



Universidade Federal de Campina Grande
Centro de Engenharia Elétrica e Informática
Programa de Pós-Graduação em Engenharia Elétrica



**EXTRAÇÃO DE CARACTERÍSTICAS EM IMAGENS COM
COMPRIMENTO DE ONDA VISÍVEL DE ISOLADORES DE ALTA
TENSÃO PARA ANÁLISE DE POLUIÇÃO**

PROJETO DE PESQUISA III

CHRISTIANE RAULINO ALMEIDA MOLINA

ORIENTADORES:

RAIMUNDO CARLOS SILVÉRIO FREIRE

JUGURTA ROSA MONTALVÃO FILHO



EXTRAÇÃO DE CARACTERÍSTICAS EM IMAGENS COM COMPRIMENTO DE ONDA VISÍVEL DE ISOLADORES DE ALTA TENSÃO PARA ANÁLISE DE POLUIÇÃO

Christiane Raulino Almeida Molina

Relatório apresentado ao Programa de Pós-graduação em Engenharia Elétrica - PPgEE, da Universidade Federal de Campina Grande, como parte dos requisitos necessários de avaliação do componente Projeto e Pesquisa III.

Orientadores:
Raimundo Carlos Silvério Freire
Jugurta Rosa Montalvão Filho

Campina Grande - PB, setembro de 2023

Sumário

1	INTRODUÇÃO	2
1.0.1	Objetivo Geral	3
1.0.2	Objetivos Específicos:	3
1.1	Estrutura do Projeto de Pesquisa	4
2	REVISÃO BIBLIOGRÁFICA	4
3	FUNDAMENTAÇÃO TEÓRICA	6
3.1	Segmentação com contornos ativos sem bordas definidas	7
3.2	Fundamentos de Probabilidade	8
3.2.1	Função de massa de probabilidade	9
3.2.2	Função de Distribuição Acumulada	10
3.3	K-NN como Classificador	11
4	ABORDAGEM PROPOSTA	12
4.1	Experimento com poluição artificial	12
4.1.1	Simple Model Fenomenológico	14
4.2	Criação da nova base de dados com poluição real	15
5	RESULTADOS	16
5.1	Experimentos com poluição artificial	17
5.2	Criação da nova base de dados com poluição real	19
6	CONCLUSÃO	19
	Referências	21

1 INTRODUÇÃO

Monitorar e realizar manutenções em equipamentos de alta potência é uma tarefa bastante desafiadora em ambientes de produção e distribuição de energia elétrica. A dificuldade desta tarefa pode ser relacionada a alguns fatores: perdas na produção, uma vez que o equipamento precisa ser desligado para uma intervenção; o alto risco de acidentes de trabalho para operadores que realizam a tarefa; além de possíveis falhas inerentes ao processo manual de inspeção. Desta maneira, métodos de monitoramento automatizados [1] [2] [3] compõem uma solução com o mínimo de intervenção e recursos humanos no espaço físico operante.

Partindo desse contexto, imagens adquiridas de plantas elétricas de alta potência através de *drones* [4] ou de captura manual remota geram dados, que ao serem analisados, podem trazer um preciso diagnóstico de problemas em curso, assim como a antecipação de problemas futuros, como é o caso da inspeção e manutenção de isoladores [5] [6], indicando a necessidade de manutenções preventivas ou substituição de equipamentos com vida útil limítrofe, por exemplo. Com efeito, a utilização de técnicas de visão computacional pode fornecer alternativas aos sistemas de monitoramento baseados em sinais elétricos ou mesmo trabalhar em conjunto com eles na construção de um monitoramento mais robusto. No entanto, as imagens adquiridas a partir de coletas não estruturadas podem ser de difícil manipulação e análise, especialmente quando coletadas de diferentes perspectivas ou através de diferentes equipamentos, situações nas quais o processo de segmentação e extração de características robusto torna-se indispensável para a boa utilização dos dados.

Devido ao papel importante de proteção que os isoladores desempenham em sistemas de potência, a aplicação de interesse que inspirou este projeto de pesquisa consiste em perceber não conformidades de operação causados por depósito de materiais poluentes em isoladores de cerâmica e/ou poliméricos presentes na área de alta potência em uma termelétrica. Através da imagem capturada, o equipamento elétrico pode ser isolado por segmentação e representado por características relevantes. Todavia, algumas dificuldades como diferentes resoluções, iluminações e perspectivas das imagens capturadas costumam prejudicar o desempenho do sistema extrator de características importantes para reconhecimento de anomalias.

Para tal aplicação, três tipos de imagens podem ser utilizadas como dado de entrada para o sistema de visão computacional: imagens em espectro ultra-violeta; infravermelho e espectro visível. Devido às grandes vantagens de menor custo de aquisição e menor sensibilidade às variações climáticas [7], quando comparado aos outros dois tipos de imagens, este projeto teve como foco o uso de imagens em comprimento de onda visível. É importante ressaltar que atributos extraídos de métodos por análise dos outros espectros podem coexistir e formar futuramente um sistema único de diagnóstico, como

visto em [8].

De modo a viabilizar o desenvolvimento futuro de sistemas de monitoramento automatizado de plantas elétricas de alta tensão, foi desenvolvido neste trabalho um método extrair características de imagens de espectro visível em uma base pública de poluição artificial. Também foi iniciada a construção de uma nova base de dados de imagens com poluição real de peças posicionadas em plantas elétricas e em área costeira.

Inicialmente, foi executada uma ampla revisão bibliográfica, tal que fosse estabelecido um embasamento teórico capaz de proporcionar um domínio do estado da arte no que diz respeito à segmentação e extração de características de imagens de isoladores de potência. Por conseguinte, o métodos mais significativo foi implementados computacionalmente, utilizando dados disponíveis na base disponível em [9]. Além disso, em paralelo ao estudo aplicado às imagens de laboratório [9], peças experimentais de isoladores poliméricos foram confeccionadas e posicionadas em planta de alta potência de uma termelétrica de Sergipe, assim como em uma residência de área costeira para análise e captura de imagens com depósito de poluição real do problema de interesse. Por fim, os resultados adquiridos no estudo laboratorial realizado foram reunidos e descritos em um artigo intitulado “A Simple Model for Dirt Deposition Classification in Insulators Based on Visible Spectrum Images”, apresentado e premiado no 7º Simpósio Internacional de Sistemas de Instrumentação, Circuitos e Transdutores – INSCIT em Agosto de 2023.

1.0.1 Objetivo Geral

Visando o monitoramento automatizado e/ou semi-automatizado de plantas elétricas de alta potência, o objetivo geral dessa proposta é realizar a extração de características de imagens com comprimento de onda visível de isoladores para análise de poluição.

1.0.2 Objetivos Específicos:

- Realizar revisão bibliográfica acerca de monitoramento por imagens de equipamentos elétricos, em especial isoladores, bem como sobre segmentação e de extração de características aplicados à esse tipo de dado;
- Implementar método de segmentação aplicado à base de equipamentos poluídos artificialmente em laboratório, disponível em [9];
- Desenvolver método para extração de características significativas das imagens para base artificial [9];

- Montar base de imagens capturadas em uma usina termelétrica instalada no estado de Sergipe (o acesso a esses dados está garantido, através de projeto de colaboração já em andamento);
- Produzir e publicar artigo científico, em periódico e anais de eventos, contendo os resultados obtidos neste projeto.

1.1 Estrutura do Projeto de Pesquisa

A sequência deste relatório de pesquisa está estruturada da seguinte maneira:

Capítulo 2 - é apresentada uma revisão bibliográfica no tocante ao uso de monitoramento automatizado de plantas elétricas, segmentação e extração de características de imagens de isoladores de alta tensão;

Capítulo 3 - uma fundamentação teórica é apresentada acerca de segmentação de contornos ativos, de fundamentos de probabilidade e do K-NN como classificador;

Capítulo 4 - descreve-se a abordagem proposta, através das etapas desenvolvidas ao longo do projeto, a fim de atingir os objetivos da disciplina;

Capítulo 5 - apresenta-se a descrição dos experimentos realizados, resultados e discussão dos mesmos;

Capítulo 6 - são discutidas as conclusões e expectativas para trabalhos futuros.

A seguir é apresentada uma revisão bibliográfica em que são abordadas características relevantes no campo de visão computacional quanto ao uso de monitoramento automatizado de plantas elétricas e detecção de poluição em imagens de espectro visível de isoladores de alta tensão.

2 REVISÃO BIBLIOGRÁFICA

O desenvolvimento de sistemas automatizados para monitoramento automático de plantas elétricas alta potência é uma área de grande potencial investigativo [3] e possui diversas abordagens. O diagnóstico de uma possível falha em um equipamento pode ser determinado através da corrente de fuga [10][11], de emissões acústicas [12], de campos elétricos [13], por sinais de vibração [14] e por ruídos ultrassônicos [15], para citar alguns exemplos. Na área de visão computacional, um dos grandes campos de aprendizado de máquina, há métodos capazes de criar modelos matemáticos para tomada de decisões de acordo com a análise de imagens dos equipamentos de alta potência. Imagens de espectro

ultra-violeta (UV) são utilizadas para detectar falha baseada em presença de descarga corona [16] [17] [18]. Outro tipo de espectro bastante utilizado é o infravermelho (*infrared-IR*, em inglês), em que o perfil térmico do equipamento pode ser um indicativo de falha [19][20][21]. Imagens de espectro visível também são utilizadas para análise. Como descrito no capítulo 1, seu baixo custo e sua invariância a condições climáticas apontam uma vantajosa direção de investigação para extração de características deste tipo de dado.

De acordo com evidências apresentadas em trabalhos científicos, o acúmulo de materiais na superfície dos equipamentos, em especial de isoladores, pode acarretar uma queda na capacidade de isolação e aumento da probabilidade de descargas [22] [23]. Para análise feita por imagem de espectro visível, a textura observada decorrente do depósito de materiais pode ser usada como informação representativa do problema. Em [24], a imagem captura a textura proveniente do acúmulo de gelo. No trabalho [25] a textura é analisada como consequência da hidrofobicidade apresentada na superfície do isolador. De outra maneira, a maior parte dos trabalhos observados na literatura tenta relacionar a textura capturada pela imagem com o depósito de sal e/ou de substâncias não solúveis, medidas por densidade equivalente por depósito de sal (em inglês, *equivalent salt deposit density* - ESDD) e densidade por depósito de não-solúvel (em inglês, *non-soluble deposit density* - NSDD), em que, de acordo com essas medidas, é classificado o grau de poluição do isolador. Independente do tipo de textura a ser avaliada, bases de dados provenientes de imagens de espectro visível reais (capturadas em campo) não são comuns nessa área de pesquisa, uma vez que a coleta de dados em plantas de alta potência é dificultada por problemas logísticos e protocolos de segurança. Desta maneira, geralmente, os trabalhos são realizados em equipamentos poluídos artificialmente [26] [7] [27] de acordo com o padrão IEC/TS 60815 [28], ou em equipamentos retirados de plantas reais [29].

Com o intuito de extrair informações significativas das imagens das bases coletadas, em outras palavras, características relevantes, o início do desenvolvimento de um método capaz de diagnosticar de falhas baseado em imagem pode ser dividido em segmentação e extração de características do equipamento monitorado. O primeiro processamento a ser feito consiste na segmentação do equipamento que se deseja monitorar, ou seja, na separação do objeto de interesse. A tarefa de segmentação de objetos possui diversas abordagens, desde as mais antigas, como modelo de contornos ativos [30][31], baseado em regiões [32], por limiarização [33], passando por métodos baseados em modelos probabilísticos [34] [35] [36], até estudos mais recentes, como os baseados em redes neurais.

As Redes neurais convolutivas (*Convolutional Neural Networks* - CNN ou ConvNets) voltaram a ser desenvolvidas, nos últimos 10 anos, com bons resultados no processamento de imagens. Implementadas com sucesso na década de 90 por alguns pesquisadores, como Lecun [37], esse tipo de rede neural foi inspirada no sistema de

visão biológico [38], onde a imagem é processada por sensibilidade local, ou seja, por regiões. Sendo assim, ao invés de tratar a imagem inteira para entrada da rede neural, como uma *Multi Layer Perceptron* (MLP) faria, as CNNs processam a imagem através de filtros (também chamados de *kernels*) treinados para capturar diferentes características da imagem (e.g. bordas, formas geométricas e sombras). Há diversos tipos de ConvNets bem estabelecidas [39][40][41][42], e suas aplicações estão presentes em diversas áreas de visão computacional, como auxílio em diagnóstico por análise de imagens [43], e na detecção de equipamentos em um planta elétrica [44][45][46][47], para citar alguns exemplos. Para segmentação fina dos equipamentos, são definidos métodos como [48] [49], como aplicado em [50].

Após a segmentação do objeto de interesse, as características relevantes para análise de poluição são extraídas. Do histograma de escala de cinza podem ser extraídas a média global e a área relativa dos 80 primeiros tons [26], como atributos de dados adquiridos em exposição de iluminação controlada. Para dados adquiridos sob forte influência do sol, do histograma de modelos HSV (do inglês, *hue, saturation, and value*) podem ser extraídos medida de diferença e erro de histograma normalizado [29]. Também em [29] foram utilizadas características baseadas em decomposição de valores singulares. A extração de 12 atributos de cor foram relacionados com medidas de ESDD/NSDD em [7], evidenciando a relação textura/poluição.

De uma maneira geral, considerando os trabalhos citados no parágrafo anterior, as imagens com poluição artificial possuem graus de poluição elevados, plano de fundo homogêneo e bom controle de iluminação, situações dificilmente encontradas em uma planta real. Todavia, o resultados obtidos evidenciam um caminho promissor para o diagnóstico de falhas por imagens de espectro visível e de grande potencial de pesquisa, principalmente no que diz respeito a situações menos controladas como na utilização de imagens com fundo heterogêneo, capturadas ao ar livre e até inseridos na complexa dinâmica de uma planta elétrica.

3 FUNDAMENTAÇÃO TEÓRICA

A fim de estabelecer uma fundamentação teórica para entendimento dos experimentos realizados durante o projeto de pesquisa, nesta seção serão apresentados conceitos relevantes para esse trabalho acerca método de segmentação por contorno ativo sem bordas definidas, fundamentos de probabilidade, e do algoritmo de K-NN usado como classificador.

3.1 Segmentação com contornos ativos sem bordas definidas

Dentre diversos métodos existentes para segmentação de objetos em uma imagem, há métodos que se baseiam na evolução de uma curva sujeita a restrições impostas pela imagem. Tais métodos são nomeados de Métodos de Contornos Ativos, *snakes* ou Modelos Deformáveis, em que um contorno arbitrário é iniciado ao redor do objeto, e pela minimização de uma função de energia, o contorno vai se ajustando dinamicamente até parar nas bordas desse objeto.

Alguns desses métodos detectam as bordas através da informação de gradiente. Porém, quando os objetos possuem fronteira suaves, de baixo gradiente, é necessário utilizar outro tipo de informação. Em [31], os autores sugerem um método capaz de segmentar elementos em uma imagem que não possuem bordas bem definidas, ou seja, a informação de borda não pode ser definida pelo gradiente. Sendo assim, é proposto no trabalho a minimização de energia como um problema de partição mínima.

Considerando uma imagem u_0 dividida em duas regiões de intensidade aproximadamente constante para cada região, a ideia básica do método consiste em minimizar um termo de “encaixe” de uma curva C , que segmentará essas duas regiões. O termo, definido em [31], está descrito na equação 3.1.

$$F_1(C) + F_2(C) = \int_{C(\text{dentro})} |u_0(x, y) - c_1|^2 dx dy + \int_{C(\text{fora})} |u_0(x, y) - c_2|^2 dx dy \quad (3.1)$$

Onde c_1 e c_2 são as médias de u_0 dentro e fora da curva, respectivamente.

Diferentes ajustes de uma curva podem ser visto no exemplo exposto na figura 1. Quando C for a fronteira de segmentação real da imagem, $F_1(C) + F_2(C) \approx 0$.




Figura 1 – Casos Possíveis na Posição da Curva (adaptado de [31])

Esse caso de partição mínima é resolvido através de método de definição de nível, onde é definida uma função de Lipschitz ϕ . A função ϕ é definida de tal forma que assume valores positivos dentro da curva C , valor nulo sobre a curva e valores negativos fora curva. Para a formulação do conjunto de níveis do modelo adotado no trabalho, a variável C é substituída pela variável ϕ e seu ajuste é feito através da solução de equações diferenciais parciais, a fim de minimizar o termo descrito na equação 3.1.

3.2 Fundamentos de Probabilidade

A Teoria de Probabilidade é o ramo da matemática que estuda fenômenos aleatórios. Em outras palavras, fenômenos que não podem ser modelados por uma função determinística, e sim por modelos matemáticos que levam em consideração a chance de um determinado evento acontecer.

Para modelar um experimento aleatório em dados matemáticos, é definida uma variável aleatória (VA) com funções que mapeiam as saídas de um experimento em um conjunto de números reais. As VAs podem ser contínuas ou discretas, a depender do fenômeno modelado. Um lançamento de um dado pode ser modelado através de uma VA discreta e a medida da glicemia do sangue humano uma VA contínua, para citar alguns exemplos. O comportamento probabilístico de uma VA discreta pode ser modelado através de funções descritas a seguir.

3.2.1 Função de massa de probabilidade

A função de massa de probabilidade (FMP) associa um valor de probabilidade a cada possível ocorrência de uma variável aleatória discreta. Por definição, seja X uma variável aleatória discreta com espaço amostral definido por $\Omega = \{k_1, k_2, \dots, k_n\}$, a função de massa de probabilidade é definida por $f : \Omega \rightarrow \mathbb{R}$, onde $0 < f(k) \leq 1$ e $f(k) = Pr(X = k)$.

Há diversos tipos bastante conhecidos na literatura de funções de massa de probabilidade. Bernoulli, Poisson, Geométrica, Binomial e Uniforme, para citar alguns exemplos. Considerando uma variável aleatória X com FMP Uniforme, ou seja, $f(k) = \frac{1}{n}$, para $k \in \mathbb{Z}^*$, o gráfico desse tipo de função apresenta contorno que pode ser identificado como a silhueta de uma função degrau e pode ser ilustrado na figura 2.




Figura 2 – Função Uniforme de Variável Aleatória com Cinco Possibilidades de Ocorrência

Caso a variável possua apenas uma possibilidade de ocorrência possível, $\Omega = \{k_1\}$, seria como estar num caso não aleatório, onde o evento é certo, e portanto, sua FMP seria $f(k) = 1$, para $k = k_1$. Nesse caso, o gráfico teria aspecto semelhante a um impulso em k_1 e pode ser ilustrado na figura 3.




Figura 3 – Função de Variável com Uma Possibilidade de Ocorrência

3.2.2 Função de Distribuição Acumulada

Outra maneira de representar probabilidades de uma variável aleatória é através da Função de Distribuição Acumulada (FDA). Por definição, a FDA de uma variável aleatória X é dada por $F_X(x) = P(X \leq x)$, para $-\infty < x < \infty$. A FDA pode ser vista como uma função de soma corrente que inicia de $-\infty$ e termina em ∞ .

Para uma variável aleatória discreta com $\Omega = \{k_1, k_2, \dots, k_n\}$, a função de distribuição será constante entre os valores de k e descontínua nos valores k .

Considerando a FMP Uniforme ilustrada na figura 2, a FDA para esta variável pode ser observada na figura 4, e seu contorno pode ser identificado como a silhueta de uma função reta.




Figura 4 – Função de Distribuição Acumulada da função exposta na figura 2

A FDA para a função de apenas uma possibilidade de ocorrência (ver figura 3) pode ser observada na figura 5.




Figura 5 – Função de Distribuição Acumulada da função exposta na figura 3

3.3 K-NN como Classificador

O K-NN (do inglês, K Nearest Neighbor) é um estimador de densidade de probabilidade. Porém, pode ser utilizado como um classificador não-linear. O algoritmo para realizar a classificação está descrito a seguir.

Considere um vetor de características x e um tipo de medida de distância, podendo ser Euclidiana, de Manhattan, Norma Máxima, entre outras. Sendo assim, os passos para realização da classificação estão descritos no algoritmo 1, adaptado de [51].

Algorithm 1 Algoritmo K-NN

Passo 1: Para um conjunto de N vetores de treinamento, identifique os k vizinhos mais próximos de acordo com a distância adotada. De maneira geral, o valor de k é escolhido para não ser múltiplo do número de classes M

Passo 2: Dentro do conjunto de k vizinhos, identifique o número de vetores que pertence a cada classe

Passo 3: Classifique x com a mesma classe do maior número de vetores identificado no passo 2

Para o caso de $k = 11$, a figura 6 ilustra os 11 vizinhos mais próximos, onde 4 são da classe preta e 7 da classe azul. Sendo assim, pelo algoritmo 1, o dado $*$ seria classificado como pertencente à classe azul.




Figura 6 – Classificação 11-NN [51]

No contexto de avaliação da capacidade de generalização do classificador, dado conjunto de dados disponível, a técnica de validação cruzada *leave-one-out* é um método derivado do k -fold, onde o número de k é o número total do conjunto de dados N . Desta maneira, neste método são executados N experimentos, onde em cada experimento 1 amostra é testada e as outras $N-1$ amostras são utilizadas para treinamento, como ilustrado na figura 7. Devido ao alto custo computacional, esse método costuma ser aplicado para conjunto de dados pequenos.

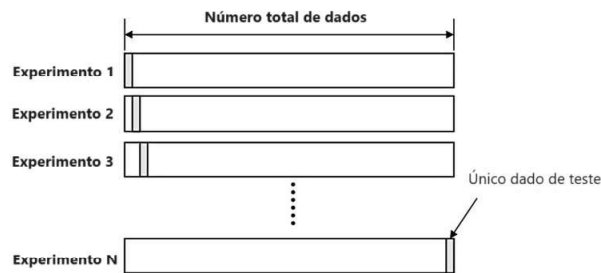


Figura 7 – Validação Cruzada *Leave-one-out*[52]

4 ABORDAGEM PROPOSTA

O desenvolvimento deste projeto de pesquisa foi executado com dois eixos paralelos de atuação: experimentos desenvolvidos com base pública de poluição artificial e criação de uma nova base de dados com poluição real de área costeira, ambos descritos nas sessões a seguir.

4.1 Experimento com poluição artificial

Para este eixo de atuação do projeto, foi utilizada a base de dados disponível em [9], em [53] os autores abordaram a estimativa do NSDD através de imagens digitais. Este conjunto de dados foi separado em 43 imagens de isoladores contaminados com quantidades controladas de NSDD e ESDD, incluindo uma classificação de cada imagem em quatro níveis de NSDD, medidas em laboratório, após cada foto ser tirada. Os quatro níveis do NSDD foram representados de 1 a 4, onde:

- ◇ Classe 1 representa 0 mg/cm^2 de NSDD
- ◇ Classe 2 representa um NSDD cuja densidade é acima de 0 até 1 mg/cm^2
- ◇ Classe 3 representa um NSDD cuja densidade é acima de 1 até 2 mg/cm^2
- ◇ Classe 4 representa um NSDD densidade acima de 2 mg/cm^2

Uma amostra de cada uma das quatro classes descritas anteriormente estão ilustradas na figura 8.

Usando a mesma base de dados e baseando-se no trabalho apresentado em [53], a segmentação dos isoladores foi realizada com pixels agrupados em uma escala de cinza, e a segmentação por contornos ativos [31] foi aplicada para eliminar o plano de fundo.



Figura 8 – Amostras das quatro classes de isoladores poluídos.

Diferentemente da extração de seis características propostas no trabalho original [53], nesse projeto foram realizados experimentos para classificação com uma abordagem de extração de características mais simples, sugerindo apenas um único parâmetro d baseado num novo modelo fenomenológico muito simples, descrito no tópico 4.1.1 a seguir.

O parâmetro d é a única medida escalar por imagem utilizada neste trabalho, e por ter uma motivação fenomenológica, esperou-se que pudesse produzir resultados de classificação tão bons quanto o vetor de parâmetros estatísticos utilizado em [53]. Para testá-lo, reproduziu-se a extração realizada em [53]. Porém, como estão disponíveis apenas 43 imagens rotuladas, foi evitado o uso de classificadores com muitos parâmetros livres, e os testes foram restritos ao classificador K-NN, que foi de fato o melhor, segundo resultados apresentados em [53]. Da mesma maneira, para a comparação com o vetor de medidas estatísticas, utilizou-se a distância cosseno, que se apresentou entre as melhores distâncias comparadas no trabalho original. Por fim, quanto à validação, novamente devido ao pequeno número de observações, utilizou-se apenas a abordagem *leave-one-out* nos experimentos.

A abordagem geral proposta, incluindo segmentação, extração de características e classificação é ilustrada na figura 9.

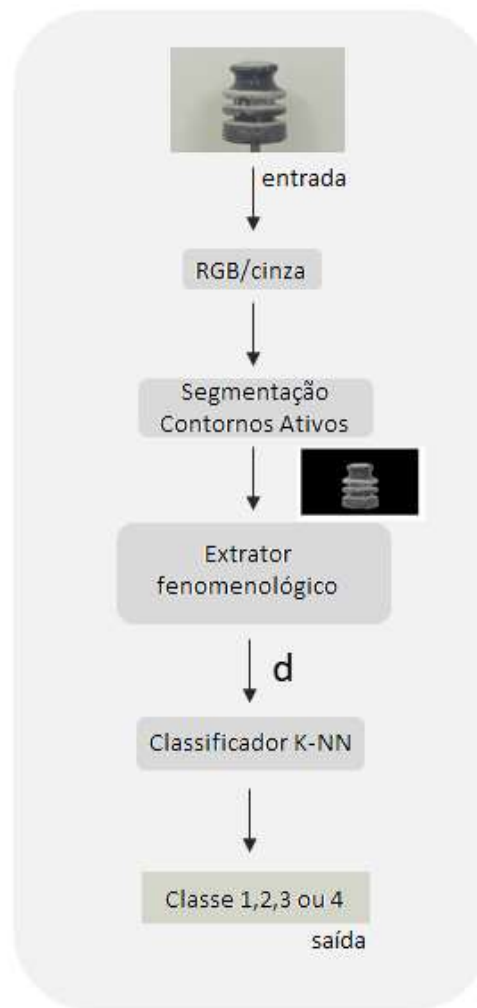


Figura 9 – Esquema geral da abordagem proposta

4.1.1 Simple Modelo Fenomenológico

O Simple Extrator Fenomenológico é baseado em duas considerações. A primeira supõe que, no caso dos isoladores utilizados em [53], o isolador limpo possui superfície monocromática. Por outro lado, a segunda assume que a poluição depositada pode ter qualquer cor ou, mais especificamente, qualquer nível de cinza (para imagens em escala de tons de cinza). Sendo assim, espera-se que o pior caso de contaminação por depósito de sujeira tenha um histograma quase constante de intensidades de tons de cinza. Em outras palavras, uma presunção ingênua de que elas fossem planas em relação aos histogramas de imagens em escala de cinza de superfícies isolantes. Mais precisamente, que $h_k = 1/M, k = 1, 2, \dots, M$ para M níveis de cinza, onde h_k representa a proporção de k -ésimo nível de cinza para todo pixel da imagem. Consequentemente, a distribuição cumulativa correspondente $c_k = \sum_{m=1}^k h_m$ seria uma linha reta de $c_1 = 0$ a $c_M = 1$, conforme ilustrado na figura 10.

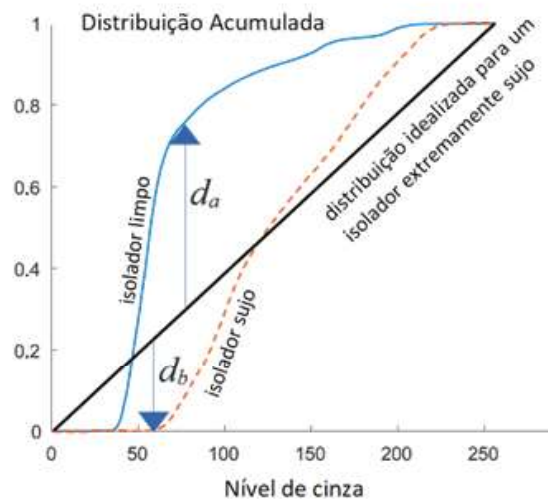


Figura 10 – Ilustração de duas distribuições cumulativas reais do conjunto de dados e a distribuição idealizada para um isolador extremamente sujo (linha reta). As distâncias verticais máximas entre cada distribuição real e a idealizada são indicadas como d_a e d_b

Em contraste, espera-se que as superfícies isoladas monocromáticas limpas tenham uma distribuição cumulativa como função degrau. Entre esses dois extremos (degrau e linha reta), outros formatos podem ocorrer em função da quantidade de sujeira na superfície do isolador (sempre sob a presunção de que o pó possui amplo espectro cromático). Este pressuposto define finalmente à medição proposta neste trabalho:

$$d = \max_k |c_k - k/M| \quad (4.1)$$

Na figura 10, também é explicado visualmente porque quanto menor for o d , mais sujo deverá ser o isolador. Por exemplo, d_a e d_b fornecem exemplos visuais de duas imagens reais do banco de dados.

Os resultados obtidos com este novo modelo estão descritos no capítulo 5.

4.2 Criação da nova base de dados com poluição real

O outro principal eixo de ação deste projeto consistiu na criação de uma nova base de dados com poluição real encontrada em áreas costeiras e da planta elétrica de uma usina termelétrica de interesse. As novas imagens, ainda com captura em andamento, estão sendo criadas a partir do Experimento Sentinela desenvolvido em parceria com o projeto GIMPSI (Gestão de Impactos de Salinidade), ao qual o doutorado da autora é vinculado.

O Experimento Sentinela consiste no monitoramento visual de como ocorre o depósito de materiais poluentes em duas unidades de peças experimentais (ver figura

11), expostas ao ambiente da planta elétrica.




Figura 11 – Esquema da Peça experimental

Para compor o conjunto de dados, a cada visita semanal estão sendo capturadas imagens de comprimento de onda visível de cada peça. Com o objetivo de caracterização e controle do comportamento do acúmulo de salinidade, as peças serão lavadas e o material depositado será analisado de acordo com padrão definido pela IEC (*International Electrotechnical Commission*), a fim de quantificar o depósito que se acumula na superfície deste equipamento, além de fornecer uma medição real de depósito. O processo de aquisição de dados em campo está ilustrado na figura 12. Os resultados obtidos para os dois principais eixos da abordagem proposta estão descritos no capítulo a seguir.




Figura 12 – Processo de Captura de Imagens

5 RESULTADOS

De acordo com a abordagem proposta descrita no capítulo anterior, os resultados serão apresentados em sessões referentes aos dois eixos principais de atuação.

5.1 Experimentos com poluição artificial

A segmentação obtida, com o objetivo de extrair o fundo das 43 imagens dos isoladores da base de poluição artificial, está exposta na figura 13. De fato, o método de segmentação por contornos ativos, também utilizado em [53], garantiu um bom resultado na segmentação do isolador.



Figura 13 – Segmentação da Base de Dados [9]

A distribuição acumulada dos tons de cinza dos pixels de cada imagem estão apresentadas na figura 14. Cada cor no gráfico representa uma das quatro classes de diferentes graus de NSDD. Pode-se perceber que os isoladores limpos (classe 1 em azul cobalto) possuem formato mais semelhante a uma função degrau. Por outro lado, os isoladores mais sujos (classe 4 em ciano) possuem formato mais parecido com uma reta, ratificando as considerações levantadas no capítulo 4.

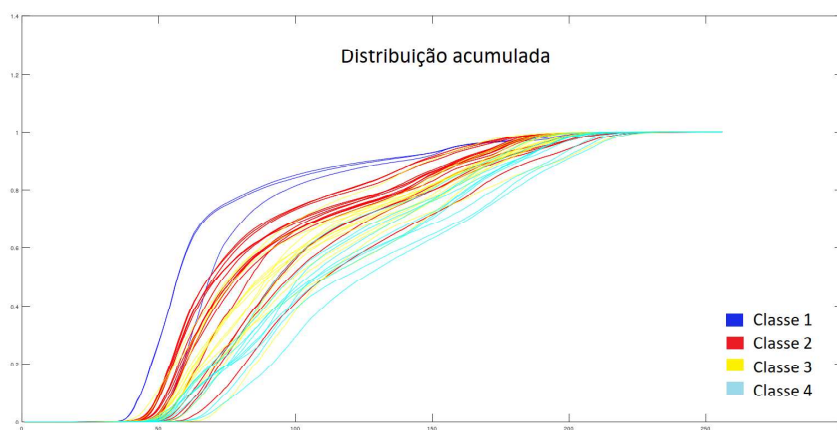


Figura 14 – Distribuição Acumulada de Acordo com as 4 Classes de Poluição

O resultado do experimento de classificação, comparando as 6 características extraídas no trabalho original em relação à extração do único parâmetro d proposto neste trabalho, está exposto na tabela 1. A tabela 1 apresenta o número de imagens classificadas corretamente em cada classe, para a melhor estrutura K-NN em cada caso, (que foi $K = 1$ para ambos os casos). Sendo assim, pode-se perceber que o modelo de apenas um parâmetro apresentou resultado semelhante ao modelo com maior número de características extraídas.

Tabela 1 – Números de Imagens Classificadas Corretamente em cada Classe

Parâmetro	Classe 1	Classe 2	Classe 3	Classe 4	Total
	3	16	14	10	
6 características como em [53]	3	14	7	5	28
único parâmetro d	3	11	8	7	29

Para estender o uso da medida d além do problema de classificação de 4 classes, uma fórmula afim potencialmente útil também foi ajustada para estimar o nível de NSDD diretamente da medição d . Esta fórmula é mostrada em (5.1), e foi ajustada para minimizar o erro quadrático de predição.

$$NSDD_{estim} = 36.9d^2 - 33.3d + 7.3 \text{ mg/cm}^2 \quad (5.1)$$

Por exemplo, a partir do conjunto de dados, uma determinada imagem, de um isolador com NSDD de cerca de $0,98 \text{ mg/cm}^2$, produziu uma medida d de $0,274$. Usando a equação 5.1), obtem-se um $NSDD_{estima}$ de cerca de $0,95 \text{ mg/cm}^2$.

Infelizmente, esta fórmula não tem um forte poder de previsão, como seria de esperar, devido à simplicidade do modelo subjacente. Mais precisamente, quando comparado com o intervalo real de NSDD no conjunto de dados - de 0 a menos de $2,7 \text{ mg/cm}^2$ -, o desvio padrão empírico dos erros de previsão - cerca de $0,7 \text{ mg/cm}^2$ - o

$NSDD_{estima}$ está fora, em média, de cerca de 25% do intervalo real do NSDD. No entanto, para fins qualitativos, ou mesmo previsões/classificações quantitativas aproximadas, como o esquema de quantização NSDD de 4 níveis usado em [53], este erro de previsão pode ser aceitável. Por exemplo, aplicando a equação 4.1 a todas as 43 instâncias do conjunto de dados e aplicando o mesmo esquema de quantização explicado na seção 4.1, essas observações foram classificadas com rótulos que são corretos para 33 instâncias, o que corresponde a uma precisão ainda melhor do que aquelas apresentadas na tabela 1.

5.2 Criação da nova base de dados com poluição real

Dois amostras de imagens capturadas durante o processo da criação da nova base de dados com poluição real estão ilustradas na figura 15.



Figura 15 – Amostras da Nova Base de Dados

Um exemplo de segmentação por contornos ativos realizada para esse tipo de imagem está exposta na figura 16.



Figura 16 – Segmentação em Amostra da Nova Base de Dados

Apesar do fundo ser mais complexo que o apresentado na base de poluição artificial, a utilização do mesmo método para segmentação apresentou bom resultado, indicando a continuidade do seu uso para a nova base de dados.

É importante ressaltar que até o final deste projeto de pesquisa, ainda não foi apresentado depósito de poluição visualmente significativo nas imagens da nova base de dados. Sendo assim, ainda não foi possível realizar o estudo de extração de características para este tipo de dado.

As conclusões deste projeto e projeções para trabalhos futuros estão descritas no capítulo a seguir.

6 CONCLUSÃO

Neste estudo, uma única medida proposta, d , extraída de imagens em níveis de cinza demonstrou poder de discriminação equivalente a vários recursos estatísticos combinados para o mesmo conjunto de dados [9]. Considerando o tamanho reduzido do conjunto de dados e o tamanho da informação estatística reduzida, é importante escolher uma extração de características simples e eficaz. De fato, esta medida d foi capaz de representar de forma simples o depósito de sujeira em uma imagem de isolante e alcançou resultados estatisticamente equivalentes ao maior número de parâmetros propostos em [53].

A distribuição cumulativa de referência da superfície limpa foi baseada no pressuposto de que os isoladores cerâmicos possuem superfície lisa isocromática e a sujeira depositada aparece em uma ampla faixa de intensidades de cinza. No entanto, uma nova referência limpa poderia ser investigada para isoladores com textura superficial e padrão de cor mais complexos. Além disso, apesar dos resultados experimentais favoráveis até agora, a fragilidade da abordagem proposta é a suposição de que a poeira tem uma dispersão máxima de intensidades cinzentas. Se esta presunção for frustrada, este modelo simples ainda pode ser útil, mas o cálculo de d deve ser modificado, pois a distribuição cumulativa de referência deve refletir o conhecimento *a priori* sobre a composição da sujeira.

Por fim, espera-se que novos experimentos e ajuste do modelo fenomenológico sejam realizados, utilizando os novos dados que estão sendo capturados de imagens com poluição real depositada nas peças experimentais, a fim de elevar o potencial do modelo proposto, tornando-o aplicável a dados reais do problema de interesse.

Referências

- [1] LEI, Y. et al. An intelligent fault diagnosis method using unsupervised feature learning towards mechanical big data. *IEEE Transactions on Industrial Electronics*, v. 63, n. 5, p. 3137–3147, 2016.
- [2] WANG, H.; ZHOU, B.; ZHANG, X. Research on the remote maintenance system architecture for the rapid development of smart substation in china. *IEEE Transactions on Power Delivery*, v. 33, n. 4, p. 1845–1852, 2018.
- [3] ZHAO, L. et al. Design of an industrial iot-based monitoring system for power substations. *IEEE Transactions on Industry Applications*, IEEE, v. 55, n. 6, p. 5666–5674, 2019.
- [4] MUHAMMAD, A. et al. Autonomous drone-based powerline insulator inspection via deep learning. In: SPRINGER. *Robot 2019: Fourth Iberian Robotics Conference: Advances in Robotics, Volume 1*. [S.l.], 2020. p. 52–62.
- [5] SALEM, A. A. et al. The leakage current components as a diagnostic tool to estimate contamination level on high voltage insulators. *IEEE Access*, v. 8, p. 92514–92528, 2020.
- [6] WERNECK, M. M. et al. Detection and monitoring of leakage currents in power transmission insulators. *IEEE Sensors Journal*, v. 15, n. 3, p. 1338–1346, 2015.
- [7] JIN, L. et al. Condition evaluation of the contaminated insulators by visible light images assisted with infrared information. *IEEE Transactions on Instrumentation and Measurement*, IEEE, v. 67, n. 6, p. 1349–1358, 2018.
- [8] JIN, L. et al. Detection of polluted insulators using the information fusion of multispectral images. *IEEE Transactions on Dielectrics and Electrical Insulation*, IEEE, v. 24, n. 6, p. 3530–3538, 2017.
- [9] INSULATOR Dataset. <https://github.com/SFStefenon/InsulatorsDataSet>. Accessed: 2023-05-13.
- [10] WERNECK, M. M. et al. Detection and monitoring of leakage currents in power transmission insulators. *IEEE sensors journal*, IEEE, v. 15, n. 3, p. 1338–1346, 2014.
- [11] HARID, N. et al. A wireless system for monitoring leakage current in electrical substation equipment. *IEEE Access*, IEEE, v. 4, p. 2965–2975, 2016.
- [12] PEI, C. et al. On-line monitoring of insulator contamination causing flashover based on acoustic emission. In: IEEE. *2008 Third International Conference on Electric Utility Deregulation and Restructuring and Power Technologies*. [S.l.], 2008. p. 1667–1671.
- [13] RAMIREZ-VAZQUEZ, I.; HERNANDEZ-CORONA, R.; MONTOYA-TENA, G. Diagnostic of nonceramic insulators aged in a salt fog chamber by using electric field sensor. In: IEEE. *Conference Record of the 2004 IEEE International Symposium on Electrical Insulation*. [S.l.], 2004. p. 471–474.

- [14] WAN, S. et al. Study on on-line detection of characteristic parameters in high voltage circuit breaker opening process based on vibration signal. *Electric Power Components and Systems*, Taylor & Francis, v. 46, n. 18, p. 1969–1978, 2018.
- [15] FERREIRA, T. V.; GERMANO, A. D.; COSTA, E. G. da. Ultrasound and artificial intelligence applied to the pollution estimation in insulations. *IEEE transactions on power delivery*, IEEE, v. 27, n. 2, p. 583–589, 2012.
- [16] DAVARI, N.; AKBARIZADEH, G.; MASHHOUR, E. Intelligent diagnosis of incipient fault in power distribution lines based on corona detection in uv-visible videos. *IEEE Transactions on Power Delivery*, IEEE, v. 36, n. 6, p. 3640–3648, 2020.
- [17] COSTA, E. G. D. et al. Characterization of polymeric insulators using thermal and uv imaging under laboratory conditions. *IEEE Transactions on Dielectrics and Electrical Insulation*, IEEE, v. 16, n. 4, p. 985–992, 2009.
- [18] ZHANG, Z. et al. Comparison of different characteristic parameters acquired by uv imager in detecting corona discharge. *IEEE Transactions on Dielectrics and Electrical Insulation*, IEEE, v. 23, n. 3, p. 1597–1604, 2016.
- [19] HE, H. et al. A contactless insulator contamination levels detecting method based on infrared images features and rbfnn. *IEEE Transactions on Industry Applications*, IEEE, v. 55, n. 3, p. 2455–2463, 2018.
- [20] XIA, C. et al. Infrared thermography-based diagnostics on power equipment: State-of-the-art. *High Voltage*, Wiley Online Library, v. 6, n. 3, p. 387–407, 2021.
- [21] JIANG, Q. et al. A contour angle orientation for power equipment infrared and visible image registration. *IEEE Transactions on Power Delivery*, IEEE, v. 36, n. 4, p. 2559–2569, 2020.
- [22] LAN, L. et al. The influence of natural contamination on pollution flashover voltage waveform of porcelain insulators in heavily polluted area. *IEEE Access*, IEEE, v. 7, p. 121395–121406, 2019.
- [23] PORTELLA, K. F. et al. Efeitos da poluição atmosférica (litorânea e industrial) em isoladores da rede elétrica da região metropolitana de salvador. *Química Nova*, SciELO Brasil, v. 31, p. 340–348, 2008.
- [24] LIU, Y. et al. Image characteristic extraction of ice-covered outdoor insulator for monitoring icing degree. *Energies*, MDPI, v. 13, n. 20, p. 5305, 2020.
- [25] KHALAYLI, L. et al. Automatic inspection of outdoor insulators using image processing and intelligent techniques. In: IEEE. *2013 IEEE Electrical Insulation Conference (EIC)*. [S.l.], 2013. p. 206–209.
- [26] PATEL, I. et al. Image processing based estimation of ceramic insulator pollution levels. In: IEEE. *2018 5th International Conference on Electric Power and Energy Conversion Systems (EPECS)*. [S.l.], 2018. p. 1–4.
- [27] STEFENON, S. F. et al. Classification of insulators using neural network based on computer vision. *IET Generation, Transmission & Distribution*, Wiley Online Library, v. 16, n. 6, p. 1096–1107, 2022.

- [28] INTERNATIONALE, C. É. *Artificial Pollution Tests on High-voltage Ceramic and Glass Insulators to be Used on Ac Systems*. [S.l.]: International Electrotechnical Commission, 2013.
- [29] MARAABA, L.; ALHAMOUZ, Z.; ALDUWAISH, H. A neural network-based estimation of the level of contamination on high-voltage porcelain and glass insulators. *Electrical Engineering*, Springer, v. 100, p. 1545–1554, 2018.
- [30] KASS, M.; WITKIN, A.; TERZOPOULOS, D. Snakes: Active contour models. *International journal of computer vision*, Kluwer Academic Publishers Dordrecht, v. 1, n. 4, p. 321–331, 1988.
- [31] CHAN, T.; VESE, L. Active contours without edges. *IEEE Transactions on Image Processing*, v. 10, n. 2, p. 266–277, 2001.
- [32] NAJMAN, L.; SCHMITT, M. Watershed of a continuous function. *Signal Processing*, Elsevier, v. 38, n. 1, p. 99–112, 1994.
- [33] OTSU, N. A threshold selection method from gray-level histograms. *IEEE transactions on systems, man, and cybernetics*, IEEE, v. 9, n. 1, p. 62–66, 1979.
- [34] PLATH, N.; TOUSSAINT, M.; NAKAJIMA, S. Multi-class image segmentation using conditional random fields and global classification. In: *Proceedings of the 26th annual international conference on machine learning*. [S.l.: s.n.], 2009. p. 817–824.
- [35] BOYKOV, Y.; VEKSLER, O.; ZABIH, R. Fast approximate energy minimization via graph cuts. *IEEE Transactions on pattern analysis and machine intelligence*, IEEE, v. 23, n. 11, p. 1222–1239, 2001.
- [36] ROTHER, C.; KOLMOGOROV, V.; BLAKE, A. "grabcut" interactive foreground extraction using iterated graph cuts. *ACM transactions on graphics (TOG)*, ACM New York, NY, USA, v. 23, n. 3, p. 309–314, 2004.
- [37] LECUN, Y. et al. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, v. 86, n. 11, p. 2278–2324, 1998.
- [38] FUKUSHIMA, K.; MIYAKE, S. Neocognitron: A self-organizing neural network model for a mechanism of visual pattern recognition. In: *Competition and cooperation in neural nets*. [S.l.]: Springer, 1982. p. 267–285.
- [39] KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. Imagenet classification with deep convolutional neural networks. In: PEREIRA, F. et al. (Ed.). *Advances in Neural Information Processing Systems*. Curran Associates, Inc., 2012. v. 25. Disponível em: <<https://proceedings.neurips.cc/paper/2012/file/c399862d3b9d6b76c8436e924a68c45b-Paper.pdf>>.
- [40] SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*, 2014.
- [41] SZEGEDY, C. et al. Going deeper with convolutions. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2015. p. 1–9.

- [42] HE, K. et al. Deep residual learning for image recognition. In: *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. [S.l.: s.n.], 2016. p. 770–778.
- [43] KAYALIBAY, B.; JENSEN, G.; SMAGT, P. van der. Cnn-based segmentation of medical imaging data. *CoRR*, abs/1701.03056, 2017. Disponível em: <<http://arxiv.org/abs/1701.03056>><http://arxiv.org/abs/1701.03056>.
- [44] XIONG, X. et al. Identification of electrical equipment based on faster lstm-cnn network. In: *2020 IEEE International Conference on Networking, Sensing and Control (ICNSC)*. [S.l.: s.n.], 2020. p. 1–6.
- [45] LEI, X.; SUI, Z. Intelligent fault detection of high voltage line based on the faster r-cnn. *Measurement*, Elsevier, v. 138, p. 379–385, 2019.
- [46] JIANLONG, G.; WEIXIA, F.; MANHUA, W. An improved faster r-cnn algorithm for electric equipment detection. In: *Proceedings of the 2019 11th International Conference on Computer and Automation Engineering*. [S.l.: s.n.], 2019. p. 138–141.
- [47] HAN, S. et al. Electrical equipment identification in infrared images based on roi-selected cnn method. *Electric Power Systems Research*, Elsevier, v. 188, p. 106534, 2020.
- [48] HE, K. et al. Mask r-cnn. In: *Proceedings of the IEEE international conference on computer vision*. [S.l.: s.n.], 2017. p. 2961–2969.
- [49] LEE, Y.; PARK, J. Centermask: Real-time anchor-free instance segmentation. In: *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*. [S.l.: s.n.], 2020. p. 13906–13915.
- [50] WANG, B. et al. Automatic fault diagnosis of infrared insulator images based on image instance segmentation and temperature analysis. *IEEE Transactions on Instrumentation and Measurement*, IEEE, v. 69, n. 8, p. 5345–5355, 2020.
- [51] THEODORIDIS, S.; KOUTROUMBAS, K. *Pattern Recognition, Fourth Edition*. [S.l.]: Academic Press, 2009. Hardcover. ISBN 9781597492720.
- [52] VALIDACÃO Cruzada Leave-one-out. <https://slideplayer.com/slide/13519285/82/images/26/Leave-one-out+Cross+Validation.jpg>. Accessed: 2023-05-10.
- [53] CORSO, M. P. et al. Classification of contaminated insulators using k-nearest neighbors based on computer vision. *Computers*, MDPI, v. 10, n. 9, p. 112, 2021.