

06/19

Um Método para Previsão de Desligamentos em Subestações de Energia Elétrica a partir de Logs em Sistemas de Supervisão e Aquisição de Dados

**Anderson Tenório
Sérgio
IN FORMA
SOFTWARE**

**Milton Vasconcelos da
Gama Neto
IN FORMA
SOFTWARE**

**José Henrique
Marques Davino
IN FORMA
SOFTWARE**

**Leningrado
Florêncio(*)
IN FORMA
SOFTWARE**

SUMÁRIO

Uma subestação é uma instalação elétrica de alta potência que contém equipamentos para transmissão de energia elétrica. Desligamentos não programados em subestações geram prejuízos à sociedade e perdas financeiras para as empresas que operam o sistema elétrico. Este trabalho apresenta um método para antecipação de desligamentos em subestações, a partir da combinação de *logs* gerados por sistema de supervisão e aquisição de dados com sistemas de gestão. Utilizando diversas técnicas de mineração de dados, o método inclui limpeza de dados, pré-processamento e a utilização de algoritmos de aprendizagem de máquina para a previsão de desligamentos. O arcabouço desenvolvido foi testado em bases de dados reais. Os resultados alcançados mostraram-se promissores, com potencial de utilização em sistemas de apoio à decisão operacional.

PALAVRAS-CHAVE

Transmissão de energia, Subestações, SCADA, Inteligência Artificial, Aprendizagem de Máquinas

1.0 - INTRODUÇÃO

Na transmissão de energia elétrica os desligamentos não programados e os desligamentos emergenciais, decorrentes de falhas em uma subestação, podem representar grandes perdas financeiras para as empresas concessionárias (1). Quando uma subestação não é capaz de realizar sua função de seccionar, transformar ou direcionar fluxos de energia elétrica o sistema elétrico local ou integrado é perturbado e os consumidores são prejudicados. Para incentivar as transmissoras a evitar as falhas, a regulação setorial impõe penalidades, a principal delas é o desconto de parcela variável da remuneração anual permitida, conhecido como PV.

Para monitorar o funcionamento de uma subestação como um todo e também de seus componentes, são utilizados os chamados sistemas SCADA (do inglês *Supervisory Control and Data Acquisition*) (2). Como produto secundário das suas principais funcionalidades, um sistema SCADA produz e armazena históricos dos sinais capturados, às vezes chamados de *logs*, que podem ser utilizados para supervisionar os diversos componentes de uma subestação e identificar comportamentos anômalos e/ou falhas. Dentre os equipamentos de uma subestação que podem ser monitorados por sistemas SCADA podem ser encontrados, por exemplo, transformadores de alta tensão e relés de proteção que acionam diversos tipos de disjuntores. Tais equipamentos podem gerar alarme em determinadas funções pré-programadas, tais como: alarmes de baixa tensão, normalização de função, subtensão e sobretensão, etc.

Em empreendimentos de geração, transmissão e distribuição de energia elétrica (GTD), a literatura aponta que técnicas de mineração de dados podem ser utilizadas para otimizar recursos, aumentar a lucratividade das empresas concessionárias ou melhorar a qualidade dos serviços prestados. Com a disponibilidade de grandes quantidades de dados e de melhores recursos computacionais, a extração de conhecimento a partir dessas informações vem se tornando uma importante ferramenta para construção de sistemas de apoio à decisão. Por exemplo, Tüfekci utiliza métodos de aprendizagem de máquinas para predição de demanda de energia em usinas elétricas (3). Em outra categoria de aplicação, Siraj *et al.* (4) utilizam árvores de decisão para detecção de fraudes em consumo de energia elétrica, facilitando a implementação das chamadas *smart grids* (5).

Dentre as possíveis aplicações de mineração de dados na indústria de energia elétrica, uma categoria que se destaca é a predição de falhas. De maneira geral, a falha de um sistema consiste em um desvio no seu funcionamento, podendo ser ou não causada por uma série de erros e/ou defeitos. De acordo com (6), a predição online de falhas diferencia-se dos métodos de confiabilidade tradicionais por ser baseada no monitoramento em tempo real do sistema, comumente utilizando dados de experiências passadas em oposição ao estudo de tendências baseados em modelos estatísticos teóricos.

É nesse contexto que se insere o processo conhecido como KDD (Descoberta de Conhecimento em Base de Dados, do inglês *Knowledge Discovery in Databases*) (7). O KDD é um processo não trivial de extração de informações implícitas, previamente desconhecidas e potencialmente úteis, a partir dos dados armazenados em um banco de dados (7). De maneira geral, o processo do KDD envolve (i) selecionar os dados a partir do entendimento do domínio; (ii) pré-processar os dados (identificação de ruídos, tratamento de dados faltantes etc.); (iii) transformar os dados para o formato utilizado na próxima etapa; (iv) minerar os dados, que implica em descobrir padrões a partir de algum modelo preditivo; e (v) interpretar/avaliar os dados, que consiste em implantar a aplicação na linguagem do usuário final (7). Apesar de muitas vezes ser utilizado como sinônimo de KDD, o termo mineração de dados consiste na aplicação de algum algoritmo para descoberta de padrões. Tais algoritmos originam-se normalmente da estatística e do subcampo da inteligência artificial conhecido como aprendizagem de máquinas (8).

Nesse sentido, este trabalho propõe um método para previsão de desligamentos de subestações a partir dos *logs* gerados por sistemas SCADA combinados com informações do sistema de gestão de operação e manutenção. De forma resumida, os dados são extraídos, pré-processados (no intuito de eliminar inconsistências e erros manuais), transformados para o formato ideal que represente o problema e submetidos a algoritmos de aprendizagem de máquinas capazes de, a partir de um grau de incerteza, predizer a possibilidade de um desligamento. O desligamento é identificado por intermédio do sistema de gestão de ativos da In Forma Software (9), o EquipMaint (EQM) (10). Especificamente, são utilizados modelos de classificação para antecipar a falha considerando o estado dos equipamentos que compõem a subestação. O método foi testado em bases de dados reais e os resultados mostraram-se promissores, podendo ser utilizados na implementação de sistemas de apoio à decisão.

O artigo está dividido da seguinte forma. A próxima seção faz um apanhado na literatura a respeito dos trabalhos de antecipação de falhas, tanto em outros tipos de sistemas como também na área de energia elétrica. A seção 3 apresenta detalhes do método desenvolvido, bem como as métricas de avaliação. Já a seção 4 mostra e discute os resultados alcançados. Finalmente, a seção 5 descreve as considerações finais e lista possíveis trabalhos futuros..

2.0 - ANTECIPAÇÃO DE FALHAS EM SISTEMAS ELÉTRICOS

De maneira geral, a predição de falhas consiste em antecipar a ocorrência de falhas, em tempo real, de acordo com o estado atual do sistema. Baseado em trabalhos anteriores, (6) define falha como um evento que ocorre quando o serviço entregue desvia de sua correteude. As falhas são geralmente identificadas por erros (detectados ou não), sendo estes definidos como estados incorretos do sistema. Muitas vezes os erros apresentam sinais até atingir o momento crítico da falha. O monitoramento de sintomas é, portanto, uma das possíveis abordagens para antecipação de falhas.

Entretanto, devido a grande quantidade de informações para serem analisadas durante o monitoramento de uma subestação, existe um grau elevado na complexidade desta tarefa. Com isto, os métodos de predição avaliam os valores atuais das variáveis do sistema, processando um grande volume de dados e entregando uma informação de valor e em menor escala para o operador tomar decisões. Assim, a antecipação de falhas é alcançada através de algoritmos de classificação que identifica se um determinado estado é propenso a uma falha ou não, através de dados históricos, onde os padrões de uma falha devem acontecer com certa frequência.

Em sistemas eletrônicos (*software* ou *hardware*), vários trabalhos utilizam a abordagem de construir classificadores para predição de falhas. É possível encontrar publicações utilizando classificadores bayesianos (11), redes neurais artificiais (12) e máquinas de vetor de suporte (13).

No campo de sistemas elétricos, diversos trabalhos na área de antecipação de falhas por meio de técnicas de mineração de dados podem ser encontrados. Por exemplo, Mohamed *et al.* utilizaram um comitê de quinze redes neurais artificiais para construção de um modelo de diagnósticos de falhas em linhas de transmissão de energia (14). Os autores alcançaram uma acurácia de 92% a 100% nas bases de dados de testes através de execuções paralelas com cada uma das arquiteturas de redes neurais. Também usando redes neurais, especificamente um modelo ELM (do inglês *Extreme Learning Machines*), Ramalho *et al.* (15) construíram um modelo de classificação para detecção de falhas em motores elétricos. Os autores utilizaram como entrada do modelo padrões de vibração dos motores, extraídos da decomposição do sinal de vibração.

Ullah *et al.*, também utilizando redes neurais artificiais com o modelo MLP (do inglês *Multilayer Perceptron*), estudaram a manutenção preventiva dos equipamentos de uma subestação (16). A entrada do modelo foi dada por termografia em raios infravermelhos. Nessa mesma direção, Tianshan e Bo

também investigaram o comportamento dos equipamentos de uma subestação através de técnicas de computação inteligente (17). Neste caso, o objetivo era prever a taxa de falha da subestação.

Especificamente em relação à antecipação de falhas a partir de dados de *logs*, a literatura apresenta vários trabalhos relacionados a sistemas computacionais e eletrônicos, como por exemplo, em (18). Dois trabalhos destacam-se por utilizar a ideia de janelas de tempo de *logs* para previsão de comportamentos defeituosos e propensos a falha (19) (20). Nesta direção, os autores buscam categorizar os *logs* e formar padrões de treinamento com rótulos dados pela presença ou ausência de uma futura falha. Assim, algoritmos comuns de classificação podem ser utilizados para antecipar os estados indesejados.

Acerca da utilização de *logs* de sistemas SCADA para previsão de falhas, dois trabalhos podem ser citados (2) (21). Em ambos os artigos, os dados do SCADA são utilizados para antecipação de falhas em turbinas eólicas, mostrando a viabilidade da ideia para aplicação em sistemas da indústria de energia, ressaltando mais uma vez que algoritmos de classificação são utilizados para alcançar o objetivo.

3.0 - MÉTODO PROPOSTO

O principal objetivo do método proposto é realizar a previsão de falhas em sistemas elétricos. A Figura 1, apresenta com mais detalhes as etapas da metodologia utilizada neste trabalho, seguindo o processo do KDD.




Figura 1 - Fluxograma

Para tanto, consideram-se determinados intervalos de tempo definidos previamente, que antecedem e sucedem o instante da previsão. O período que antecede é chamado janela de monitoramento e é utilizado para determinar o estado, de acordo com os eventos ocorridos, e representam os atributos da base de dados, vide Figura 2. O período que sucede é a janela de previsão, que representa o tempo que uma falha demonstra sinais e o estado deve indicar a ocorrência da futura falha, este valor é o alvo. Os valores de ambas janelas são calculados com base nas informações existentes no sistema SCADA. Portanto, a partir de cada *log* existente, em ordem cronológica, criam-se os padrões da base de dados (atributos e alvos), que serão utilizados tanto para treinamento quanto para teste.




Figura 2 - Abordagem de janela de monitoramento.

Os atributos da base de dados são formados pelos valores dos sensores e o alvo terá o rótulo "Falha" se na janela de previsão houver uma falha ou o rótulo "Normal" em caso contrário. A Figura 2 apresenta uma ilustração didática de como funciona esse processo de conversão. No lado esquerdo, pode-se observar os *logs* com suas respectivas datas. Já no lado direito, a base de dados que foi formada. Nesse exemplo, existem três equipamentos: E1, E2 e E3. Cada um deles pode assumir, por exemplo, o estado "A" ou "N", de "Alarme" e "Normal", respectivamente. Os valores "?" presentes na base de dados, correspondem aos

atributos faltantes, porque até então não se sabe o valor. Para o exemplo da Figura 3, utilizou-se uma janela de previsão de 3 dias.

Data	Log
01/01	E1#A
03/01	E2#A
05/01	E3#A
06/01	DESLIGAMENTO
06/01	E3#N
06/01	E2#N
06/01	E1#N

(a) Logs registrados

Atributos			Alvo
E1	E2	E3	
A	?	?	Normal
A	A	?	DESLIGAMENTO
A	A	A	DESLIGAMENTO
A	A	N	Normal
A	N	N	Normal
N	N	N	Normal

(b) Base de dados gerada

Figura 3 - Ilustração didática do processo de conversão de *logs* em uma base de dados supervisionada.

A Figura 3 exemplifica a modelagem do problema, na qual o *log* no arquivo inicial segue o formato da seguinte *tag*: Equipamento-Função#Valor. Cada linha neste arquivo representa uma instância na base de dados final e as colunas representam todos os possíveis valores de Equipamento-Função. A primeira instância é formada por valores desconhecidos (“?”) e quando um novo *log* é criado, uma cópia da última instância é criada e a coluna correspondente a Equipamento-Função é atualizada com o Valor da *tag*. A coluna “Alvo” indica se o estado, ou instância, deve apontar a ocorrência futura de uma falha em *x* dias. Se ocorrer uma falha em *x* dias, então o valor do alvo será “DESLIGAMENTO”, caso contrário será “NORMAL”.

3.1 Métrica de Avaliação

Para avaliar os modelos preditivos, é necessário estabelecer uma métrica para que a comparação seja justa e realizada de forma automatizada. Isto porque é inviável analisar sempre os gráficos ou saídas do modelo para entender os acertos e erros. Neste trabalho, foi elaborada uma forma diferente para avaliar o desempenho da solução.

Neste sentido, a predição será realizada para cada instância, a qual representa um novo evento, conforme descrito na seção anterior quanto a criação da base de dados final. Para analisar os valores preditos, não foi computada apenas uma verificação direta com o alvo daquela instância (maneira tradicional) mas sim, utilizado um período de espera após a predição de uma falha e neste intervalo é avaliada a assertividade.

Inicialmente é feito um agrupamento das falhas em intervalos próximos, a partir de um parâmetro que estabelece o tempo deles e considera-se que estas falhas são as mesmas. Outro parâmetro importante é o “eco” das falhas detectadas. O objetivo é criar um período de espera para que as saídas do modelo voltem a ser analisadas, partindo do pressuposto que após a falha ocorrer, os estados da subestação podem indicar ainda a ocorrência da falha, o que introduziria um erro na avaliação que não seria introduzido em produção por não ser um erro real.

Para cada ocorrência de falha é verificado se houve alguma detecção dentro de uma janela de erro previamente estabelecido (quantidade de horas), sendo este o principal parâmetro da avaliação. A detecção considerada como acerto é a primeira dentro deste intervalo, que representa o primeiro alerta no sistema de monitoramento. Em geral, o sistema continuará alertando, o que será útil no momento em que for implantado, apesar de que para a avaliação, não importa a quantidade de predições positivas nem os períodos que o modelo não indica a falha dentro da janela de erro. Entretanto, quando não há nenhum sinal de falha dentro desta janela, significa que o modelo não conseguiu prever a falha e a performance do modelo é penalizada. Também existe o cenário em que o modelo indica a chance de ocorrer uma falha, porém, ela não acontece. Este último também é considerado como um erro, um alarme falso.

Apesar de ser um problema modelado em uma classificação binária, os valores apresentados ao operador são os scores do modelo, que representam a propensão da instância pertencer a classe alvo (falha). A indicação de falha, por padrão, são os scores acima de 0.5, porém esse valor pode ser

parametrizado para deixar o sistema mais rigoroso ou mais flexível. A alteração vai impactar nos resultados.

A Figura 3 representa os parâmetros e a lógica da métrica de avaliação, com exceção dos alarmes dentro da janela de erro, nestes aparecem duas predições de falhas, no entanto apenas a primeira ocorrência é válida para computar o acerto.




Figura 3 - Representação da métrica de avaliação.

A tabela 1 apresenta um resumo dos parâmetros mencionados da métrica de avaliação.

Tabela 1 - Descrição dos parâmetros de avaliação.

Parâmetro	Descrição
Janela de erro (dias)	Período máximo permitido entre a predição e a falha. Se a predição for feita dentro da janela, é considerada como acerto.
Diferença mínima entre falhas (dias)	Quantidade de dias mínima entre as falhas. Se for menor que o valor estabelecido, a falha é considerada como uma apenas, mantendo-se a primeira.
Eco das falhas (dias)	Período de silêncio posterior à falha detectada. Não considera predições no intervalo de tempo determinado pelo parâmetro.
score threshold (0-1)	Limite inferior para considerar a predição como falha (classe alvo).

Por fim, são computados taxa de acerto e precisão com base no total de falhas e predições considerando a métrica.

3.2 Base de Dados

O estudo foi realizado com dados de transmissão de energia elétrica e com dados de uma subestação coletora de geração eólica. Foram extraídos dados, referentes ao intervalo de aproximadamente 2 anos, armazenados no sistema SCADA e a quantidade de registros variaram entre 20 mil e 320 mil.

Outra fonte muito importante para construção da solução foi o *software* EquipMaint (EQM), que permitiu selecionar os desligamentos nos sistemas analisados. Estes foram utilizados como alvo, ou seja, a falha que a solução deseja antecipar. As falhas costumam ser reportadas para o ONS (Operador Nacional do Sistema Elétrico) e também estão presentes nos *logs* do sistema supervisor. Entretanto, em ambos é difícil coletar tal informação, devido a grande quantidade e a estrutura dos dados (relatórios para ONS) e por existir diferentes tipos de falhas. Então, o EQM foi a base de dados escolhida para extração dos dados de falhas. Vale ressaltar que este tipo de informação não será necessária no momento em que o

modelo for implantado, pois a intenção é antecipar a falha, mesmo não sabendo se ela realmente ocorrerá. As informações de falhas serão necessárias apenas durante o treinamento do modelo de classificação, podendo servir posteriormente para validar os resultados reais em um cenário de produção, porém com alguns cuidados.

As subestações apresentaram quantidades diferentes de desligamentos. Esta característica é relevante, uma vez que é necessário um número de falhas considerável para que o modelo consiga capturar o comportamento padrão a partir dos dados. Por ter diferentes configurações, equipamentos, quantidade de falhas, comportamento, e outros fatores, pressupõe-se resultados diferentes para cada base analisada.

4.0 - EXPERIMENTOS

Foram realizados diversos experimentos com as bases da seção 3.2 e variando os parâmetros da avaliação da Tabela 1, buscando encontrar bons resultados com critérios que atendam especificações de negócios.

Para cada base, foi executado um conjunto de classificadores com o objetivo de encontrar o modelo que tenha maior assertividade, ou seja, que consiga mapear melhor as características para o alvo desejado. Os modelos de classificação utilizados foram k-NN (*k-Nearest Neighbors*), Árvore de Decisão, MLP (*Multilayer Perceptron*), *Random Forest* e modelos de ELM (*Extreme Learning Machine*). Para cada classificador foi feito um ajuste nos parâmetros específicos de cada modelo.

Os classificadores gerados a partir da base supervisionada são avaliados utilizando o método de validação *k-fold cross validation*, mas sem aleatorizar as instâncias. Isso foi feito com o intuito de preservar a ordem temporal nos *folds*, ou seja, simular o comportamento dos classificadores em um cenário o mais realista possível. Apesar de dividir em *k folds*, eventos próximos devem ficar no mesmo *fold*, evitando *overfitting*. A avaliação destes é feita por meio de uma métrica descrita na seção seguinte.

4.1 Resultados e Discussão

Nesta seção, serão apresentados os resultados obtidos para os experimentos definidos. A subseção 4.1.1 exibe os resultados alcançados para subestações do setor de transmissão de energia elétrica. Em seguida, os resultados encontrados para geração de energia elétrica são apresentados na subseção 4.1.2. Por fim, uma discussão sobre os resultados levantados será realizada. Os resultados registrados nas tabelas seguintes omitem os classificadores e parâmetros que alcançaram os respectivos resultados. Foi selecionado o melhor classificador para cada base de dados considerando a métrica de avaliação.

4.1.1 Resultados em transmissão elétrica

Nesta subseção são apresentados os resultados encontrados para 7 subestações do setor de transmissão de energia elétrica. A Tabela 2 apresenta os valores utilizados em cada parâmetro dos experimentos, e seus respectivos resultados são expostos na Tabela 3.

Tabela 2 - Parâmetros de avaliação para transmissão elétrica.

Parâmetro	Valor
Janela de erro (dias)	15
Diferença mínima entre falhas (dias)	1
Eco das falhas (dias)	1
<i>score threshold</i> (0-1)	0.5

Tabela 3 - Resultados para linha de transmissão.

Instalação	Desligamentos registrados	Desligamentos previstos	Taxa de acerto	Alarmes falsos	Precisão	Janela média de previsão (dias)
Subestação A	18	11	61.1%	1	94.7%	7.8 (1.6)
Subestação B	31	13	41.9%	2	86.6%	7.8 (1.6)
Subestação C	27	19	70.4%	4	82.6%	9.89 (6.8)
Subestação D	5	2	40.0%	0	100%	3.0 (1.0)
Subestação E	6	1	16.7%	0	100%	2.0 (0.0)
Subestação F	3	2	66.7%	0	100%	14.5 (12.5)
Subestação G	10	2	20.0%	0	100%	9.0 (2.1)

As principais bases no estudo realizado para transmissão elétrica, foram as subestações A, B e C, devido a quantidade de desligamentos registrados. É necessário uma quantidade razoável de exemplos de falha para que a solução seja robusta e o modelo consiga detectar os padrões que levam até as falhas. Tais subestações foram as que apresentaram um número maior destes exemplos.

Existem duas medidas importantes que devem ser consideradas, a taxa de acerto e a precisão. A primeira representa a proporção de falhas antecipadas, enquanto a segunda representa a assertividade do modelo quando ele indica que ocorrerá uma falha. A precisão pode indicar a confiança do modelo, pois quanto mais alto o valor, menor a quantidade de alarmes falsos. Os resultados da Tabela 3 mostram que apesar de não atingir uma taxa de acerto alta para algumas subestações, a precisão do modelo se mantém alta.

4.1.2 Resultados em geração eólica

Nesta subseção, os resultados alcançados para o setor de geração eólica são apresentados. A Tabela 4 exibe os valores definidos para cada parâmetro utilizado no experimento e, os respectivos resultados, são expostos na Tabela 5.

Tabela 4 - Parâmetros de avaliação para geração eólica.

Parâmetro	Valor
Janela de erro (dias)	10
Diferença mínima entre falhas (dias)	1
Eco das falhas (dias)	1
<i>score threshold</i> (0-1)	0.5

Tabela 5 - Resultados para geração.

Instalação	Desligamentos registrados	Desligamentos previstos	Taxa de acerto	Alarmes falsos	Precisão	Janela média de previsão (dias)
Subestação A	12	6	50.0%	1	85.71%	5.81 (5.74)
Subestação B	39	21	53.85%	6	77.78%	6.02 (3.51)
Subestação C	10	2	20%	0	100%	5.97 (0.49)

Os resultados apresentados confirmam que a solução de predição de falha pode ser aplicada para diferentes segmentos da energia elétrica. Os modelos obtiveram uma precisão alta e a quantidade de falhas antecipadas podem representar um impacto significativo na economia das concessionárias.

A Figura 4, apresenta um determinado período do tempo utilizado para identificar acertos e erros das predições de acordo com a métrica estabelecida para Subestação A. O período apresentado no gráfico contempla apenas 6 desligamentos dos 12 totais. Nesse período houve 3 acertos, 1 alarme falso e 3 desligamentos não previstos.




Figura 4 - Predições em um determinado período da Subestação A.

5.0 - CONCLUSÃO

Não foram encontradas particularidades na abordagem utilizada que impeçam a solução desenvolvida de ser escalada para diversos tipos de falhas em segmentos diferentes dos setores de geração, transmissão e distribuição (GTD) de energia elétrica. As falhas previstas a partir do sistema de suporte à decisão podem ser evitadas com o devido planejamento e operação, evitando a degradação da saúde dos equipamentos e custos para empresa prestadora do serviço. Chegando a 70.4% de cobertura das falhas e casos de 100% de precisão na predição do modelo, é possível antecipar uma quantidade alta de falhas e com um grau de confiança elevado. O trabalho alcançou resultados ainda melhores, aumentando o volume de dados e inserindo especialistas das subestações para auxiliar no entendimento dos dados.

6.0 - REFERÊNCIAS BIBLIOGRÁFICAS

(1) BRASÍLIA. Luciano Nascimento. Agência Brasil. Aneel multa ONS e operadora por apagão de março do ano passado: Incidente deixou sem energia 13 estados das regiões Norte e Nordeste. 2019.

Disponível em: <<http://agenciabrasil.ebc.com.br/economia/noticia/2019-02/aneel-multa-ons-e-operadora-por-apagao-de-marco-do-ano-passado>>. Acesso em: 14 jun. 2019.

(2) KIM, Kyusung et al. Use of SCADA data for failure detection in wind turbines. National Renewable Energy Lab.(NREL), Golden, CO (United States), 2011.

(3) TÜFEKCI, Pinar. Prediction of full load electrical power output of a base load operated combined cycle power plant using machine learning methods. International Journal of Electrical Power & Energy Systems, v. 60, p. 126-140, 2014.

(4) CODY, Christa; FORD, Vitaly; SIRAJ, Ambareen. Decision tree learning for fraud detection in consumer energy consumption. In: 2015 IEEE 14th International Conference on Machine Learning and Applications (ICMLA). IEEE, 2015. p. 1175-1179.

(5) FARHANGI, Hassan. The path of the smart grid. IEEE power and energy magazine, v. 8, n. 1, p. 18-28, 2010.

(6) SALFNER, Felix; LENK, Maren; MALEK, Mirosław. A survey of online failure prediction methods. ACM Computing Surveys (CSUR), v. 42, n. 3, p. 10, 2010.

(7) FAYYAD, Usama; PIATETSKY-SHAPIO, Gregory; SMYTH, Padhraic. From data mining to knowledge discovery in databases. AI magazine, v. 17, n. 3, p. 37-37, 1996.

(8) MITCHELL, Tom et al. Machine learning. Annual review of computer science, v. 4, n. 1, p. 417-433, 1990.

(9) INSTITUCIONAL (Recife). In Forma Software. 2019. Disponível em: <<https://www.informa.com.br/institucional/>>. Acesso em: 14 jun. 2019.

(10) EQUIPMAINT (Recife). In Forma Software - EquipMaint. 2019. Disponível em: <<https://www.informa.com.br/solucoes/EqM-M%C3%B3vel/>>. Acesso em: 14 jun. 2019.

(11) HAMERLY, Greg et al. Bayesian approaches to failure prediction for disk drives. In: ICML. 2001. p. 202-209.

(12) BERENJI, Hamid R.; AMETHA, Jayesh; VENGEROV, David. Inductive learning for fault diagnosis. In: The 12th IEEE International Conference on Fuzzy Systems, 2003. FUZZ'03. IEEE, 2003. p. 726-731.

(13) MURRAY, Joseph F.; HUGHES, Gordon F.; KREUTZ-DELGADO, Kenneth. Hard drive failure prediction using non-parametric statistical methods. In: Proceedings of ICANN/ICONIP. 2003.

(14) MOHAMED, E. A.; TALAAT, H. A.; KHAMIS, E. A. Fault diagnosis system for tapped power transmission lines. Electric Power Systems Research, v. 80, n. 5, p. 599-613, 2010.

(15) RAMALHO, Geraldo Luis Bezerra et al. Detecção de falhas em motores elétricos através da classificação de padrões de vibração utilizando uma rede neural ELM. Holos, v. 4, 2014.

(16) ULLAH, Irfan et al. Predictive maintenance of power substation equipment by infrared thermography using a machine-learning approach. Energies, v. 10, n. 12, p. 1987, 2017.

(17) TIANSHAN, Gao; BO, Gao. Failure rate prediction of substation equipment combined with grey linear regression combination model. In: 2016 IEEE International Conference on High Voltage Engineering and Application (ICHVE). IEEE, 2016. p. 1-5.

(18) LIANG, Yinglung et al. Bluegene/l failure analysis and prediction models. In: International Conference on Dependable Systems and Networks (DSN'06). IEEE, 2006. p. 425-434.

(19) SIPOS, Ruben et al. Log-based predictive maintenance. In: Proceedings of the 20th ACM SIGKDD international conference on knowledge discovery and data mining. ACM, 2014. p. 1867-1876.

(20) ZHONG, Jiang; GUO, Weili; WANG, Zhenhua. Study on network failure prediction based on alarm logs. In: 2016 3rd MEC International Conference on Big Data and Smart City (ICBDSC). IEEE, 2016. p. 1-7.

(21) LEAHY, Kevin et al. Diagnosing and predicting wind turbine faults from SCADA data using support vector machines. 2018.

7.0 - DADOS BIOGRÁFICOS

Anderson Tenório Sérgio

Doutor em Ciência da Computação pela Universidade Federal de Pernambuco (2017), com ênfase em Inteligência Computacional. Mestre em Ciência da Computação pela Universidade Federal de Pernambuco (2013). Bacharel em Engenharia da Computação pela Universidade de Pernambuco (2008). Docente em cursos diversos de tecnologia de nível superior, tendo ministrado disciplinas principalmente nas áreas de sistemas de apoio à decisão, engenharia de software e programação. Coordenador de Pós-Graduação Lato Sensu em Inteligência Artificial com Ênfase em Ciência dos Dados

Milton Vasconcelos da Gama Neto

Mestrando em Ciência da Computação pela Universidade Federal de Pernambuco (UFPE), possui graduação em Ciência da Computação pela UFPE (2018). Atualmente é cientista de dados na In Forma Software, criando soluções para Gestão de Ativos no setor de Energia Elétrica. Tem experiência na área de Ciência da Computação e também atuou em projeto de P&D&I pelo Lika/UFPE (Laboratório de Imunopatologia Keizo Asami). Suas áreas de interesse e atuação atualmente são Aprendizagem de Máquina, Ciência dos Dados e Visão Computacional.

José Henrique Marques Davino

Mestre em Ciência da Computação pelo Centro de Informática da UFPE (2017) com ênfase em Contexto Computacional. Pós-Graduado em Tecnologias para Desenvolvimento de Aplicações Móveis pelo Cesar.edu (2011) e Bacharel em Sistemas de Informação pela Faculdade Santa Maria (2009). Atua na In Forma Software como Líder Técnico da equipe de Aplicações Autônomas Inteligentes. Possui experiência com análise, desenvolvimento e implantação de sistemas. Nos últimos anos, tem explorado temas como: Aprendizagem de Máquina, Cloud Computing, Sistemas Distribuídos, Sistemas de Recomendação, Contexto Computacional, Métodos Heurísticos, Desenvolvimento Seguro de Software.

Leningrado Florêncio

Atualmente é diretor da In Forma Software S/A. Tem experiência na área de Matemática, com ênfase em Análise Numérica, Arquitetura e Desenvolvimento de Software. Conhecimentos nas áreas de Análise Laboratorial, Sistemas de Mineração e Sistemas Gestão de Ativos Físicos.