

Métodos de Aprendizado de Máquina para Detecção de Chuva voltados à Classificação de Risco em Dados de Rede de Sensores sem Fio

Leandro H. Silva, Sergio C. Oliveira

Escola Politécnica de Pernambuco
Universidade de Pernambuco
Recife – PE, Brasil
{lhss, scampello}@ecomp.poli.br

Eduardo Fontana

Departamento de Eletrônica e Sistemas
Universidade Federal de Pernambuco
Recife – PE, Brasil
fontana@ufpe.br

Resumo—Uma rede de sensores sem fio (RSSF) para monitoração de descargas parciais em cadeias de isoladores de alta tensão foi previamente desenvolvida e encontra-se em operação há aproximadamente três anos. As descargas parciais ocorrem quando há poluição depositada sobre as cadeias de isoladores e a umidade relativa do ar está elevada. Devido à natureza do processo o fenômeno sofre influência das condições climáticas. Para monitorar o ambiente a RSSF provê informações de temperatura e umidade a cada hora. Posteriormente um classificador *fuzzy* foi desenvolvido para extrair o risco de ocorrência de um *flashover* (uma descarga completa que pode tirar a linha de operação). Entretanto, as chuvas lavam naturalmente a cadeia removendo a camada de poluição e reduzindo o risco de *flashover*. A RSSF não pode ser equipada com sensores de chuva, porém um evento de chuva causa uma perturbação no padrão diário da temperatura e umidade e estudos iniciais comprovam que técnicas de reconhecimento de padrão são capazes de identificar eventos de chuva utilizando apenas dados de temperatura e umidade. Esse artigo apresenta um comparativo entre as técnicas no que diz respeito à generalização do treinamento para bases obtidas de sensores instalados em regiões com diversos comportamentos climáticos.

Palavras Chave — descargas parciais; detecção de chuva; reconhecimento de padrões, isoladores, sensores ópticos, *flashover*.

I. INTRODUÇÃO

As linhas de transmissão de alta tensão são afetadas por diversos problemas, dentre os quais se encontra a presença de poluição depositada sobre as cadeias de isoladores. Quando exposta a um ambiente com alta umidade relativa a camada de poluentes torna-se condutiva e através dela flui uma corrente elétrica de fuga. A corrente de fuga causa aquecimento e evaporação de maneira quase aleatória criando pequenas regiões dielétricas, denominadas de bandas secas. Nas bandas secas o campo elétrico muito intenso aplicado sobre uma região do espaço pode quebrar a rigidez dielétrica do ar e causar descargas parciais. A intensidade das descargas pode aumentar levando à ocorrência de uma descarga completa fase-terra, conhecida como *flashover*, causando uma falha na linha de transmissão [1], [2].

Um sensor óptico que monitora as descargas parciais observadas no sinal da corrente de fuga do isolador foi

desenvolvido e implantado [3], [4] em seis estações de monitoramento no nordeste do Brasil. Esse sistema, em funcionamento há aproximadamente três anos, transmite via satélite as informações de corrente de fuga, temperatura e umidade para armazenamento em uma base de dados. Essas informações são disponibilizadas internamente na CHESF (companhia responsável pela geração e transmissão de eletricidade na região) pelo sistema ADECI (Avaliação de Desempenho Elétrico em Cadeias de Isoladores). Analisando a corrente de fuga é possível estimar o nível de contaminação do isolador e agendar manutenções [5], [6], evitando intervenções desnecessárias e seus consequentes custos, assim como também, a interrupção no fornecimento de energia por ocorrência de um *flashover*.

Resultados preliminares indicam que é possível unicamente utilizar dados de temperatura e umidade para realizar a detecção de chuva [7]. A partir da detecção de chuva nas bases de dados do sistema ADECI as ações de manutenção poderão ser decididas com mais eficiência e confiabilidade. Foram experimentadas três técnicas para detecção de chuva: Classificador Bayesiano, Rede Neural *Multilayer Perceptron* (MLP) e Máquina de Vetor de Suporte.

Entretanto, o comportamento da temperatura e umidade está diretamente relacionado com o clima particular de cada região. Objetivando obter um classificador com o maior poder de generalização possível, este artigo avalia qual das três técnicas citadas anteriormente apresenta melhor resultado quando o treinamento é realizado com dados de determinada região e a avaliação é realizada com os dados das outras regiões (com diferente clima).

II. TÉCNICAS APLICADAS

A. Classificador Bayesiano

Um Classificador Bayesiano é uma técnica de aprendizado estatístico supervisionado [8]. Um vetor x representa m características (x_1, x_2, \dots, x_m) . Neste trabalho, cada dimensão do vetor x representa um atributo da base de dados. A probabilidade a posteriori de ter chovido em determinado dia pode ser calculada pelo Teorema de Bayes expresso por

$$P(\text{chuva}|x) = \frac{P(\text{chuva})P(x|\text{chuva})}{P(x)}. \quad (1)$$

Em (1), $P(x)$ é a probabilidade de ocorrência de x na base de dados e $P(x|chuva)$ é a probabilidade de ocorrência de x na classe *chuva*.

Assumindo que os atributos são independentes, a probabilidade $P(x|chuva)$ é dada por

$$P(x|chuva) = \prod_{i=1}^m P(x_i|chuva). \quad (2)$$

Ou seja, assumindo atributos independentes, a probabilidade $P(chuva|x)$ pode ser expressa por

$$P(chuva|x) = \frac{1}{Z} P(chuva) \prod_{i=1}^m P(x_i|chuva), \quad (3)$$

onde Z , a evidência, é uma fator dependente apenas dos atributos do vetor x .

Todos os parâmetros do Classificador Bayesiano (a probabilidade da classe *a priori* e as distribuições de probabilidade dos atributos) podem ser aproximados pelas frequências relativas obtidas no conjunto de treinamento. Nesse trabalho, foram aproximadas distribuições Gaussianas para os valores contínuos associados a cada classe.

B. Rede Neural Multilayer Perceptron

Uma MLP [9] é uma rede neural artificial cuja arquitetura é baseada em múltiplas camadas de neurônios: uma camada de entrada, uma ou mais camadas escondidas e uma camada de saída. O número de camadas escondidas depende do problema a ser solucionado.

Numa rede neural artificial, cada neurônio pode ser visto como um elemento com entradas, pesos associados a cada entrada, uma função de ativação e um sinal de saída. A saída de um neurônio é dada por

$$y_j = f \left(\sum_{i=1}^n x_{ji} w_{ji} \right), \quad (4)$$

onde, y_j é o sinal de saída do neurônio j , x_{ji} é a i -ésima entrada do neurônio j , w_{ji} é o i -ésimo peso do neurônio j e f é a função de ativação. Neste trabalho, a função sigmoide logística foi utilizada como função de ativação [9]. O sinal é propagado da camada de entrada para a camada de saída – onde o resultado da classificação é obtido.

O treinamento da rede neural consiste no ajuste dos pesos. O objetivo do treinamento é atingir um ponto em que a rede neural MLP responda corretamente para os dados de treinamento, mas também obtenha bons resultados para outros dados similares não utilizados para o treinamento; ou seja, o objetivo é treinar a rede neural MLP para obter um bom poder de generalização. Para esse objetivo, o algoritmo *backpropagation* foi utilizado juntamente com conjuntos de treinamento e validação para finalizar a etapa de treinamento [9].

C. Máquina de Vetor de Suporte

As SVMs (do inglês *Support Vector Machine*) [10] são um método de aprendizado estatístico, no qual o processo de

treinamento consiste em encontrar um hiperplano ótimo que maximize a margem entre as duas classes.

Dado um conjunto de dados com n amostras x_i ($i = 1, \dots, n$), classificadas em duas classes. Cada classe é associada aos seguintes rótulos: $y_i = +1$ para a classe positiva (*chuva*) e $y_i = -1$ para a classe negativa (*não-chuva*). Para dados lineares, é possível determinar o hiperplano

$$f(x) = xw + b = 0, \quad (5)$$

em que w é um vetor M -dimensional e b é um escalar. Esse hiperplano deve satisfazer as seguintes restrições

$$\begin{aligned} x_i w + b &\geq 1, \text{ se } y_i = +1, \\ x_i w + b &\leq -1, \text{ se } y_i = -1. \end{aligned} \quad (6)$$

Além disso, como uma SVM busca um hiperplano de separação ótimo, a margem entre os vetores de suporte e o hiperplano ótimo deve ser maximizada, conforme exibido na Fig. 1. A margem é calculada por

$$2 \cdot d = \frac{2}{\|w\|}, \quad (7)$$

então $\|w\|$ deve ser maximizado.




Fig. 1. Vetores de suporte e hiperplano de separação.

Também há a introdução de uma variável positiva ξ_i , cujo objetivo é estabelecer uma tolerância para erros, tratando assim possíveis *outliers* na base de dados. O hiperplano ótimo que separa as classes pode ser obtido resolvendo o seguinte problema de otimização:

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^M \xi_i, \quad (8)$$

sujeito a

$$y_i(x_i \cdot w + b) - 1 + \xi_i \geq 0. \quad (9)$$

As restrições objetivam que as instâncias $y_i = +1$ fiquem posicionadas de um lado do hiperplano e as instâncias $y_i = -1$ fiquem posicionadas no lado oposto. C é o parâmetro custo, cujo valor positivo é especificado pelo usuário.

O problema de otimização das SVMs é solucionado por meio dos Multiplicadores Lagrangianos, transformando o problema em uma otimização quadrática.

SVMs também podem ser utilizadas para classificar problemas não linearmente separáveis. Por meio de uma função de mapeamento, chamada de função *Kernel*, os dados originais podem ser remapeados em outro espaço com maior quantidade de dimensões, onde a separação linear é possível. Existem várias funções *Kernel* utilizadas nas SVMs. A seleção dessa função constitui etapa importante, já que ela define o espaço no qual os atributos serão representados e apresentados para o treinamento.

III. BASE DE DADOS E PADRÃO DE CHUVA

A temperatura e a umidade possuem um padrão bastante regular, conforme pode ser visto na Fig. 2. Durante o dia, a temperatura é alta e a umidade é baixa. Ao anoitecer, a umidade aumenta e a temperatura diminui. Entretanto, um evento de chuva causa uma ruptura no padrão observado: ocorre uma diminuição abrupta na temperatura e um aumento abrupto na umidade, como pode ser visualizado na Fig. 2. É importante notar que quanto mais intensa for a chuva maior será a variação no comportamento regular da temperatura e umidade.




Fig. 2. Influência de um evento de chuva no comportamento padrão da temperatura e umidade. Dados da estação de Garanhuns.

Para realizar o treinamento e avaliação das técnicas apresentadas anteriormente, foram utilizados dados do INMET (Instituto Nacional de Meteorologia) [11]. Os dados de interesse coletados foram: temperatura média, umidade média e quantidade de chuva em milímetros. O INMET disponibiliza esses dados a cada hora. Falhas na base de dados menores que cinco horas foram preenchidas por interpolação linear. Os dias com mais de cinco horas consecutivas de dados faltantes foram excluídos da base de dados. Neste trabalho foram utilizados dados de cinco estações do INMET distribuídas na região Nordeste, conforme visualizado na Fig. 3.

Os dados foram organizados em vetores representando um dia inteiro, conforme mostrado na Tabela I. Ou seja, cada instância contém a temperatura média para cada hora do dia (T0 a T23), a umidade média para cada hora do dia (U0 a U23) e um booleano indicando se houve ou não chuva no dia. Se o dia teve um total de precipitação maior do que 1 mm ele foi considerado como chuvoso.

Dentre as bases de dados utilizadas há notáveis diferenças entre algumas estações. A Fig. 4 mostra dados da estação de Fortaleza e Garanhuns, cujos climas são bastante diferentes – semiárido em Fortaleza e mesotérmico em Garanhuns.

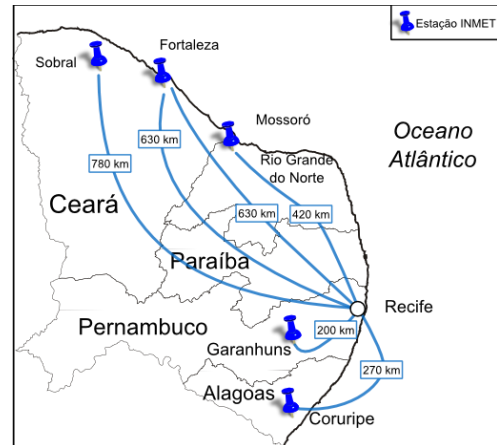


Fig. 3. Localização das estações do INMET utilizadas.

TABELA I. ATRIBUTOS E CLASSE DOS DADOS.

Atributos						Classe
T0	...	T23	U0	...	U23	[chuva / não-chuva]

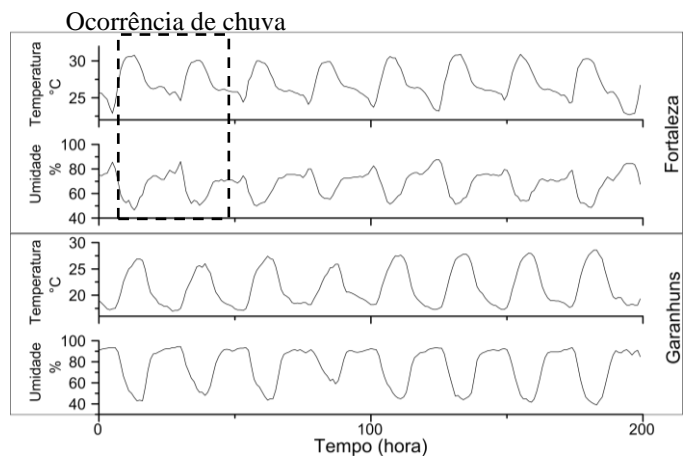


Fig. 4. Diferenças climáticas entre Fortaleza e Garanhuns.

Os valores médios e a amplitude da variação da temperatura e umidade são diferentes, embora o comportamento seja semelhante. Essa diferença climática gera maior dificuldade para o classificador, tendo em vista que embora o padrão seja o mesmo, os valores absolutos de temperatura e umidade divergem entre as estações meteorológicas utilizadas nos experimentos. Na Fig. 4, nos primeiros dados exibidos para estação de Fortaleza, há um exemplo de chuva.

IV. METODOLOGIA

Em um trabalho anterior [7] foram realizados experimentos para identificar a melhor configuração de parâmetros para as técnicas utilizadas. Para a Rede Neural MLP, das várias topologias experimentadas, nenhuma mostrou diferenças estatisticamente significativas, sendo escolhida a topologia

com menor número de neurônios – uma única camada escondida com dez neurônios e dois neurônios na camada de saída (cada um para indicar pertinência de uma das classes). Como estratégia de parada do treinamento, foi criado um conjunto de validação, composto de 30% da base de dados utilizada no treinamento.

Para o Classificador Bayesiano, foi assumida distribuição de probabilidade Gaussiana para os atributos. Já para a SVM, foi utilizada a função de *Kernel Radial Basis*, com $C = 10$, conforme resultados encontrados em [7].

Todas as bases de dados foram normalizadas individualmente objetivando reduzir ao máximo a influência das diferentes amplitudes da temperatura e umidade entre as bases utilizadas. Os experimentos consistiram em treinar os classificadores com dados de uma das cinco estações e realizar a avaliação com dados das demais estações. Esse procedimento foi repetido para quatro estações: Fortaleza (clima semiárido), Sobral (clima semiárido), Garanhuns (clima mesotérmico) e Coruripe (clima tropical chuvoso). O objetivo é investigar o poder de generalização do classificador.

O método de teste para todos os experimentos foi a validação-cruzada estratificada executada vinte vezes para cada experimento. A métrica utilizada para comparar os resultados é a taxa de TP (*True Positive*) de ambas as classes. Nessa aplicação, a taxa de TP da classe não-chuva é muito importante e deve ser maximizada, porque um falso positivo para chuva causará um decremento no nível de risco de um *flashover*, levando o sistema de previsão de manutenção a não emitir um alarme. Em outras palavras as equipes de manutenção reduziram seu estado de risco indevidamente o que poderia ocasionar falhas por falta de manutenção.

V. RESULTADOS

A Tabela II mostra os resultados do treinamento do Classificador Bayesiano realizado com os dados obtidos na estação do INMET de Coruripe e a avaliação com dados das demais estações. Os resultados para estação de Coruripe (utilizada para treinamento) foram obtidos realizando uma avaliação preliminar, apenas com o conjunto de treinamento e validação cruzada estratificada com 10-*folds*. Essa avaliação ocorrerá para todos os classificadores.

O resultado mais crítico encontrado para o experimento foi para a estação de Sobral, onde 38% dos exemplos da classe “não-chuva” foram classificados erroneamente, o que é inviável para a aplicação. No caso específico de Sobral, a amplitude da variação da temperatura durante o dia é maior do que na estação de Coruripe – já que a temperatura máxima de Sobral é na média 5°C maior do que em Coruripe. A queda mais acentuada da temperatura ao anoitecer em Sobral pode ser considerada incorretamente um evento de chuva pelo classificador.

Para a estação de Garanhuns, a umidade permanece alta (acima de 90%) por um período maior de tempo, em comparação com a base de dados de treinamento Coruripe. O classificador pode identificar erroneamente esse comportamento como um evento de chuva. Esse comportamento pode ser o motivo pelo qual o classificador tenha uma taxa de falso negativo de 30% para a classe “não-

chuva” em Garanhuns. Já Fortaleza e Mossoró possuem resultados bastante semelhantes, assim como também é semelhante o comportamento da temperatura e umidade nessas bases de dados. Nessas duas bases a umidade possui picos de umidade bem agudos (com picos entre 80 e 90%), diferentemente da base de dados Coruripe que passa mais tempo com umidade acima de 80%. A umidade alta está diretamente associada ao evento de chuva, portanto, esse comportamento da umidade pode ser associado a taxa de TP para classe “chuva” nas estações de Fortaleza e Mossoró – entretanto, a taxa de acerto para classe “não-chuva” nessas duas estações é de 95% o que é desejável para a aplicação.

TABELA II. CLASSIFICADOR BAYESIANO - RESULTADOS PARA CONJUNTO DE TREINAMENTO CORURIFE.

Base de Dados	Taxa TP Classe “chuva”	Taxa TP Classe “não-chuva”
<i>Coruripe</i>	0,79	0,81
<i>Fortaleza</i>	0,47	0,95
<i>Garanhuns</i>	0,92	0,70
<i>Mossoró</i>	0,59	0,95
<i>Sobral</i>	0,93	0,62

A Tabela III mostra os resultados do treinamento da Rede Neural MLP realizado com os dados obtidos na estação do INMET de Coruripe e a avaliação com dados das demais estações.

TABELA III. REDE NEURAL MLP - RESULTADOS PARA CONJUNTO DE TREINAMENTO CORURIFE.

Base de Dados	Taxa TP Classe “chuva”	Taxa TP Classe “não-chuva”
<i>Coruripe</i>	0,83 (0,06)	0,88 (0,03)
<i>Fortaleza</i>	0,25 (0,06)	0,99 (0,01)
<i>Garanhuns</i>	0,94 (0,03)	0,70 (0,06)
<i>Mossoró</i>	0,59 (0,12)	0,94 (0,05)
<i>Sobral</i>	0,67 (0,08)	0,87 (0,04)

Para as estações de Mossoró e Garanhuns, os resultados obtidos são semelhantes aos encontrados para o Classificador Bayesiano. Já para os dados de Fortaleza, a taxa de acerto para classe chuva foi apenas de 25%. Diferenças na amplitude da variação da temperatura durante o dia, intensidade e duração dos picos de umidade podem ter sido a causa determinante para esse resultado; entretanto, essa hipótese ainda precisa de verificação.

A Tabela IV mostra os resultados do treinamento da SVM treinada com dados de Coruripe. O comportamento dos resultados é bastante semelhante ao da Rede Neural MLP, então, aplica-se a mesma justificativa. Entretanto, comparando apenas o resultado para a estação de Coruripe, e tendo como critério a necessidade da aplicação, a SVM apresentou melhor resultado do que as demais técnicas para a base de dados de Coruripe. A Fig. 5 apresenta as informações das Tabelas II, III e IV de forma gráfica, permitindo uma análise visual.

A Fig. 6 mostra os resultados obtidos para o Classificador Bayesiano, a Rede Neural MLP e a SVM, respectivamente,

utilizando como base de treinamento dados da estação de Garanhuns.

TABELA IV. SVM - RESULTADOS PARA CONJUNTO DE TREINAMENTO CORURIFE.

Base de Dados	Taxa TP Classe "chuva"	Taxa TP Classe "não-chuva"
Coruripe	0,76	0,91
Fortaleza	0,37	0,99
Garanhuns	0,98	0,67
Mossoró	0,66	0,92
Sobral	0,58	0,86




Fig. 5. Resultados para Treinamento em Coruripe.

Conforme já explicado, Garanhuns naturalmente possui média de umidade alta em comparação as demais bases, portanto, um evento de chuva não causa aumento de umidade tão notável quanto nas outras bases. Portanto, utilizando essa base como treinamento, a detecção de chuva nas demais bases fica bastante prejudicada, conforme pode ser visualizado nos resultados para as três técnicas. Uma exceção encontrada foi a base de Sobral para o Classificador Bayesiano, o qual apresentou taxas de TP acima de 80% para ambas as classes. Foi identificado que alguns eventos de chuva na estação Sobral foram bastante intensos fazendo com que a umidade permanecesse alta durante um período de tempo semelhante ao que acontece em Garanhuns. Esse pode ter sido o motivo pelo qual esse classificador obteve bom resultado.

A Fig. 7 mostra os resultados obtidos utilizando como base de treinamento dados da estação de Fortaleza. É importante ressaltar que para essa base de dados, existem 75 exemplos da classe "chuva" e 305 exemplos da classe "não-chuva".

Mesmo com a maior parte da base de treinamento sendo constituída de dados pertencentes à classe "não-chuva", a Rede Neural MLP e a SVM foram capazes de identificar corretamente mais de 50% dos exemplos de chuva para as

demais classes, com exceção da base de dados Mossoró. Nessa base existem poucos exemplos da classe "chuva" e a quebra do padrão não é tão expressiva quanto nas demais bases, devido a intensidade da maioria das chuvas.




Fig. 6. Resultados para Treinamento em Garanhuns.

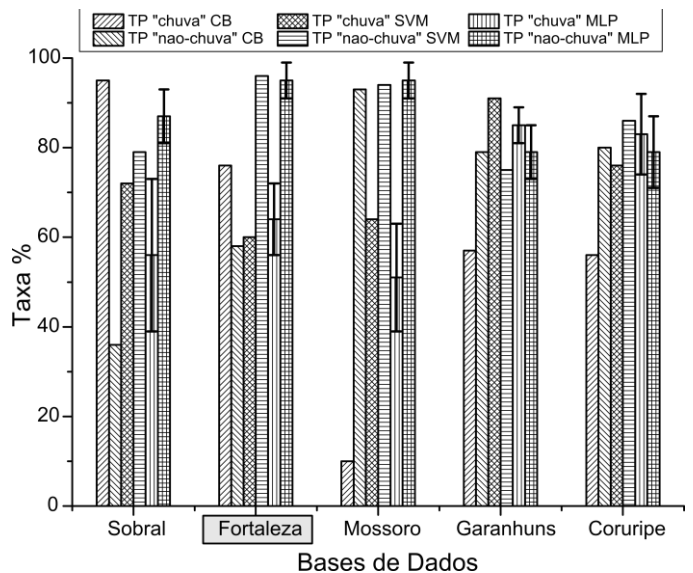


Fig. 7. Resultados para Treinamento em Fortaleza.

As Fig. 8 e 9 mostram os resultados para os treinamentos realizados nas bases de Mossoró e Sobral, respectivamente. Essas duas bases não apresentaram bons resultados quando os classificadores foram aplicados nas demais bases. Entretanto, verificou-se que essas duas bases de dados possuem poucos exemplos da classe chuva; a base de Mossoró possui 574 exemplos de "não chuva" e apenas 70 exemplos de "chuva", já a base de Sobral possui 317 exemplos de "não chuva" e 57 exemplos de "chuva". Portanto, além da diferença climática, para essas duas bases a pouca representatividade da classe "chuva" pode exercer um fator determinante nos resultados obtidos.




Fig. 8. Resultados para Treinamento em Mossoró.

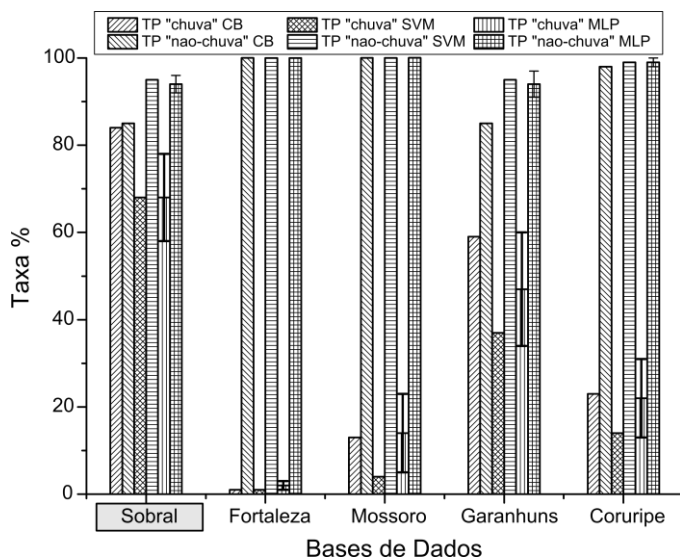


Fig. 9. Resultados para Treinamento em Sobral.

VI. CONCLUSÕES E TRABALHOS FUTUROS

Este trabalho apresentou uma investigação da interferência climática no reconhecimento do padrão de chuva em dados de temperatura e umidade. A aplicação alvo deste trabalho é o sistema de monitoração de descargas parciais, tendo como principal objetivo aumentar a confiabilidade do sistema de previsão de necessidade de manutenção nas cadeias de isoladores. Os resultados apontam que é possível utilizar classificadores bem estabelecidos para introduzir essa característica no sistema.

A principal conclusão deste trabalho é que é possível reconhecer o padrão de chuva nos dados de temperatura e umidade, entretanto, esse padrão sofre modificações de acordo com o clima da região. Os resultados indicam que os três classificadores utilizados (Classificador Bayesiano, Rede Neural MLP e Máquina de Vetor de Suporte) são sensíveis às

diferenças climáticas que modificam o comportamento natural da temperatura e umidade. Entretanto, para o treinamento com a base de Fortaleza, a Rede Neural MLP e a SVM apresentaram bons resultados para a avaliação nas demais bases. Portanto, a depender da necessidade de precisão do classificador, pode ser satisfatório o poder de generalização observado na Rede Neural MLP e na SVM.

Para a aplicação alvo deste trabalho, a melhor alternativa, tendo em vista a confiabilidade do sistema é escolher uma base de dados meteorológicos de localidade próxima à região de aplicação do classificador, com a finalidade de eliminar o risco de erro por variação climática.

Trabalhos futuros objetivam através de uma análise detalhada acerca dos casos de acerto/erro de cada classificador, propor um sistema de detecção de chuva que utilize dois ou mais classificadores. O objetivo desse sistema é aumentar o grau de confiabilidade do sistema de detecção, adicionando uma condição de dúvida quando as saídas dos dois classificadores forem divergentes. Em casos de divergência, pode-se realizar uma análise humana.

REFERENCES

- [1] B. F. Hampton, "Flashover mechanism of polluted insulation," *Proceedings of the Institution of Electrical Engineers*, vol. 111, no. 5, p. 985, 1964.
- [2] M. Sforzini, "Testing of polluted insulators—the present situation and problems of the future," *Journal of the Franklin Institute*, vol. 294, no. 6, pp. 437–468, Dec. 1972.
- [3] E. Fontana, S. C. Oliveira, F. J. M. M. Cavalcanti, R. B. Lima, J. F. Martins-Filho, and E. Meneses-Pacheco, "Novel Sensor System for Leakage Current Detection on Insulator Strings of Overhead Transmission Lines," *IEEE Transactions on Power Delivery*, vol. 21, no. 4, pp. 2064–2070, Oct. 2006.
- [4] R. A. de Lima, E. Fontana, J. F. Martins-Filho, T. L. Prata, G. O. Cavalcanti, R. B. Lima, S. C. Oliveira, and F. J. M. M. Cavalcanti, "Satellite telemetry system for pollution detection on insulator strings of high-voltage transmission lines," in *2009 SBMO/IEEE MTT-S International Microwave and Optoelectronics Conference (IMOC)*, 2009, pp. 574–577.
- [5] H. O. de Lima, S. C. Oliveira, and E. Fontana, "Flashover risk prediction on polluted insulators strings of high voltage transmission lines," in *2011 11th International Conference on Intelligent Systems Design and Applications*, 2011, pp. 397–401.
- [6] H. O. de Lima, S. C. Oliveira, and E. Fontana, "Fuzzy inference system for risk classification on polluted insulator strings of high voltage transmission lines," *2011 SBMO/IEEE MTT-S International Microwave and Optoelectronics Conference (IMOC 2011)*, pp. 117–120, Oct. 2011.
- [7] L. H. S. Silva, S. C. Oliveira, and E. Fontana, "Evaluation of Machine Learning Methods in a Rain Detection System for Partial Discharge Data Analysis," *INTELLI 2013: The Second International Conference on Intelligent Systems and Applications*, pp. 176–183, 2013.
- [8] R. Duda, P. Hart, and D. Stork, *Pattern Classification*. Wiley-Interscience; 2 edition (October 2000), 2000, p. 654.
- [9] S. Haykin, *Neural Networks: A Comprehensive Foundation*. PTR Upper Saddle River, NJ, USA,: Prentice Hall, 1994.
- [10] A. Christmann and I. Steinwart, *Support Vector Machines*, Springer. New York, NY: Springer New York, 2008.
- [11] D. Ministério da Agricultura Pecuária e Abastecimento, "Instituto Nacional de Meteorologia (INMET)." [Online]. Available: <http://www.inmet.gov.br/portal/>. [Accessed: 04-Jul-2012].