70% del tiempo sopla el viento del norte (32%) o del este (38%), siendo el viento del oeste o del sur menos frecuente. En invierno (mes 0, 12 y 24) sopla más viento del sur y del oeste. En verano, los vientos del norte y del este alcanzan su máximo (80%, mes 6, 18, 30).

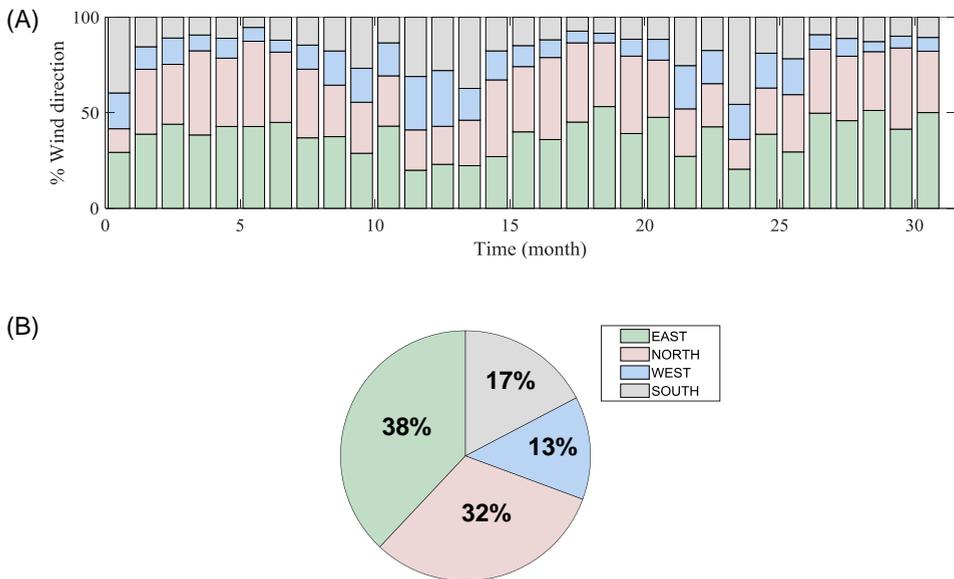


Figura 51. Porcentaje de tiempo en el que sopla el viento del este, norte, oeste y sur. (A) Evolución temporal mensual. (B) Indicador global.

La Figura 52 se muestra la evolución temporal de las corrientes de fuga en bruto registradas en los 7 aisladores. La Figura 53 muestra las gráficas de cajas y bigotes de las corrientes de fuga registradas en los aisladores. La Tabla 6 muestra los parámetros estadísticos de las corrientes de fuga. En ella se puede apreciar que la corriente de fuga presenta una fluctuación anual independientemente del aislador, alcanzando sus valores máximos en los meses 6, 18 y 30 aproximadamente. Asimismo, se evidencia la presencia de unos picos anómalos en las corrientes de fuga en los 7 aisladores, que podrían estar asociados con otros factores externos [48], por ejemplo, cortes de energía o condiciones ambientales adversas extremas como lluvia y heladas. En el aislador 3 se ha registrado mayor corriente de fuga, con un valor máximo de unos 3798 μA y el percentil 90 de unos 716 μA . Las corrientes de fuga en los aisladores 4 y 5 presentan valores máximos sobre los 1900 μA , y el percentil 90 de unos 110-120 μA . Los aisladores 1, 2 y 6 obtuvieron magnitudes similares de la corriente de fuga, donde los valores máximos oscilan entre los 500-650 μA y el percentil 90 entre los 80-112 μA . En cambio, el aislador 7 tiene la menor corriente de fuga de todos los aisladores, con un valor máximo entorno a los 80 μA y el percentil 90 de unos 35 μA .

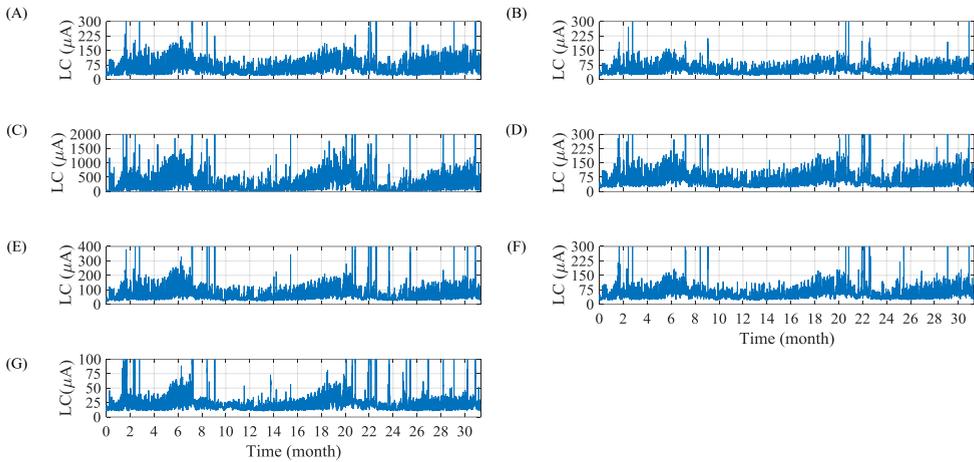


Figura 52. Evolución temporal de la corriente de fuga en aisladores de alta tensión. (A) Aislador 1. (B) Aislador 2. (C) Aislador 3. (D) Aislador 4. (E) Aislador 5. (F) Aislador 6. (G) Aislador 7.

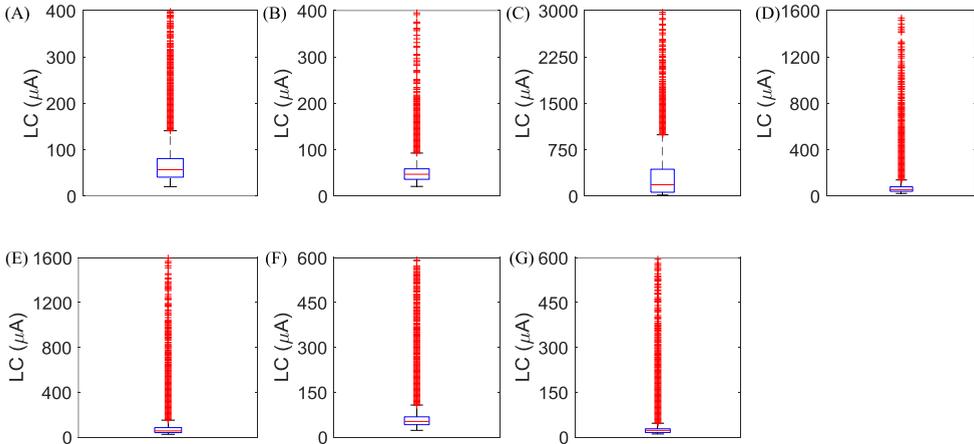


Figura 53. Gráficas de cajas y bigotes de las corrientes de fugas en bruto registradas en los aisladores. (A) Aislador 1. (B) Aislador 2. (C) Aislador 3. (D) Aislador 4. (E) Aislador 5. (F) Aislador 6. (G) Aislador 7.

Las Figura 54 y Figura 55 muestran la evolución temporal del valor promedio diario de las variables ambientales y las corrientes de fuga. Parece evidenciar cierta relación entre promedio diario de la temperatura y de las corrientes de fuga, ya que presentan su valor máximo en el mes 6, 18-19 y 30 (agosto), y su valor mínimo se encuentra entorno al mes 0, 12 y 24 (febrero).

relaciones entre otras variables, si las hay, no se evidencian visualmente.

Tabla 6. Estadística de la corriente de fuga de cada aislador.

Aislador	1 (μA)	2 (μA)	3 (μA)	4 (μA)	5 (μA)	6 (μA)	7 (μA)
Máximo	532	522.80	3798	1919	1963	640.8	671
Mínimo	20.05	20.50	14.82	21.11	24.39	22.42	10.45
Rango	511.95	502.30	3783.2	1897.9	1938.6	618.38	660.55
Promedio	64.15	50.85	286.1	64.409	69.66	58.35	24.12
Percentil10	25.94	26.94	36.15	26.69	31.61	29.58	12.64
Percentil25	40.51	35.81	59.45	39.55	39.94	41.47	15.32
Percentil 50	56.63	46.78	181.5	54.72	54.98	52.34	22.37
Percentil 75	80.60	58.49	431.9	78.87	84.4	67.77	27.73
Percentil 90	112.8	81.40	716.9	114.4	128.4	92.9	35.62

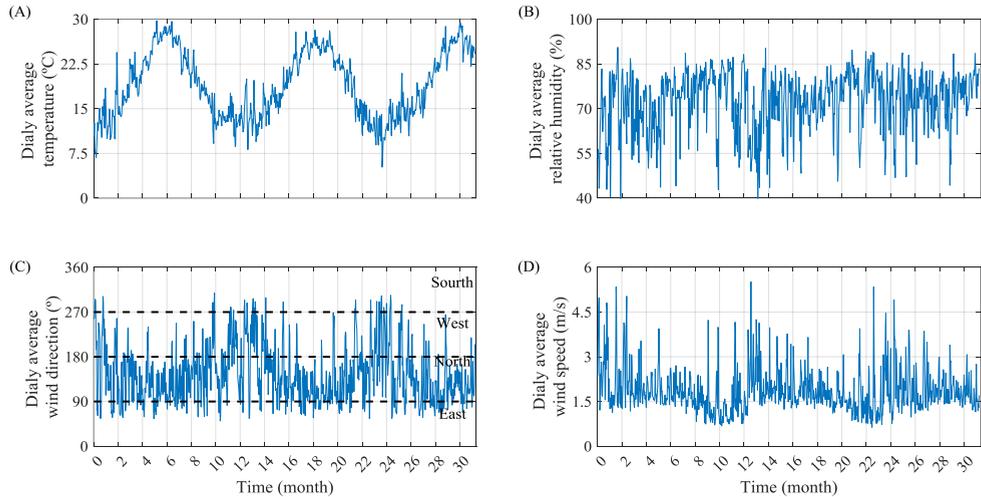


Figura 54. Evolución temporal de las variables ambientales promedios diarios. (A) Temperatura. (B) Humedad relativa. (C) Dirección del viento. (D) Velocidad del viento.

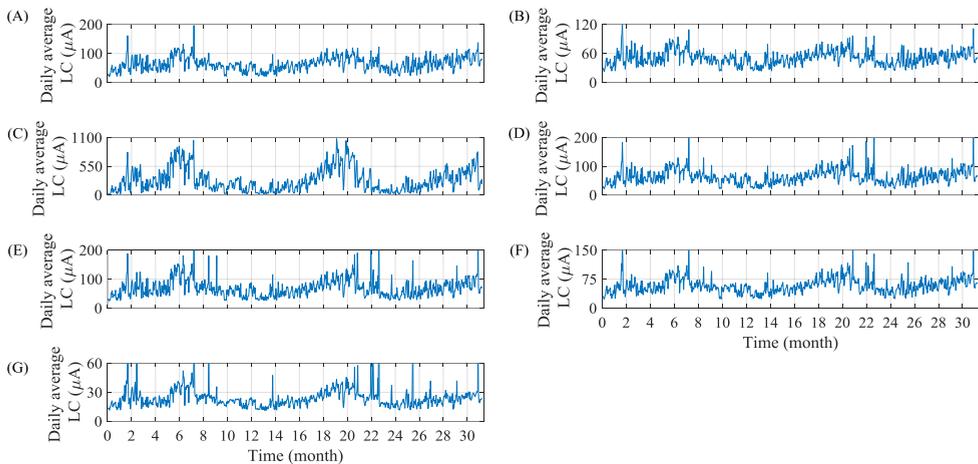


Figura 55. Evolución temporal de la corriente de fuga promedio diaria en aisladores de alta tensión. (A) Aislador 1. (B) Aislador 2. (C) Aislador 3. (D) Aislador 4. (E) Aislador 5. (F) Aislador 6. (G) Aislador 7.

6.2 Relación entre la corriente de fuga y las variables ambientales

La Figura 56 muestra la gráfica de dispersión de la corriente de fuga en bruto del aislador 3 y las diferentes variables ambientales. No se muestran las gráficas de dispersión de los otros aisladores porque se observan las mismas tendencias, pero de distinta magnitud para la corriente de fuga y por tanto no aporta más información de la que ya hay disponible. Ello es debido a que el aislador 3 no dispone de recubrimiento. La corriente de fuga en bruto presenta una relación no lineal débil con la temperatura (ver traza a), con valores más bajos para altas y bajas temperaturas ($T > 30^{\circ}\text{C}$ o $T < 5^{\circ}\text{C}$). No se obtuvo ninguna dirección de viento predominante durante todo el año (véase la traza c). Asimismo, no se observó ninguna relación clara entre la dirección del viento y la corriente de fuga en bruto. En cambio, se puede apreciar una clara relación, no lineal, entre la corriente de fuga en bruto y la humedad (traza b) y la velocidad del viento (traza d); las altas velocidades del viento estaban asociadas con una menor corriente de fuga, mientras que una mayor humedad relativa conllevaba a la obtención de valores mayores de corrientes de fuga.

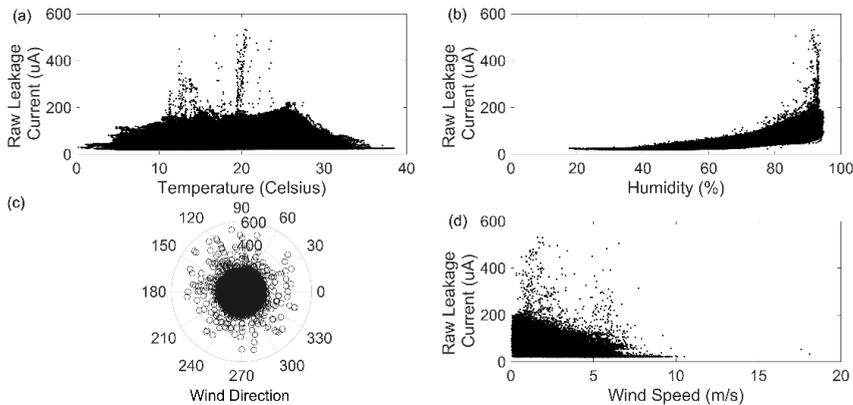


Figura 56. Gráfico de dispersión de la corriente de fuga cruda registrada en el aislador 3 y las diferentes variables ambientales. (a) Temperatura. (b) Humedad relativa. (c) Dirección del viento. (d) Velocidad del viento.

La Tabla 7 muestra, para los diferentes aisladores, el coeficiente de correlación de Spearman de la corriente de fuga en bruto con las diferentes variables ambientales. La figura 57 proporciona el valor R^2 promedio del ajuste por mínimos cuadrados de la corriente de fuga en bruto, con las diferentes variables ambientales de los 7 aisladores, utilizando distintos tipos de regresión: lineal, polinomial y exponencial. Viendo los diferentes gráficos, lo primero que se observa, es que los diferentes aisladores tienen relaciones similares con las diferentes variables ambientales. La corriente de fuga en bruto apenas se correlaciona con la temperatura, logrando un coeficiente de correlación promedio relativamente bajo de 0.139 ± 0.063 . Esto también se refleja en un R^2 promedio bajo (por debajo de 0.05) independientemente del tipo de función de ajuste. En cambio, independientemente del tipo de aislador, se ha observado una fuerte correlación entre la corriente de fuga en bruto y la humedad, obteniendo así un coeficiente de correlación promedio de hasta 0.826 ± 0.051 . En este caso, las funciones polinómicas y exponenciales describen mejor la relación subyacente que la función lineal, obteniendo un R^2 medio de aproximadamente 0.50. La corriente de fuga en bruto, también presenta una relación inversa moderada con la dirección y la velocidad del viento, obteniendo un coeficiente de

correlación promedio de -0.315 ± 0.009 y -0.469 ± 0.036 respectivamente. De forma análoga, las funciones polinómicas y exponenciales definen mejor la relación subyacente de la corriente de fuga en bruto con la dirección y la velocidad del viento ($R^2 \sim 0.25$). Por lo tanto, se ha analizado la correlación parcial de la corriente de fuga en bruto de los aisladores individuales con la humedad, la dirección del viento y la velocidad, controlando los efectos de las otras variables. Como se puede ver en la Tabla 7, la corriente de fuga cruda tiene una alta correlación parcial con la humedad (0.834 ± 0.043) y una correlación parcial considerablemente menor con la dirección y la velocidad de viento -0.076 ± 0.018 y -0.123 ± 0.029 , respectivamente.

Tabla 7. Coeficiente de correlación de Spearman de la corriente de fuga en bruto con las diferentes variables ambientales. Se han obtenido correlaciones parciales de la corriente de fuga en bruto respecto a la humedad relativa, dirección del viento y velocidad, teniendo el efecto de las otras variables controlado.

Aislador	Temperatura		Humedad		Dirección del viento		Velocidad del viento	
	Corr.	Parcial	Corr.	Parcial	Corr.	Parcial	Corr.	Parcial
1	0.114	NA	0.860	0.870	-0.315	-0.070	-0.494	-0.142
2	0.085	NA	0.858	0.853	-0.311	-0.073	-0.490	-0.115
3	0.275	NA	0.717	0.750	-0.334	-0.115	-0.397	-0.117
4	0.116	NA	0.847	0.851	-0.315	-0.077	-0.487	-0.134
5	0.148	NA	0.841	0.858	-0.316	-0.068	-0.484	-0.153
6	0.121	NA	0.849	0.857	-0.313	-0.068	-0.487	-0.135
7	0.114	NA	0.810	0.801	-0.303	-0.063	-0.447	-0.066
$\mu \pm \sigma$	0.139 ± 0.063	NA	0.826 ± 0.051	0.834 ± 0.043	-0.315 ± 0.009	-0.076 ± 0.018	-0.469 ± 0.036	-0.123 ± 0.029

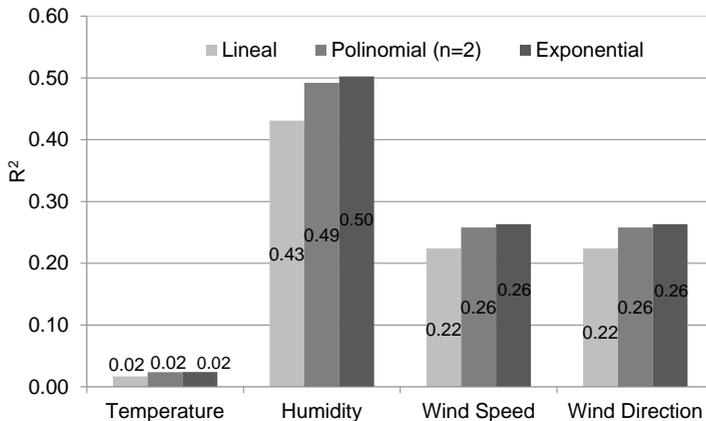


Figura 57. Valor de R^2 medio del ajuste por mínimos cuadrados entre la corriente de fuga en bruto y diferentes variables ambientales para los 7 aisladores.

Asimismo, se han determinado las relaciones causa-efecto entre las distintas variables ambientales y la corriente de fuga registrada en cada aislador. La Figura 58 se muestra el criterio de información Bayesiano para la selección del orden óptimo de los modelos de vectores autoregresivos. Se puede observar que los distintos aisladores tienen un comportamiento bastante similar entre ellos. El orden óptimo de los modelos de vectores autorregresivos se sitúan en entorno al 20, variando desde orden 17 para el aislador 2 al orden 31 para el aislador 5 (ver Tabla 8). Es decir, el modelo óptimo de la corriente de fuga se obtiene cuando se tiene en cuenta la información de las 20 muestras anteriores. Por tanto, se ha considerado emplear las muestras actuales y también las 20 muestras anteriores de las variables ambientales para la predicción de la corriente de fuga de los aisladores.

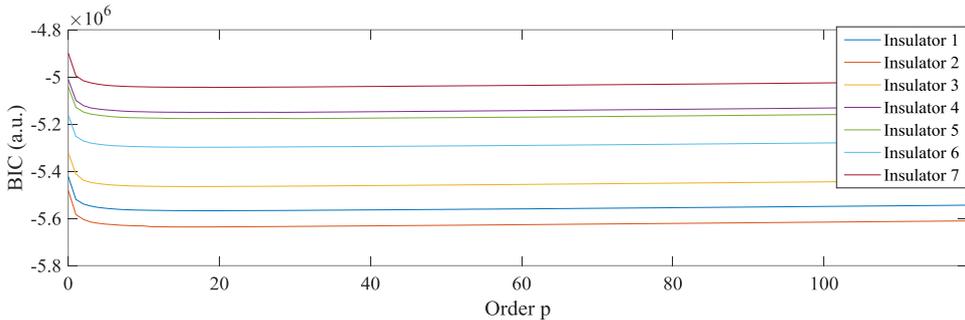


Figura 58. Criterio de información Bayesiano (BIC) para la selección del orden óptimo de los modelos de vectores autoregresivos.

En la Tabla 8 se muestra la fuerza de interacción entre cada variable ambiental y la corriente de fuga, controlando las otras variables ambientales, utilizando la causalidad condicional de Granger. Se puede apreciar que independientemente del aislador, la causalidad entre las distintas variables ambientales y la corriente de fuga es estadísticamente significativa, excepto para la dirección del viento, que solo obtuvo significancia estadística para los aisladores 1-3 y 5. Asimismo, la humedad obtuvo una mayor causalidad de Granger que la velocidad del viento, seguida de la temperatura y de la dirección del viento.

Tabla 8. Causalidad condicional de Granger, de las variables ambientales con la corriente de fuga de cada aislador y el orden óptimo del modelo de vectores autorregresivos. La causalidad estadísticamente significativa está sombreada en color gris.

Aislador	Orden óptimo	Temperatura	Humedad	Dirección del viento	Velocidad del viento
1	19	0.0032	0.0189	0.0003	0.0005
2	17	0.0032	0.0160	0.0002	0.0005
3	18	0.0022	0.0146	0.0002	0.0014
4	21	0.0015	0.0056	0.0001	0.0004
5	31	0.0014	0.0048	0.0002	0.0006
6	17	0.0018	0.0083	0.0001	0.0003
7	20	0.0006	0.0036	0.0001	0.0004
Total	20.4±4.9	0.0020±0.0010	0.0103±0.0061	0.0002±0.0001	0.0006±0.0004

6.3 Estimación de la PLC en aisladores de alta tensión

De la Figura 59 a la Figura 65 se muestra el registro simultáneo de humedad relativa (traza a) y corriente de fuga en bruto (traza b) de los distintos aisladores. La traza c muestra la señal de salida $x[k]$, después de eliminar la influencia de la humedad relativa mediante el filtro adaptativo. Se puede ver, que la evolución del tiempo de las señales de corriente de fuga en bruto y la humedad relativa muestra una tendencia similar, que desaparece después de aplicar el filtro adaptativo. Además, el filtro de diseño propio también filtra adecuadamente los picos anómalos presentes en el registro original, obteniendo una corriente de fuga remanente rectificadora $|z[k]|$ con una variación suave con el tiempo. La corriente de fuga remanente rectificadora $|z[k]|$, presenta una fluctuación cuasi anual con el tiempo, obteniendo el valor mínimo en invierno y el valor máximo en verano.

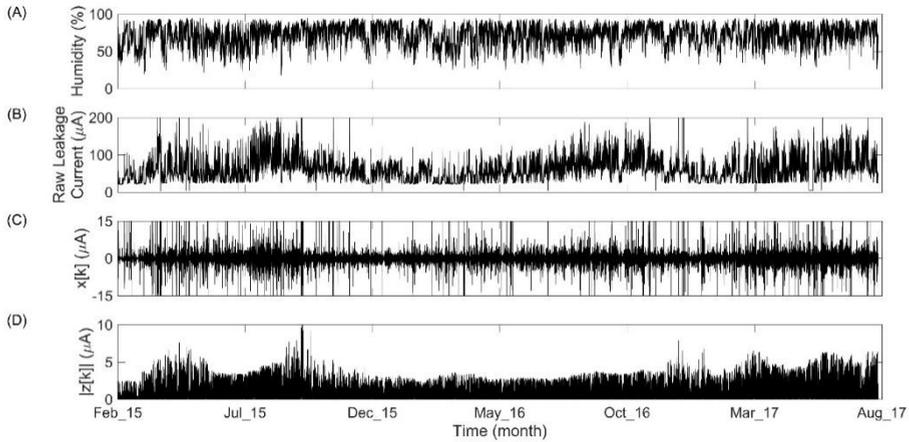


Figura 59. Registro simultáneo de la humedad relativa (A) y la corriente de fuga en bruto de aislador 1 (B) después de cancelar el efecto de la humedad relativa mediante el filtro adaptativo (C) y después de filtrar los picos anómalos en el registro (D).

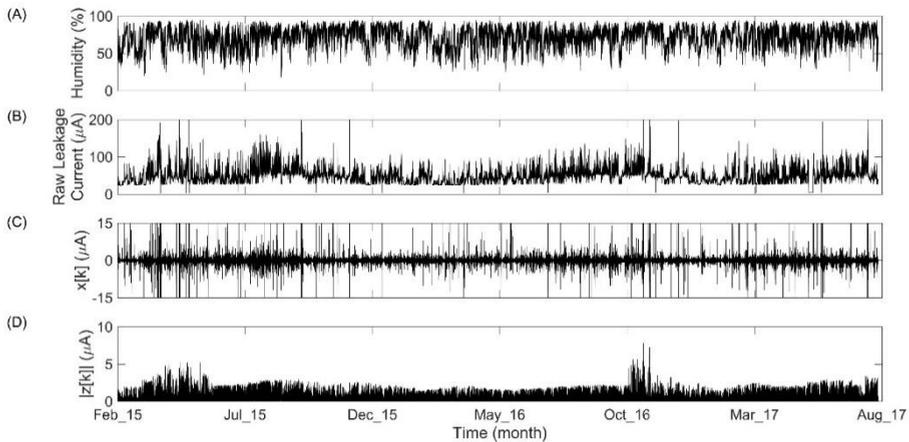


Figura 60. Registro simultáneo de la humedad relativa (A) y la corriente de fuga en bruto de aislador 2 (B) después de cancelar el efecto de la humedad relativa mediante el filtro adaptativo (C) y después de filtrar los picos anómalos en el registro (D).

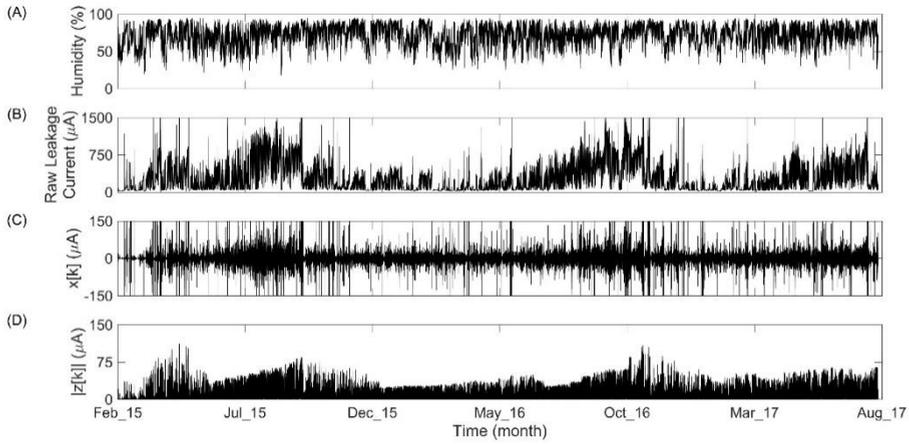


Figura 61. Registro simultáneo de la humedad relativa (A) y la corriente de fuga en bruto de aislador 3 (B) después de cancelar el efecto de la humedad relativa mediante el filtro adaptativo (C) y después de filtrar los picos anómalos en el registro (D).

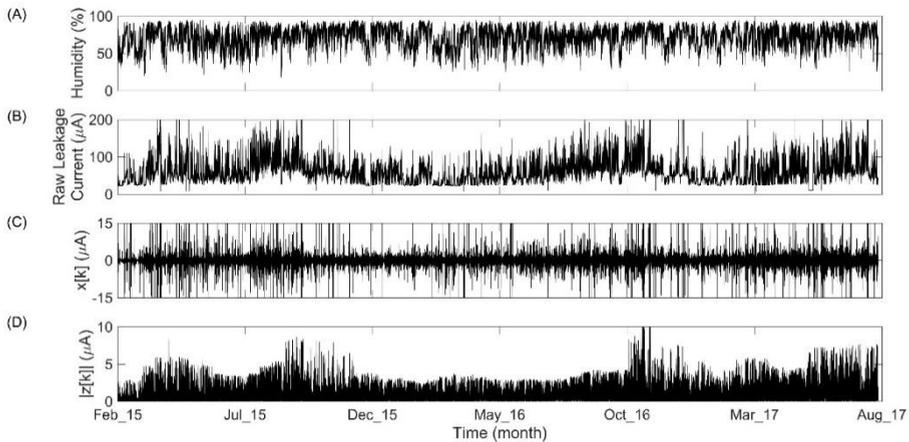


Figura 62. Registro simultáneo de la humedad relativa (A) y la corriente de fuga en bruto de aislador 4 (B) después de cancelar el efecto de la humedad relativa mediante el filtro adaptativo (C) y después de filtrar los picos anómalos en el registro (D).

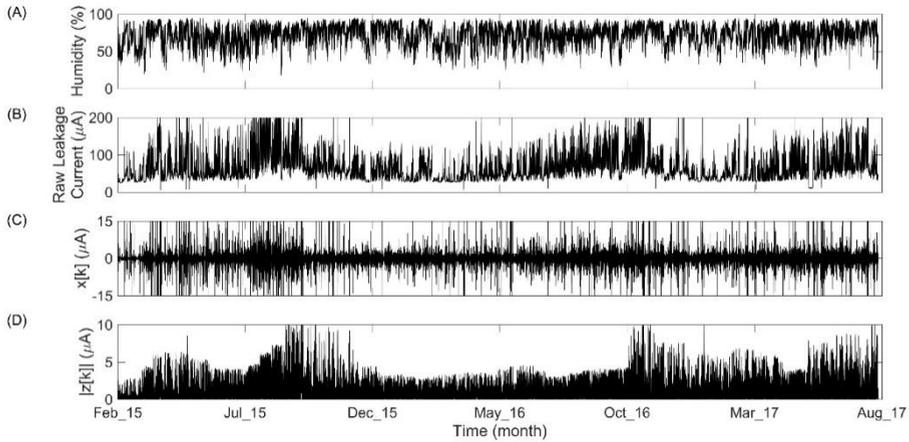


Figura 63. Registro simultáneo de la humedad relativa (A) y la corriente de fuga en bruto de aislador 5 (B) después de cancelar el efecto de la humedad relativa mediante el filtro adaptativo (C) y después de filtrar los picos anómalos en el registro (D).

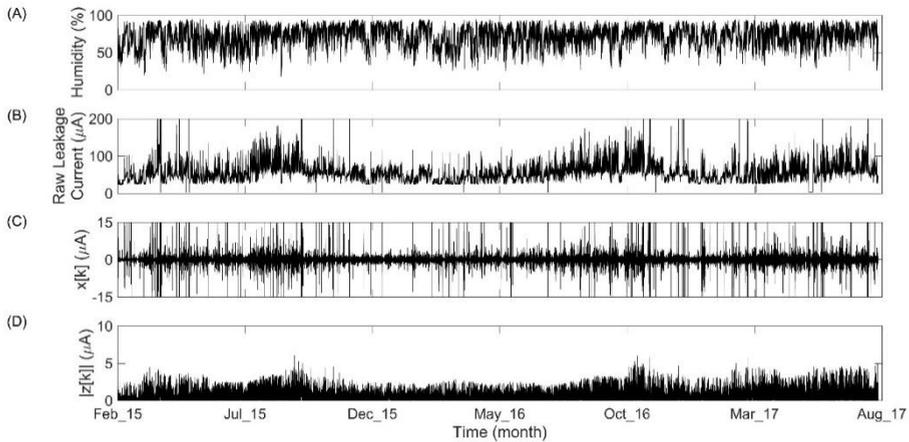


Figura 64. Registro simultáneo de la humedad relativa (A) y la corriente de fuga en bruto de aislador 6 (B) después de cancelar el efecto de la humedad relativa mediante el filtro adaptativo (C) y después de filtrar los picos anómalos en el registro (D).

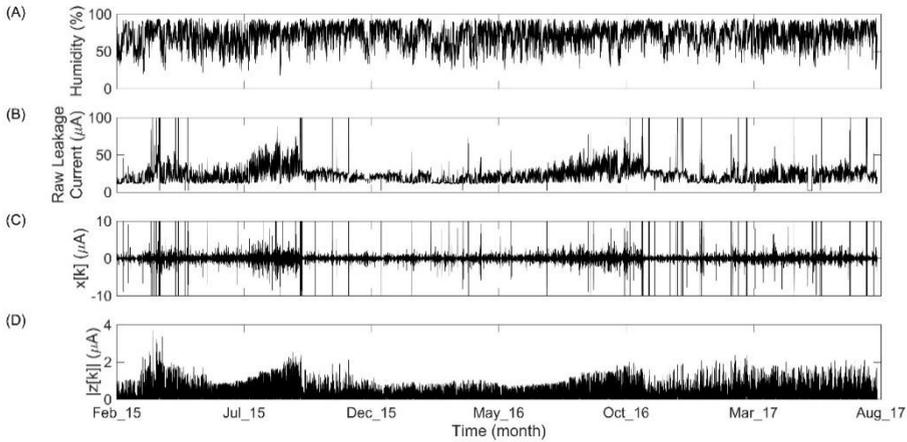


Figura 65. Registro simultáneo de la humedad relativa (A) y la corriente de fuga en bruto de aislador 7 (B) después de cancelar el efecto de la humedad relativa mediante el filtro adaptativo (C) y después de filtrar los picos anómalos en el registro (D).

De La Figura 66 a la Figura 72 se muestran las gráficas de dispersión de la corriente de fuga en bruto (izquierda) y las diferentes variables ambientales de los distintos aisladores. A la derecha de estas figuras se muestran las gráficas de dispersión de la corriente remanente rectificadora $|z[k]|$ vs. las diferentes variables ambientales. Se puede apreciar claramente la relación de la corriente de fuga en bruto con la humedad relativa. Cuanto mayor es humedad relativa, mayor es la corriente de fuga en bruto. En cambio, la relación de la corriente de fuga en bruto con las otras variables ambientales es bastante más sutil. A diferencia de la corriente de fuga en bruto, no se ha encontrado ninguna relación específica de la corriente de fuga remanente rectificadora $|z[k]|$ con ninguna de las variables ambientales, incluyendo la humedad relativa.

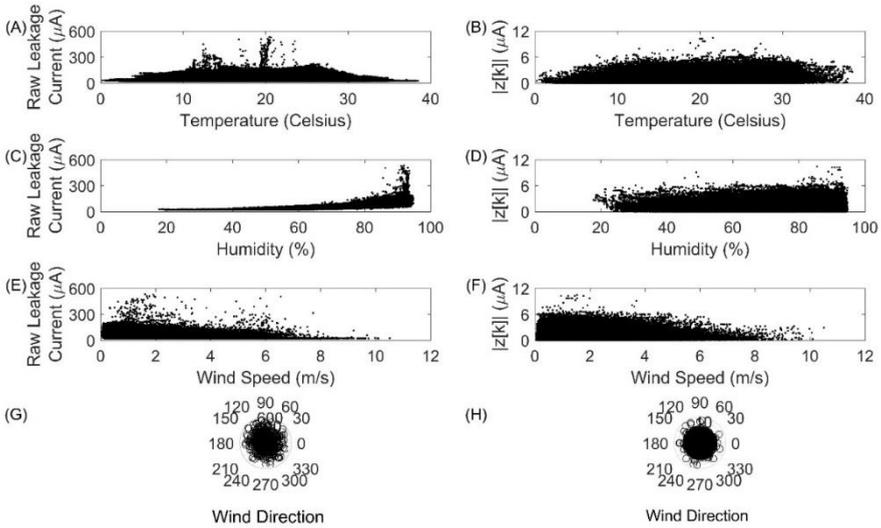


Figura 66. Diagramas de dispersión de la corriente de fuga en bruto el aislador 1 vs. a las diferentes variables ambientales: (A) Temperatura. (C) Humedad relativa (E) Velocidad del viento (G) Dirección del viento y la corriente de fuga remanente rectificad $|z[k]|$ vs. las diferentes variables ambientales: (B) Temperatura. (D) Humedad relativa. (F) Velocidad del viento (H) Dirección del viento.

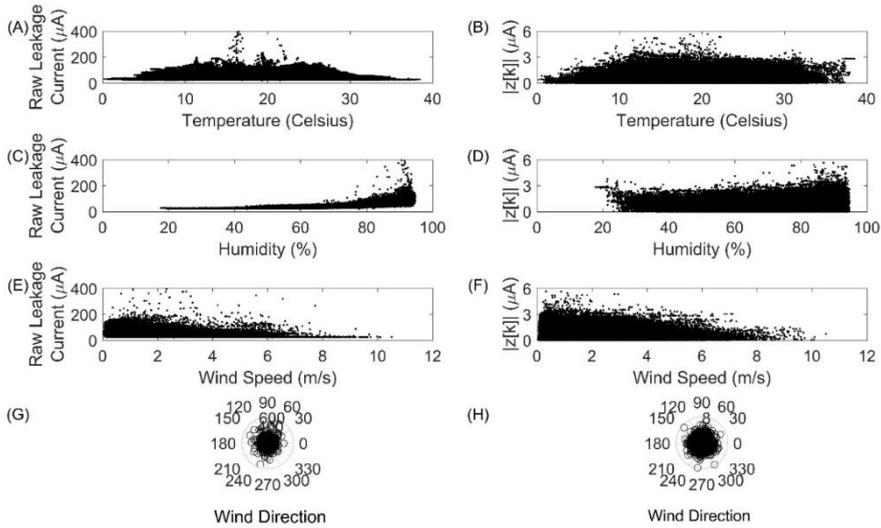


Figura 67. Diagramas de dispersión de la corriente de fuga en bruto el aislador 2 vs. a las diferentes variables ambientales: (A) Temperatura. (C) Humedad relativa (E) Velocidad del viento (G) Dirección del viento y la corriente de fuga remanente rectificad $|z[k]|$ vs. las diferentes variables ambientales: (B) Temperatura. (D) Humedad relativa. (F) Velocidad del viento (H) Dirección del viento.

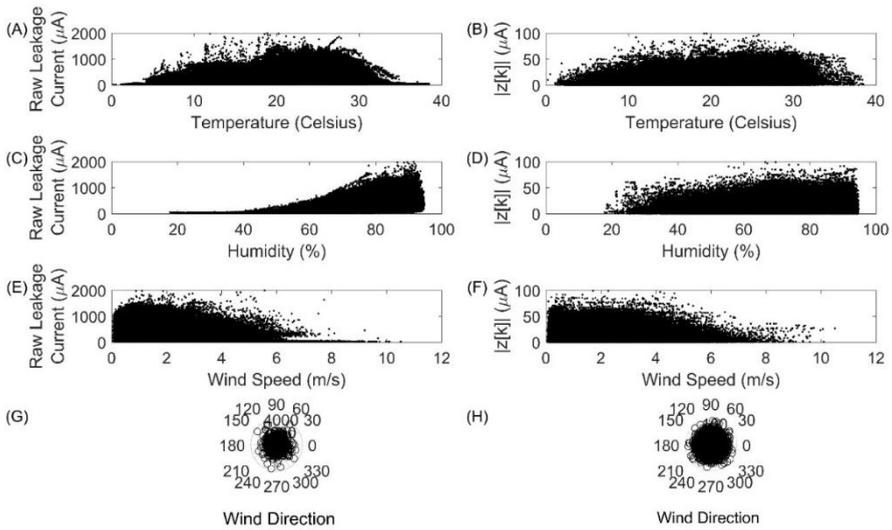


Figura 68. Diagramas de dispersión de la corriente de fuga en bruto el aislador 3 vs. a las diferentes variables ambientales: (A) Temperatura. (C) Humedad relativa (E) Velocidad del viento (G) Dirección del viento y la corriente de fuga remanente rectificadas $|z[k]|$ vs. las diferentes variables ambientales: (B) Temperatura. (D) Humedad relativa. (F) Velocidad del viento (H) Dirección del viento.

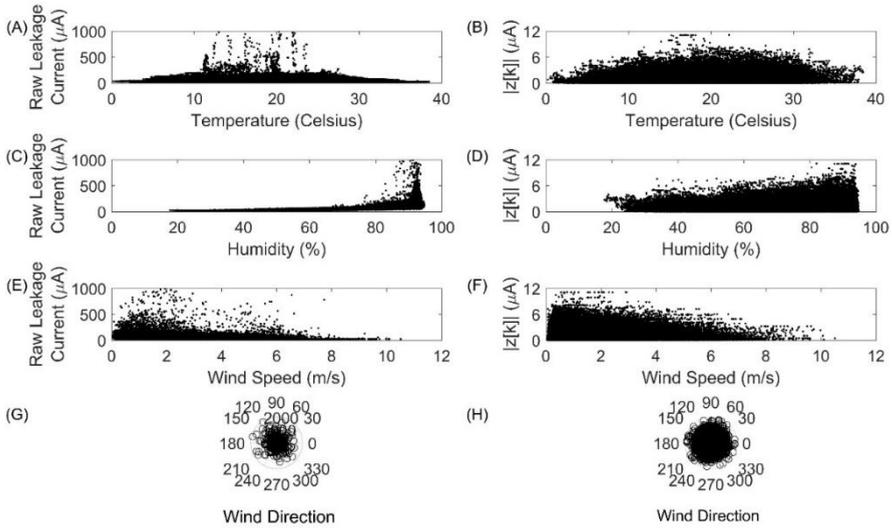


Figura 69. Diagramas de dispersión de la corriente de fuga en bruto el aislador 4 vs. a las diferentes variables ambientales: (A) Temperatura. (C) Humedad relativa (E) Velocidad del viento (G) Dirección del viento y la corriente de fuga remanente rectificad $|z[k]|$ vs. las diferentes variables ambientales: (B) Temperatura. (D) Humedad relativa. (F) Velocidad del viento (H) Dirección del viento.

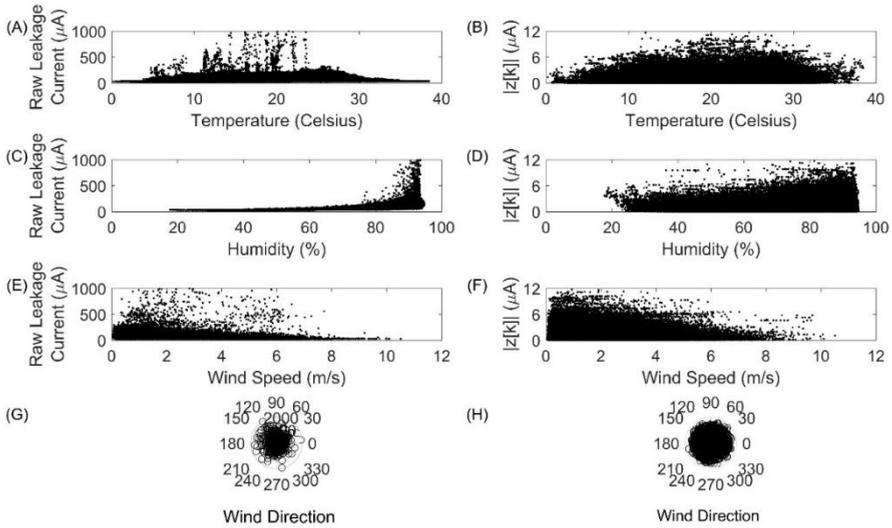


Figura 70. Diagramas de dispersión de la corriente de fuga en bruto el aislador 5 vs. a las diferentes variables ambientales: (A) Temperatura. (C) Humedad relativa (E) Velocidad del viento (G) Dirección del viento y la corriente de fuga remanente rectificad $|z[k]|$ vs. las diferentes variables ambientales: (B) Temperatura. (D) Humedad relativa. (F) Velocidad del viento (H) Dirección del viento.

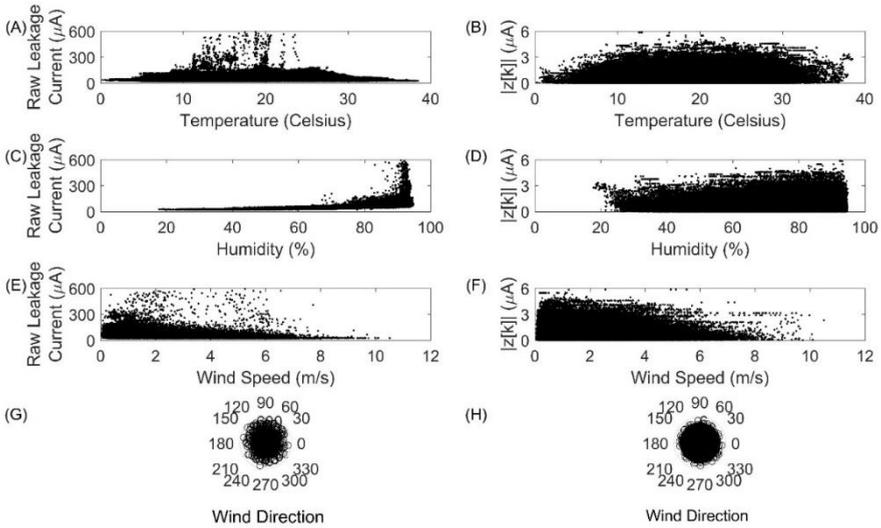


Figura 71. Diagramas de dispersión de la corriente de fuga en bruto el aislador 6 vs. a las diferentes variables ambientales: (A) Temperatura. (C) Humedad relativa (E) Velocidad del viento (G) Dirección del viento y la corriente de fuga remanente rectificadas $|z[k]|$ vs. las diferentes variables ambientales: (B) Temperatura. (D) Humedad relativa. (F) Velocidad del viento (H) Dirección del viento.

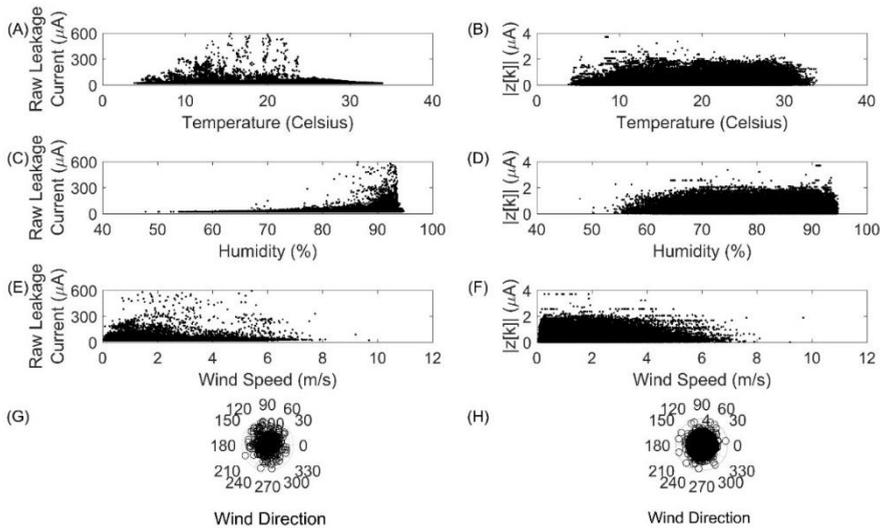


Figura 72. Diagramas de dispersión de la corriente de fuga en bruto el aislador 7 vs. a las diferentes variables ambientales: (A) Temperatura. (C) Humedad relativa (E) Velocidad del viento (G) Dirección del viento y la corriente de fuga remanente rectificadora $|z[k]|$ vs. las diferentes variables ambientales: (B) Temperatura. (D) Humedad relativa. (F) Velocidad del viento (H) Dirección del viento.

La Tabla 9 muestra el coeficiente de correlación de Spearman de la corriente de fuga resultante rectificadora $|z[k]|$ con diferentes variables ambientales. Una vez más, independientemente del tipo de aislador, $|z[k]|$ después de eliminar la influencia de la humedad y los picos anómalos presenta una correlación irrelevante con diferentes variables ambientales por debajo de 0.03.

Tabla 9. Coeficiente de correlación de Spearman de la señal procesada $z[k]$ con diferentes variables ambientales.

Aislador	Temperatura	Humedad	Dirección del viento	Velocidad del viento
1	0.015	0.021	-0.027	0.008
2	0.034	0.001	-0.017	0.004
3	-0.009	0.034	-0.023	0.041
4	0.000	0.032	-0.021	-0.012
5	0.013	0.023	-0.025	-0.004
6	0.014	0.024	-0.025	-0.012
7	0.008	-0.001	-0.010	0.027
$\mu \pm \sigma$	0.011 ± 0.013	0.019 ± 0.014	-0.021 ± 0.006	0.007 ± 0.020

Los datos estadísticos representativos de la corriente de fuga resultante rectificadora se muestran en la Tabla 10. La corriente de fuga resultante del aislador 3 fue aproximadamente 10 veces mayor que las otras, obteniendo una corriente de fuga promedio de $9.53 \pm 10.253 \mu\text{A}$. El comportamiento de los aisladores 1, 4 y 5 fue similar, con una corriente media de fuga de aproximadamente $0.9 \mu\text{A}$. El mejor rendimiento, con el valor más bajo, se obtuvo para aislador 7, con una corriente media de fuga de $0.275 \pm 0.298 \mu\text{A}$.

Tabla 10. Valores estadísticos representativos ($\mu \pm \sigma$ y máximo) de la corriente de fuga resultante rectificadora de los diferentes aisladores.

Aislador	$\mu \pm \sigma$ (μA)	Máximo (μA)
1	0.876 ± 0.896	10.439
2	0.479 ± 0.503	7.790
3	9.530 ± 10.253	111.517
4	0.922 ± 0.979	11.153
5	0.997 ± 1.089	12.391
6	0.634 ± 0.669	6.097
7	0.275 ± 0.298	3.712

6.4 Predicción de la corriente de fuga en base a los variables ambientales

Tal y como se mencionó anteriormente, se han utilizado las muestras actuales y las 20 muestras anteriores de las variables ambientales, como características de entrada del modelo de predicción de la corriente de fuga, donde 20 es el orden óptimo promedio de los modelos de vectores autorregresivos del análisis de la causalidad condicional de Granger.

6.4.1. Regresión multivariable lineal

En las Tabla 11 y Tabla 12 se muestran las métricas (media y desviación típica) de los 10 modelos de predicción de la corriente de fuga, a partir de las muestras actuales y las últimas 21 muestras de variables ambientales, mediante regresión multivariable lineal (MVR) respectivamente. La Figura 73 muestra el R^2 promedio de los modelos de predicción de la corriente de fuga, a partir de variables ambientales

mediante MVR. En general, no hay diferencias significativas entre los grupos de entrenamiento, validación y test (ver Tabla 11 y Tabla 12). Un mayor R^2 está asociado con un menor NRMSE, sin embargo, NMAE no mantiene una relación clara con R^2 , ya que éste depende en gran medida el pico máximo de corriente de fuga.

Cuando se utilizan las muestras actuales como características de entrada, los rendimientos de los modelos de predicción son relativamente bajos, siendo R^2 promedio de los 7 aisladores de unos 0.40. El NRMSE y NMAE promedio de los 7 aisladores es del 18% y 2.3% respectivamente. Los mejores rendimientos se han obtenido en los aisladores 1 y 2, con un R^2 promedio de 0.55 y NRMSE inferior al 10%. Los aisladores 3-5 han obtenido un R^2 de 0.30-0.40 y un NRMSE que varía entre 19-31%, lo cual es ligeramente inferior al de aislador 6 ($R^2=0.45$). El peor rendimiento del modelo se obtuvo con aislador 7, donde el R^2 era de 0.22.

Cuando se utilizan las 21 últimas muestras como características de entrada, los modelos de predicción obtuvieron, independientemente del aislador, resultados significativamente mejores (ver Tabla 13). El R^2 promedio de los 7 aisladores era de 0.42 ± 0.13 y un NRMSE promedio de $17.45\pm 8.63\%$, los cuales indican que los modelos basados en MVR son poco precisos para la predicción de la corriente de fuga.

Tabla 11. Media y desviación típica del rendimiento de los modelos de predicción de la corriente de fuga a partir de las muestras actuales de variables ambientales mediante MVR. *^oy^Δ indica diferencia significativa de las distintas métricas entre los grupos de entrenamiento vs. validación, entrenamiento y test, validación y test respectivamente.

Aislador	Entrenamiento			Validación			Test		
	R ²	NRMSE	NMAE	R ²	NRMSE	NMAE	R ²	NRMSE	NMAE
1	0.55 ±0.00	9.72 ±0.06	3.17 ±0.01	0.55 ±0.01	9.82 ±0.20	3.35 ±0.13	0.55 ±0.01	9.69 ±0.21	3.43 ±0.13
2	0.55 ±0.00	7.04 ±0.03	2.16 ±0.17	0.55 ±0.00	7.06 ±0.13	2.59 ±0.42	0.55 ±0.00	7.15 ±0.11	2.37 ±0.31
3	0.37 ±0.00	30.90 ±0.06	4.68 ±0.18	0.37 ±0.00	31.08 ±0.17	5.06 ±0.63	0.37 ±0.00	30.97 ±0.23	5.08 ±0.47
4	0.36 ±0.01	19.31 ±0.37	0.98 ±0.04	0.36 ±0.02	19.16 ±1.19	1.13 ±0.09	0.35 ±0.02	20.10 ±1.22	1.05 ±0.08
5	0.31 ±0.00	23.72 ±0.36	1.19 ±0.00	0.32 ±0.02	23.59 ±1.53	1.39 ±0.16	0.31 ±0.02	23.98 ±1.63	1.36 ±0.16
6	0.45 ±0.00	10.81 ±0.12	2.02 ±0.01	0.45 ±0.01	10.83 ±0.39	2.14 ±0.12	0.46 ±0.01	10.69 ±0.42	2.21 ±0.15
7	0.22 ±0.00	24.64 ±0.29	0.89 ±0.01	0.22 ±0.01	24.14 ±1.03	1.04 ±0.08	0.22 ±0.01	24.80 ±1.31	0.96 ±0.07
Total	0.40 ±0.12	18.02 ±8.99	2.16 ±1.37	0.40 ±0.12	17.95 ±8.94	2.39 ±1.45	0.40 ±0.13	18.20 ±9.08	2.35 ±1.49

Tabla 12. Media y desviación típica del rendimiento de los modelos de predicción de la corriente de fuga a partir de las últimas 21 muestras de variables ambientales mediante MVR. *^oy^Δ indica diferencia significativa de las distintas métricas entre los grupos de entrenamiento vs. validación, entrenamiento y test, validación y test respectivamente.

Aislador	Entrenamiento			Validación			Test		
	R ²	NRMSE	NMAE	R ²	NRMSE	NMAE	R ²	NRMSE	NMAE
1	0.58 ±0.00	9.06 ±0.05	3.03 ±0.01	0.58 ±0.01	9.15 ±0.20	3.20 ±0.13	0.58 ±0.01	9.04 ±0.20	3.28 ±0.13
2	0.57 ±0.00	6.73 ±0.03	2.10 ±0.16	0.57 ±0.00	6.76 ±0.13	2.52 ±0.40	0.57 ±0.00	6.85 ±0.11	2.31 ±0.30
3	0.42 ±0.00	28.52 ±0.07	4.48 ±0.17	0.42 ±0.00	28.68 ±0.16	4.84 ±0.60	0.42 ±0.00	28.59 ±0.26	4.87 ±0.45
4	0.38 ±0.01	18.69 ±0.36	0.94 ±0.04	0.38 ±0.02	18.55 ±1.18	1.10 ±0.09	0.37 ±0.02	19.51 ±1.23	1.02 ±0.07
5	0.33 ±0.00	23.07 ±0.36	1.16 ±0.00	0.33 ±0.02	22.94 ±1.54	1.35 ±0.16	0.33 ±0.02	23.37 ±1.64	1.32 ±0.16
6	0.47 ±0.00	10.44 ±0.11	1.96 ±0.01	0.47 ±0.01	10.45 ±0.39	2.07 ±0.12	0.47 ±0.01	10.33 ±0.42	2.15 ±0.14
7	0.23 ±0.00	24.29 ±0.29	0.88 ±0.01	0.23 ±0.01	23.81 ±1.04	1.02 ±0.07	0.23 ±0.01	24.48 ±1.30	0.94 ±0.07
Total	0.43 ±0.13	17.26 ±8.53	2.08 ±1.31	0.43 ±0.13	17.19 ±8.46	2.30 ±1.38	0.42 ±0.13	17.45 ±8.63	2.27 ±1.41

Tabla 13. Análisis estadístico del rendimiento de los modelos de predicción de la corriente de fuga a partir de las muestras actuales y las últimas 21 muestras de variables ambientales mediante MVR. Sombreado gris (P -valor <0.05) indica diferencia estadísticamente significativa entre ambos modelos.

Aislador	Entrenamiento			Validación			Test		
	R ²	NRMSE	NMAE	R ²	NRMSE	NMAE	R ²	NRMSE	NMAE
1	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002
2	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002
3	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002
4	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002
5	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002
6	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002
7	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002
total	<0.001	<0.001	<0.001	<0.001	<0.001	<0.001	<0.001	<0.001	<0.001



Figura 73. R² promedio de los modelos de predicción de la corriente de fuga a partir de variables ambientales mediante MVR. Izquierda: Muestras actuales. Derecha: Las últimas 21 muestras.

De la Figura 74 a la Figura 80 se muestran la corrientes de fuga registradas (línea azul de la traza superior) y su predicción basada en MVR (línea negra de la traza superior), así como el error de predicción (traza inferior) del aislador 1 al 7 respectivamente. Idealmente el error de predicción, debe ser una línea horizontal centrada en 0 si la predicción fuera perfecta. Se puede observar que independientemente del aislador, hay un importante error de predicción (casi comparable con su magnitud original), especialmente en los meses 6, 18-20 y 30-31.

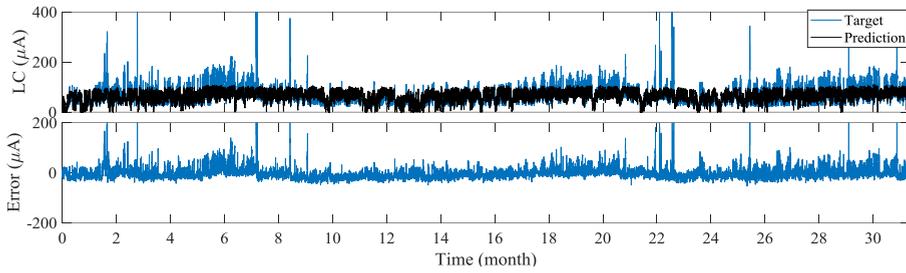


Figura 74. Superior: Predicción de la corriente de fuga a partir de las últimas 21 muestras de variables ambientales del aislador 1 mediante MVR. Inferior: Error de predicción.

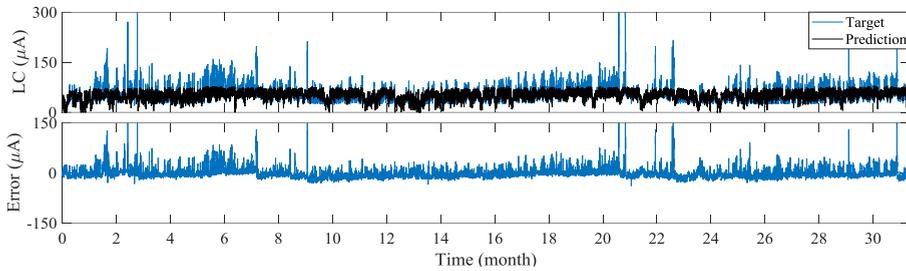


Figura 75. Superior: Predicción de la corriente de fuga a partir de las últimas 21 muestras variables ambientales del aislador 2 mediante MVR. Inferior: Error de predicción.

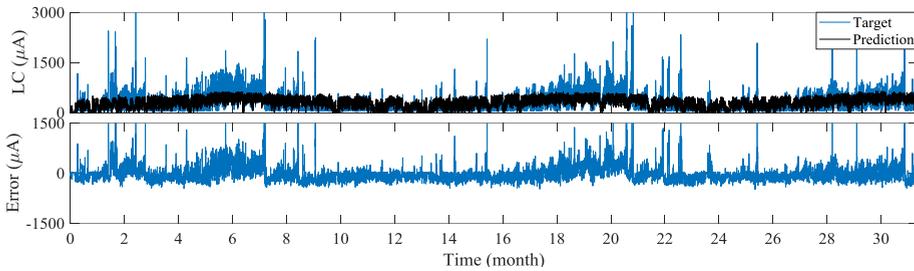


Figura 76. Superior: Predicción de la corriente de fuga a partir de las últimas 21 muestras de variables ambientales del aislador 3 mediante MVR. Inferior: Error de predicción.

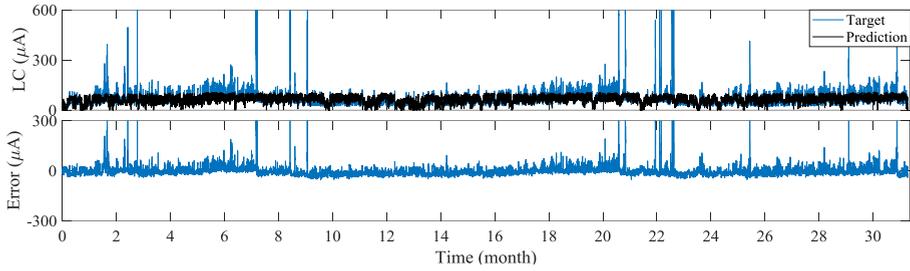


Figura 77. Superior: Predicción de la corriente de fuga a partir de las últimas 21 muestras de variables ambientales del aislador 4 mediante MVR. Inferior: Error de predicción.

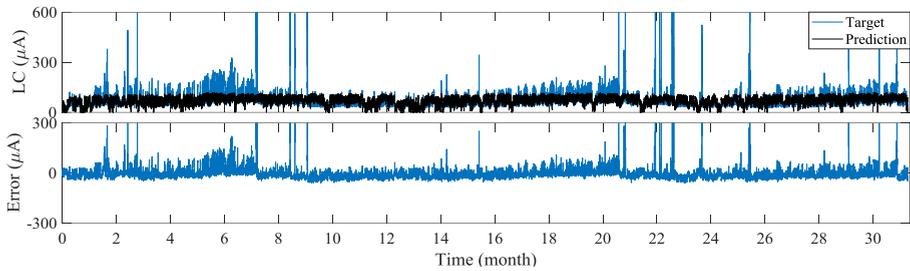


Figura 78. Superior: Predicción de la corriente de fuga a partir de las últimas 21 muestras de variables ambientales del aislador 5 mediante MVR. Inferior: Error de predicción.

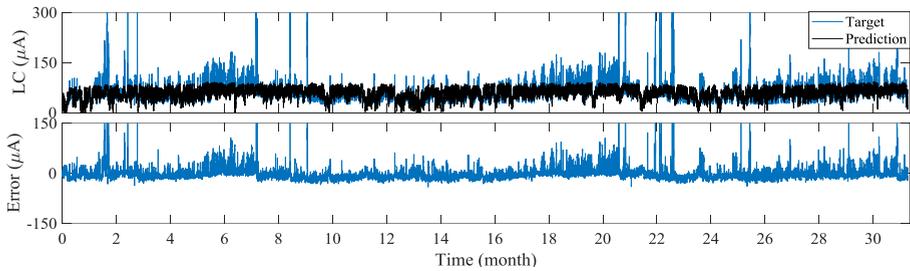


Figura 79. Superior: Predicción de la corriente de fuga a partir de las últimas 21 muestras de variables ambientales del aislador 6 mediante MVR. Inferior: Error de predicción.

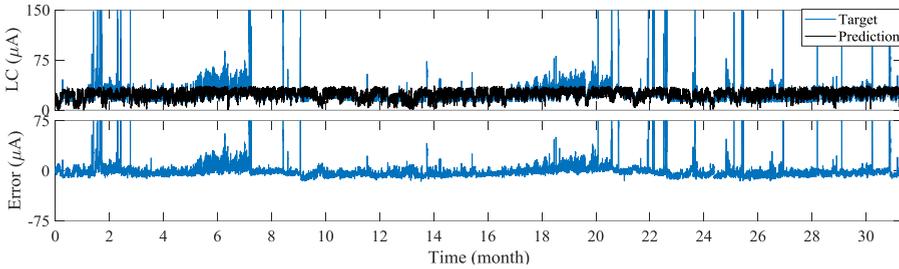


Figura 80. Superior: Predicción de la corriente de fuga a partir de las últimas 21 muestras de variables ambientales del aislador 7 mediante MVR. Inferior: Error de predicción.

En la Figura 81 se muestra la gráfica de dispersión de la predicción de la corriente de fuga a partir de las últimas 21 muestras, mediante MVR respecto a la propia corriente de fuga registrada en el aislador. Cuanto más precisa es la predicción, la nube de datos debe alojarse en la línea roja de 45° de referencia (línea roja) o cerca de la misma. Se puede apreciar que los modelos sobrestiman la corriente, para corrientes de fuga registradas pequeñas y subestima su valor, para corrientes de fuga de mayor magnitud. Todos los resultados sugieren que MVR no resulta ser un método efectivo para la predicción de la corriente de fuga en base a las variables ambientales.

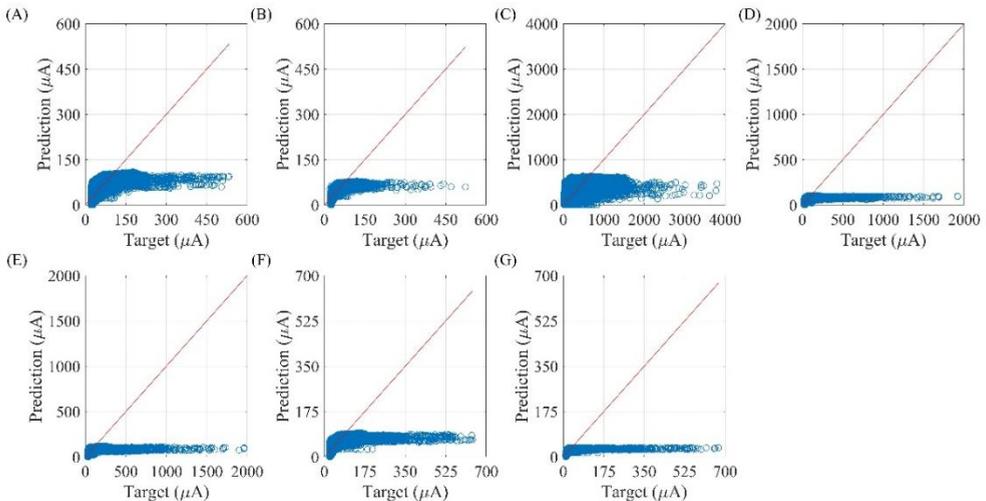


Figura 81. Gráfica de dispersión de la predicción de la corriente de fuga a partir de las últimas 21 muestras de variables ambientales mediante MVR. (A) Aislador 1. (B) Aislador 2. (C) Aislador 3. (D) Aislador 4. (E) Aislador 5. (F) Aislador 6. (G) Aislador 7.

6.4.2. Soporte vectorial para la regresión

La Tabla 14 muestra el rendimiento de los modelos de predicción de la corriente de fuga basados en el soporte vectorial para la regresión (SVR) utilizando las muestras actuales de las variables ambientales como las características de entrada. En general, se puede apreciar que un mayor R^2 está asociado con un menor NRMSE. Sin embargo, esta relación no siempre se mantiene con NMAE. Análogamente, se han observado una gran diferencia en la predictabilidad de la corriente de fuga en los distintos aisladores (R^2 de aislador 1, 2>6>3-5>7). El R^2 promedio de los 7 aisladores es de 0.74 ± 0.10 para los datos de entrenamiento, lo cual es significativamente mayor que el grupo de validación y test (0.70 ± 0.12 , ver Tabla 14). En cambio, no ha habido diferencia significativa entre el R^2 del grupo de validación y el de test (ver Tabla 14).

Cuando se utilizan las últimas 21 muestras de las variables ambientales como características de entrada para la predicción de la corriente de fuga (ver Tabla 15), de nuevo el R^2 del grupo de entrenamiento, es significativamente mayor que el grupo de validación y test, siendo la diferencia entre estos dos últimos grupos estadísticamente insignificante, excepto en los aisladores 4 y 7 (ver Tabla 15). En comparación con los modelos que utilizan solo las muestras actuales como características de entrada, el R^2 del grupo de entrenamiento incrementó considerablemente, con la diferencia muy marcada en los aisladores 3-7 (ver Tabla 14, Tabla 15, y Figura 82). La diferencia significativa se ha obtenido en todos los aisladores excepto el aislador 7 (ver Tabla 16), obteniendo un R^2 promedio de 0.86 ± 0.05 (ver Tabla 15), sin embargo, no se ha producido una mejora significativa en los rendimientos del modelo, excepto en el aislador 1 en el grupo de validación, y en el aislador 3 en los grupos de validación y de test (ver Tabla 16).

En términos generales, utilizar las últimas 21 muestras como características de entrada, ha obtenido prácticamente los mismos resultados en los grupos de validación y test, que cuando se emplean las muestras actuales, sin diferencias significativas entre ellos. Estos resultados sugieren que se ha producido un sobre-entrenamiento del

modelo cuando se utilizan las últimas 21 muestras como características de entrada del SVR, sin capacidad de generalización en los datos de test 'nunca' vistos por el modelo.

Tabla 14. Media y desviación típica del rendimiento de los modelos de predicción de la corriente de fuga a partir de las muestras actuales de variables ambientales mediante SVR. *^oy^Δ indica diferencia significativa de las distintas métricas entre los grupos de entrenamiento vs. validación, entrenamiento y test, validación y test respectivamente.

Aislador	Entrenamiento			Validación			Test		
	R ²	NRMSE	NMAE	R ²	NRMSE	NMAE	R ²	NRMSE	NMAE
1	0.86 ±0.01* ^o	3.10 ±0.19* ^o	1.45 ±0.10* ^o	0.84 ±0.01*	3.42 ±0.19*	1.63 ±0.07*	0.85 ±0.00 ^o	3.34 ±0.13 ^o	1.66 ±0.06 ^o
2	0.83 ±0.01* ^o	2.68 ±0.11* ^o	1.14 ±0.09* ^o	0.82 ±0.00*	2.88 ±0.11*	1.43 ±0.24*	0.81 ±0.00 ^o	2.94 ±0.09 ^o	1.31 ±0.17 ^o
3	0.72 ±0.02* ^o	13.87 ±1.05* ^o	2.44 ±0.18* ^o	0.70 ±0.01*	14.62 ±1.05*	2.74 ±0.33*	0.70 ±0.01 ^o	14.65 ±0.37 ^o	2.77 ±0.30 ^o
4	0.69 ±0.09* ^o	9.26 ±2.74* ^o	0.49 ±0.12* ^o	0.64 ±0.07*	10.86 ±2.74*	0.64 ±0.12*	0.63 ±0.07 ^o	11.56 ±2.36 ^o	0.60 ±0.14 ^o
5	0.72 ±0.07* ^o	9.75 ±2.34* ^o	0.56 ±0.05* ^o	0.66 ±0.04*	11.73 ±2.34*	0.73 ±0.17*	0.66 ±0.04 ^o	11.94 ±1.90 ^o	0.70 ±0.09 ^o
6	0.78 ±0.02* ^o	4.28 ±0.40* ^o	0.98 ±0.05* ^o	0.75 ±0.01*	4.92 ±0.40*	1.15 ±0.08*	0.75 ±0.01 ^o	4.86 ±0.26 ^o	1.19 ±0.07 ^o
7	0.55 ±0.11* ^o	14.20 ±3.58* ^o	0.56 ±0.07* ^o	0.48 ±0.06*	16.27 ±3.58*	0.72 ±0.04*	0.49 ±0.06 ^o	16.04 ±1.68 ^o	0.60 ±0.07 ^o
Total	0.74 ±0.10* ^o	8.16 ±4.89* ^o	1.09 ±0.69* ^o	0.70 ±0.12*	9.24 ±5.48*	1.29 ±0.75*	0.70 ±0.12 ^o	9.33 ±5.50 ^o	1.27 ±0.77 ^o

Tabla 15. Media y desviación típica del rendimiento de los modelos de predicción de la corriente de fuga a partir de las últimas 21 muestras de variables ambientales mediante SVR. *^oy^Δ indica diferencia significativa de las distintas métricas entre los grupos de entrenamiento vs. validación, entrenamiento y test, validación y test respectivamente.

Aislador	Entrenamiento			Validación			Test		
	R ²	NRMSE	NMAE	R ²	NRMSE	NMAE	R ²	NRMSE	NMAE
1	0.88 ±0.01* ^o	2.53 ±0.24* ^o	1.17 ±0.12* ^o	0.85 ±0.01*	3.36 ±0.15*	1.61 ±0.06*	0.85 ±0.01 ^o	3.30 ±0.15 ^o	1.65 ±0.07 ^o
2	0.85 ±0.01* ^o	2.36 ±0.23* ^o	0.96 ±0.11* ^o	0.82 ±0.01*	2.90 ±0.14*	1.42 ±0.22*	0.81 ±0.01 ^o	2.97 ±0.10 ^o	1.30 ±0.18 ^o
3	0.88 ±0.02* ^o	5.94 ±1.05* ^o	1.05 ±0.18* ^o	0.73 ±0.00*	13.13 ±0.15*	2.62 ±0.33*	0.73 ±0.00 ^o	13.14 ±0.24 ^o	2.64 ±0.24 ^o
4	0.91 ±0.10* ^o	2.77 ±3.00* ^o	0.11 ±0.12* ^o	0.66 ±0.03* ^Δ	10.17 ±1.31* ^Δ	0.64 ±0.06*	0.63 ±0.03 ^{oΔ}	11.40 ±1.20 ^{oΔ}	0.60 ±0.04 ^o
5	0.83 ±0.11* ^o	5.85 ±3.93* ^o	0.27 ±0.14* ^o	0.67 ±0.04*	11.31 ±1.57*	0.68 ±0.08*	0.66 ±0.03 ^o	11.93 ±1.37 ^o	0.68 ±0.09 ^o
6	0.89 ±0.04* ^o	2.13 ±0.73* ^o	0.53 ±0.15* ^o	0.74 ±0.01*	5.06 ±0.33*	1.22 ±0.07*	0.74 ±0.01 ^o	5.02 ±0.32 ^o	1.26 ±0.07 ^o
7	0.76 ±0.26* ^o	7.48 ±8.03* ^o	0.30 ±0.23* ^o	0.48 ±0.08* ^Δ	16.26 ±2.74* ^Δ	0.78 ±0.05*	0.45 ±0.07 ^{oΔ}	17.37 ±2.51 ^{oΔ}	0.72 ±0.04 ^o
Total	0.86 ±0.05* ^o	4.15 ±2.20* ^o	0.63 ±0.43* ^o	0.71 ±0.12* ^Δ	8.88 ±5.18* ^Δ	1.28 ±0.70*	0.70 ±0.13 ^{oΔ}	9.30 ±5.56 ^{oΔ}	1.26 ±0.72 ^o

Tabla 16. Análisis estadístico del rendimiento de los modelos de predicción de la corriente de fuga a partir de las muestras actuales y las últimas 21 muestras de variables ambientales mediante SVR. Sombreado gris (P -valor <0.05) indica diferencia estadísticamente significativa entre ambos modelos.

Aislador	Entrenamiento			Validación			Test		
	R ²	NRMSE	NMAE	R ²	NRMSE	NMAE	R ²	NRMSE	NMAE
1	0.002	0.002	0.002	0.020	0.020	0.375	0.105	0.084	0.557
2	0.002	0.002	0.002	0.625	0.625	0.375	0.193	0.193	0.432
3	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002
4	0.002	0.002	0.002	0.084	0.084	0.084	0.375	0.375	0.084
5	0.049	0.049	0.002	0.557	0.557	0.770	0.846	0.846	0.846
6	0.002	0.002	0.002	0.064	0.064	0.062	0.064	0.064	0.065
7	0.064	0.064	0.010	0.846	0.846	0.064	0.322	0.275	0.067
total	<0.001	<0.001	<0.001	0.102	0.075	0.680	0.951	0.799	0.369

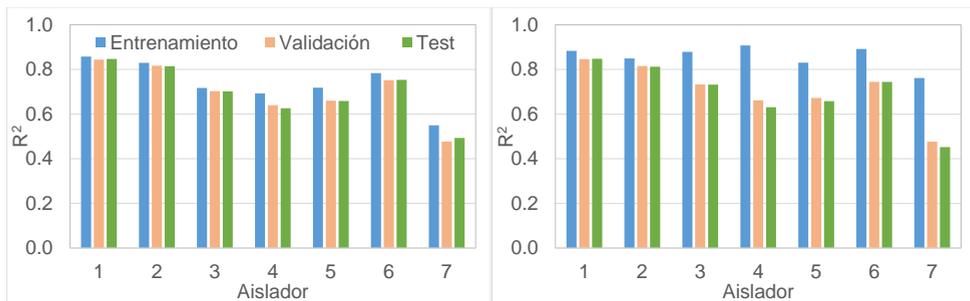


Figura 82. R² promedio de los modelos de predicción de la corriente de fuga a partir de variables ambientales mediante SVR. Izquierda: Muestras actuales. Derecha: Las últimas 21 muestras.

De la Figura 83 a la Figura 89 se muestra la corriente de fuga registrada en los aisladores 1-7 (línea azul de la traza superior) y su predicción a partir de las muestras actuales de variables ambientales (línea negra de la traza superior), así como el error de predicción (traza inferior). En este caso, se ha optado por representar las figuras obtenidas cuando se utilizan las muestras actuales como características de entrada, porque estos modelos representan más fielmente su capacidad de generalización real para los nuevos datos entrantes. Si bien es cierto, que aparentemente la predicción se asemeja en gran medida a la corriente de fuga registrada, el error de predicción sigue presentando magnitudes comparables a la propia corriente de fuga. Análogamente que MVR, los mayores errores de

predicción se obtienen en los meses correspondientes al verano (meses 6-8, 18-20, 28- 30).

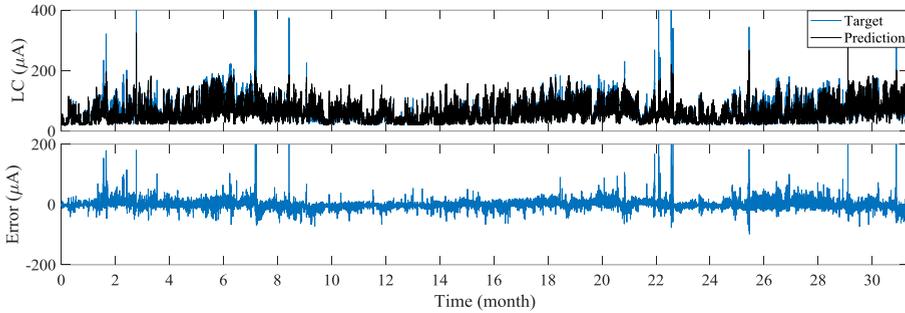


Figura 83. Superior: Predicción de la corriente de fuga a partir de las muestras actuales de variables ambientales del aislador 1 mediante SVR. Inferior: Error de predicción.

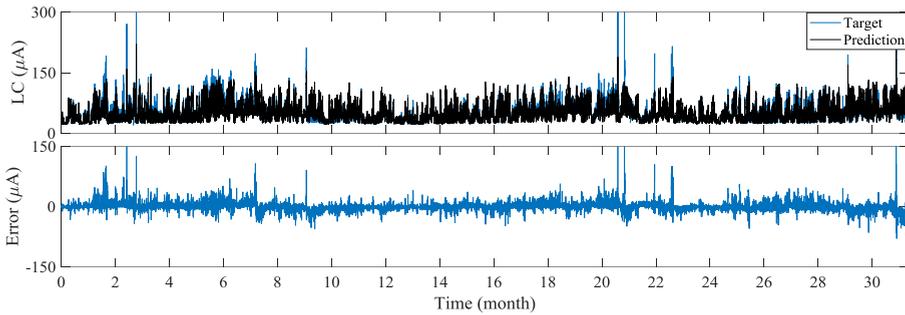


Figura 84. Superior: Predicción de la corriente de fuga a partir de las muestras actuales de variables ambientales del aislador 2 mediante SVR. Inferior: Error de predicción.

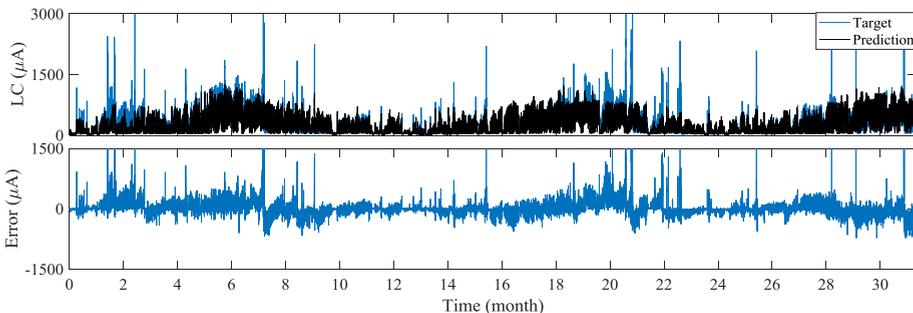


Figura 85. Superior: Predicción de la corriente de fuga a partir de las muestras actuales de variables ambientales del aislador 3 mediante SVR. Inferior: Error de predicción.

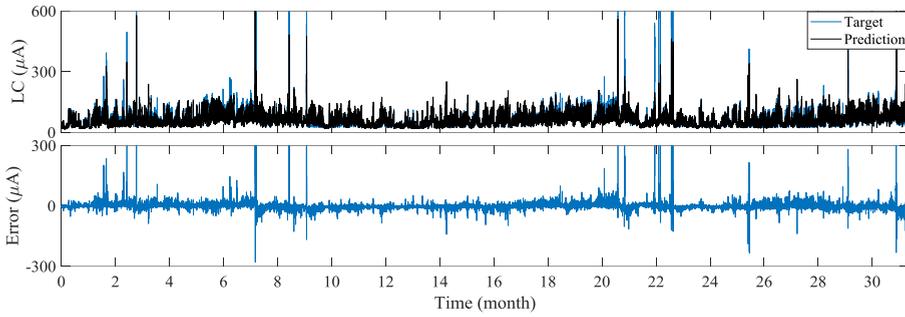


Figura 86. Superior: Predicción de la corriente de fuga a partir de las muestras actuales de variables ambientales del aislador 4 mediante SVR. Inferior: Error de predicción.

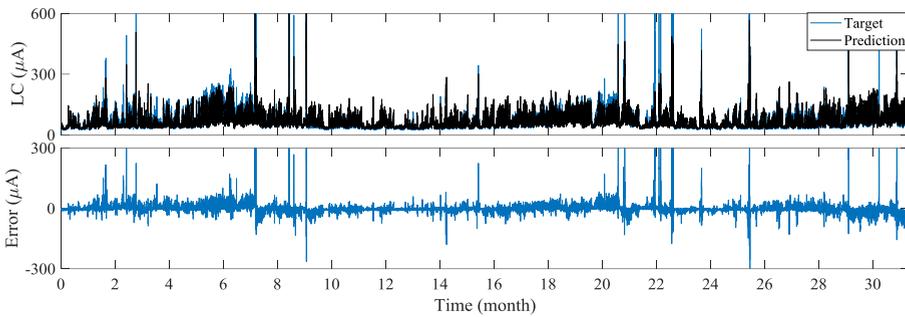


Figura 87. Superior: Predicción de la corriente de fuga a partir de las muestras actuales de variables ambientales del aislador 5 mediante SVR. Inferior: Error de predicción.

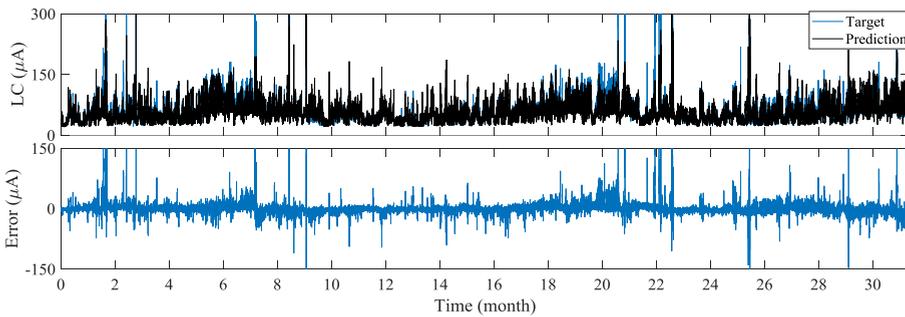


Figura 88. Superior: Predicción de la corriente de fuga a partir de las muestras actuales de variables ambientales del aislador 6 mediante SVR. Inferior: Error de predicción.

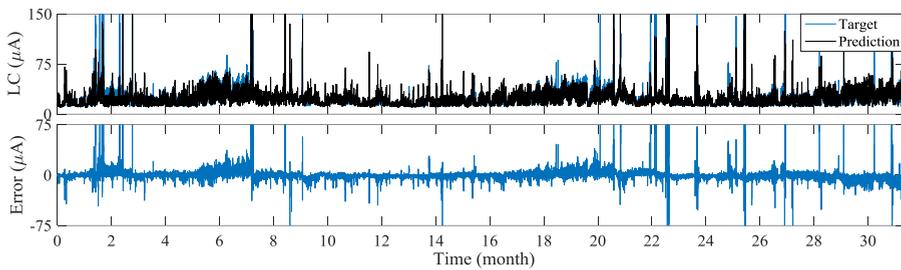


Figura 89. Superior: Predicción de la corriente de fuga a partir de las muestras actuales de variables ambientales del aislador 7 mediante SVR. Inferior: Error de predicción.

Por la misma razón mencionada anteriormente, se han representado las gráficas de dispersión de la predicción de la corriente de fuga, a partir de las muestras actuales de las variables ambientales mediante SVR, respecto a la propia corriente de fuga registrada en el aislador (ver Figura 90). La nube de datos se alinea bastante más a la línea recta de 45° de referencia (línea roja si la predicción hubiera sido perfecta) que cuando se utiliza MVR (compárese la Figura 81 con la Figura 90). Para corrientes de fuga pequeñas, se producen tanto sobrestimaciones (por encima de la línea roja) como subestimaciones (por debajo de la línea roja) en el modelo mediante SVR. En cambio, los modelos tienden a subestimar su valor para corrientes de fuga de mayor magnitud. En los aisladores 3, 4, 5 y 7, la gráfica de dispersión se asemeja a un rectángulo, cuya diagonal está en paralelo a la línea recta de 45° , sugiriendo que SVR no permite predecir con precisión la corriente de fuga, a partir de las variables ambientales. En cambio, los modelos de los aisladores 1 y 2 han obtenido resultados bastante satisfactorios, aunque sigue habiendo margen de mejora.

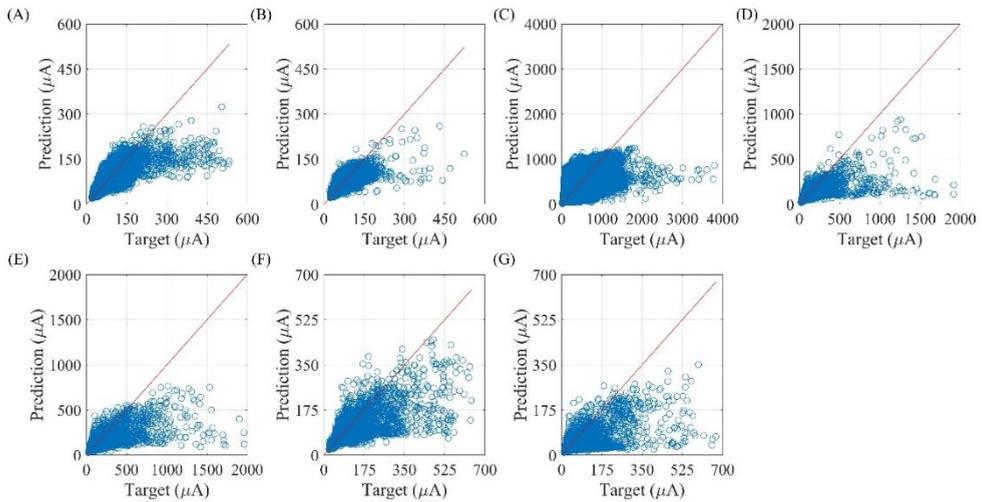


Figura 90. Gráfica de dispersión de la predicción de la corriente de fuga a partir de las muestras actuales de variables ambientales mediante SVR. (A) Aislador 1. (B) Aislador 2. (C) Aislador 3. (D) Aislador 4. (E) Aislador 5. (F) Aislador 6. (G) Aislador 7.

6.4.3. 2SL-CNN

La Tabla 17 muestra los resultados de los modelos de predicción basados en 2SL-CNN, utilizando las muestras actuales de las variables ambientales, como características de entrada. De nuevo, el R^2 mantiene una relación inversa con NRMSE, pero no con NMAE. Al igual que los métodos de SVR y MVR, se han alcanzado mejores rendimientos en el aislador 1 y en el 2 ($R^2 > 0.80$), mientras que el peor rendimiento se ha obtenido para el aislador 7 ($R^2 = 0.44 \pm 0.02$). Independientemente del aislador, no hay apenas diferencias entre el grupo de entrenamiento, validación y test. El análisis estadístico revela que las diferencias eran estadísticamente irrelevantes, excepto para el NMAE de los aisladores 1, 2 y 3, en los que se han obtenido diferencias significativas entre el grupo de entrenamiento y validación, y/o entrenamiento y test. El R^2 promedio en el grupo de test, es de unos 0.68 ± 0.13 , lo cual es ligeramente inferior que SVR (0.70 ± 0.12).

En cambio, cuando se utilizan las últimas 21 muestras de las variables ambientales como características de entrada, el rendimiento de los modelos en el grupo de entrenamiento (R^2 promedio 0.92 ± 0.02), es significativamente mayor que el del grupo de validación y test

(R^2 promedio: 0.73 ± 0.11), sin que haya diferencia significativa en estos dos últimos grupos (ver Tabla 18). Estos resultados sugieren el posible sobre-entrenamiento del modelo 2SL-CNN, cuando se utilizan las últimas 21 muestras como características de entrada. De nuevo, los mejores resultados se han obtenidos en los aisladores 1 y 2 (R^2 : 0.85 ± 0.01 y 0.83 ± 0.01 para el grupo de test respectivamente), siendo el peor rendimiento, el obtenido en el aislador 7 con R^2 de 0.52 ± 0.02 para el grupo de test.

Tabla 17. Media y desviación típica del rendimiento de los modelos de predicción de la corriente de fuga a partir de las muestras actuales de variables ambientales mediante el modelo 2SL-CNN. * $^{\circ}$ y $^{\Delta}$ indica diferencia significativa de las distintas métricas entre los grupos de entrenamiento vs. validación, entrenamiento y test, validación y test respectivamente.

Aislador	Entrenamiento			Validación			Test		
	R^2	NRMSE	NMAE	R^2	NRMSE	NMAE	R^2	NRMSE	NMAE
1	0.84 ± 0.00	3.48 ± 0.08	1.67 $\pm 0.03^*$	0.84 ± 0.01	3.50 ± 0.20	1.79 $\pm 0.08^*$	0.84 ± 0.01	3.49 ± 0.11	1.70 ± 0.06
2	0.80 ± 0.01	3.13 ± 0.17	1.21 $\pm 0.04^{*\circ}$	0.80 ± 0.01	3.14 ± 0.24	1.55 $\pm 0.23^*$	0.80 ± 0.01	3.07 ± 0.16	1.64 $\pm 0.17^{\circ}$
3	0.70 ± 0.01	14.58 ± 0.44	2.65 $\pm 0.09^{*\circ}$	0.70 ± 0.01	14.82 ± 0.48	3.2 $\pm 0.37^*$	0.70 ± 0.01	14.81 ± 0.44	3.04 $\pm 0.42^{\circ}$
4	0.62 ± 0.01	11.34 ± 0.51	0.56 ± 0.03	0.63 ± 0.04	11.12 ± 1.64	0.66 ± 0.08	0.61 ± 0.02	11.89 ± 1.16	0.63 ± 0.09
5	0.63 ± 0.01	12.63 ± 0.52	0.63 ± 0.03	0.64 ± 0.03	12.39 ± 1.23	0.73 ± 0.06	0.62 ± 0.03	13.25 ± 1.6	0.68 ± 0.07
6	0.72 ± 0.01	5.48 ± 0.30	1.20 ± 0.01	0.72 ± 0.02	5.52 ± 0.54	1.27 ± 0.06	0.72 ± 0.01	5.51 ± 0.29	1.27 ± 0.10
7	0.44 ± 0.03	17.77 ± 1.00	0.67 ± 0.05	0.44 ± 0.03	17.33 ± 1.48	0.75 ± 0.09	0.44 ± 0.02	17.58 ± 1.28	0.73 ± 0.10
Total	0.68 ± 0.13	9.77 ± 5.77	1.23 ± 0.74	0.68 ± 0.13	9.69 ± 5.67	1.42 ± 0.90	0.68 ± 0.13	9.94 ± 5.85	1.38 ± 0.86

Tabla 18. Media y desviación típica del rendimiento de los modelos de predicción de la corriente de fuga a partir de las últimas 21 muestras de variables ambientales mediante el modelo 2SL-CNN. * ° y Δ indica diferencia significativa de las distintas métricas entre los grupos de entrenamiento vs. validación, entrenamiento y test, validación y test respectivamente.

Aislador	Entrenamiento			Validación			Test		
	R ²	NRMSE	NMAE	R ²	NRMSE	NMAE	R ²	NRMSE	NMAE
1	0.94 ±0.01*°	1.29 ±0.31*°	1.11 ±0.12*°	0.85 ±0.01*	3.22 ±0.21*	1.72 ±0.08*	0.85 ±0.01°	3.20 ±0.28°	1.64 ±0.09°
2	0.93 ±0.02*°	1.08 ±0.28*°	0.81 ±0.12*°	0.83 ±0.01*	2.68 ±0.23*	1.49 ±0.23*	0.83 ±0.01°	2.63 ±0.2°	1.57 ±0.18°
3	0.94 ±0.02*°	3.07 ±0.81*°	1.29 ±0.15*°	0.75 ±0.01*	12.35 ±0.45*	2.95 ±0.35*	0.75 ±0.01°	12.44 ±0.58°	2.81 ±0.37°
4	0.93 ±0.02*°	2.17 ±0.56*°	0.38 ±0.05*°	0.71 ±0.03*	8.76 ±1.2*	0.64 ±0.08*	0.70 ±0.03°	9.24 ±1.38°	0.61 ±0.08°
5	0.92 ±0.03*°	2.91 ±1.05*°	0.43 ±0.06*°	0.71 ±0.03*	9.91 ±1.16*	0.73 ±0.06*	0.70 ±0.03°	10.64 ±1.46°	0.67 ±0.09°
6	0.92 ±0.05*°	1.61 ±0.89*°	0.85 ±0.21*°	0.77 ±0.05*	4.63 ±1.02*	1.29 ±0.15*	0.76 ±0.04°	4.65 ±0.8°	1.28 ±0.15°
7	0.90 ±0.04*°	3.25 ±1.29*°	0.44 ±0.06*°	0.51 ±0.04*	15.22 ±1.44*	0.71 ±0.07*	0.52 ±0.02°	15.22 ±1.36°	0.69 ±0.05°
Total	0.92 ±0.02*°	2.20 ±0.89*°	0.76 ±0.36*°	0.73 ±0.11*	8.11 ±4.79*	1.36 ±0.82*	0.73 ±0.11°	8.29 ±4.88°	1.33 ±0.78°

Tabla 19. Análisis estadístico del rendimiento de los modelos de predicción de la corriente de fuga a partir de las muestras actuales y las últimas 21 muestras de variables ambientales mediante el modelo 2SL-CNN. Sombreado gris (P-valor<0.05) indica diferencia estadísticamente significativa entre ambos modelos.

Aislador	Entrenamiento			Validación			Test		
	R ²	NRMSE	NMAE	R ²	NRMSE	NMAE	R ²	NRMSE	NMAE
1	0.002	0.014	0.014	0.002	0.014	0.014	0.002	0.020	0.027
2	0.002	0.002	0.004	0.002	0.002	0.004	0.002	0.014	0.014
3	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002
4	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.131	0.064
5	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.432	0.375
6	0.002	0.014	0.048	0.002	0.014	0.037	0.004	0.375	0.322
7	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.084	0.064
total	<0.001	<0.001	<0.001	<0.001	<0.001	<0.001	<0.001	<0.001	<0.001

En comparación con cuando se utilizan las muestras actuales como características de entrada, el incremento del rendimiento de los modelos en el grupo de entrenamiento es especialmente relevante en los aisladores del 3 al 7 (ver Figura 91), obteniendo diferencias significativas en todas las métricas y en todos los aisladores, (ver Tabla 19). Asimismo, se ha producido un aumento significativo en el

rendimiento del modelo en el grupo de validación y en el de test (R^2 promedio: 0.68 ± 0.13 muestras actuales vs. 0.73 ± 0.11 últimas 21 muestras), excepto NRMSE y NMAE para los aisladores 4, 5 y 6 (ver Tabla 19).

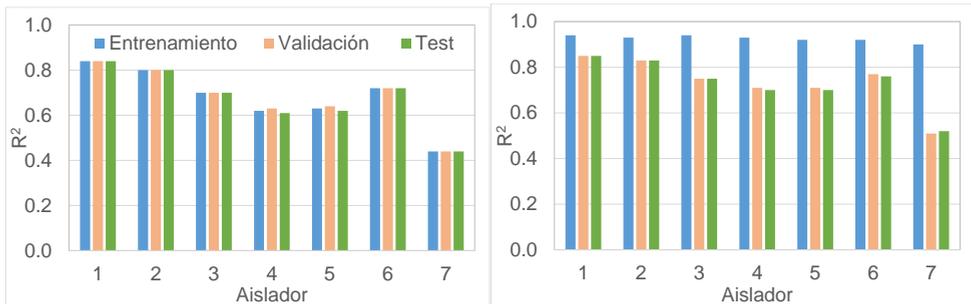


Figura 91. R^2 promedio de los modelos de predicción de la corriente de fuga a partir de variables ambientales mediante el modelo 2SL-CNN. Izquierda: Muestras actuales. Derecha: Las últimas 21 muestras.

De la Figura 92 a la Figura 98 se muestra la corriente de fuga registrada de los aisladores 1 al 7 (línea azul de la traza superior) junto con su predicción basada en el modelo 2SL-CNN (línea negra de la traza superior) utilizando las últimas 21 muestras como características de entrada, así como su error de predicción (traza inferior). En este caso, se ha optado por representar las figuras obtenidas cuando se utilizan las últimas 21 muestras como características de entradas, porque se han conseguido rendimientos significativamente mejores en el grupo de test que cuando se utilizan las muestras actuales. Al igual que SVR, aparentemente la predicción se asemeja mucho a la propia corriente de fuga registrada (ver traza superior de estas figuras). Sin embargo, el error de predicción sigue siendo muy grande, especialmente en los meses 6-8, 18-20 y 28-30.

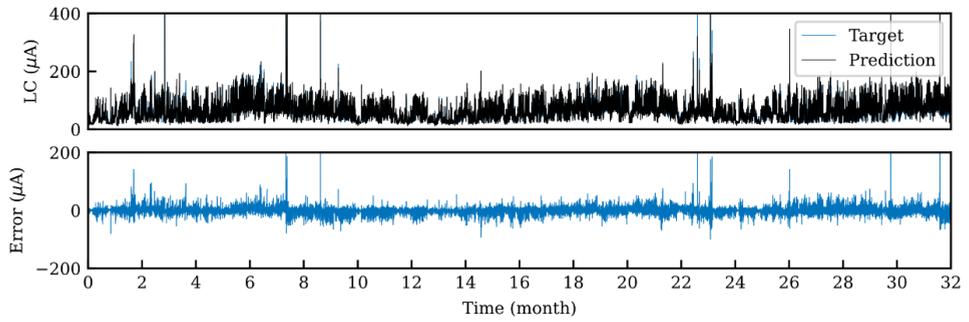


Figura 92. Superior: Predicción de la corriente de fuga a partir de las últimas 21 muestras de variables ambientales del aislador 1 mediante el modelo 2SL-CNN. Inferior: Error de predicción.

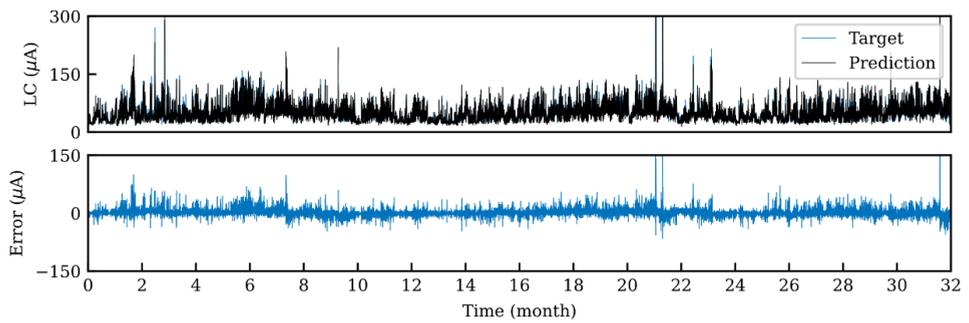


Figura 93. Superior: Predicción de la corriente de fuga a partir de las últimas 21 muestras de variables ambientales del aislador 2 mediante el modelo 2SL-CNN. Inferior: Error de predicción.

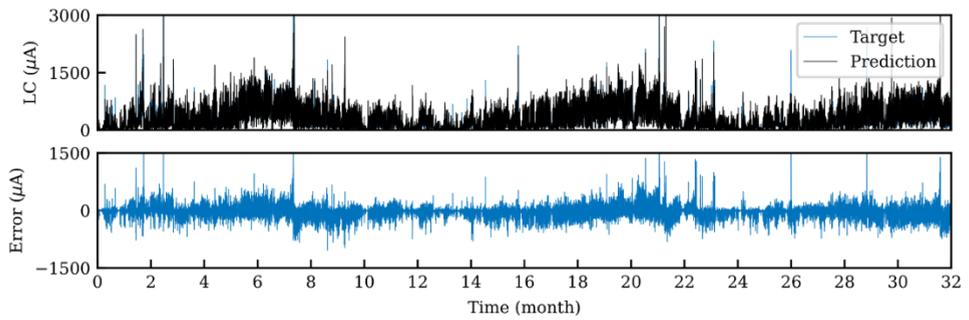


Figura 94. Superior: Predicción de la corriente de fuga a partir de las últimas 21 muestras de variables ambientales del aislador 3 mediante el modelo 2SL-CNN. Inferior: Error de predicción.

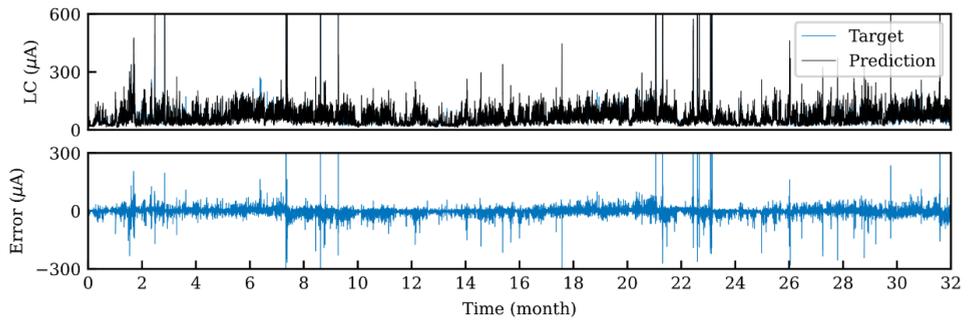


Figura 95. Superior: Predicción de la corriente de fuga a partir de las últimas 21 muestras de variables ambientales del aislador 4 mediante el modelo 2SL-CNN. Inferior: Error de predicción.

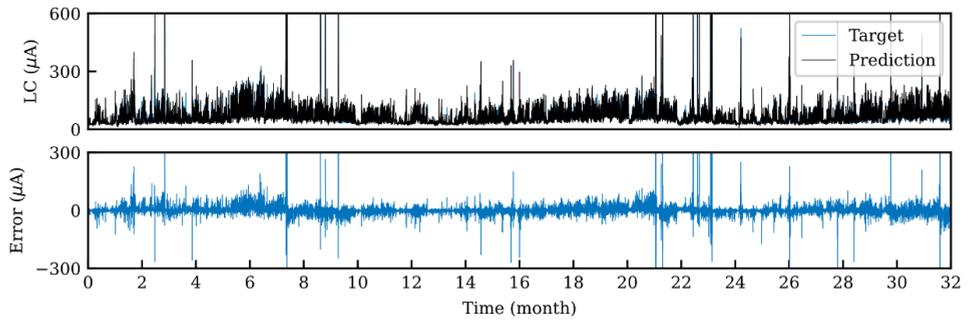


Figura 96. Superior: Predicción de la corriente de fuga a partir de las últimas 21 muestras de variables ambientales del aislador 5 mediante el modelo 2SL-CNN. Inferior: Error de predicción.

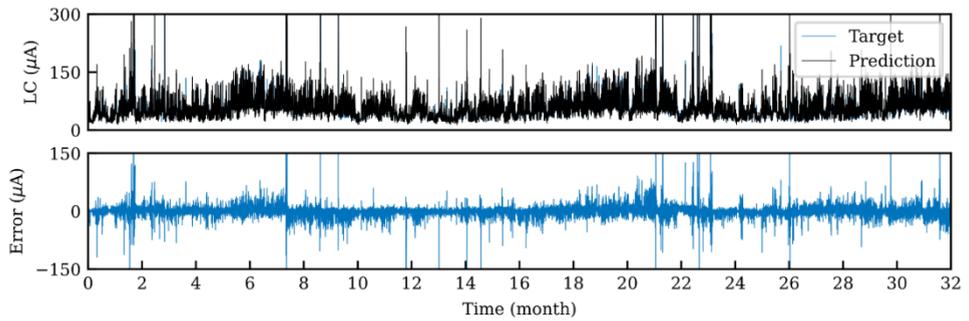


Figura 97. Superior: Predicción de la corriente de fuga a partir de las últimas 21 muestras de variables ambientales del aislador 6 mediante el modelo 2SL-CNN. Inferior: Error de predicción.

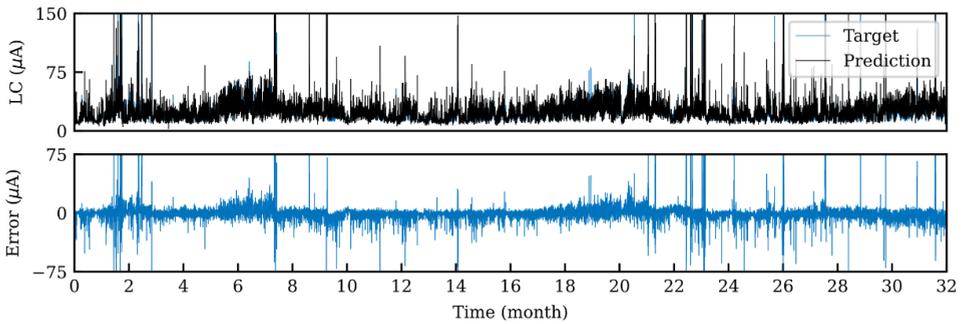


Figura 98. Superior: Predicción de la corriente de fuga a partir de las últimas 21 muestras de variables ambientales del aislador 7 mediante el modelo 2SL-CNN. Inferior: Error de predicción.

En la Figura 99 se muestra la gráfica de dispersión de la corriente de fuga predicha con el modelo 2SL-CNN frente a la corriente de fuga registrada. Se ha representado en estas gráficas los resultados de los modelos utilizando las últimas 21 muestras, por el mismo motivo indicado anteriormente. En ella se puede apreciar que la nube de datos se alinea con la línea recta de 45° de referencia (línea roja que se corresponde a la predicción perfecta) en los aisladores 1 y 2. En el aislador 3, la nube de datos forma casi un rectángulo casi paralelo a la línea recta de 45° de referencia, sugiriendo que la corriente de fuga predicha sigue a la tendencia de la corriente de fuga registrada, pero con una variabilidad importante alrededor del valor real, lo cual se puede interpretar como si fuera un ruido aleatorio. En los aisladores 4, 5 y 7, el modelo tiende a subestimar la corriente de fuga, especialmente para corrientes de fugas de mayor magnitud.

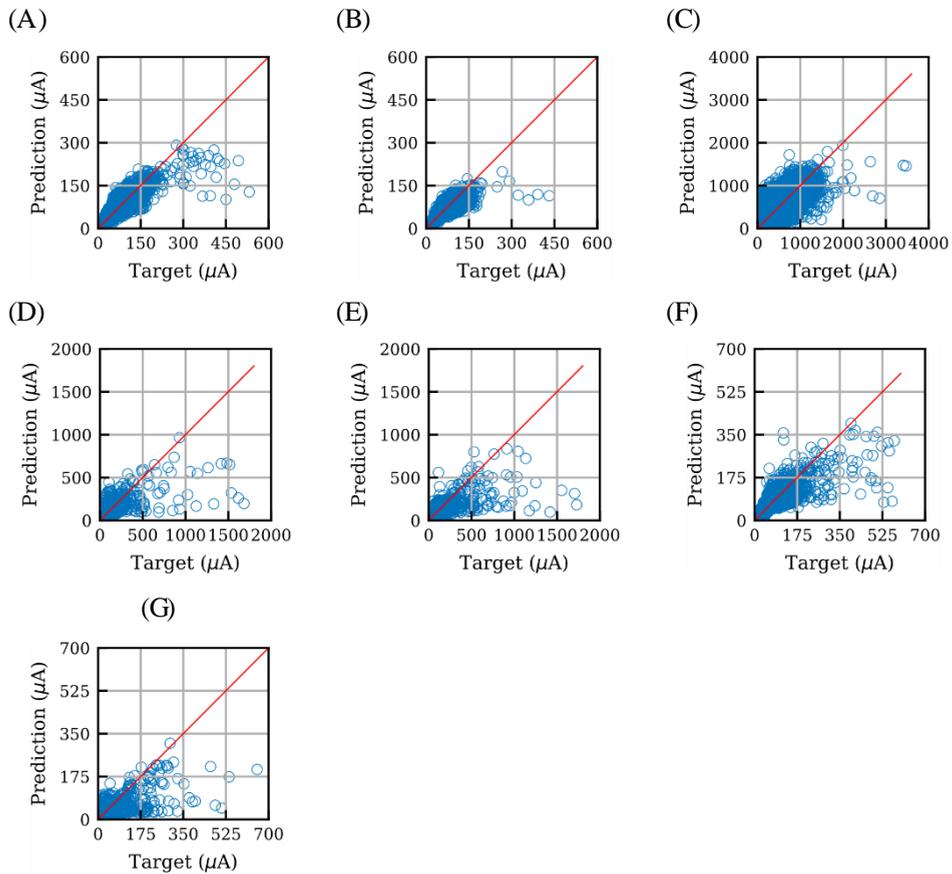


Figura 99. Gráfica de dispersión de la predicción de la corriente de fuga a partir de las últimas 21 muestras de variables ambientales mediante el modelo 2SL-CNN. (A) Aislador 1. (B) Aislador 2. (C) Aislador 3. (D) Aislador 4. (E) Aislador 5. (F) Aislador 6. (G) Aislador 7.

6.4.4. 2IL-CNN

Los resultados de la predicción de la corriente de fuga mediante el modelo 2IL-CNN en base a las muestras actuales y las últimas 21 muestras de variables ambientales se muestran en la Tabla 20 y en la Tabla 21 respectivamente. En el caso de utilizar solo las muestras actuales para la predicción de corriente de fuga, no hay grandes diferencias respecto al modelo 2SL-CNN, como cabe esperar. No hay diferencias significativas en el R^2 y NRMSE entre los grupos de entrenamiento, validación y test. En cambio, el NMAE del grupo de validación es significativamente mayor que el de entrenamiento, en todos los aisladores. Asimismo, el NMAE del grupo de test, es

significativamente mayor que el de entrenamiento, para los aisladores 2, 3 y 7, siendo las diferencias estadísticamente insignificantes para los demás aisladores. No se han observado diferencias significativas entre las métricas del grupo de validación y test. Si bien es cierto que no se ha observado el fenómeno de sobre-entrenamiento del modelo, el R^2 promedio para el grupo de test es moderado (0.68 ± 0.14).

En cambio, en comparación con los resultados de predicción utilizando las muestras actuales, los rendimientos del modelo cuando se utilizan las últimas 21 muestras para la predicción de la corriente de fuga, eran significativamente mejores tanto para el grupo de entrenamiento, validación como para el grupo de test (ver Figura 100 y la Tabla 22). Asimismo, los rendimientos del grupo de entrenamiento eran significativamente mejores que los del grupo de validación y test, siendo las diferencias entre estos dos últimos estadísticamente insignificantes. Independientemente del aislador, el R^2 es superior al 0.98 para el grupo de entrenamiento. Para el grupo de test, el R^2 , de nuevo, depende del aislador, donde los mejores resultados se han obtenido en los aisladores 1 y 2 ($R^2=0.95 \pm 0.00$), seguido de los aisladores 3 y 6 ($R^2=0.91 \pm 0.01$), siendo los peores resultados obtenidos en el aislador 7 ($R^2=0.79 \pm 0.03$). En términos generales, la predicción de la corriente de fuga mediante el modelo 2IL-CNN con las últimas 21 muestras es bastante precisa, obteniendo un R^2 promedio es de 0.89 ± 0.06 para el grupo de test.

Tabla 20. Media y desviación típica del rendimiento de los modelos de predicción de la corriente de fuga a partir de las muestras actuales de variables ambientales mediante el modelo 2IL-CNN. *^oy^Δ indica diferencia significativa de las distintas métricas entre los grupos de entrenamiento vs. validación, entrenamiento y test, validación y test respectivamente.

Aislador	Entrenamiento			Validación			Test		
	R ²	NRMSE	NMAE	R ²	NRMSE	NMAE	R ²	NRMSE	NMAE
1	0.84 ±0.01	3.57 ±0.13	1.68 ±0.02*	0.83 ±0.01	3.60 ±0.23	1.8 ±0.06*	0.84 ±0.01	3.58 ±0.14	1.72 ±0.05
2	0.80 ±0.02	3.23 ±0.28	1.22 ±0.06* ^o	0.79 ±0.02	3.24 ±0.31	1.56 ±0.23*	0.8 ±0.02	3.19 ±0.28	1.65 ±0.19 ^o
3	0.72 ±0.01	13.93 ±0.36	2.58 ±0.1* ^o	0.71 ±0.01	14.34 ±0.37	3.14 ±0.37*	0.71 ±0.01	14.38 ±0.33	2.98 ±0.41 ^o
4	0.62 ±0.01	11.59 ±0.41	0.56 ±0.03* ^o	0.62 ±0.04	11.38 ±1.62	0.66 ±0.08*	0.61 ±0.04	12.13 ±1.55	0.63 ±0.08 ^o
5	0.63 ±0.03	12.67 ±0.93	0.62 ±0.03*	0.64 ±0.03	12.48 ±1.04	0.73 ±0.07*	0.62 ±0.05	13.52 ±2.37	0.67 ±0.07
6	0.74 ±0.01	5.20 ±0.19	1.20 ±0.07*	0.73 ±0.02	5.3 ±0.52	1.26 ±0.05*	0.73 ±0.01	5.27 ±0.29	1.27 ±0.16
7	0.43 ±0.05	17.94 ±1.52	0.66 ±0.05* ^o	0.43 ±0.05	17.73 ±1.84	0.74 ±0.06*	0.43 ±0.05	17.81 ±2.18	0.72 ±0.07 ^o
Total	0.68 ±0.14	9.73 ±5.74	1.22 ±0.73* ^o	0.68 ±0.13	9.73 ±5.7	1.41 ±0.88*	0.68 ±0.14	9.98 ±5.87	1.38 ±0.84 ^o

Tabla 21. Media y desviación típica del rendimiento de los modelos de predicción de la corriente de fuga a partir de las últimas 21 muestras de variables ambientales mediante el modelo 2IL-CNN. *^oy^Δ indica diferencia significativa de las distintas métricas entre los grupos de entrenamiento vs. validación, entrenamiento y test, validación y test respectivamente.

Aislador	Entrenamiento			Validación			Test		
	R ²	NRMSE	NMAE	R ²	NRMSE	NMAE	R ²	NRMSE	NMAE
1	0.99 ±0.00* ^o	0.21 ±0.05* ^o	0.48 ±0.06* ^o	0.95 ±0.00*	1.17 ±0.10*	1.03 ±0.09*	0.95 ±0.00 ^o	1.16 ±0.11 ^o	0.98 ±0.06 ^o
2	0.99 ±0.00* ^o	0.15 ±0.03* ^o	0.32 ±0.04* ^o	0.95 ±0.01*	0.80 ±0.10*	0.80 ±0.14*	0.95 ±0.00 ^o	0.76 ±0.12 ^o	0.84 ±0.09 ^o
3	0.99 ±0.00* ^o	0.57 ±0.21* ^o	0.56 ±0.10* ^o	0.9 1±0.01*	4.58 ±0.55*	1.75 ±0.23*	0.91 ±0.01 ^o	4.63 ±0.67 ^o	1.66 ±0.24 ^o
4	0.99 ±0.00* ^o	0.35 ±0.10* ^o	0.17 ±0.03* ^o	0.86 ±0.03*	4.30 ±1.22*	0.40 ±0.05*	0.86 ±0.02 ^o	4.35 ±0.79 ^o	0.38 ±0.04 ^o
5	0.99 ±0.00* ^o	0.44 ±0.15* ^o	0.19 ±0.03* ^o	0.88 ±0.02*	4.19 ±0.83*	0.42 ±0.04*	0.87 ±0.02 ^o	4.58 ±0.95 ^o	0.39 ±0.04 ^o
6	0.99 ±0.01* ^o	0.26 ±0.12* ^o	0.37 ±0.10* ^o	0.91 ±0.02*	1.75 ±0.38*	0.73 ±0.08*	0.91 ±0.01 ^o	1.77 ±0.25 ^o	0.73 ±0.11 ^o
7	0.98 ±0.00* ^o	0.50 ±0.10* ^o	0.20 ±0.02* ^o	0.79 ±0.03*	6.42 ±1.13*	0.43 ±0.05*	0.79 ±0.03 ^o	6.51 ±1.33 ^o	0.41 ±0.03 ^o
Total	0.99 ±0.00* ^o	0.36 ±0.16* ^o	0.33 ±0.15* ^o	0.89 ±0.05*	3.31 ±2.1*	0.79 ±0.49*	0.89 ±0.06 ^o	3.39 ±2.16 ^o	0.77 ±0.46 ^o

Tabla 22. Análisis estadístico del rendimiento de los modelos de predicción de la corriente de fuga a partir de las muestras actuales y las últimas 21 muestras de variables ambientales mediante el modelo 2IL-CNN. Sombreado gris (P -valor <0.05) indica diferencia estadísticamente significativa entre ambos modelos.

Aislador	Entrenamiento			Validación			Test		
	R ²	NRMSE	NMAE	R ²	NRMSE	NMAE	R ²	NRMSE	NMAE
1	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002
2	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002
3	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002
4	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002
5	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002
6	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002
7	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002
Total	<0.001	<0.001	<0.001	<0.001	<0.001	<0.001	<0.001	<0.001	<0.001



Figura 100. R² promedio de los modelos de predicción de la corriente de fuga a partir de variables ambientales mediante el modelo 2IL-CNN. Izquierda: Muestras actuales. Derecha: Las últimas 21 muestras.

La evolución temporal de la corriente de fuga registrada en cada aislador (línea azul) y su predicción mediante el modelo 2IL-CNN (línea negra) con las últimas 21 muestras, se representan en la traza superior de la Figura 101 a la Figura 107 respectivamente, y en la traza inferior se ilustran el error de predicción en cada aislador. No se han representado las gráficas del mismo modelo utilizando las muestras actuales, porque sus rendimientos son significativamente inferiores. Se puede apreciar en estas figuras, que la predicción de la corriente de fuga se aproxima a la corriente de fuga propiamente registrada, con un error de predicción relativamente pequeño.

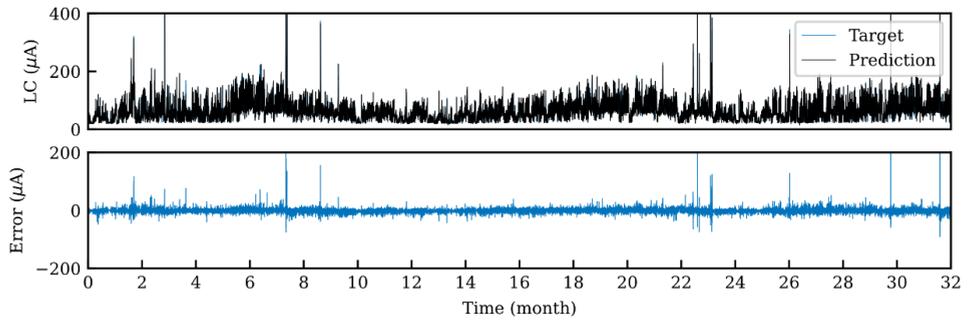


Figura 101. Superior: Predicción de la corriente de fuga a partir de las últimas 21 muestras de variables ambientales del aislador 1 mediante el modelo 2IL-CNN. Inferior: Error de predicción.

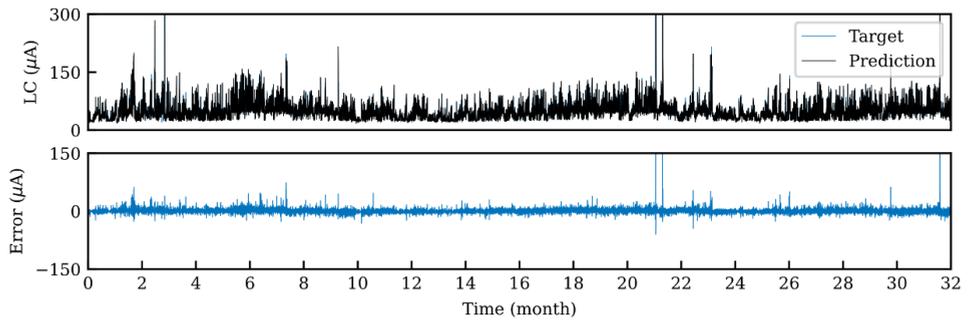


Figura 102. Superior: Predicción de la corriente de fuga a partir de las últimas 21 muestras de variables ambientales del aislador 2 mediante el modelo 2IL-CNN. Inferior: Error de predicción.

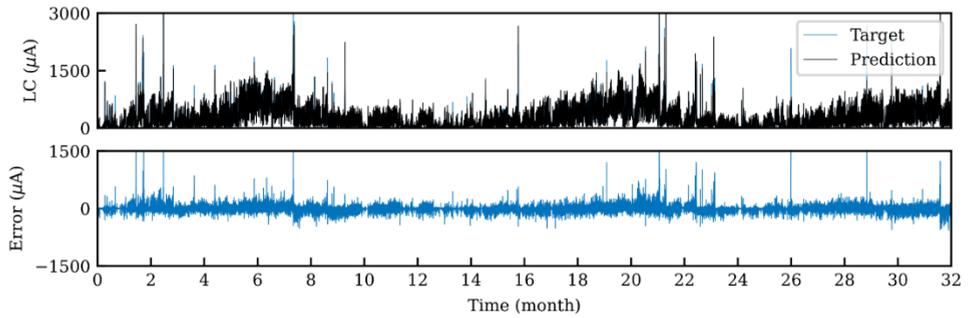


Figura 103. Superior: Predicción de la corriente de fuga a partir de las últimas 21 muestras de variables ambientales del aislador 3 mediante el modelo 2IL-CNN. Inferior: Error de predicción.

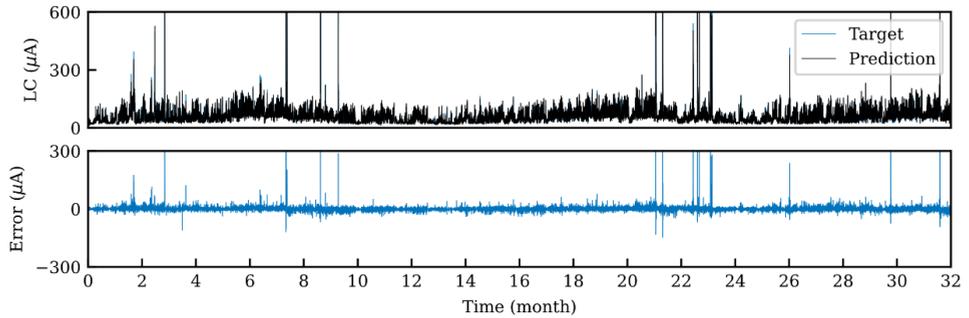


Figura 104. Superior: Predicción de la corriente de fuga a partir de las últimas 21 muestras de variables ambientales del aislador 4 mediante el modelo 2IL-CNN. Inferior: Error de predicción.

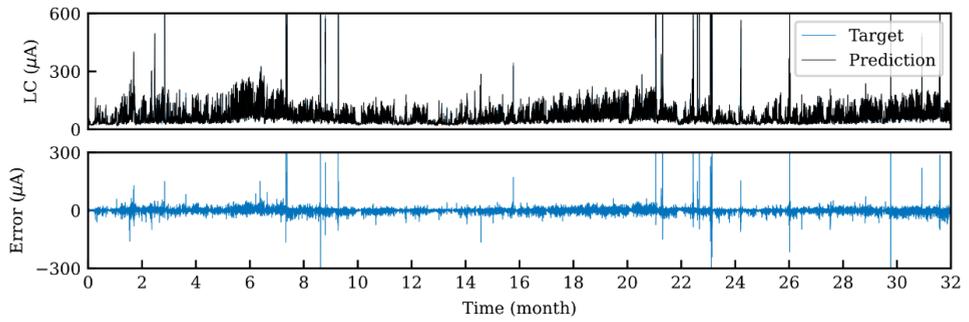


Figura 105. Superior: Predicción de la corriente de fuga a partir de las últimas 21 muestras de variables ambientales del aislador 5 mediante el modelo 2IL-CNN. Inferior: Error de predicción.

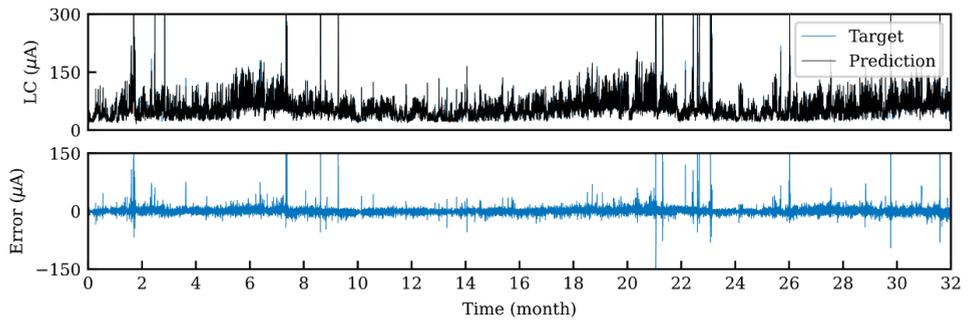


Figura 106. Superior: Predicción de la corriente de fuga a partir de las últimas 21 muestras de variables ambientales del aislador 6 mediante el modelo 2IL-CNN. Inferior: Error de predicción.

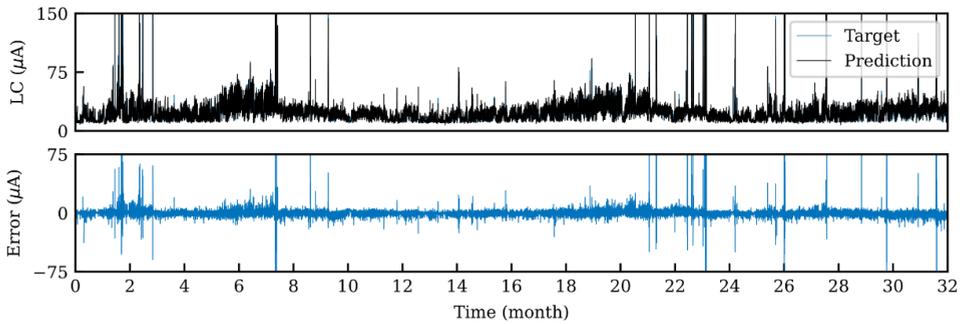


Figura 107. Superior: Predicción de la corriente de fuga a partir de las últimas 21 muestras de variables ambientales del aislador 7 mediante el modelo 2IL-CNN. Inferior: Error de predicción.

Para analizar más detalladamente la bondad de la predicción de corriente de fuga, se ha representado la gráfica de dispersión entre la corriente predicha con el modelo y la corriente de fuga registrada (ver Figura 108). Por el motivo indicado anteriormente, no se ha representado en esta figura el caso de cuando se utilizan sólo las muestras actuales de las variables ambientales. En este caso, la nube de datos empieza a alojarse en la línea recta de 45° de referencia o cerca de la misma, con una distribución casi aleatoria alrededor de dicha recta. De nuevo, para valores de corriente de fuga anormalmente altos, que podrían estar asociados a las condiciones ambientales adversas extremas como lluvia y heladas, el modelo tiende a subestimarlos.

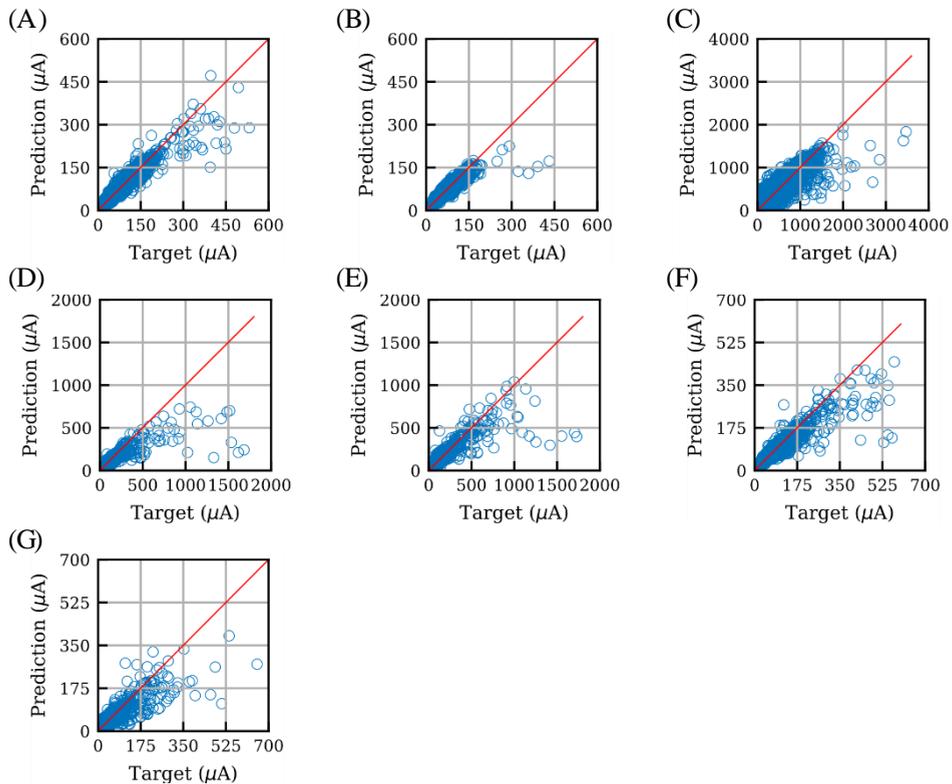


Figura 108. Gráfica de dispersión de la predicción de la corriente de fuga a partir de las últimas 21 muestras de variables ambientales mediante el modelo 2IL-CNN. (A) Aislador 1. (B) Aislador 2. (C) Aislador 3. (D) Aislador 4. (E) Aislador 5. (F) Aislador 6. (G) Aislador 7.

6.4.5. 4IL-CNN

La Tabla 23 y la Tabla 24 muestran los resultados de la predicción de la corriente de fuga basados en el modelo 4IL-CNN, utilizando las muestras actuales y las últimas 21 muestras de las variables ambientales respectivamente. En el caso de utilizar sólo las muestras actuales, no se observan grandes diferencias respecto a los modelos 2SL-CNN y 2IL-CNN. Al igual que los modelos 2SL-CNN y 2IL-CNN, no hay diferencias significativas en los indicadores del modelo entre el grupo de entrenamiento, validación y test, excepto para el NMAE que obtuvo diferencia significativa entre los grupos de entrenamiento y validación, en todos los aisladores. En términos generales, el rendimiento del modelo es moderadamente bueno. El R^2 promedio es de 0.68 ± 0.14 para el grupo de test, con los mejores resultados

obtenidos en los aisladores 1 y 2 (R^2 0.83 ± 0.01 y 0.80 ± 0.01 respectivamente), y el peor rendimiento se obtuvo en el aislador 7 (0.43 ± 0.03).

En cambio, cuando se utilizan las últimas 21 muestras de las variables ambientales como características de entrada, el rendimiento del modelo incrementó considerablemente, tanto en el grupo de entrenamiento, validación como test (ver Figura 109), obteniendo así diferencias significativas en todos los indicadores y en todos los aisladores (ver Tabla 25). Del mismo modo, se han obtenido diferencias significativas en todas métricas entre grupo de entrenamiento y el de validación, y entre grupo de entrenamiento y el de test, siendo las diferencias entre el grupo de validación y el de test estadísticamente irrelevantes (ver Tabla 24). Independientemente del aislador, el R^2 es superior al 0.98 para el grupo de entrenamiento. En el grupo de test, los rendimientos dependen de nuevo del aislador. Los mejores resultados se tienen en los aisladores 1 y 2 ($R^2=0.98\pm 0.00$), aunque los otros aisladores cerámicos también han obtenido rendimientos muy buenos, siendo el $R^2>0.92$. De nuevo, el peor rendimiento se ha obtenido en el aislador 7 ($R^2=0.88\pm 0.02$). El R^2 promedio es del 0.94 ± 0.03 para el grupo de test, lo cual representa la capacidad de generalización del modelo 4IL-CNN a los nuevos datos entrantes 'nunca' vistos por el modelo.

Tabla 23. Media y desviación típica del rendimiento de los modelos de predicción de la corriente de fuga a partir de las muestras actuales de variables ambientales mediante el modelo 4IL-CNN. *^oy^Δ indica diferencia significativa de las distintas métricas entre los grupos de entrenamiento vs. validación, entrenamiento y test, validación y test respectivamente.

Aislador	Entrenamiento			Validación			Test		
	R ²	NRMSE	NMAE	R ²	NRMSE	NMAE	R ²	NRMSE	NMAE
1	0.83 ±0.01	3.74 ±0.27	1.72 ±0.06*	0.83 ±0.02	3.77 ±0.43	1.84 ±0.11*	0.83 ±0.01	3.74 ±0.28	1.76 ±0.08
2	0.80 ±0.01	3.12 ±0.16	1.21 ±0.04* ^o	0.80 ±0.01	3.14 ±0.19	1.55 ±0.22*	0.80 ±0.01	3.08 ±0.17	1.64 ±0.17
3	0.72 ±0.01	13.80 ±0.42	2.58 ±0.08* ^o	0.71 ±0.01	14.22 ±0.32	3.14 ±0.39*	0.71 ±0.01	14.21 ±0.32	2.99 ±0.44
4	0.62 ±0.01	11.50 ±0.47	0.56 ±0.03* ^o	0.62 ±0.04	11.32 ±1.76	0.66 ±0.08*	0.61 ±0.03	12.01 ±1.24	0.63 ±0.10
5	0.64 ±0.03	12.27 ±0.91	0.64 ±0.06*	0.6 ±0.03	12.08 ±1.28	0.75 ±0.08*	0.63 ±0.04	12.94 ±1.76	0.69 ±0.09
6	0.73 ±0.01	5.38 ±0.27	1.20 ±0.03*	0.72 ±0.03	5.51 ±0.72	1.27 ±0.05*	0.73 ±0.02	5.42 ±0.36	1.26 ±0.10
7	0.43 ±0.03	18.14 ±1.07	0.66 ±0.05* ^o	0.43 ±0.03	17.66 ±1.44	0.74 ±0.09*	0.43 ±0.03	18.05 ±1.74	0.72 ±0.09
Total	0.68 ±0.14	9.71 ±5.7	1.22 ±0.73* ^o	0.68 ±0.13	9.67 ±5.6	1.42 ±0.88*	0.68 ±0.14	9.92 ±5.82	1.38 ±0.84

Tabla 24. Media y desviación típica del rendimiento de los modelos de predicción de la corriente de fuga a partir de las últimas 21 muestras de variables ambientales mediante el modelo 4IL-CNN. *^oy^Δ indica diferencia significativa de las distintas métricas entre los grupos de entrenamiento vs. validación, entrenamiento y test, validación y test respectivamente.

Aislador	Entrenamiento			Validación			Test		
	R ²	NRMSE	NMAE	R ²	NRMSE	NMAE	R ²	NRMSE	NMAE
1	0.99 ±0.00* ^o	0.17 ±0.04* ^o	0.42 ±0.05* ^o	0.98 ±0.00*	0.52 ±0.08*	0.63 ±0.05*	0.98 ±0.00 ^o	0.51 ±0.07 ^o	0.60 ±0.05 ^o
2	0.99 ±0.00* ^o	0.17 ±0.04* ^o	0.32 ±0.03* ^o	0.97 ±0.00*	0.40 ±0.08*	0.53 ±0.08*	0.98 ±0.00 ^o	0.37 ±0.06 ^o	0.56 ±0.07 ^o
3	0.99 ±0.00* ^o	0.38 ±0.16* ^o	0.44 ±0.09* ^o	0.97 ±0.00*	1.42 ±0.19*	0.86 ±0.13*	0.97 ±0.01 ^o	1.53 ±0.32 ^o	0.81 ±0.11 ^o
4	0.99 ±0.00* ^o	0.37 ±0.10* ^o	0.15 ±0.03* ^o	0.93 ±0.02*	2.14 ±0.74*	0.26 ±0.05*	0.93 ±0.02 ^o	2.25 ±0.73 ^o	0.24 ±0.05 ^o
5	0.98 ±0.02* ^o	0.52 ±0.60* ^o	0.17 ±0.07* ^o	0.92 ±0.03*	2.61 ±1.06*	0.28 ±0.06*	0.92 ±0.02 ^o	2.75 ±0.86 ^o	0.26 ±0.08 ^o
6	0.99 ±0.01* ^o	0.25 ±0.16* ^o	0.34 ±0.10* ^o	0.95 ±0.01*	0.93 ±0.23*	0.49 ±0.09*	0.95 ±0.01 ^o	0.92 ±0.17 ^o	0.49 ±0.13 ^o
7	0.98 ±0.00* ^o	0.49 ±0.13* ^o	0.17 ±0.02* ^o	0.89 ±0.02*	3.42 ±0.62*	0.26 ±0.03*	0.88 ±0.02 ^o	3.64 ±0.84 ^o	0.26 ±0.03 ^o
Total	0.9 ±0.00* ^o	0.33 ±0.14* ^o	0.29 ±0.12* ^o	0.95 ±0.03*	1.63 ±1.13*	0.47 ±0.22*	0.94 ±0.03 ^o	1.71 ±1.22 ^o	0.46 ±0.22 ^o

Tabla 25. Análisis estadístico del rendimiento de los modelos de predicción de la corriente de fuga a partir de las muestras actuales y las últimas 21 muestras de variables ambientales mediante el modelo 4IL-CNN. Sombreado gris (P -valor <0.05) indica diferencia estadísticamente significativa entre ambos modelos.

Aislador	Entrenamiento			Validación			Test		
	R ²	NRMSE	NMAE	R ²	NRMSE	NMAE	R ²	NRMSE	NMAE
1	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002
2	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002
3	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002
4	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002
5	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002
6	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002
7	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002
Total	<0.001	<0.001	<0.001	<0.001	<0.001	<0.001	<0.001	<0.001	<0.001

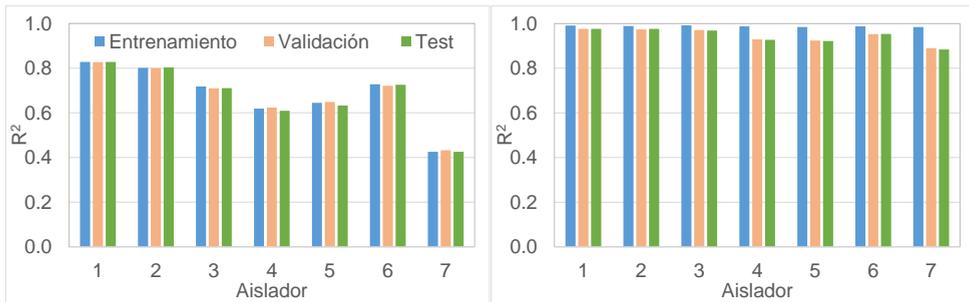


Figura 109. R² promedio de los modelos de predicción de la corriente de fuga a partir de variables ambientales mediante el modelo 4IL-CNN. Izquierda: Muestras actuales. Derecha: Las últimas 21 muestras.

De la Figura 110 a la Figura 116 se muestra la corriente de fuga registrada en los aisladores (línea azul de la traza superior) y su predicción con el modelo 4IL-CNN, utilizando las últimas 21 muestras de variables ambientales como características de entrada (línea negra de la traza superior), así como el error de predicción (traza inferior) respectivamente. Se ha optado por estos modelos porque sus rendimientos fueron estadísticamente mejores que cuando se utilizan las muestras actuales como características de entrada. Independientemente del aislador, el error de predicción es pequeño en comparación con la propia corriente de fuga registrada, sugiriendo la bondad del modelo para capturar la interacción subyacente entre las variables ambientales y la corriente de fuga.

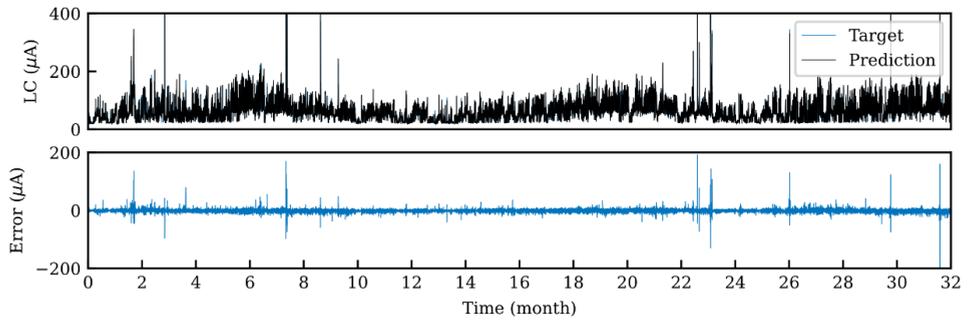


Figura 110. Superior: Predicción de la corriente de fuga a partir de las últimas 21 muestras de variables ambientales del aislador 1 mediante el modelo 4IL-CNN. Inferior: Error de predicción.

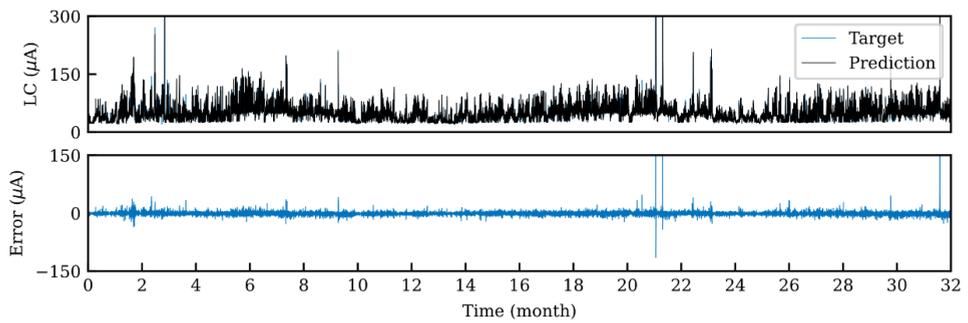


Figura 111. Superior: Predicción de la corriente de fuga a partir de las últimas 21 muestras de variables ambientales del aislador 2 mediante el modelo 4IL-CNN. Inferior: Error de predicción.

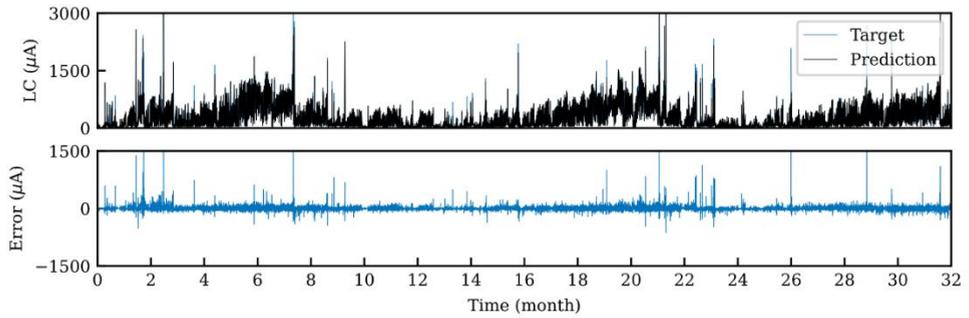


Figura 112. Superior: Predicción de la corriente de fuga a partir de las últimas 21 muestras de variables ambientales del aislador 3 mediante el modelo 4IL-CNN. Inferior: Error de predicción.

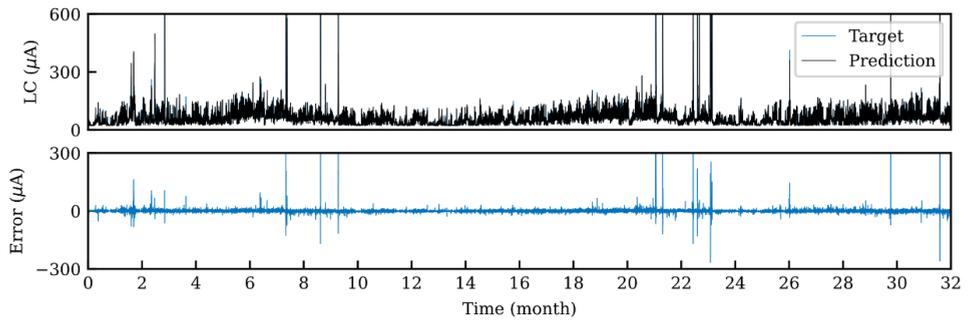


Figura 113. Superior: Predicción de la corriente de fuga a partir de las últimas 21 muestras de variables ambientales del aislador 4 mediante el modelo 4IL-CNN. Inferior: Error de predicción.

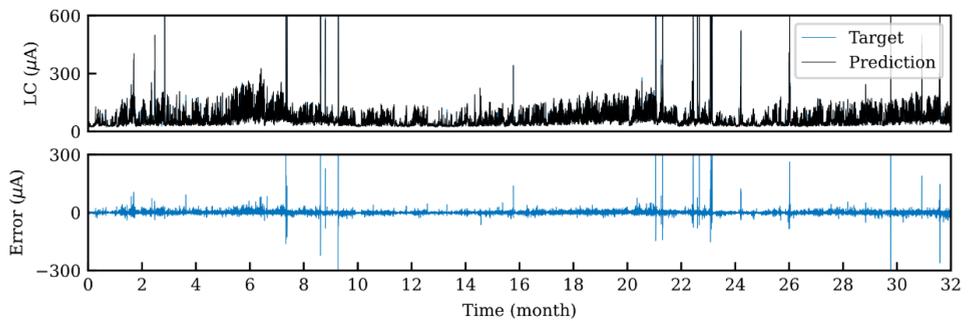


Figura 114. Superior: Predicción de la corriente de fuga a partir de las últimas 21 muestras de variables ambientales del aislador 5 mediante el modelo 4IL-CNN. Inferior: Error de predicción.

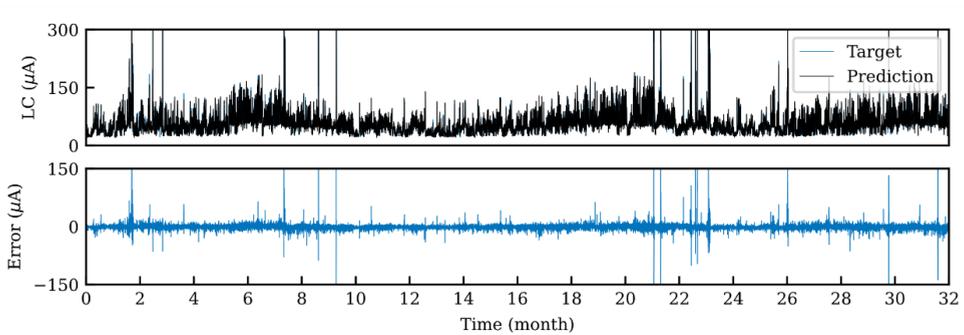


Figura 115. Superior: Predicción de la corriente de fuga a partir de las últimas 21 muestras de variables ambientales del aislador 6 mediante el modelo 4IL-CNN. Inferior: Error de predicción.

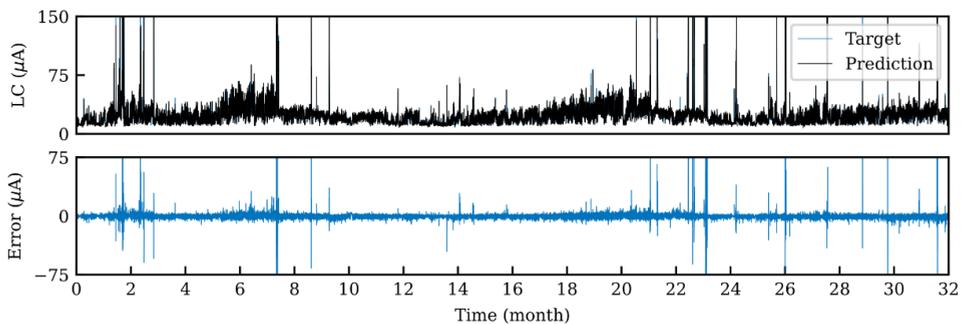


Figura 116. Superior: Predicción de la corriente de fuga a partir de las últimas 21 muestras de variables ambientales del aislador 7 mediante el modelo 4IL-CNN. Inferior: Error de predicción.

La Figura 117 muestra la gráfica de dispersión de la predicción de la corriente de fuga mediante el modelo 4IL-CNN, utilizando las últimas 21 muestras de variables ambientales frente a la corriente de fuga registrada. Independientemente del aislador, la nube de datos se acerca a la línea recta de 45° de referencia (línea roja si hubiera obtenido una predicción ideal), con una distribución casi aleatoria alrededor de la misma. Solo en caso de corriente de fuga muy elevada (picos de corriente anómalos debido a las condiciones ambientales adversas extremas como lluvia y heladas), el modelo tiende a

subestimarlas. De nuevo, estos resultados confirman la bondad del modelo para predecir la corriente de fuga a partir de las variables ambientales.

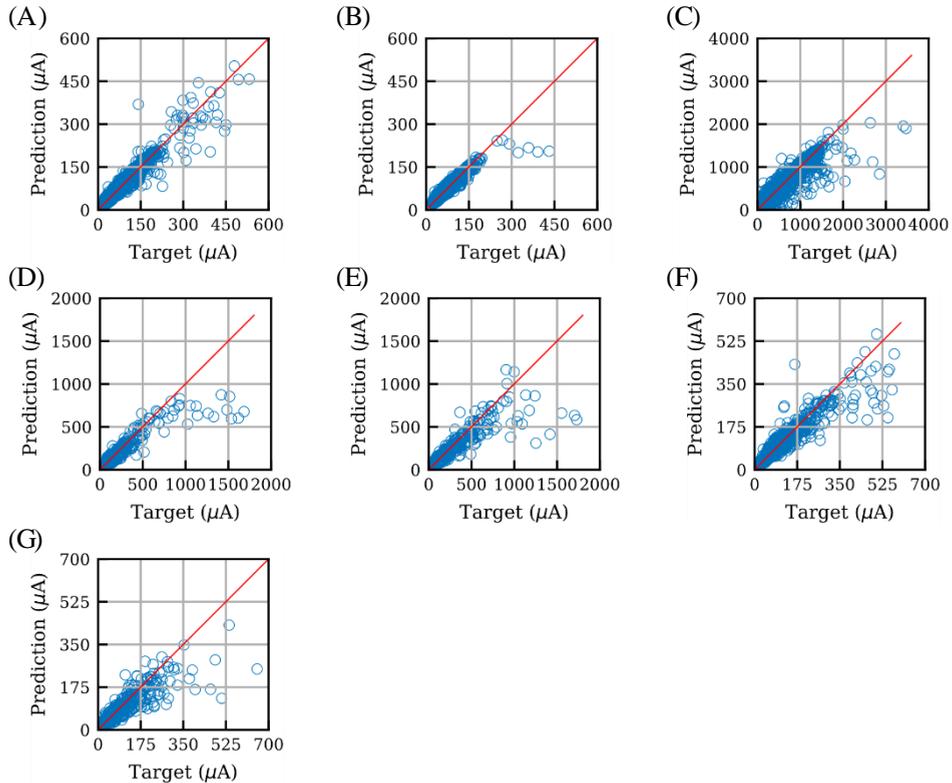


Figura 117. Gráfica de dispersión de la predicción de la corriente de fuga a partir de las últimas 21 muestras de variables ambientales mediante el modelo 4IL-CNN. (A) Aislador 1. (B) Aislador 2. (C) Aislador 3. (D) Aislador 4. (E) Aislador 5. (F) Aislador 6. (G) Aislador 7.

6.4.6. Análisis comparativo entre las distintas técnicas

En este apartado se presentan los resultados del estudio comparativo de las distintas técnicas para la predicción de corriente de fuga utilizando las últimas 21 muestras de variables ambientales. Esto es debido, a que en los apartados anteriores se ha observado que en general, el hecho de utilizar las últimas 21 muestras, obtuvo rendimientos significativamente mejores que cuando utilizan sólo las muestras actuales.

Para determinar la bondad de los distintos modelos de predicción de la corriente de fuga, se ha realizado el estudio comparativo de las tres métricas del grupo de test (ver R^2 en la Tabla 26, NRMSE en la Tabla 27 y NMAE en la Tabla 28). El estudio comparativo solo se realiza para el rendimiento en el grupo de test, ya que éste representa la capacidad de generalización real para los nuevos datos entrantes 'nunca' vistos por el modelo. De la Figura 118 a la Figura 124 se muestran las gráficas de cajas y bigotes de los rendimientos en el grupo de test de la predicción de la corriente de fuga de cada aislador. La Figura 125 muestra estas gráficas para el total de los 7 aisladores.

Tabla 26. Media y desviación del R^2 de los distintos modelos de predicción de la corriente de fuga en el grupo de test.

Aislador	MVR	SVR	2SL-CNN	2IL-CNN	4IL-CNN
1	0.58±0.01	0.85±0.01	0.85±0.01	0.95±0.00	0.98±0.00
2	0.57±0.00	0.81±0.01	0.83±0.01	0.95±0.00	0.98±0.00
3	0.42±0.00	0.73±0.00	0.75±0.01	0.91±0.01	0.97±0.01
4	0.37±0.02	0.63±0.03	0.70±0.03	0.86±0.02	0.93±0.02
5	0.33±0.02	0.66±0.03	0.70±0.03	0.87±0.02	0.92±0.02
6	0.47±0.01	0.74±0.01	0.76±0.04	0.91±0.01	0.95±0.01
7	0.23±0.01	0.45±0.07	0.52±0.02	0.79±0.03	0.88±0.02
Total	0.42±0.13	0.70±0.13	0.73±0.11	0.89±0.06	0.94±0.03

Tabla 27. Media y desviación del NRMSE de los distintos modelos de predicción de la corriente de fuga en el grupo de test.

Aislador	MVR	SVR	2SL-CNN	2IL-CNN	4IL-CNN
1	9.04±0.20	3.30±0.15	3.2±0.28	1.16±0.11	0.51±0.07
2	6.85±0.11	2.97±0.10	2.63±0.20	0.76±0.12	0.37±0.06
3	28.59±0.26	13.14±0.24	12.44±0.58	4.63±0.67	1.53±0.32
4	19.51±1.23	11.40±1.20	9.24±1.38	4.35±0.79	2.25±0.73
5	23.37±1.64	11.93±1.37	10.64±1.46	4.58±0.95	2.75±0.86
6	10.33±0.42	5.02±0.32	4.65±0.8	1.77±0.25	0.92±0.17
7	24.48±1.30	17.37±2.51	15.22±1.36	6.51±1.33	3.64±0.84
Total	17.45±8.63	9.30±5.56	8.29±4.88	3.39±2.16	1.71±1.22

Tabla 28. Media y desviación del NMAE de los distintos modelos de predicción de la corriente de fuga en el grupo de test.

Aislador	MVR	SVR	NMAE	2IL-CNN	4IL-CNN
1	3.28±0.13	1.65±0.07	1.64±0.09	0.98±0.06	0.60±0.05
2	2.31±0.30	1.30±0.18	1.57±0.18	0.84±0.09	0.56±0.07
3	4.87±0.45	2.64±0.24	2.81±0.37	1.66±0.24	0.81±0.11
4	1.02±0.07	0.60±0.04	0.61±0.08	0.38±0.04	0.24±0.05
5	1.32±0.16	0.68±0.09	0.67±0.09	0.39±0.04	0.26±0.08
6	2.15±0.14	1.26±0.07	1.28±0.15	0.73±0.11	0.49±0.13
7	0.94±0.07	0.72±0.04	0.69±0.05	0.41±0.03	0.26±0.03
Total	2.27±1.41	1.26±0.72	1.33±0.78	0.77±0.46	0.46±0.22

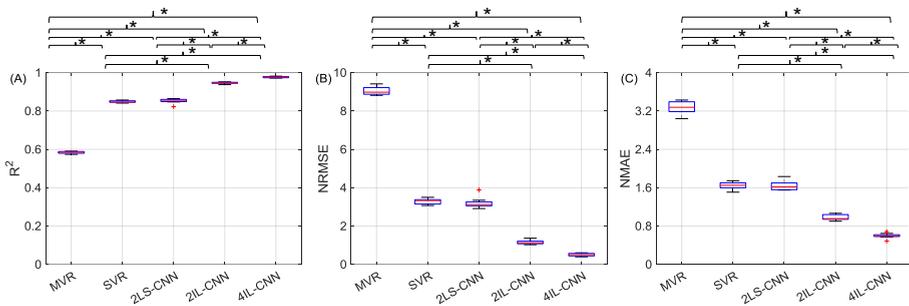


Figura 118. Gráficas de cajas y bigotes de los rendimientos en el grupo de test de la predicción de corriente de fuga del aislador 1 empleando las últimas 21 muestras. * indica diferencias significativas de la métrica entre distintas técnicas. (A) R^2 . (B) NRMSE. (C) NMAE.

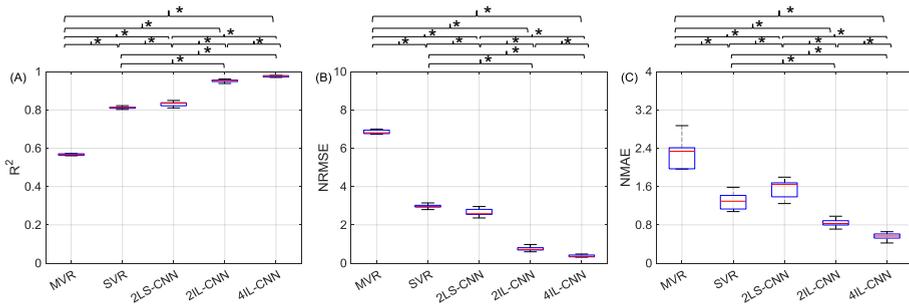


Figura 119. Gráficas de cajas y bigotes de los rendimientos en el grupo de test de la predicción de corriente de fuga del aislador 2 empleando las últimas 21 muestras. * indica diferencias significativas de la métrica entre distintas técnicas. (A) R^2 . (B) NRMSE. (C) NMAE.

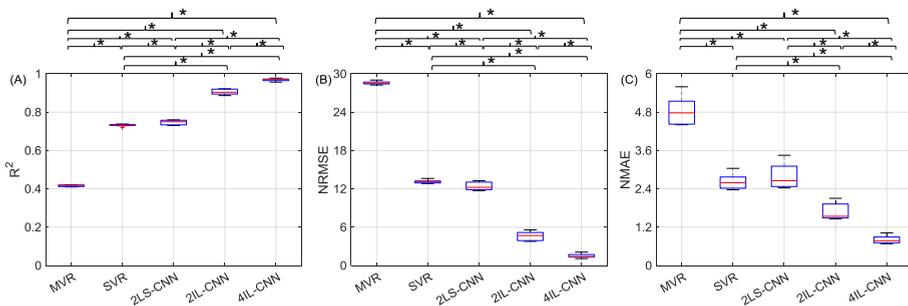


Figura 120. Gráficas de cajas y bigotes de los rendimientos en el grupo de test de la predicción de corriente de fuga del aislador 3 empleando las últimas 21 muestras. * indica diferencias significativas de la métrica entre distintas técnicas. (A) R^2 . (B) NRMSE. (C) NMAE.

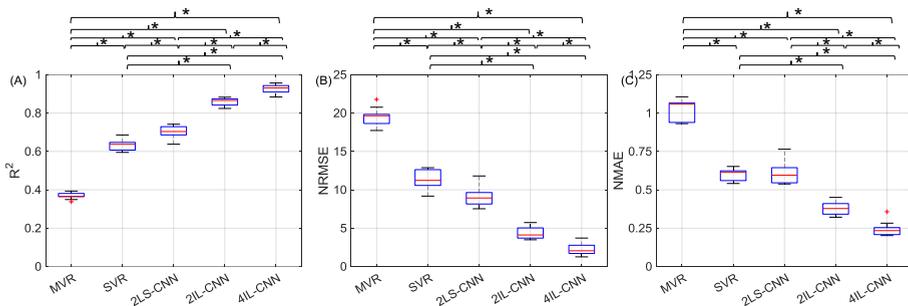


Figura 121. Gráficas de cajas y bigotes de los rendimientos en el grupo de test de la predicción de corriente de fuga del aislador 4 empleando las últimas 21 muestras. * indica diferencias significativas de la métrica entre distintas técnicas. (A) R^2 . (B) NRMSE. (C) NMAE.

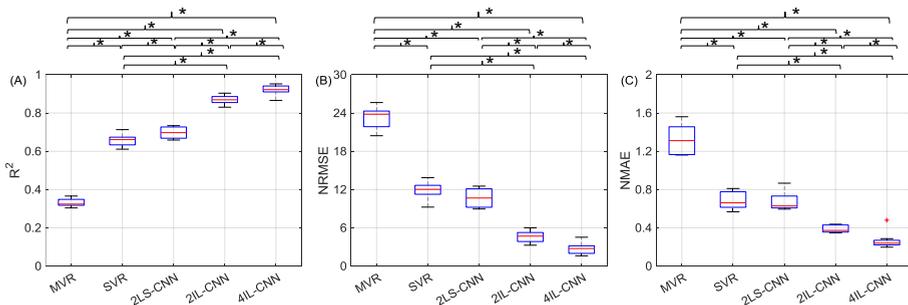


Figura 122. Gráficas de cajas y bigotes de los rendimientos en el grupo de test de la predicción de corriente de fuga del aislador 5 empleando las últimas 21 muestras. * indica diferencias significativas de la métrica entre distintas técnicas. (A) R^2 . (B) NRMSE. (C) NMAE.

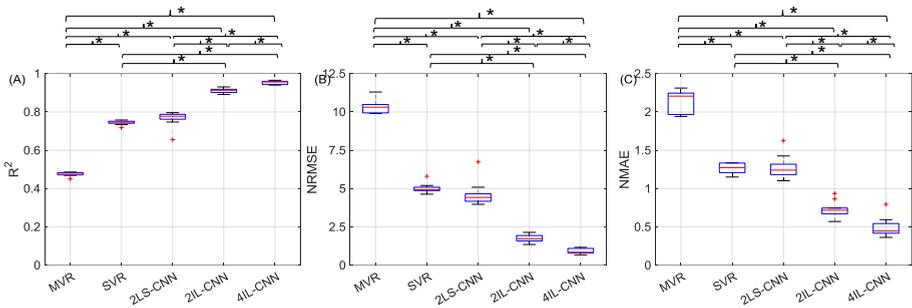


Figura 123. Gráficas de cajas y bigotes de los rendimientos en el grupo de test de la predicción de corriente de fuga del aislador 6 empleando las últimas 21 muestras. * indica diferencias significativas de la métrica entre distintas técnicas. (A) R^2 . (B) NRMSE. (C) NMAE.

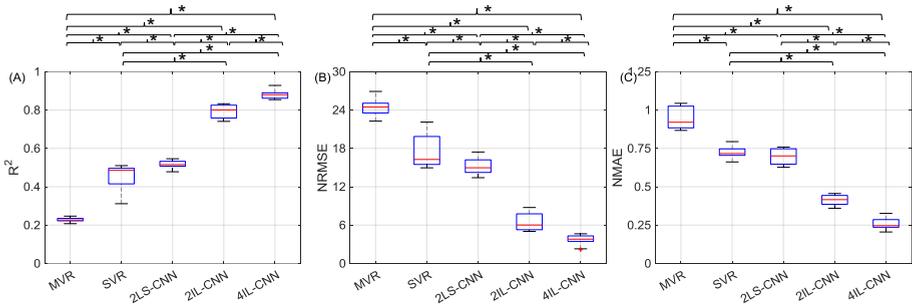


Figura 124. Gráficas de cajas y bigotes de los rendimientos en el grupo de test de la predicción de corriente de fuga del aislador 7 empleando las últimas 21 muestras. * indica diferencias significativas de la métrica entre distintas técnicas. (A) R^2 . (B) NRMSE. (C) NMAE.

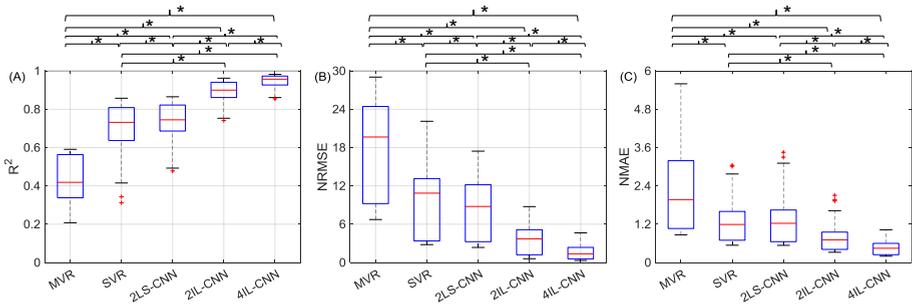


Figura 125. Gráficas de cajas y bigotes de los rendimientos en el grupo de test de la predicción de corriente de fuga de los 7 aisladores empleando las últimas 21 muestras. * indica diferencias significativas de la métrica entre distintas técnicas. (A) R^2 . (B) NRMSE. (C) NMAE.

En términos generales, el modelo MVR obtuvo peor rendimiento para la predicción de la corriente de fuga. El R^2 promedio es 0.42 ± 0.13 , con el peor rendimiento en el aislador 7 (0.23 ± 0.01) y los mejores resultados se obtienen en el aislador 1 (0.58 ± 0.01). Estos resultados sugieren, que la interacción entre las variables ambientales y la corriente de fuga, es una relación altamente no-lineal. Además, hay una gran variabilidad entre distintos aisladores en la predictabilidad de la corriente de fuga a partir de las variables ambientales.

El problema se logra mitigar parcialmente con el modelo SVR, que obtuvo resultados sustancialmente mejores, obteniendo el R^2 promedio es 0.70 ± 0.13 para el modelo SVR, con el peor rendimiento en el aislador 7 (0.45 ± 0.07), y los mejores resultados se obtienen en el aislador 1 (0.85 ± 0.01). El análisis estadístico indica que el modelo SVR, presenta rendimiento significativamente mejor que MVR: mayor R^2 , menor NRMSE y NMAE. Este fenómeno se observa en las tres métricas de cada uno de los aisladores y también en el total de los 7 aisladores (ver Figura 125). Si bien es cierto que el SVR mejora la predictabilidad de la corriente de fuga a partir de variables ambientales, pero éste no disminuye la variabilidad entre los distintos aisladores.

El modelo 2SL-CNN obtiene un R^2 promedio de 0.73 ± 0.11 , que es ligeramente mayor que el obtenido con SVR (0.70 ± 0.13). De nuevo, el peor rendimiento se obtiene en el aislador 7 (0.52 ± 0.02) y los mejores resultados se obtienen en el aislador 1 (0.85 ± 0.01). El análisis estadístico indica que en comparación con el modelo SVR, el R^2 obtenido con el modelo 2SL-CNN es significativamente mayor en los aisladores 2, 3, 4, 5 y 7, siendo las diferencias de R^2 estadísticamente irrelevantes en los aisladores 1 y 6. En cambio, el NRMSE del modelo 2SL-CNN es significativamente menor en los aisladores 2, 3, 4 y 7, y en el resto de aisladores las diferencias del NRMSE entre estos dos modelos es insignificante. En cuanto al NMAE, sólo obtuvo diferencia significativa entre estos dos modelos para el aislador 2, mientras que las diferencias en los demás aisladores son estadísticamente insignificantes. Para el total de los 7 aisladores, se han obtenido

diferencias significativas en R^2 y NRMSE entre el modelo SVR y 2SL-CNN, en cambio, estos modelos no presentaron diferencias significativas en NMAE. El modelo 2SL-CNN obtuvo un rendimiento significativamente mejor que el MVR, obteniendo mayor R^2 , menor NRMSE y NMAE en las tres métricas de cada aislador y en el total de los 7 aisladores.

Asimismo, el uso de las capas *inceptions* mejoró considerablemente los rendimientos del modelo. En comparación con MVR, SVR y 2SL-CNN, tanto el modelo 2IL-CNN como 4IL-CNN obtuvieron un R^2 significativamente mayor y NRMSE y NMAE significativamente menor. Este fenómeno se puede observar en las tres métricas y en cada uno de los aisladores, y por tanto en el total de los 7 aisladores. Como resultados generales, destacar que el R^2 promedio del modelo 2IL-CNN es de 0.89 ± 0.06 para el total de los 7 aisladores, cuyo valor varía desde 0.79 ± 0.03 para el aislador 7 al 0.95 ± 0.00 para el aislador 1. En cambio, el R^2 promedio del modelo 4IL-CNN es de 0.94 ± 0.03 para el total de los 7 aisladores, variando desde 0.88 ± 0.02 para el aislador 7 al 0.98 ± 0.00 para el aislador 1 y 2. Es decir, las capas *inceptions*, no solo aumentaron significativamente el rendimiento promedio de la predicción de corriente de fuga, sino también redujeron la variabilidad entre los distintos aisladores. En comparación con el modelo 2IL-CNN, el rendimiento del modelo 4IL-CNN es incluso superior, mejorando las diferencias estadísticamente significativas en las tres métricas en cada aislador y para el total de los 7 aisladores.

Fuerza y honor.
Máximo Décimo Meridio

**CAPÍTULO V:
DISCUSIÓN**

7. Discusión

En esta tesis, se ha pretendido contribuir al desarrollo una nueva tecnología, basada en la información, para el mantenimiento preventivo de los aisladores eléctricos de alta tensión. Todo ello con el objetivo de aumentar la fiabilidad y resiliencia de la red eléctrica. Específicamente se busca estimar la corriente de fuga asociada a los depósitos de contaminación (PLC) en aisladores eliminando la influencia de las variables ambientales y desarrollando modelos robustos y precisos de predicción de la corriente de fuga a partir de las variables ambientales.

7.1. Relación entre la corriente de fuga y las variables ambientales

Independientemente del aislador, nuestros resultados indican que la mayor corriente de fuga en bruto se tiene en épocas secas (verano) y por tanto, está asociada con la mayor probabilidad de corte de suministro, especialmente en momentos de neblinas o alta humedad relativa. Después de la época lluviosa (gota fría en otoño) los aisladores eléctricos se mantienen con un nivel bajo de depósitos de contaminación, por lo que presentan un riesgo bajo de aparición de la descarga disruptiva. Estos resultados concuerdan con otros autores que analizaron el riesgo de aparición de descarga disruptiva y fallo del sistema eléctrico a través de la monitorización continua de la corriente de fuga [161].

Asimismo, se ha analizado la relación subyacente entre la corriente de fuga en bruto registrada y las diferentes variables ambientales. Se encontró que la corriente de fuga en bruto estaba estrechamente correlacionada con la humedad relativa, el modelo que mejor describió esta relación fue con una función exponencial o polinómica. Este hallazgo coincide con el de Zhicheng *et al.*, en el que analizaron la relación entre la corriente de fuga y la humedad relativa para diferentes niveles de sustancias contaminantes en laboratorio y

confirmaron que esta última obedecía a una función exponencial [80] y también con otros autores que analizaron esta relación en instalaciones *in situ* [59,68–70]. En comparación con el aislador 3 sin recubrimiento, la corriente de fuga en bruto registrada en aisladores recubiertos de RTV, presentó una mayor correlación con la humedad relativa. Esto se debe probablemente al hecho de que los aisladores no recubiertos, en presencia de humedad, tienen una distribución más heterogénea de gotas de agua en la superficie del aislador, con una proporción importante de superficie hidrófila, en la que la película de agua es continua y tiende a producir bandas secas. Por otro lado, la magnitud de la corriente de fuga en los aisladores con recubrimiento RTV es más uniforme, debido a la distribución más homogénea de las gotas de agua en la superficie, dando lugar a una mayor correlación con la humedad relativa.

Asimismo, se ha observado, que independientemente del aislador, la corriente de fuga promedio diaria muestra una fluctuación estacional similar a la temperatura promedio diaria, alcanzando su valor máximo en los meses 6-8, 18-20 y 30, mientras que los valores mínimos se obtienen en los meses de invierno (meses 0, 12 y 24) (ver Figura 54 y Figura 55), lo cual sugiere que probablemente existe una relación entre ellas. En cambio, en la gráfica de dispersión se ha visto que los valores mas bajos de corriente de fuga en bruto, se obtuvieron para los rangos de temperatura alta y baja, dando lugar a una correlación débil entre estos dos factores. Este hallazgo coincide parcialmente con otros autores, que sugirieron que la corriente de fuga disminuyó, debido al secado a medida que aumentaba la temperatura [71]. Sin embargo, también encontramos valores bajos de corriente de fuga a temperaturas inferiores a 5°C, que pueden estar asociados con las condiciones climáticas específicas de la instalación. Concretamente, la temperatura inferior a 5°C sucede en el invierno, después del efecto de auto-lavado debido a “la gota fría” del otoño. La correlación de Spearman indica que la corriente de fuga aumenta con la temperatura, lo cual discrepa con la observación de otros autores que indicaron que la temperatura, tenía efecto irrelevante [67,71] o la corriente de fuga presenta una relación inversa débil con la temperatura [70].

Salam *et al.* encontraron que la dirección del viento puede dar lugar a la deposición heterogénea de sustancias contaminantes en las superficies de los aisladores [63], mientras que Hussain *et al.* encontraron un aumento de los depósitos salinos en la dirección del viento predominante, en períodos de tiempo cortos [64]. Tanto la distancia al mar como el tiempo de exposición influyeron en los depósitos salinos depositados [64]. En esta tesis, no se ha encontrado una dirección del viento predominante (70% del tiempo sopla el viento de norte o de este, ver Figura 51) debido a que el registro es larga duración de 30 meses. En cambio, la dirección del viento presenta una fluctuación estacional (aproximadamente 50% viento de sur y de oeste en invierno, y ~80% vientos de norte y de este en verano), debido a la climatología específica del lugar donde se instalaron los aisladores. Sin embargo, se ha determinado una relación inversa moderada entre la corriente de fuga en bruto y la dirección del viento, posiblemente debido a la orientación específica con respecto al mar. Específicamente, un ángulo pequeño de dirección del viento se asoció con depósitos salinos húmedos y valores de corriente de fugas más altos. Por otro lado, la velocidad del viento obtuvo una relación inversa moderada con la corriente de fuga. Este hallazgo no concuerda con los resultados de Salam *et al.* [63], que determinaron que la corriente de fuga es mayor para altas velocidades de viento en sus ensayos de laboratorio y describieron esta relación como $I = D_c (wW)^b$ [63]. Esta discrepancia puede deberse al hecho de que sólo analizaron la influencia de la velocidad del viento en un rango restringido de 2-4 m/s en sus ensayos y en esta tesis se ha analizado los datos adquiridos *in-situ* de larga duración. Nuestros resultados coinciden parcialmente con Hussain *et al.*, que determinaron una relación no lineal entre la corriente de fuga y la velocidad del viento [64]. Observaron que la corriente de fuga aumentaba con velocidades de viento inferiores a 10 m/s debido a los depósitos de contaminación más altos en las superficies de los aisladores. Por el contrario, la corriente de fuga tendía a disminuir a velocidades de viento superiores a 10 m/s, debido al efecto de secado y/o arrastre [64]. Nuestros resultados sugieren que la relación entre la corriente de fuga en bruto y las variables ambientales durante todo el año en registros a largo plazo, es mucho

más compleja que el registro a corto plazo o en condiciones de laboratorio.

De hecho, se ha verificado que la correlación parcial con la dirección y la velocidad del viento, al controlar el efecto de otras variables ambientales, era mucho más débil que sus coeficientes de correlación correspondientes. Además, la corriente de fuga resultante, después de cancelar la influencia de la humedad relativa en la corriente de fuga, presentó un coeficiente de correlación con las diferentes variables ambientales menor de 0.03. Estos resultados sugieren que la relación entre la corriente de fuga y la temperatura, la dirección y la velocidad del viento, eran principalmente atribuibles a la fluctuación de la humedad relativa producida por la variación de estas variables ambientales, lo que indica, que no es necesario diseñar un filtro específico para cancelar la influencia de estas tres variables en la corriente de fuga, como se hizo para la humedad relativa. Nuestros resultados coinciden con los de Castillo Sierra *et al.*, quienes consideraron que la temperatura y la dirección del viento sólo provocaron un pequeño cambio en el riesgo de fallo, en registros de larga duración [161,162]. También concuerdan con Salam *et al.*, quienes declararon que los cambios de temperatura tuvieron un efecto insignificante en la corriente de fuga, a humedad relativa constante, en las pruebas de laboratorio [63]. Estos hallazgos también están de acuerdo con Hussain *et al.*, quienes sugirieron que la relación no lineal entre la corriente de fuga y la velocidad del viento, estaba asociada con el proceso de humedecido y secado, y por lo tanto con la humedad relativa [64].

Asimismo, se ha analizado la relación causa-efecto entre las distintas variables ambientales y la corriente de fuga mediante causalidad de Granger. Independientemente del aislador, tanto la temperatura, la humedad como la velocidad del viento presenta una causalidad de Granger significativa, sugiriendo que contiene información relevante para predecir la corriente de fuga. En cambio, la dirección del viento solo presentó una causalidad de Granger significativa en los aisladores 1, 2, 3 y 5. Por simplificar el procedimiento, se han utilizado posteriormente las 4 variables ambientales para la predicción de la

corriente de fuga. Además, se ha determinado que las 20 muestras (100 minutos) anteriores contienen información relevante para la predicción de la corriente de fuga de acuerdo con el modelo de vectores autorregresivos, lo cual coincide con el orden óptimo del filtro adaptativo utilizado para estimar la PLC, que se determinó experimentalmente. Esto probablemente, esté asociado con el efecto retardado de deposición de la humedad en la superficie del aislado y absorción por la capa contaminante. Este fenómeno fue observado por otros autores que analizaron en el laboratorio la magnitud máxima de la corriente de fuga y el tiempo de absorción (tiempo en alcanzar la magnitud máxima) cuando se deposita una mezcla de kierselguhr y una sustancia no soluble de cloruro sódico de concentración variable sobre 4 aisladores diferentes [117] con una caudal de bruma que varía desde 50 ± 10 g/h·m³ hasta 350 ± 10 g/h·m³. Determinaron que el tiempo de absorción de la humedad aumenta con la concentración de sustancias solubles y varía entre 5-20 minutos en función del tipo de aislador [117]. Además, el tiempo de absorción aumenta conforme va disminuyendo el caudal volumétrico de bruma, pudiendo alcanzar el tiempo de absorción hasta los 30 minutos. Asimismo la temperatura desempeña un papel importante en el proceso de humedecido [117,163]. Zhang *et al.* encontraron que el tiempo de absorción de la humedad aumenta para temperaturas mayores [117]. La diferencia entre la temperatura del aislador y el punto de rocío ambiental influye en gran medida la magnitud de la corriente de fuga [163]. A este respecto, la temperatura del aislador puede depender principalmente de la información pasada de la temperatura ambiente debido a la inercia térmica. En cambio, el punto de rocío ambiental depende de la información actual de la temperatura ambiente y humedad. Esto justifica que la inclusión de la información pasada de las variables ambientales, mejora el rendimiento del modelo de predicción de la corriente de fuga. Wang *et al.* analizaron en el laboratorio el efecto de la diferencia de temperatura entre el aire y el aislador, sobre el proceso de humedecido de los depósitos de contaminación y concluyeron que la absorción de agua de los depósitos de contaminación, es directamente proporcional a la diferencia de temperatura para niveles de humedad medio (60-75%) [118]. Además

la cantidad de agua absorbida alcanza su valor máximo después de 1 hora, para temperatura ambiente de 25°C y humedad de 70% [118]. La diferencia en el tiempo de absorción de la humedad, probablemente sea debido a las condiciones de ensayo en estos trabajos. En este respecto, en los registros de larga duración, puede presentarse una interacción compleja entre la temperatura, la humedad y la composición indeterminada y variable de depósitos de contaminación [83], lo cual podría dar lugar a un tiempo de absorción todavía mayor. Además, hay que tener en cuenta que en esta tesis, no se midió el tiempo de absorción de la humedad en sí, sino más bien se determinó la estructura temporal de los datos mediante el modelo de vectores autorregresivos.

7.2. Estimación de la PLC mediante filtro adaptativo

En esta tesis, se propone utilizar el filtro adaptativo para cancelar la influencia de la humedad relativa, utilizando la humedad relativa registrada como señal de ruido de referencia. Utilizando los niveles de umbral adaptativos mediante métodos estadísticos simples, el filtro de picos anómalos puede cancelar eficazmente tanto los picos de corriente anómalos dispersos y de alta densidad en el tiempo. Creemos que la corriente de fuga remanente rectificadora $|z[k]|$ estaba asociada a las sustancias contaminantes por varias razones. En primer lugar, la corriente de fuga remanente rectificadora, no era atribuible a las diferentes variables ambientales, ya que su correlación era insignificante (ver Tabla 9). En segundo lugar, se obtuvo una tendencia similar en la corriente de fuga resultante en los diferentes aisladores. Las pequeñas discrepancias en las tendencias de las corrientes de fuga resultantes, pueden ser debidas a la diferencia en la capacidad de repulsión de los depósitos de contaminación, y a la capacidad de auto-lavado con las lluvias fuertes de los distintos aisladores. Todos ellos presentaron una fluctuación cuasi anual, que puede deberse al efecto de auto-limpieza de las condiciones climáticas. Además, la magnitud de corriente de fuga resultante de los diferentes aisladores, estaba dentro del rango de PLC obtenido en los ensayos de laboratorio de otros autores. En los ensayos de laboratorio

realizados con un generador de 14 kV conectado a un aislador de vidrio sin contaminación, Bezerra *et al.* obtuvieron una corriente de fuga máxima media de 8.5 μA y 12 μA respectivamente [164]. Cuando se aplicó un ESDD = 0.2 mg/cm² de contaminación y una suspensión conductiva = 80 mS/cm, se obtuvo una corriente de fuga máxima media de 42.5 μA y 60 μA respectivamente [164]. Estos resultados son compatibles con los obtenidos para el aislador 3 (corriente de fuga media y máxima de 9.530 y 111.517 μA respectivamente). Al aplicar un voltaje de 19 kV en los ensayos de laboratorio a un aislador de compuesto de silicona, se ha obtenido una corriente de fuga promedio de aproximadamente 6.5 μA , antes del proceso de envejecimiento prematuro del aislador [165], que es similar al obtenido para aislador 7 (ver Tabla 10). Roman *et al.* midió la corriente de fuga en aisladores compuestos de silicona *in situ* en una línea de transporte de alta tensión (400-500 kV) en corriente continua (HVDC) y obtuvo valores a largo plazo, que van desde 10 hasta 60 μA [166]. La variabilidad de la corriente de fuga obtenida en estos estudios puede estar asociada con las diferentes condiciones del ensayo, por ejemplo, la diferente tensión aplicada. Además, en este caso se han realizado registros al aire libre, en una instalación real a largo plazo en lugar de usar datos de laboratorio, lo que puede dar lugar a una magnitud de corriente de fuga diferente debido a una cantidad y composición de contaminación desconocida. Nuestros resultados sugieren que solo se requiere registrar la corriente de fuga y la humedad relativa para estimar la PLC mediante filtro adaptativo, siendo la temperatura, la dirección y la velocidad del viento medidas irrelevantes, por tanto, se simplifica considerablemente el procesamiento de datos requerido para estimar la PLC y también se reducen los costes asociados.

Este estudio proporciona una técnica novedosa para estimar la PLC, que se puede implementar fácilmente en aplicaciones en tiempo real, lo que es fundamental, para conocer el estado del aislador. Esto podría ser muy útil para cuantificar mejor el rendimiento del aislador *in situ*, mejorar la continuidad y la calidad del servicio, al evitar fallos de energía causados por descargas disruptivas y optimizar los recursos humanos para el mantenimiento de las líneas de alta tensión.

Dado que el método propuesto permite anular las influencias de las variables ambientales en la corriente de fuga, no será necesario diferenciar los periodos secos y húmedos para determinar el riesgo de fallo, como propusieron Castillo Sierra *et al.* [161,167]. Esta técnica tiene la ventaja añadida, de que no se requiere información *a priori* sobre las fluctuaciones de la humedad relativa, sino sólo un sensor adicional para medir esta magnitud. Por lo tanto, creemos que esta técnica podría utilizarse para todo tipo de aisladores de subestación, independientemente de su ubicación geográfica, aunque en este caso, sólo se ha validado en una subestación específica. El coste de esta técnica es relativamente bajo, ya que sólo requiere la instalación de un sensor de humedad relativa y otro de la corriente de fuga en los aisladores, para predecir la PLC. Con los últimos avances en la instrumentación electrónica, el sensor de humedad relativa incluso podría integrarse en el propio sensor de corriente de fuga, sin un costo adicional excesivo. Además, se debe incluir un microcontrolador, microprocesador o procesador de señal digital con el algoritmo propuesto para el procesamiento de datos. También sería recomendable establecer un período inicial de al menos 3 meses, para recopilar suficientes datos y calcular las medidas estadísticas, para determinar el umbral óptimo para filtrar los picos de corriente anómalos de los registros en subestaciones. Después de estimar la PLC por el método propuesto, esta información puede transmitirse en tiempo real para una planificación eficiente del mantenimiento de los aisladores.

7.3. Predicción de la corriente de fuga a partir de variables ambientales

En esta tesis, con el objetivo de desarrollar modelos robustos con capacidad de generalización, se han utilizado los 30 meses de registros simultáneos de la corriente de fuga y las variables ambientales, para capturar la fluctuación estacional de las distintas variables. Para ello, se han comparado las muestras actuales y las últimas 21 muestras como variables predictoras. Comparando el caso

de utilizar las muestras actuales, con el caso de utilizar las últimas 21 muestras, en este último se ha obtenido una mejora significativa del rendimiento, independientemente del aislador, excepto para la técnica SVR. Estos resultados sugieren, que el pasado de las variables ambientales, contiene información relevante para determinar la diferencia de la temperatura entre el aislador y el ambiente. Estudios anteriores han confirmado, que esto junto con la humedad, juegan un rol importante sobre el proceso de humedecido o absorción de la humedad [117,118,163].

Asimismo, independientemente de la técnica de regresión empleada, se ha observado cierta diferencia en la predictabilidad de la corriente de fuga a partir de las variables ambientales. Los aisladores 1 y 2 de cerámica con recubrimiento RTV presentaron rendimientos similares, y suelen ser ligeramente mejores que el aislador 3 (cerámica sin recubrimiento) y 6 (cerámica con recubrimiento RTV), y esto a su vez presentaron mejores rendimientos que los aisladores 4 y 5 (cerámica con recubrimiento RTV). En cambio, el aislador 7 de silicona, en el que registró menor corriente de fuga, obtuvo el peor rendimiento de la predicción de la corriente de fuga. El aislador cerámico sin recubrimiento (aislador 3) presentó la mayor corriente de fuga debido a su hidrofiliidad (8-10 veces superior a la del aislador de silicona). El recubrimiento RTV reduce considerablemente la corriente de fuga registrada en la superficie del aislador. Nuestro resultado concuerda con otros autores, que reportaron que la corriente de fuga en aisladores cerámicos, suele ser hasta 4.7 veces mayor que la de aisladores de silicona [21]. La inclusión de los depósitos de contaminación en los aisladores de silicona, bajo una capa de aceite de silicona de bajo peso molecular y el complejo proceso humedecido de los mismos, probablemente justifica la dificultad de predecir la corriente de fuga a partir de las variables ambientales. En este respecto, la formación de gotas de agua aisladas, dificulta la corriente de fuga en la superficie del aislador de silicona, por el aislamiento eléctrico en los espacios de aire entre gotas. Aun así, como resultado de los depósitos de contaminación, aumenta la conductividad de las gotas y en consecuencia el campo eléctrico entre ellas [41,73]. La

reducción hidrófoba, debido al aumento del campo eléctrico entre gotas, las deforma en formas semiovaladas. A través de una serie de gotas deformadas, comienza a fluir la corriente de fuga, que puede desencadenar las descargas en las bandas secas y/o descarga disruptivas [41]. Consecuentemente hay una degradación de la hidrofobicidad de la superficie de los aisladores de silicona, debido a los depósitos de contaminación [41,168]. En comparación con aisladores cerámicos, se ha observado un mayor tiempo de absorción y una menor influencia de temperatura en el proceso de absorción de humedad, en los aisladores de silicona [117]. Además la exposición a la radiación ultravioleta de la luz solar y la exposición al calor, también juegan un papel en la degradación de la superficie de los aisladores de silicona [168], que pueden variar el proceso de humedecido a lo largo del tiempo. En cambio, a pesar de que el aislador 3 sin recubrimiento, presenta la mayor corriente de fuga, el proceso de humedecido de este tipo de aislador parece ser menos complejo ya que la deposición de agua en la superficie es más uniforme, formando una película de agua debido a la hidrofiliidad del material. Además los aisladores cerámicos no se ven influenciados por la exposición a la radiación ultravioleta de la luz solar y la exposición al calor [169]. En consecuencia, la influencia de las variables ambientales sobre la corriente de fuga, es relativamente menos compleja. En cuanto a los aisladores cerámicos con recubrimiento RTV, el proceso de humedecido depende en gran medida del tratamiento superficial, que determina la inclusión de los depósitos de contaminación y la hidrofobicidad de la superficie.

Se han implementado y comparado en esta tesis 5 modelos de regresión para la predicción de la corriente de fuga: MVR, SVR, 2SL-CNN, 2IL-CNN y 4IL-CNN. Se ha observado que el MVR, se ajusta relativamente bien para registros de corta duración de cada semana (resultados no mostrados). No obstante, los coeficientes de regresión del modelo presentan una fluctuación importante y deben ajustarse dinámicamente con los datos medidos cada periodo corto de tiempo. Estos resultados concuerdan con otros autores que han desarrollado modelos de predicción de la corriente de fuga a partir de las variables

ambientales [107,108]. En cambio, para registros de larga duración, la técnica MVR obtuvo un rendimiento bastante pobre, con un R^2 promedio de 0.40 ± 0.13 y 0.42 ± 0.13 cuando se utilizan las muestras actuales o las últimas 21 muestras, lo cual es considerablemente inferior a los resultados obtenidos por otros autores que han obtenido un $R^2=0.729$ para registro de 1 semana [108] y $R^2=0.674$ para registro de 43 días [71]. Vosloo desarrolló modelos de predicción con MVR con registros diarios, y obtuvo un R^2 que varía entre 0.43 y 0.88 en un periodo de 7 días [107]. A partir del registro simultáneo de la corriente de fuga y variables ambientales *in situ* de 14 días, la técnica MVR obtuvo un R^2 de 0.938 y un error absoluto promedio de 6.14% [109]. Estos resultados sugieren que la interacción de las distintas variables ambientales y la corriente de fuga es dinámica, con grandes fluctuaciones en el tiempo, dando lugar a una estructura de datos mucho más compleja que una relación lineal, por lo que la técnica MVR obtiene rendimientos relativamente pobres.

En la literatura, se han propuesto la función exponencial para la predicción de la corriente de fuga a partir de la humedad relativa, obteniendo mejores rendimientos que la técnica MVR. Para los mismos registros diarios, Vosloo obtuvo un R^2 que varía entre 0.56 y 0.95 en un periodo de 7 días [107]. Zhao *et al.* obtuvieron un R^2 de 0.93 para el mismo registro de 1 semana [108]. Otros autores han obtenido un R^2 entorno al 0.65 con la función exponencial, siendo el periodo de observación 28 días [66]. Nuestro resultado concuerda con la literatura, ya que la función exponencial permite describir mejor la relación entre la humedad relativa y la corriente de fuga, aunque el rendimiento de nuestro modelo es inferior (R^2 de 0.50). De nuevo, el peor rendimiento de nuestro modelo puede ser debido, a la diferencia en la cantidad de datos que se ha utilizado para entrenar el modelo. En los registros de larga duración hay una gran variabilidad de la corriente de fuga para las mismas condiciones ambientales, que no se presenta en el registro de corta duración.

Dada la relación subyacente no-lineal entre las variables predictoras y la corriente de fuga, se ha propuesto la técnica SVR para predecir la corriente de fuga, a partir de variables ambientales. Gracias a la

transformación no-lineal mediante la función de base radial, se ha mejorado significativamente el rendimiento del modelo con respecto a MVR, alcanzando un R^2 promedio de 0.70 ± 0.13 . Creemos que la aplicación de las redes neuronales artificiales (ANN) hubiera obtenido resultados similares. De nuevo, nuestro resultado es mucho inferior a los obtenidos por Bahramiazar quien utilizó ANN para predecir la corriente de fuga y obtuvo un R^2 de 0.98 con un registro total de 20 horas [111]. Asimismo el MAE normalizado, con respecto a la propia corriente de fuga es del orden 18% (resultado no mostrado en la tesis)¹, lo cual es superior al 9.11% obtenido por Kazemi sobre un registro de 60 días [46]. De nuevo, creemos que el peor rendimiento de nuestro modelo, se debe a una mayor complejidad de estructura de datos al utilizar registros de larga duración y nuestro resultado refleja más fielmente la capacidad de generalización del modelo. En cambio, los resultados obtenidos de registros de corta duración, tienden a sobreestimar el rendimiento del modelo porque no tienen datos representativos, que refleje el mecanismo subyacente de la corriente de fuga. Asimismo, no se dispone de indicadores cuantitativos de la bondad del modelo desarrollado por Gao *et al.*, por lo que resulta difícil comparar ambos modelos. Independientemente de ello, los propios autores sugirieron la dificultad de desarrollar un modelo global válido para magnitudes de corriente de fuga grandes y pequeñas [112]. Asimismo, nuestro resultado es difícilmente comparable con el modelo de Cho quien empleó la técnica SVM, para clasificar niveles categóricos de la corriente de fuga a partir de las variables ambientales, alcanzando una exactitud de 87% [113]. Cabe mencionar que, en este caso específico, la inclusión de las últimas 21 muestras de las variables ambientales dio lugar al sobreentrenamiento del modelo en el grupo de entrenamiento sin repercutir en una mejora del rendimiento del grupo de test. Esto sugiere que es necesario preprocesar las últimas 21 muestras de las variables ambientales, para extraer la información relevante para predecir la corriente de fuga.

¹ El NMAE que se utilizó en esta tesis fue normalizado por el fondo de escala de la corriente de fuga, no es comparable con el resultado de Kazemi.

Asimismo, en esta tesis se han propuesto distintas arquitecturas de CNN para la predicción de la corriente de fuga, a partir de las muestras actuales y las 21 muestras anteriores de las variables ambientales. Teóricamente, las CNN presentan la ventaja de fusionar los procesos de extracción de características y la tarea de clasificación y/o regresión en una única arquitectura de aprendizaje, con ello pueden aprender a optimizar las características durante la fase de entrenamiento, directamente desde la entrada sin procesar [130]. Independientemente de la arquitectura de red (2SL-CNN, 2IL-CNN o 4IL-CNN), los rendimientos de los modelos obtenidos a partir de las muestras actuales eran moderados y similares a los obtenidos a la técnica SVR, lo cual podría ser debido a que la estructura de datos es excesivamente compleja, para predecir con precisión la corriente de fuga a partir de las muestras actuales de las variables ambientales. Es decir, la corriente de fuga puede ser diferente incluso con los mismos datos de entrada de variables ambientales en función de una serie de factores: época del año, cantidad de depósito de contaminación entre otros. Además, al utilizar solo las muestras actuales, se está restringiendo a emplear tamaño de *kernel* $K=1$, por lo tanto, la arquitectura *inception* no aporta ninguna ventaja respecto a las capas convolucionales estándares, ya que no permite extraer la información a distintas escalas temporales, por lo que no mejora el rendimiento del modelo en el grupo de test para los datos ‘nunca’ vistos por el modelo. Además, creemos que tampoco obtendría mejores resultados si utilizáramos más capas de convolución con una arquitectura estándar más profunda.

En cambio, cuando se utilizan las últimas 21 muestras, nuestros resultados sugirieron que el 4IL-CNN obtuvo significativamente mejor resultado que 2IL-CNN, y este a su vez mejores que 2SL-CNN con tamaño de *kernel* $K=3$. Estos resultados ponen en manifiesto la importancia de extraer tanto la información local como regional, mediante la arquitectura *inception* [153]. En este contexto la arquitectura *inception* se diseñó para extraer la información local ($K=1$) y regional ($K=3$ y $K=5$), para hallar la interacción de las distintas variables ambientales en K instantes de tiempo [153]. La combinación

de la información local y regional, en el mismo mapa de características, permite determinar la relación subyacente entre las mismas. La aplicación sucesiva de esta arquitectura, permite extraer información de regiones cada vez más grandes, donde las características extraídas pueden ser jerárquicamente y progresivamente más complejas [153]. Con ello, las capas convolucionales basadas en arquitectura *inception*, permiten capturar automáticamente la interacción dinámica entre las variables ambientales y la corriente de fuga incluyendo el proceso de humedecido sin interacción humana o conocimientos de expertos [131], obteniendo un R^2 promedio de 0.94 ± 0.03 en el grupo de test para el modelo 4IL-CNN. Destacar que el rendimiento del modelo entre distintos aisladores varía desde 0.88 al 0.98 para el aislador 7 y 1 respectivamente, esta diferencia es mucho más pequeña que otras técnicas.

El rendimiento del modelo 4IL-CNN es muy superior a los distintos modelos de predicción de la corriente de fuga desarrollados en la literatura [46,66,71,107–109,112,113]. En comparación con el método propuesto por De Santos *et al.* para la predicción de la corriente de fuga [83], que han logrado un R^2 de 0.947, 0.860 y 0.869 para aisladores no recubiertos, medio-recubierto y completamente cubiertos respectivamente, nuestro resultado ofrece rendimientos similares. No obstante, nuestra técnica ofrece una serie de ventajas. Primero, De Santos *et al.* estimaron el índice de acumulación de contaminantes, teniendo en cuenta tanto el índice de polución con la medida adicional de depósito de polvo direccional, como el coeficiente de lavado, siendo necesario la medida de ESDD cada intervalo de tiempo junto con la corriente de fuga. Se debe configurar experimentalmente los parámetros del modelo matemático para cada aislador y el lugar donde se instalan los aisladores, y por tanto no son fácilmente adaptables a otras subestaciones, ya que el mecanismo subyacente entre estos factores no necesariamente responde al mismo modelo matemático. Más aún, los aisladores de referencia, para medir los niveles de ESDD no estaban energizados. Los contaminantes no se depositan de la misma forma en los aisladores energizados y los no energizados [38]. Asimismo, solo registraron los picos máximos positivos y negativos superiores a 10 mA en intervalo

de 5 minutos, lo cual podría simplificar considerablemente la complejidad de la estructura de datos, facilitando el desarrollo de modelos de predicción de la corriente de fuga. Si bien es cierto, que el riesgo de aparición de las descargas disruptivas, aumenta con la corriente de fuga y en general no presenta riesgo alguno por debajo de 10 mA, esto podría limitar la aplicación práctica de sus modelos. En cambio, el modelo 4IL-CNN desarrollado en esta tesis, no solo es preciso para predecir la corriente de fuga tanto en aisladores cerámicos con o sin recubrimientos RTV, como en aisladores de silicona a partir de las últimas 21 muestras de variables ambientales, sino también puede implementarse en aplicaciones de tiempo real en dispositivos móviles [145,147,170], ya que se tratan de 1D-CNN con menor coste computacional. Además, al tratarse de un modelo desarrollado con registros de larga duración de 30 meses, el modelo tiene datos representativos del mecanismo subyacente, entre las distintas variables ambientales y la corriente de fuga de la instalación *in-situ*, incluyendo la fluctuación estacional y por tanto tiene una alta capacidad de generalización, para predecir la corriente de fuga de los mismos aisladores en la misma subestación para tiempo *a posteriori*. Además, gracias a la capacidad de autoaprendizaje de las características relevantes de CNN, el modelo es fácilmente adaptable a otros aisladores y/o otras subestaciones. En principio, sólo se requiere el registro simultáneo de la corriente de fuga y las distintas variables ambientales para desarrollar el modelo como se hizo en este trabajo. Más aún, al disponer ya un modelo de CNN entrenado, se puede utilizar la transferencia de aprendizaje, para desarrollar modelos de predicción de la corriente de fuga de otros aisladores y/o subestaciones, transfiriendo conocimientos contenidos en un dominio fuente diferente, pero relacionado (el modelo desarrollado en esta tesis) al dominio de interés (otros aisladores y/o subestaciones) [171]. En tal caso, se ha demostrado que la transferencia de aprendizaje requiere de bastantes menos muestras para su entrenamiento [171].

7.4. Limitaciones del estudio y líneas futuras

A pesar de los resultados prometedores, este trabajo no está exento de limitaciones. En primer lugar, no se han tomado muestras discretas

(una muestra cada cierto tiempo) de los depósitos de contaminación para validar, aún más, el método propuesto en esta tesis para estimar la PLC y proporcionar una curva experimental de la magnitud de PLC y los depósitos de contaminación. A este respecto, cabe destacar la dificultad de medir los depósitos de contaminación en aplicaciones reales. Además, la medición de los depósitos de contaminación mediante la limpieza del aislador puede alterar la muestra. En consecuencia, no se podrá determinar la evolución real de los depósitos de contaminación en la superficie y el posible efecto de la limpieza natural.

Segundo, teniendo en cuenta que la vida útil de un aislador eléctrico [18,172] varía entre 16 y 30 años y la vida media es de alrededor de 24 años, el envejecimiento del material durante sus primeros dos años de vida puede considerarse insignificante. La corriente de fuga registrada a largo plazo, en aplicaciones reales, no sólo contiene influencia de las variables ambientales y la PLC, sino también la fluctuación de la corriente de fuga debido al envejecimiento. Se diseñarán estudios en el futuro para determinar la viabilidad de medir la PLC y el efecto de envejecimiento del material. Del mismo modo, se ha entrenado el modelo de predicción de la corriente de fuga con los registros de los primeros 30 meses de la vida útil del aislador. En el modelo, se ha tenido en cuenta los depósitos de contaminación y su auto-lavado registrado *in situ*, pero no se ha contemplado en el modelo el envejecimiento del aislador. En la práctica, no será necesario determinar los depósitos de contaminación y el envejecimiento por separado para mejorar el mantenimiento del aislador. De hecho, el modelo desarrollado en esta tesis podría utilizarse para anticipar las consecuencias negativas de la climatología y/o depósitos de contaminación a corto y medio plazo, cuando el efecto del envejecimiento en la corriente de fuga es irrelevante. Asimismo, nuestro modelo de predicción de la corriente de fuga constituye potencialmente una nueva herramienta ingenieril, para diseñar un plan estratégico de mantenimiento preventivo de los aisladores eléctricos de alta tensión. Se puede utilizar el modelo desarrollado en esta tesis para determinar la discrepancia de la

corriente de fuga predicha, con respecto a los datos medidos *in situ*. En el caso de que haya una gran discrepancia, puede ser un indicador de alguna anomalía: una deposición anormalmente alta de contaminantes, envejecimiento del aislador y/o presencia del daño superficial. Se puede programar una acción de mantenimiento sobre los aisladores. A este respecto, el registro simultáneo de la temperatura superficial del aislador mediante cámaras, podría ayudar la identificación de la presencia del daño superficial [173]. Por lo que sería de gran utilidad la colocación de la cámara térmica para medir la temperatura superficial del aislador. El aumento de la frecuencia de las paradas de instalación estaría relacionado con el efecto de envejecimiento del material, de modo que los aisladores antiguos, tendrían que ser reemplazados por otros nuevos. Asimismo, el registro de la corriente de fuga en tiempo real y la predicción de la misma mediante el modelo desarrollado en esta tesis, podría utilizarse para determinar la variación de la corriente de fuga durante el proceso del envejecimiento de los aisladores eléctricos de alta tensión, proporcionando información muy valiosa para el mantenimiento preventivo de los mismos.

Para poder desarrollar un modelo de predicción de la corriente de fuga válido para toda la vida útil del aislador, sería necesario la recopilación de datos *in situ* de larga duración durante toda la vida útil del aislador o en distintos periodos de su vida, para disponer de una completa caracterización del comportamiento del mismo. También se pueden construir distintos modelos de predicción de corriente de fuga para aisladores nuevos, semi-nuevos y envejecidos. Para unas determinadas condiciones ambientales, se puede proporcionar un intervalo de confianza de la corriente de fuga en función de si se trata de aislador nuevo o envejecido, utilizando distintos modelos para los mismos, con ello se pueden anticipar las posibles consecuencias negativas de la climatología y/o depósitos de contaminación, entre otros. Por otro lado, en la literatura se ha propuesto el uso de redes neuronales para la predicción de corriente de fuga en la etapa final del envejecimiento prematuro de aisladores de silicona, en las pruebas de niebla salina realizadas en laboratorio [174,175], obteniendo un

error máximo de 3.5-5.3% [174,175]. Los modelos obtenidos en los ensayos de laboratorio, podrían utilizarse para determinar el mecanismo subyacente del envejecimiento y la corriente de fuga, lo cual es fundamental para generar un modelo de predicción de la corriente de fuga a partir de variables ambientales, válido para toda la vida útil del aislador.

Independiente de que el modelo 4IL-CNN ha obtenido resultados muy prometedores para la predicción de la corriente de fuga, el modelo tiende a subestimar la corriente de fuga, para picos de corriente de fuga, debido a la lluvia u otros fenómenos. Creemos que se puede obtener un modelo de predicción de la corriente de fuga más preciso, incluyendo otras variables ambientales, por ejemplo, precipitación, radiación, temperatura en la superficie del aislador mediante cámaras térmicas entre otros. Otros autores sugirieron que las imágenes de las descargas superficiales, podrían aportar información adicional para la predicción de la corriente de fuga. Específicamente el porcentaje de área de la descarga y el cambio en el brillo de la región de interés, extraídos de las imágenes, podrían mejorar significativamente el rendimiento del modelo (error absoluto relativo: 9.47% variables ambientales vs. 3.94% variables ambientales, área de descarga, cambio de brillo) [28]. En futuros estudios se puede explorar la utilidad de las imágenes de las descargas superficiales junto con las variables ambientales, para la predicción de la corriente de fuga durante toda la vida útil del aislador. Independientemente de ello, por lo que sabemos, ésta es la primera vez, que se ha desarrollado un modelo preciso de predicción de la corriente de fuga basado en solo 4 variables ambientales, en registros de larga duración de 30 meses, con una metodología fácilmente trasladable a otros aisladores y/o a otras subestaciones. Nuestro resultado allana el camino para desarrollar un sistema *on-line* de preaviso, que anticipe las posibles consecuencias negativas de la climatología y/o depósitos de contaminación entre otros. Todo ello, contribuirá a minimizar las descargas disruptivas que ocasionan cortes imprevistos del suministro eléctrico, aumentando la fiabilidad y resiliencia de la red eléctrica.

*Procura que donde estés haya
ese buen humor, esa alegría, que
es fruto de la vida interior.*

José María Escrivá de Balaguer

**CAPÍTULO VI:
CONCLUSIONES**

El análisis de las medidas de corrientes de fuga en aisladores puede ser de gran utilidad para el mantenimiento preventivo en redes de alta tensión. Ello puede redundar en un incremento de la calidad y continuidad del suministro, al disminuir las faltas relacionadas con descargas disruptivas en aisladores. También en una mejora y disminución de costes en el mantenimiento.

En la tesis se han abordado dos aproximaciones a dicho análisis, que tienen su foco tanto en determinar la influencia de la capa contaminante situada en la superficie del aislador, cuyos efectos sobre la conducción superficial pueden derivar en una descarga, como en la predicción a corto plazo de la corriente de fugas, permitiendo detectar comportamientos anómalos al compararla con la corriente de fugas real.

Las técnicas propuestas, aplicadas en el ámbito de la tesis al caso de aisladores cerámicos con recubrimiento para subestaciones, permiten su implementación en campo con un número reducido de sensores. Ello abre la puerta a una nueva generación de dispositivos que formen parte del sistema control-operación-protección de las subestaciones, incrementando su fiabilidad y, en definitiva, su resiliencia.

En conclusión, los objetivos concretos y resultados alcanzados han sido los siguientes:

Objetivo 1. Determinar la relación subyacente entre la corriente de fuga y las variables ambientales

Se ha analizado la relación subyacente entre la corriente de fuga en bruto en los aisladores y diferentes variables ambientales en registros de larga duración. La corriente de fuga presentó una correlación débil y positiva con la temperatura ambiente, siendo el coeficiente de correlación promedio 0.139 ± 0.063 . En cambio, presentó una correlación fuerte positiva con la humedad, obteniendo un coeficiente de correlación promedio de 0.826 ± 0.051 , siendo la función exponencial la que mejor describe dicha relación. Tanto la dirección como velocidad del viento, presentaron una relación inversa

moderada con la corriente de fuga, obteniendo un coeficiente de correlación promedio de -0.315 ± 0.009 y -0.469 ± 0.036 respectivamente. Asimismo, se ha determinado que la relación entre la corriente de fuga en bruto y la temperatura, la dirección y la velocidad del viento se debe principalmente a la influencia de estas variables en la humedad relativa.

Más aún, se ha confirmado que independientemente del aislador, las distintas variables ambientales presentaron una causalidad de Granger estadísticamente significativa con la corriente de fuga, excepto la dirección del viento, que solo obtuvo una causalidad de Granger significativa en 4 de los 7 aisladores. Estos resultados sugieren que la inclusión de la información pasada de las variables ambientales, permite mejorar la predicción de la corriente de fuga, mediante el modelo de vectores autorregresivos, siendo el orden óptimo 20. Es decir, las últimas 21 muestras de variables ambientales contienen información relevante para predecir la corriente de fuga en la superficie del aislador.

El análisis de la relación entre las distintas variables ambientales y la corriente de fuga mediante el coeficiente de Spearman, no es contribución original de la tesis. En cambio, la aplicación del análisis de correlación parcial, el análisis de causalidad condicional de Granger, así como la interpretación de los resultados, son contribuciones originales de esta tesis.

Objetivo 2. Desarrollar técnica de procesamiento para estimar la PLC en tiempo real para aisladores a la intemperie durante la operación normal mediante la eliminación de la influencia de las variables ambientales

Se ha propuesto una técnica novedosa para estimar la corriente de fuga asociada a los depósitos de contaminación (PLC) eliminando la influencia de la humedad relativa mediante un filtro adaptativo. Asimismo, se ha diseñado un filtro de picos anómalos específico en base a niveles de umbral adaptativo, determinados por métodos

estadísticos simples, que permiten cancelar eficazmente tanto los picos anómalos dispersos, como los de alta densidad (en el tiempo) en el registro, obteniendo así la PLC con variaciones graduales con el tiempo. La técnica propuesta es de bajo coste y allana el camino para estimar la PLC en tiempo real, lo que determinaría mejor el rendimiento de los diferentes aisladores *in-situ*, mejoraría la continuidad y la calidad del servicio. Al mismo tiempo, esto también facilitaría la planificación de los cortes programados en la línea eléctrica, conduciría a una mejor gestión de los recursos para llevar a cabo las tareas asociadas y, en consecuencia, reduciría los costes de mantenimiento.

El uso del filtro adaptativo para eliminar la influencia de la humedad relativa de la corriente de fuga y el diseño de filtros para cancelar los picos anómalos de corriente dispersos como los de alta densidad (en el tiempo) en el registro, son contribuciones originales de esta tesis.

Objetivo 3. Desarrollar modelos robustos y precisos de predicción en tiempo real de la corriente de fuga en los aisladores de alta tensión a partir de variables ambientales durante la operación normal, que permita crear un nuevo sistema on-line de preaviso que anticipe las posibles consecuencias negativas de la climatología y/o depósitos de contaminación entre otros.

En esta tesis, se han desarrollado y comparado 5 modelos de regresión para predecir la corriente de fuga en distintos tipos de aisladores (cerámico sin recubrimiento y con recubrimiento RTV, aisladores de silicona) a partir de 4 variables ambientales en registros de larga duración: MVR, SVR, 2SL-CNN, 2IL-CNN y 4IL-CNN. Se ha comparado el rendimiento del modelo empleando solo las muestras actuales y las últimas 21 muestras como variables predictoras. Excepto para SVR, el rendimiento del modelo utilizando las últimas 21 muestras como variables predictoras, era significativamente superior que cuando se utiliza solo las muestras actuales, sugiriendo que la información pasada de las variables ambientales contiene información relevante para predecir la corriente de fuga. Además, es necesario

preprocesar los datos de entrada del modelo, para capturar la interacción de las variables ambientales entre distintos instantes temporales con la corriente de fuga.

Asimismo, se ha determinado que el rendimiento de los modelos no-lineales (SVR, 2SL-CNN, 2IL-CNN y 4IL-CNN), es significativamente superior al de modelo obtenido con MVR, sugiriendo que el mecanismo subyacente entre las variables ambientales y la corriente de fuga, es un proceso dinámico y no-lineal. El R^2 promedio del modelo 2SL-CNN basado en 2 capas convolucionales estándares para el grupo de test, era ligeramente superior al de SVR (2SL-CNN: 0.73 ± 0.11 vs. SVR: 0.70 ± 0.13), siendo esta diferencia estadísticamente significativa. Gracias a la extracción simultánea de la información local y regional, cada vez más grande, mediante la aplicación sucesiva la arquitectura *inception*, se ha podido capturar la compleja interacción dinámica no-lineal, entre las variables ambientales y la corriente de fuga. El rendimiento de los modelos basados en arquitectura *inception* en la capa convolucional era muy superior a los de otros modelos, obteniendo un R^2 promedio de 0.89 ± 0.06 para el modelo 2IL-CNN y 0.94 ± 0.03 para el modelo 4IL-CNN. Nuestros resultados también sugieren que el proceso humedecido con depósitos de contaminación en la superficie, es mucho más complejo en los aisladores de silicona que en los aisladores cerámicos. Aun así, el modelo 4IL-CNN es válido, para predecir con precisión la corriente de fuga tanto en aisladores cerámicos y de silicona.

El modelo desarrollado en esta tesis podría utilizarse para anticipar las consecuencias negativas de la climatología y/o depósitos de contaminación a corto y medio plazo, cuando el efecto de envejecimiento es irrelevante, constituyendo potencialmente una herramienta ingenieril, para diseñar un plan estratégico de mantenimiento preventivo de los aisladores eléctricos de alta tensión y minimizar las descargas disruptivas que provoquen fallos inesperados de la red eléctrica, aumentando así la fiabilidad y resiliencia de la red eléctrica. El modelo desarrollado en esta tesis también podría utilizarse para la caracterización completa del

envejecimiento natural del aislador, durante la operación normal, allanando el camino para desarrollar modelos de predicción robustos y precisos de la corriente de fuga durante la toda vida útil del aislador, y crear un sistema *on-line* de preaviso que anticipe las posibles consecuencias negativas de la climatología y/o depósitos de contaminación entre otros.

El uso de la técnica MVR para predecir la corriente de fuga a partir de las variables ambientales, no es novedoso, por tanto, no es una contribución original de la tesis. La aplicación de SVR y los distintos modelos de CNN para predecir la corriente de fuga a partir de las variables ambientales, son contribuciones originales de la tesis. Determinar que el pasado de las variables ambientales contiene información relevante para la predicción de la corriente de fuga, también es contribución original de esta tesis.

*Honra y prez de todo el orbe: tú,
la porción más ilustre del globo.*

San Isidoro de Sevilla

PUBLICACIONES

Durante el desarrollo de este plan de investigación, que comenzó con la obtención del diploma de estudios avanzados (DEA) y que culmina con este documento de tesis, se han realizado diversas publicaciones en revistas internacionales, algunas indexadas en JCR, y en congresos internacionales.

La buena aceptación de los trabajos presentados y el interés que suscitaban, han servido de aliento en muchas ocasiones para continuar con la investigación.

La relación de trabajos que se presenta a continuación se divide en revistas, diferenciando las indexadas en JCR, capítulos de libro con editorial internacional y congresos, internacionales.

Publicaciones en revistas indexadas JCR derivadas de la tesis

Jose-M. Bueno-Barrachina; Yiyao Ye-Lin; Felix Nieto-del-Amor; Vicente Fuster-Roig. (2023). Inception 1D-convolutional neural network for accurate prediction of electrical insulator leakage current from environmental data during its normal operation using long-term recording. *Engineering Applications of Artificial Intelligence*. <https://doi.org/10.1016/j.engappai.2022.105799>

Jose-M Bueno-Barrachina; César-S Cañas-Peñuelas; Yiyao Ye-Lin; Vicente Fuster-Roig. (2021). Novel technique for estimating pollution-associated leakage current in high voltage insulators based on adaptive filtering in long-term recording. *Measurement Science and Technology*. 32(5):1-10. <https://dx.doi.org/10.1088/1361-6501/abea3d>

Otras publicaciones en revistas indexadas JCR

Y Ye-Lin, J M Bueno-Barrachina, G Prats-Boluda, R Rodriguez de Sanabria, J Garcia-Casado. Wireless sensor node for non-invasive high precision electrocardiographic signal acquisition based on a multi-ring electrode. Measurement, Volume 97, February 2017. 195-202. doi: <http://dx.doi.org/10.1016/j.measurement.2016.11.009>.

G Prats-Boluda, Y Ye-Lin, J M Bueno Barrachina, E Senent, R Rodriguez de Sanabria, J Garcia-Casado. Development of a portable wireless system for bipolar concentric ECG recording. Measurement Science and Technology, Volume 26, Number 7. 10pp. doi: <http://dx.doi.org/10.1088/0957-0233/26/7/075102>

G Prats-Boluda, Y Ye-Lin, J M Bueno Barrachina, R Rodriguez de Sanabria, J Garcia-Casado. Towards the clinical use of concentric electrodes in ECG recordings: influence of ring dimensions and electrode position. Measurement Science and Technology, Volume 27, Number 2. 11pp. doi: <http://dx.doi.org/10.1088/0957-0233/27/2/025705>

Otras publicaciones en revistas no indexadas

Bueno Barrachina, JM.; Cañas Peñuelas, CS.; Catalán Izquierdo, S.; Quijano López, A. (2008). Modelization of earth electrode excited by atmospheric discharges based on FEM. Renewable energy & power quality journal (issn: 2172-038X). 1(6) March 2008.

Jose-M. Bueno-Barrachina, César-S. Cañas-Peñuelas, S. Catalan-Izquierdo, Francisco Cavallé-Sesé. Aplicación del método de los elementos finitos al cálculo de capacidades. Electrical Engineering Electronic Journal; 2009, Vol1, num. 1, 245. <http://www.aedie.org/eeej/webrevista/articulos/num1/Vol1num1.html>

Bueno Barrachina, JM.; Cañas Peñuelas, CS.; Catalán Izquierdo, S.; Cavallé-Sesé, F. (2009). Capacitance evaluation on perpendicular plate capacitors by means of finite elemental analysis. Renewable energy & power quality journal (issn: 2172-038X). 1(7).

Cañas Peñuelas, CS.; Catalán Izquierdo, S.; Bueno Barrachina, JM.; Cavallé-Sesé, F. (2009). Unit cube capacity calculation by means of finite element analysis. Renewable energy & power quality journal (issn: 2172-038X). 1(7).

César-S. Cañas-Peñuelas, S. Catalan-Izquierdo, Jose-M. Bueno-Barrachina. Optimización de electrodos de puesta a tierra. Electrical Engineering Electronic Journal; 2009, Vol1, num. 1, 245. <http://www.aedie.org/eeej/webrevista/articulos/num1/Vol1num1.html>

Catalán Izquierdo, S.; Bueno Barrachina, JM.; Cañas Peñuelas, CS.; Cavallé-Sesé, F. (2009). Capacitance evaluation on parallel-plate capacitors by means of finite element analysis. Renewable energy & power quality journal (issn: 2172-038X). 1(7).

Bueno Barrachina, JM.; Catalán Izquierdo, S.; Cañas Peñuelas, CS. (2011). Grounding system impedance characterization using FEM. Renewable energy & power quality journal (issn: 2172-038X). 9(12). <http://hdl.handle.net/10251/55480>.

J M Bueno-Barrachina, C.S. Cañas-Peñuelas, S. Catalan-Izquierdo. Capacitance Evaluation on Non-parallel Thick-Plate Capacitors by Means of Finite Element Analysis. Journal of Energy & Power Engineering -hard copy (ISSN1934-8975) and online (ISSN 1934-7367)-; Apr 2011, Vol. 5 Issue 4, p 373-378.

Jose-M. Bueno-Barrachina, Cesar-S. Cañas-Peñuelas, Saturnino Catalan-Izquierdo. FEM Edge Effect and Capacitance Evaluation on Cylindrical Capacitors. Journal of Energy & Power Engineering -hard copy (ISSN1934-8975) and online (ISSN 1934-7367)-; Dec 2012, Vol. 6 Issue 12, p 2063-2069.

Capítulos de libro, editorial internacional

Y. Ye-Lin, J. Garcia-Casado, Jose-M. Bueno-Barrachina, J. Guimera-Tomas, G. Prats-Boluda and J.L. Martinez-de-Juan, New Developments in Biomedical Engineering, Chapter 16: Characterization and Enhancement of Non-Invasive Recordings of Intestinal Myoelectrical Activity, book edited by Domenico Campolo, ISBN 978-953-7619-57-2, Published: January 1, 2010 under CC BY-NC-SA 3.0 license. © The Author(s). DOI 10.5772/7612.

Congresos internacionales

J. M. Bueno Barrachina, C. S. Canas Penuelas, S. Catalan Izquierdo, F. Cavalle Sese, FEM transitory current simulation in circuit breakers, XIII International Symposium on Electromagnetic Fields in Mechatronics, Electrical and Electronic Engineering (ISEF 2007), Prague, Czech Republic, September 13-15, 2007 ISBN: 978-80-01-03784.

J. M. Bueno Barrachina, S. Catalan Izquierdo, C. S. Canas Penuelas, F. Cavalle Sese, ARC roots FEM modelling and simulation at plane electrodes, 2007 8th International Conference on Electric Fuses and their Applications, Clermont-Ferrand, 2007, pp. 139-143. doi: 10.1109/ICEFA.2007.4419979. 4 autores
<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=4419979&isnumber=4419953>.

Bueno Barrachina, JM.; Cañas Peñuelas, CS.; Catalán Izquierdo, S.; Cavallé Sesé, F. Arc roots FEM modelling in electrodes with macroscopic imperfections. XCLEEE – 10th Portuguese- Spanish Congress in Electrical Engineering, Funchal, Madeira, 5-7 July 2007, Portugal.

Bueno Barrachina, JM.; Cañas Peñuelas, CS.; Catalán Izquierdo, S.; Cavallé Sesé, F. Methodology for the study of the overvoltages caused by the kilometric fault in the protection systems. XCLEEE – 10th Portuguese- Spanish Congress in Electrical Engineering, Funchal, Madeira, 5-7 July 2007, Portugal.

J. M. Bueno Barrachina, S. Catalan Izquierdo, C. S. Canas Penuelas , A. Quijano Lopez, FEM model at atmospheric pressure in air of arc root creators, ICEC 2008 24th International conference on Electrical contacts, Saint-Malo, France, June 8-12, 2008.pp 419-422.

Y. Ye-Lin, G. Prats-Boluda, J. Alberola-Rubio, J. M. Bueno Barrachina, A. Perales and J. Garcia-Casado, "Prediction of labor using non-invasive laplacian EHG recordings," 2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), Osaka, 2013, pp. 7428-7431. doi: 10.1109/EMBC.2013.6611275

<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=6611275&isnumber=6609410>

Y. Ye-Lin et al., "Non-invasive electrohysterogram recording using flexible concentric ring electrode," 2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, Chicago, IL, 2014, pp. 4050-4053. doi: 10.1109/EMBC.2014.6944513

<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=6944513&isnumber=694351>

Bueno-Barrachina, José Manuel; Ye-Lin, Yiyao; Prats-Boluda, Gema; Rodriguez de Sanabria, Rafael; Garcia-Casado, Javier, Desarrollo de un sistema inalámbrico de alta precisión para el registro no-invasivo de señales bioeléctricas mediante electrodos multi-anulares flexibles, XXXII Congreso Anual de la Sociedad Española de Ingeniería Biomédica (CASEIB 2014). Barcelona, Instituto de Bioingeniería de Catalunya (IBEC) y Sociedad Española de Ingeniería Biomédica, 2014. ISBN 978-84-617-2446-8.

*España es el único lugar
del mundo donde dos y
dos no suman cuatro.*

Arthur Wellesley

BIBLIOGRAFÍA

BIBLIOGRAFÍA

- [1] U.S. Energy Information Administration 2016 *International Energy Outlook 2016*
- [2] Eurostat 2021 *Energy statistics - an overview - Statistics Explained*
- [3] Anon Use of energy in industry - U.S. Energy Information Administration (EIA)
- [4] Brem S 2011 The Swiss Programme on Critical Infrastructure Protection
- [5] Linares P and Rey L 2013 The costs of electricity interruptions in Spain. Are we sending the right signals? *Energy Policy* **61** 751–60
- [6] Federico G and Vives X 2010 Políticas energéticas en la UE: seguridad de suministro, medio ambiente y competencia *Cuad. económicos ICE, ISSN 0210-2633, N° 79, 2010 (Ejemplar Dedic. a Contrib. A LA Econ. LA ENERGÍA)*, págs. 117-137 117–37
- [7] Amadi H 2015 Analysis of Methodologies for the Evaluation of Power Outage Costs *Int. J. Eng. Res. Technol.* **4** 956–60
- [8] Küfeoğlu S 2015 *at a public examination held at the lecture hall S1 of the school on*
- [9] Sanz Arnaiz I 2015 *Análisis de la evolución y el impacto de los vehículos eléctricos en la economía europea* (Universidad Pontificia de Comillas)
- [10] Rezaee S, Farjah E and Khorramdel B 2013 Probabilistic analysis of plug-in electric vehicles impact on electrical grid through homes and parking lots *IEEE Trans. Sustain. Energy* **4** 1024–33

- [11] FOCP 2015 *The Swiss Programme on Critical Infrastructure Protection*
- [12] Jiang X (Western W U and William Shive P (Western W U 2019 Electric Power Distribution System Reliability and Outage Costs: An Undergraduate Industry Collaboration 2019 ASEE PNW Section Conference ed American Society for Engineering Education (Corvallis, Oregon: American Society for Engineering Education) p 12
- [13] REE 2020 *Informe del Sistema Eléctrico Español 2020*. (Madrid)
- [14] Anon 4.2. Transporte y operación del sistema - Energía y Sociedad
- [15] SIGP 2010 *Introduction to NISTIR 7628 Guidelines for Smart Grid Cyber Security*
- [16] ENISA 2012 *ENISA Smart Grid Security Recommendations — ENISA*
- [17] Pignini A 2019 Guide for the Selection of Insulators in Respect of Polluted Conditions *Lect. Notes Electr. Eng.* **599** LNEE 170–81
- [18] Amin M and Amin S 2014 Aging research on sir and tpe insulators (an overview) *Rev. Adv. Mater. Sci.* **36** 29–39
- [19] Swift D A 1990 Composite rod insulators for AC power lines: Electrical performance of various designs at a coastal testing station *IEEE Trans. Power Deliv.* **5** 1944–55
- [20] Vosloo W L, Holtzhausen J P and Roediger A H A 1996 Leakage current performance of naturally aged non-ceramic insulators under a severe marine environment *IEEE AFRICON Conf.* **1** 489–95
- [21] Chrzan K L and Zipp M 2020 Anomalous leakage currents on silicone rubber hollow insulators *Prz. Elektrotechniczny* **96** 91–3

- [22] Manrique S and Hernandez A 2012 Silicona vulcanizada a temperatura ambiente para aisladores cerámicos: cómo debe especificarse para garantizar su desempeño *Jornadas técnicas ISA 2012* pp 1–7
- [23] Prette A L G, Sglavo V M, Alarcon O E and Fredel M C 2010 Application of semiconductor ceramic glazes to high-voltage ceramic insulators *Ceram. Eng. Sci. Proc.* **30** 33–7
- [24] Pylarinos D, Siderakis K, Thalassinakis E, MAavrikakis N, Koudoumas E, Drakakis E and Kymakis E 2016 A New Approach for Open Air Insulator Test Stations: Experience from Talos and the Polydiagno Project *J. Electr. Eng.* **16** 6–6
- [25] Liang M and Wong K L 2017 Improving the Long-term Performance of Composite Insulators Use Nanocomposite: A Review *Energy Procedia* **110** 168–73
- [26] Gençoğlu M T and Cebeci M 2008 The pollution flashover on high voltage insulators *Electr. Power Syst. Res.* **78** 1914–21
- [27] Ahmed R, Kim T, Lee Y J, Jeon S, Yi J, Choi I H, Son J A and Koo J Bin 2020 Online Condition Monitoring and Leakage Current Effect Based on Local Area Environment *Trans. Electr. Electron. Mater.*
- [28] Thanh P N, Cho M Y and Da T N 2021 Insulator leakage current prediction using surface spark discharge data and particle swarm optimization based neural network *Electr. Power Syst. Res.* **191** 106888
- [29] Zhi-yi S 2003 To intensify basic external insulation level of power system-fundamental way for prevention of large-scale pollution flashover *Electr. Power*
- [30] Gu C, Lu G, Yi M and Li J 2016 Study on artificial contamination test of typical transmission line insulators *Proc. 5th IEEE Int. Conf. Electr. Util. Deregulation, Restruct. Power Technol. DRPT 2015* 1624–7

- [31] Salam M A, Ang S P, Ong B T, Malik O A, Voon W and Alinurrezan M 2013 Measurement of pollution level of 66 kV transmission line insulators *Annu. Rep. - Conf. Electr. Insul. Dielectr. Phenomena, CEIDP* 1124–7
- [32] Morgan V T 1998 Effects of frequency, temperature, compression, and air pressure on the dielectric properties of a multilayer stack of dry kraft paper *IEEE Trans. Dielectr. Electr. Insul.* **5** 125–31
- [33] Naito K, Mizuno Y and Naganawa W 1995 A study on probabilistic assessment of contamination flashover of high voltage insulator *IEEE Trans. Power Deliv.* **10** 1378–84
- [34] Renyu Z and Jianchao Z 1990 Progress in Outdoor Insulation Research in China *IEEE Trans. Electr. Insul.* **25** 1125–37
- [35] Rahal A and Huraux C 1979 Flashover Mechanism of High Voltage Insulators *IEEE Trans. Power Appar. Syst.* **PAS-98** 2223–31
- [36] Alston L L and Zoledziowski S 1963 Growth of discharges on polluted insulation *Proc. Inst. Electr. Eng.* **110** 1260–6
- [37] Li J, Sima W, Sun C and Sebo S A 2010 Use of leakage currents of insulators to determine the stage characteristics of the flashover process and contamination level prediction *IEEE Trans. Dielectr. Electr. Insul.* **17** 490–501
- [38] Vosloo W L 2002 *A Comparison of the Performance of High-Voltage Insulator Materials In a Severely Polluted Coastal Environment* (Stellenbosch: Stellenbosch University)
- [39] Subba Reddy B and Kumar U 2011 Enhancement of surface flashover performance of high voltage ceramic disc insulators *J. Mater. Eng. Perform.* **20** 24–30
- [40] Phillips A J, Childs D J and Schneider H M 1999 Aging of non-ceramic insulators due to corona from water drops *IEEE Trans. Power Deliv.* **14** 1081–6

- [41] Kumagai S and Yoshimura N 2004 Leakage current characterization for estimating the conditions of ceramic and polymeric insulating surfaces *IEEE Trans. Dielectr. Electr. Insul.* **11** 681–90
- [42] Reynders J P, Jandrell I R and Reynders S M 2020 Review of aging and recovery of silicone rubber insulation for outdoor use *IEEE Trans. Dielectr. Electr. Insul.* **6** 620–31
- [43] Yoshimura N, Kumagai S and Nishimura S 2020 Electrical and environmental aging of silicone rubber used in outdoor insulation *IEEE Trans. Dielectr. Electr. Insul.* **6** 632–50
- [44] Kim J, Chaudhury M K and Owen M J 2020 Hydrophobicity loss and recovery of silicone HV insulation *IEEE Trans. Dielectr. Electr. Insul.* **6** 695–702
- [45] Hillborg H and Gedde U W 2020 Hydrophobicity changes in silicone rubbers *IEEE Trans. Dielectr. Electr. Insul.* **6** 703–17
- [46] Kazemi A, Hassanzadeh M T and Gholami A 2008 Artificial neural network for insulator leakage currents prediction from environmental data *PECon 2008 - 2008 IEEE 2nd Int. Power Energy Conf.* 13–7
- [47] Kontargyri V T, Gialketsi A A, Tsekouras G J, Gonos I F and Stathopoulos I A 2007 Design of an artificial neural network for the estimation of the flashover voltage on insulators *Electr. Power Syst. Res.* **77** 1532–40
- [48] Zhang Z, Qiao X, Yang S and Jiang X 2018 Non-uniform distribution of contamination on composite insulators in HVDC transmission lines *Appl. Sci.* **8**
- [49] Jolly D C and Poole C D 1979 Flashover of contaminated insulators with cylindrical symmetry under DC conditions *IEEE Trans. Electr. Insul.* **EI-14** 77–84
- [50] Lambeth P J 1971 Effect of pollution on high-voltage outdoor insulators *Proceedings of the Institution of Electrical Engineers* vol 118 p 1130

- [51] Faramarzi Palangar M and Mirzaie M 2016 Mathematical Modeling of Critical Parameters on the Polluted Ceramic Insulators Under AC Voltage: Based on Experimental Tests *Arab. J. Sci. Eng.* 2016 419 **41** 3501–10
- [52] Astorga O A M and do Prado A J 1994 Flashover phenomenon: an analysis with influence of the thickness of the layer pollution of the high voltage polluted insulators *Conf. Rec. IEEE Int. Symp. Electr. Insul.* 546–9
- [53] Salem A A, Abd-Rahman R, Rahiman W, Al-Gailani S A, Al-Ameri S M, Ishak M T and Sheikh U U 2021 Pollution flashover under different contamination profiles on high voltage insulator: Numerical and experiment investigation *IEEE Access* **9** 37800–12
- [54] Ramos N. G, Campillo R. M T and Naito K 1993 A study on the characteristics of various conductive contaminants accumulated on high voltage insulators *IEEE Trans. Power Deliv.* **8** 1842–50
- [55] Schindelholz E and Kelly R G 2012 Wetting phenomena and time of wetness in atmospheric corrosion: A review *Corros. Rev.* **30** 135–70
- [56] Abeysekara A H A D, Kumara J R S S, Fernando M A R M, Eakanayake M P B, Godaliyadda G M R I and Wijayakulasooriya J V. 2017 Remote leakage current detector for identification of insulators discharges *IEEE Trans. Dielectr. Electr. Insul.* **24** 2449–58
- [57] Gouda O E and El Dein A Z 2014 Experimental techniques to simulate naturally polluted high voltage transmission line insulators *IEEE Trans. Dielectr. Electr. Insul.* **21** 2199–205
- [58] Tahir Khan Niazi M, Arshad, Ahmad J, Alqahtani F, Baotham F A B and Abu-Amara F 2020 Prediction of Critical Flashover Voltage of High Voltage Insulators Leveraging Bootstrap Neural Network *Electron.* 2020, Vol. 9, Page 1620 **9** 1620
- [59] Amin M and Salman M 2006 Aging of polymeric insulators (an overview) *Rev. Adv. Mater. Sci.* **13** 93–116

- [60] Fierro-Chavez J L, Ramirez-Vazquez I and Montoya-Tena G 1996 On-line leakage current monitoring of 400kV insulator strings in polluted areas *IEE Proc. Gener. Transm. Distrib.* **143** 560–4
- [61] Ramirez-Vazquez I and Fierro-Chavez J L 1999 Criteria for the diagnostic of polluted ceramic insulators based on the leakage current monitoring technique *Conference on Electrical Insulation and Dielectric Phenomena (CEIDP), Annual Report* pp 715–8
- [62] Sahli Z, Mekhaldi A, Boudissa R and Boudrahem S 2011 Prediction parameters of dimensioning of insulators under non-uniform contaminated conditions by multiple regression analysis *Electr. Power Syst. Res.* **81** 821–9
- [63] Salam M A, El-fadil N and Nadir Z 2006 A Novel Approach to Predict Leakage Current in Insulators from Wind Velocity *ECTI Trans. Electr. Eng. Electron. Commun.* **4** 47–50
- [64] Hussain M M, Chaudhary M A and Razaq A 2019 Mechanism of Saline Deposition and Surface Flashover on High-Voltage Insulators near Shoreline: Mathematical models and experimental validations *Energies* **12** 1–20
- [65] Ramirez I, Hernández R and Montoya G 2012 Measurement of leakage current for monitoring the performance of outdoor insulators in polluted environments *IEEE Electr. Insul. Mag.*
- [66] Pinotti M A and Meyer L H 2017 Mathematical model for prediction of the leakage current on distribution insulators of 25 kV class *2017 IEEE Electr. Insul. Conf. EIC 2017* 256–60
- [67] Amin M, Amin S and Ali M 2009 Monitoring of leakage current for composite insulators and electrical devices *Rev. Adv. Mater. Sci.* **21** 75–89
- [68] Nakanishi T, Komiya H, Shinokubo H, Matsuoka R, Kumagai S, Hikita M and Irie T 2002 Comparative leakage current measurements on silicone rubber rods in salt fog chamber by different measuring systems *Conference Record of IEEE International Symposium on Electrical Insulation* pp 252–5

- [69] Matsuoka R, Naito K, Irie T and Kondo K 2002 Evaluation methods of polymer insulators under contaminated conditions *IEEE/PES Transmission and Distribution Conference and Exhibition* vol 3 (IEEE) pp 2197–202
- [70] Waluyo, Fauziah D and Khaidir I M 2021 The Evaluation of Daily Comparative Leakage Currents on Porcelain and Silicone Rubber Insulators under Natural Environmental Conditions *IEEE Access* **9** 27451–66
- [71] Ahmad A S, Ghosh P S, Aljunid S A K and Ahmad S 2003 Estimation of leakage current level on the transformer bushing using regression technique *Proceedings of the 7th International Conference on Properties and Applications of Dielectric Materials (Cat. No.03CH37417)* vol 3 (IEEE) pp 1174–7
- [72] Rodriguez A, Nour H, Wang F and Dale S J 1985 Effect of Insulator Surface Temperature on the Flashover Voltage of Outdoor Insulators *Proc. Electr. Insul. Conf.* 56–61
- [73] Hussain M M, Farokhi S, McMeekin S G and Farzaneh M 2017 Mechanism of saline deposition and surface flashover on outdoor insulators near coastal areas part II: Impact of various environment stresses *IEEE Trans. Dielectr. Electr. Insul.*
- [74] Venkataraman S, Gorur R S and Mishra A P 2008 Impact of weathering on flashover performance of nonceramic insulators *IEEE Trans. Dielectr. Electr. Insul.* **15** 1073–80
- [75] Lambrecht J, Barsch R, Gubanski S M and Fernando M A R M 1998 Evaluation of the hydrophobicity-dynamics of artificially polluted silicone-rubber model insulators *ICSD'98. Proceedings of the 1998 IEEE 6th International Conference on Conduction and Breakdown in Solid Dielectrics (Cat. No.98CH36132)* (IEEE) pp 430–3

- [76] Ito A, Marungsri B, Satake A, Shinokubo H, Matsuoka R, Guo Z J and Yu Z 2003 Fundamental investigation results of diagnostic techniques for deteriorated polymer insulators *Proceedings of the 7th International Conference on Properties and Applications of Dielectric Materials (Cat. No.03CH37417)* vol 1 (IEEE) pp 385–8
- [77] Sampe T, Hirayama T, Ito M, Kubota T, Matsumoto T, Yaeguchi M, Marungsri B, Shinokubo H, Matsuoka R, Zhou Jian Guo and Zhang Yu 2004 Fundamental investigation results of diagnostic technique for deteriorated polymer insulators *Conference Record of the 2004 IEEE International Symposium on Electrical Insulation* vol 1 (IEEE) pp 288–91
- [78] Arshad, Nekahi A, McMeekin S G and Farzaneh M 2018 Measurement of surface resistance of silicone rubber sheets under polluted and dry band conditions *Electr. Eng.* **100** 1729–38
- [79] Venkataraman S and Gorur R S 2006 Prediction of flashover voltage of non-ceramic insulators under contaminated conditions *IEEE Trans. Dielectr. Electr. Insul.* **13** 862–9
- [80] Zhicheng G, Yingke M, Liming W, Ruihai L, Hua W and Yi M 2009 Leakage Current and Discharge Phenomenon of Outdoor Insulators *Int. J. Electr. Eng. Informatics* **1** 1–17
- [81] Li J Y, Sun C X, Sima W X and Yang Q 2009 Stage pre-warning based on leakage current characteristics before contamination flashover of porcelain and glass insulators *IET Gener. Transm. Distrib.* **3** 605–15
- [82] Kim J H, Song W C, Lee J H, Park Y K, Cho H G, Yoo Y S and Yang K J 2001 Leakage current monitoring and outdoor degradation of silicone rubber *IEEE Trans. Dielectr. Electr. Insul.*
- [83] De Santos H and Sanz Bobi M A 2020 A Cumulative Pollution Index for the Estimation of the Leakage Current on Insulator Strings *IEEE Trans. Power Deliv.* **35** 2438–46

- [84] Manjang S, Syafaruddin, Tambi, Musaruddin M and Kitta I 2021 Study of Leakage Current Characteristics of High Voltage Insulators Ageing After Dry Season in Polluted Environmental Conditions 074–8
- [85] Schwardt W H, Holtzhausen J P and Vosloo W L A comparison between measured leakage current and surface conductivity during salt fog tests [power line insulator applications] 2004 *IEEE Africon. 7th Africon Conf. Africa (IEEE Cat. No.04CH37590)* **1** 597–600
- [86] Holtzhausen J P 1997 *A critical evaluation of AC pollution flashover models for HV insulators having hydrophilic surfaces* (Stellenbosch: Stellenbosch University)
- [87] Verma M P 1973 Highest leakage current impulse as criterion for the performance of polluted insulators *Paris, Fr. CIGRE*
- [88] P H J and P D T L 1987 Insulator pollution: Interrelationship of highest leakage current, specific creepage distance and salinity in a salt fog test. *Trans. South African Inst. Electr. Eng.* **78** 1–6
- [89] Holtzhausen J P and Vosloo W L 2001 The pollution flashover of ac energized post type insulators *IEEE Trans. Dielectr. Electr. Insul.* **8** 191–4
- [90] Salem A A, Abd-Rahman R, Al-Gailani S A, Kamarudin M S, Ahmad H and Salam Z 2020 The Leakage Current Components as a Diagnostic Tool to Estimate Contamination Level on High Voltage Insulators *IEEE Access* **8** 92514–28
- [91] Zhao S, Jiang X, Zhang Z, Hu J and Shu L 2013 Flashover voltage prediction of composite insulators based on the characteristics of leakage current *IEEE Trans. Power Deliv.* **28** 1699–708
- [92] Chandrasekar S, Kalaivanan C and Karthikeyan S 2008 Study on Pollution Severity of Porcelain Insulators Using LC and Phase Angle Measurement 2008 *IEEE Region 10 and the Third international Conference on Industrial and Information Systems* (IEEE) pp 1–5

- [93] Palangar M F and Mirzaie M 2016 Detection of Critical Conditions in Ceramic Insulators Based on Harmonic Analysis of Leakage Current <http://dx.doi.org/10.1080/15325008.2016.1183723> **44** 1854–64
- [94] Kordkheili H H, Abravesh H, Tabasi M, Dakhem M and Abravesh M M 2010 Determining the probability of flashover occurrence in composite insulators by using leakage current harmonic components *IEEE Trans. Dielectr. Electr. Insul.* **17** 502–12
- [95] Zhao C, Mei H, Zhu M, Dai H, Wang L and Zhou Z 2015 Development of contamination flashover pre-warning system and analysis of operating experience *IEEE Trans. Dielectr. Electr. Insul.* **22** 2234–41
- [96] Jayaprakash Narayanan V, Sivakumar M, Karpagavani K and Chandrasekar S 2014 Prediction of Flashover and Pollution Severity of High Voltage Transmission Line Insulators Using Wavelet Transform and Fuzzy C-Means Approach *J. Electr. Eng. Technol.* **9** 1677–85
- [97] Chen W, Wang W, Xia Q, Luo B and Li L 2012 Insulator Contamination Forecasting Based on Fractal Analysis of Leakage Current *Energies* **5** 2594–607
- [98] Sidthik A S, Kalaivani L and Iruthayarajan M W 2013 Evaluation and prediction of contamination level in coastal region insulators based on leakage current characteristics *Proc. IEEE Int. Conf. Circuit, Power Comput. Technol. ICCPCT 2013* 132–7
- [99] Narmadhai N and Jeyakumar A E 2011 Analysis of leakage current to predict insulator flashover using artificial neural network *J. Comput. Sci.* **7** 167–72
- [100] Li J, Sun C, Sima W, Yang Q and Hu J 2010 Contamination level prediction of insulators based on the characteristics of leakage current *IEEE Trans. Power Deliv.* **25** 417–24

- [101] Marungsri B, Shinokubo H, Matsuoka R and Kumagai S 2006 Effect of specimen configuration on deterioration of silicone rubber for polymer insulators in salt fog ageing test *IEEE Trans. Dielectr. Electr. Insul.* **13** 129–38
- [102] Devendranath D, Channakeshava and Rajkumar A D 2002 Leakage current and charge in RTV coated insulators under pollution conditions *IEEE Trans. Dielectr. Electr. Insul.* **9** 294–9
- [103] Samakosh J D and Mirzaie M 2020 Experimental-based models for predicting the flashover voltage of polluted sir insulators using leakage current characteristics *IET Sci. Meas. Technol.* **14** 943–52
- [104] Topalis F V, Gonos I F and Stathopoulos I A 2001 Dielectric behaviour of polluted porcelain insulators *IEE Proceedings-Generation, Transm. Distrib.* **148** 269–74
- [105] Albadi M H, Abri R S Al, Hinai A S Al and Al-Badi A H 2018 Harmonics Temporal Profile in High-Voltage Networks: Case Study *Power System Harmonics: Analysis, Effects and Mitigation Solutions for Power Quality Improvement* ed Z Ahmed, H E Shady, A Abdel and E B Murat (London: INTECHOPEN LIMITED) pp 35–50
- [106] Xia Y, Jiang X, Sun C and Dong B 2012 A method to estimate leakage current of polluted insulators *Prz. Elektrotechniczny* **88** 161–4
- [107] Vosloo W L and Holtzhausen J P 2002 The prediction of insulator leakage currents from environmental data *IEEE AFRICON Conf.* **2** 603–8
- [108] Zhao L, Jiang J, Duan S, Fang C, Wang J, Wang K, Cao P and Zhou J 2011 The prediction of post insulators leakage current from environmental data *2011 Int. Conf. Electr. Control Eng. ICECE 2011 - Proc.* 5103–6
- [109] Castillo-Sierra R, Oviedo-Trespalacios O, Candelo J E and Soto-Ortiz J D 2018 Modeling leakage current of ceramic insulators subject to high pollution levels for improving maintenance activities *DYNA* **85** 364–71

- [110] Ahmad A S, Ahmad H, Salam M A, Tamsir T, Buntat Z and Mustafa M W 2000 Prediction of salt contamination on high voltage insulators in rainy season using regression technique *IEEE Reg. 10 Annu. Int. Conf. Proceedings/TENCON* **3**
- [111] Bahramiazar A and Oskuoee M 2014 Experimental Study of the Artificial Neural Network Solutions for Insulators Leakage Current Modeling in a Power Network *Int. J. Electr. Energy* **2**
- [112] Gao S, Jia Y, Bi X, Cao B, Li X, Yang D and Wang L 2018 Prediction method of leakage current of insulators on the transmission line based on BP neural network *Proc. 2018 IEEE 2nd Int. Electr. Energy Conf. CIEEC 2018* 569–72
- [113] Cho M-Y and Lin P-S 2015 Using Support Vector Machine for Classifying Insulator Leakage Current *Int. J. Electr. Comput. Sci. IJECS-IJENS* **15** 30–9
- [114] Ali H 2016 Leakage current prediction for high voltage insulators flashover based on extreme value theory *Proc. -2016 IEEE Int. Symp. Comput. Consum. Control. IS3C 2016* 870–3
- [115] CIGRE 2008 *CIGRE WG C4.303 Outdoor Insulation in polluted Conditions: Guidelines for Selection and dimensioning - Part 1: General Principles and the A.C. Case*
- [116] Barnett L and Seth A K 2014 The MVGC multivariate Granger causality toolbox: A new approach to Granger-causal inference *J. Neurosci. Methods* **223** 50–68
- [117] Zhang Z, Jiang X, Huang H, Sun C, Hu J and Gao D W 2013 Study on the wetting process and its influencing factors of pollution deposited on different insulators based on leakage current *IEEE Trans. Power Deliv.* **28** 678–85
- [118] Wang L, Cao B, Guan Z and Wang K 2017 Influence of temperature difference on wetting characteristics of insulators *IEEE Trans. Dielectr. Electr. Insul.* **24** 3622–9
- [119] Hamilton J D 2020 *Time Series Analysis* ed P U Press (Princeton University Press)

- [120] Morf M, Vieira A, Lee D T L and Kailath T 1978 Recursive Multichannel Maximum Entropy Spectral Estimation *IEEE Trans. Geosci. Electron.* **16** 85–94
- [121] Mei H W, Mao Y K, Bian X M, Peng G M, Wang L M and Guan Z C 2010 Effect of relative humidity on the maximum leakage current of insulators *Gaodianya Jishu/High Volt. Eng.* **36** 627–31
- [122] Salem A A and Abd-rahman R 2018 A Review of the Dynamic Modelling of Pollution Flashover on High Voltage Outdoor Insulators *J. Phys. Conf. Ser.* **1049** 1–11
- [123] Li Y, Gong S, Sherrah J and Liddell H 2004 Support vector machine based multi-view face detection and recognition *Image Vis. Comput.* **22** 413–27
- [124] Thai L H, Hai T S and Thuy N T 2012 Image Classification using Support Vector Machine and Artificial Neural Network *Int. J. Inf. Technol. Comput. Sci.* **4** 32–8
- [125] Hasseim A A, Sudirman R and Khalid P I 2013 Handwriting Classification Based on Support Vector Machine with Cross Validation *Engineering* **05** 84–7
- [126] Maglogiannis I, Loukis E, Zafiroopoulos E and Stasis A 2009 Support Vectors Machine-based identification of heart valve diseases using heart sounds *Comput. Methods Programs Biomed.* **95** 47–61
- [127] Ismail Fawaz H, Forestier G, Weber J, Idoumghar L and Muller P A 2019 Deep learning for time series classification: a review *Data Min. Knowl. Discov.* **33** 917–63
- [128] Wang X, Zhao J, Li Q, Fang N, Wang P, Ding L and Li S 2020 A Hybrid Model for Prediction in Asphalt Pavement Performance Based on Support Vector Machine and Grey Relation Analysis *J. Adv. Transp.* **2020**

- [129] Awad M and Khanna R 2015 Support Vector Regression *Efficient Learning Machines: Theories, Concepts, and Applications for Engineers and System Designers* (Berkeley, CA: Apress) pp 67–80
- [130] Kiranyaz S, Avci O, Abdeljaber O, Ince T, Gabbouj M and Inman D J 2021 1D convolutional neural networks and applications: A survey *Mech. Syst. Signal Process.* **151** 107398
- [131] Li Z, Liu F, Yang W, Peng S and Zhou J 2020 A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects *IEEE Trans. Neural Networks Learn. Syst.* 1–21
- [132] Scheuer C, Boot E, Carse N, Clardy A, Gallagher J, Heck S, Marron S, Martinez-Alvarez L, Masarykova D, Mcmillan P, Murphy F, Steel E, Ekdom H Van and Vecchione H 1990 Handwritten digit recognition with a back-propagation network ed G. Balint, B Antala, C Carty, J-M A Mabieme, I B Amar and A Kaplanova *Phys. Educ. Sport Child. Youth with Spec. Needs Res. – Best Pract. – Situat.* 343–54
- [133] Krizhevsky A, Sutskever I and Hinton G E 2012 ImageNet Classification with Deep Convolutional Neural Networks *Adv. Neural Inf. Process. Syst.* **25**
- [134] Deng J, Dong W, Socher R, Li L-J, Kai Li and Li Fei-Fei 2010 ImageNet: A large-scale hierarchical image database 248–55
- [135] Lu P, Song B and Xu L 2020 Human face recognition based on convolutional neural network and augmented dataset <http://mc.manuscriptcentral.com/tssc> **9** 29–37
- [136] Wang W, Yang Y, Wang X, Wang W and Li J 2019 Development of convolutional neural network and its application in image classification: a survey <https://doi.org/10.1117/1.OE.58.4.040901> **58** 040901
- [137] Bora M B, Daimary D, Amitab K and Kandar D 2020 Handwritten Character Recognition from Images using CNN-ECOC *Procedia Comput. Sci.* **167** 2403–9

- [138] Zhang S 2021 Language Processing Model Construction and Simulation Based on Hybrid CNN and LSTM *Comput. Intell. Neurosci.* **2021**
- [139] Alaskar H 2018 Convolutional Neural Network Application in Biomedical Signals *J. Comput. Sci. Inf. Technol.* **6**
- [140] Yamashita R, Nishio M, Do R K G and Togashi K 2018 Convolutional neural networks: an overview and application in radiology *Insights Imaging* **9** 611–29
- [141] Wang Y, Li Y, Song Y and Rong X 2020 The Influence of the Activation Function in a Convolution Neural Network Model of Facial Expression Recognition *Appl. Sci.* **2020**, Vol. 10, Page 1897 **10** 1897
- [142] M.R.Narasinga Rao D, Venkatesh Prasad V, Sai Teja P, Zndavali M and Phanindra Reddy O 2018 A Survey on Prevention of Overfitting in Convolution Neural Networks Using Machine Learning Techniques *Int. J. Eng. Technol.* **7** 177
- [143] Kiranyaz S, Ince T and Gabbouj M 2016 Real-Time Patient-Specific ECG Classification by 1-D Convolutional Neural Networks *IEEE Trans. Biomed. Eng.* **63** 664–75
- [144] Avci O, Abdeljaber O, Kiranyaz S and Inman D 2017 Structural Damage Detection in Real Time: Implementation of 1D Convolutional Neural Networks for SHM Applications *Conf. Proc. Soc. Exp. Mech. Ser.* 49–54
- [145] Abdeljaber O, Avci O, Kiranyaz S, Gabbouj M and Inman D J 2017 Real-time vibration-based structural damage detection using one-dimensional convolutional neural networks *J. Sound Vib.* **388** 154–70
- [146] Ince T, Kiranyaz S, Eren L, Askar M and Gabbouj M 2016 Real-Time Motor Fault Detection by 1-D Convolutional Neural Networks *IEEE Trans. Ind. Electron.* **63** 7067–75

- [147] Kiranyaz S, Gastli A, Ben-Brahim L, Al-Emadi N and Gabbouj M 2019 Real-Time Fault Detection and Identification for MMC Using 1-D Convolutional Neural Networks *IEEE Trans. Ind. Electron.* **66** 8760–71
- [148] Abdel-Hamid O, Mohamed A R, Jiang H, Deng L, Penn G and Yu D 2014 Convolutional neural networks for speech recognition *IEEE Trans. Audio, Speech Lang. Process.* **22** 1533–45
- [149] Yu Y, Wang C, Gu X and Li J 2018 A novel deep learning-based method for damage identification of smart building structures: <https://doi.org/10.1177/1475921718804132> **18** 143–63
- [150] Li T, Hua M and Wu X 2020 A Hybrid CNN-LSTM Model for Forecasting Particulate Matter (PM2.5) *IEEE Access* **8** 26933–40
- [151] Chen Y, Qin S, Qiao S, Dou Q, Che W, Su G, Yao J and Nnanwuba U E 2020 Spatial Predictions of Debris Flow Susceptibility Mapping Using Convolutional Neural Networks in Jilin Province, China *Water 2020, Vol. 12, Page 2079* **12** 2079
- [152] Russakovsky O, Deng J, Su H, Krause J, Satheesh S, Ma S, Huang Z, Karpathy A, Khosla A, Bernstein M, Berg A C and Fei-Fei L 2015 ImageNet Large Scale Visual Recognition Challenge *Int. J. Comput. Vis.* **115** 211–52
- [153] Szegedy C, Liu W, Jia Y, Sermanet P, Reed S, Anguelov D, Erhan D, Vanhoucke V and Rabinovich A 2015 Going deeper with convolutions *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.* **07-12-June-2015** 1–9
- [154] Szegedy C, Vanhoucke V, Ioffe S, Shlens J and Wojna Z 2016 Rethinking the Inception Architecture for Computer Vision *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.* **2016-December** 2818–26
- [155] Lin M, Chen Q and Yan S 2013 Network In Network *2nd Int. Conf. Learn. Represent. ICLR 2014 - Conf. Track Proc.*

- [156] Arora S, Bhaskara A, Ge R and Ma T 2013 Provable Bounds for Learning Some Deep Representations *31st Int. Conf. Mach. Learn. ICML 2014* **1** 883–91
- [157] Halawa L J, Wibowo A and Ernawan F 2019 Face Recognition Using Faster R-CNN with Inception-V2 Architecture for CCTV Camera *ICICOS 2019 - 3rd Int. Conf. Informatics Comput. Sci. Accel. Informatics Comput. Res. Smarter Soc. Era Ind. 4.0, Proc.*
- [158] Yang Q, Cheng M, Zhou W, Chen Y, Qiu M and Lin W 2018 IncepText: A New Inception-Text Module with Deformable PSROI Pooling for Multi-Oriented Scene Text Detection *IJCAI/Int. Jt. Conf. Artif. Intell.* **2018-July** 1071–7
- [159] Santamaria-Vazquez E, Martinez-Cagigal V, Vaquerizo-Villar F and Hornero R 2020 EEG-Inception: A Novel Deep Convolutional Neural Network for Assistive ERP-Based Brain-Computer Interfaces *IEEE Trans. Neural Syst. Rehabil. Eng.* **28** 2773–82
- [160] Kingma D P and Ba J L 2014 Adam: A Method for Stochastic Optimization *3rd Int. Conf. Learn. Represent. ICLR 2015 - Conf. Track Proc.*
- [161] Castillo Sierra R, Oviedo-Trespalacios O, Candelo J E and Soto J D 2015 Assessment of the risk of failure of high voltage substations due to environmental conditions and pollution on insulators *Environ. Sci. Pollut. Res.* **22** 9749–58
- [162] Castillo Sierra R, Oviedo-Trespalacios O, Candelo J E and Soto J D 2015 The influence of atmospheric conditions on the leakage current of ceramic insulators on the Colombian Caribbean coast *Environ. Sci. Pollut. Res.* **22** 2526–36
- [163] Dai H, Mei H, Liming W and Zhicheng G 2011 Preliminary research of temperature effect on surface leakage current of insulators *XVII International Symposium on High Voltage Engineering* (Hannover, Germany) pp 1–5

- [164] de Barros Bezerra J M, Lima A M N, Deep G S and da Costa E G 2009 An Evaluation of Alternative Techniques for Monitoring Insulator Pollution *IEEE Trans. Power Deliv.* **24** 1773–80
- [165] R. M. Fernando M and Gubanski S 2010 Ageing of silicone rubber insulators in coastal and inland tropical environment *IEEE Trans. Dielectr. Electr. Insul.* **17** 326–33
- [166] Roman M, van Zyl R R, Parus N and Mahatho N 2019 In-Situ Monitoring of Leakage Current on Composite and Glass Insulators of the Cahora Bassa HVDC Transmission Line *SAIEE Africa Res. J.* **110** 4–10
- [167] Chrzan K L, Vosloo W L and Holtzhausen J P 2011 Leakage Current on Porcelain and Silicone Insulators Under Sea or Light Industrial Pollution *IEEE Trans. Power Deliv.* **26** 2051–2
- [168] Arshad, Nekahi A, McMeekin S and Farzaneh M 2016 Flashover Characteristics of Silicone Rubber Sheets under Various Environmental Conditions *Energies*
- [169] Gençoğlu M T 2007 The comparison of ceramic and non-ceramic insulators *Eng. Sci.* **2** 274–94
- [170] Avcı O, Abdeljaber O, Kiranyaz S, Hussein M and Inman D J 2018 Wireless and real-time structural damage detection: A novel decentralized method for wireless sensor networks *J. Sound Vib.* **424** 158–72
- [171] Zhuang F, Qi Z, Duan K, Xi D, Zhu Y, Zhu H, Xiong H and He Q 2019 A Comprehensive Survey on Transfer Learning *Proc. IEEE* **109** 43–76
- [172] Ghosh D and Khastgir D 2018 Degradation and Stability of Polymeric High-Voltage Insulators and Prediction of Their Service Life through Environmental and Accelerated Aging Processes *ACS Omega* **3** 11317–11330

- [173] Darwison, Arief S, Abral H, Hazmi A, Ahmad M H, Waldi E P and Fernandez R 2019 A leakage current estimation based on thermal image of polymer insulator *Indones. J. Electr. Eng. Comput. Sci.* **16** 1096–106
- [174] El-Hag A H, Jahromi A N and Sanaye-Pasand M 2008 Prediction of leakage current of non-ceramic insulators in early aging period *Electr. Power Syst. Res.* **78** 1686–92
- [175] Jahromi A N, El-Hag A H, Jayaram S H, Cherney E A, Sanaye-Pasand M and Mohseni H 2006 A neural network based method for leakage current prediction of polymeric insulators *IEEE Trans. Power Deliv.* **21** 506–7