



Artigo

Integração com SCADA para gestão de indicadores de manutenção em parques eólicos

Lianderson Ribeiro ^[1], Fabrício Cavalcante ^[2] e Zoroastro Vilar ^[3]

^[1] UFERSA; lianderson_alves@yahoo.com.br

^[2] UFERSA; fabriciocavalcante@ufersa.edu.br

^[3] UFERSA; zoroastro@ufersa.edu.br

Recebido: 13/05/2021;

Aceito: 15/08/2021;

Publicado: 06/12/2021.

Resumo: Atualmente, a gestão da manutenção possui um papel estratégico dentro da indústria. A crescente demanda pela alta disponibilidade e maior confiabilidade dos ativos, abre espaço para aplicação de técnicas e metodologias de Engenharia de Manutenção, visando identificar os principais empecilhos para cumprimento destes objetivos, baseados em Confiabilidade, Manutenibilidade e Disponibilidade. Este artigo apresentará a aplicação do método de *Knowledge Discovery in Databases* – KDD, associado ao diagrama de Jack-Knife, para elencar os padrões de falhas numa usina eólica.

Palavras-chave: indicadores de performance; manutenção; processamento de dados; energia eólica.

Abstract: Nowadays, maintenance management has been assuming strategic place into industry. The growing demand by assets availability and better reliability, It's has given room to apply techniques and methodologies from maintenance engineering, looking for identify the main trammels for reaching the goals, based on reliability, manteinability and availability. This paper is gonna show the method Knowledge Discovery in Databases – KDD, together Jack-Knife diagram, to evaluate failure patterns in a wind farm.

Key-words: key performance indicators; maintenance; data processing; wind energy.

1. INTRODUÇÃO

Fronte ao cenário econômico e social global, as fontes de energia renovável têm conquistado cada vez mais espaço, seja para diversificação da matriz energética, substituição das usinas de combustível fóssil ou geração distribuída. Segundo o Balanço Energético Anual de 2019, publicado pela Empresa de Pesquisa Energética – EPE, a fonte eólica apresentou 8,6% no atendimento da demanda interna do Brasil.

Com a crescente expansão e amadurecimento do segmento eólico, acrescenta-se a demanda para atingir altas valores de disponibilidade e maximização das receitas de venda de energia pelos agentes de geração. Neste cenário, a manutenção, associada aos métodos e modelos computacionais, se utiliza de ferramentas para prover as análises, disponibilidade e confiabilidade.

Neste trabalho, a partir do histórico de dados operacionais de eventos do sistema *Supervisory Control And Data Acquisition* – SCADA de um parque eólico, propõe-se utilizar uma técnica de análise e descobrimento de dados para a parti daí, fazer limpeza e transformação destes dados para em seguida aplicar as técnicas de Engenharia de Manutenção. Essas técnicas são capazes de identificar padrões de falhas e repetibilidade, de forma que seja possível categorizá-las em nível de prioridade. Não obstante, o acompanhamento contínuo desses índices são um fator chave para melhoria do desempenho da manutenção, pois além de evidenciarem quais componentes levam a uma baixa performance, é possível verificar a eficácia das ações sobre os problemas levantados.

2. MATERIAIS E MÉTODOS

Nesta seção serão apresentados os principais métodos utilizados neste artigo, incluindo o processo KDD para descoberta e tratamento dos dados, bem como a aplicação dos principais indicadores de manutenção e apresentação do diagrama *Jack-Knife*.

O KDD pode ser definido como um processo não trivial de identificar, em dados, padrões válidos, novos, potencialmente úteis e ultimamente compreensíveis”, com o objetivo de evidenciar padrões que possam agregar valor ao negócio [2].

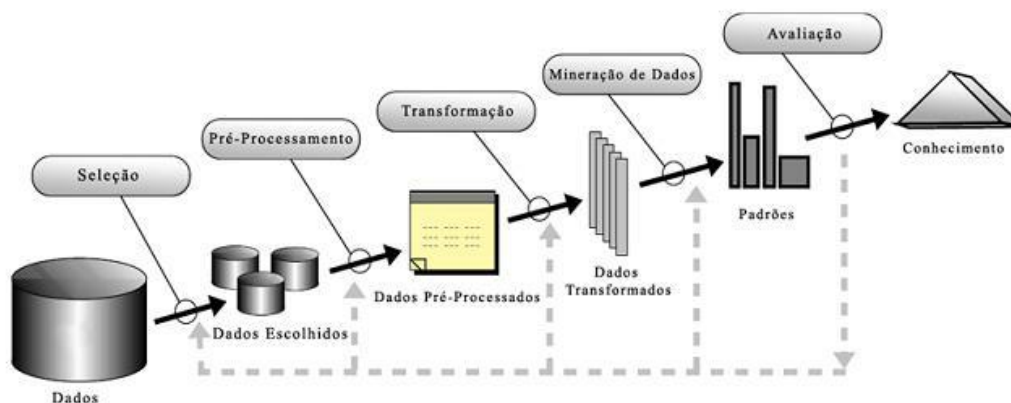


Figura 1: Visão geral do processo KDD. [2]

Na Figura 1 foi exposta o fluxograma geral do processo, que consiste nas seguintes etapas:

- Seleção – Consiste no entendimento dos dados;
- Pré processamento – Limpeza dos outliers e valores inconsistentes;
- Transformação – Modelagem dos dados;
- Mineração de dados – Modelagem dos dados e aplicação das técnicas de manutenção;
- Avaliação – Verificação da consistência dos resultados.

2.1 Base de dados

Os sistemas de SCADA atuais, em sua maioria, dispõem de protocolos nativos para acesso aos dados de processo, independentemente do segmento industrial. Na Figura 2, é apresentada a arquitetura de funções do SIMATIC WinCC da Siemens.

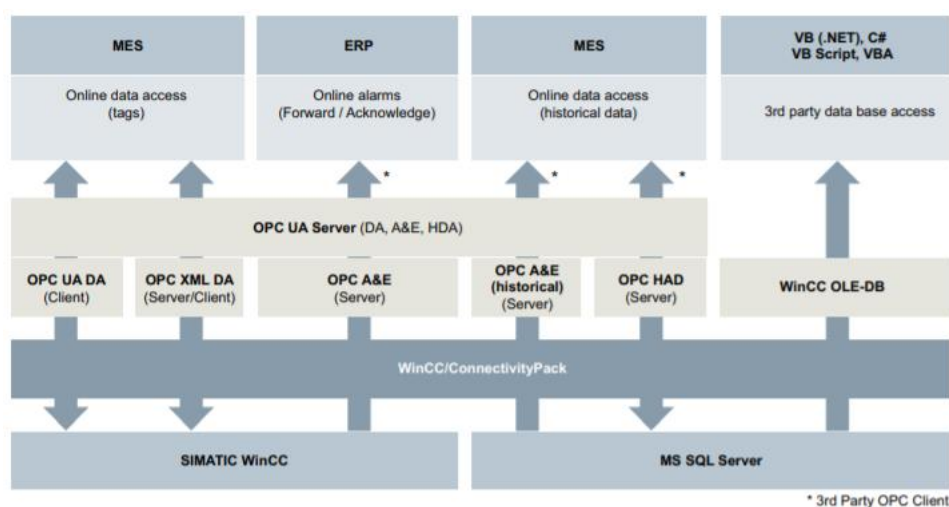


Figura 2: Arquitetura de funções do SCADA SIMATIC WinCC da Siemens. [9]

Comumente, cada usina eólica possui seu próprio sistema supervisor, caracterizando um conjunto de sistemas descentralizados. Para fins de controle e gerenciamento, optou-se por consolidar as diversas

informações, provenientes das diversas fontes, num banco de dados em nuvem, como exemplificado na Figura 3. E, a partir deste, são realizadas todas as demais etapas de tratamento, transformação e avaliação. De forma geral, os dados de processo – vazão, pressão, temperatura, rotação, potência, etc. – são gerados a nível dos Controladores Lógicos Programáveis – CLPs ou SCADA, dando origem aos alarmes e avisos sistêmicos, que indicam mal funcionamento do equipamento e/ou componente.




Figura 3: Topologia de rede para aquisição e consolidação dos dados de processo. (Autoria Própria)

2.2 Pré processamento e transformação dos dados

Geralmente, os alarmes das turbinas eólicas estão dispostos em formato de log, onde há vários alarmes simultâneos. Neste ponto, a limpeza do log de eventos é necessária, de tal sorte que, os alarmes relevantes para a próxima etapa seja apenas o evento raiz, ou mais provável, para aquela interrupção. Nesta etapa, o conhecimento do processo é de suma importância, pois desta forma os filtros aplicados serão mais eficientes e confiáveis. A etapa de preparação do banco de dados pode compreender até 80% dentro dos projetos de KDD [6].

Ainda, é necessário efetuar a parametrização e consolidação dos dados, de forma que seja possível se obter uma base de dados única para os diferentes fabricantes de turbinas eólicas. Como o objeto deste estudo são os eventos, ou comumente denominado alarmes, faz-se necessário utilizar a técnica de agrupamento dos registros, segregando-os em subsistemas, conforme ilustrado na Figura 4.

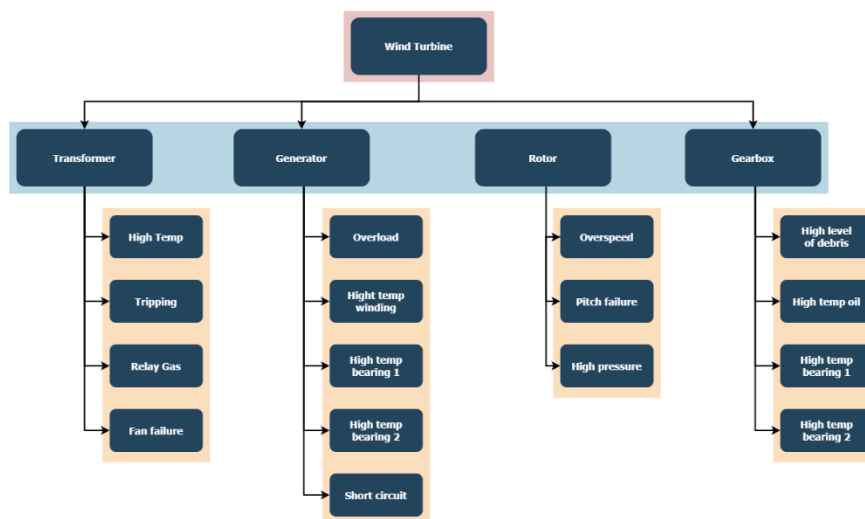


Figura 4: Exemplo resumido de uma árvore de falhas para turbina eólica. (Autoria Própria)

A hierarquização tem como objetivo agrupar as falhas e eventos de natureza similar. Nas próximas seções, será exposto em maiores detalhes a motivação desta categorização em grupos.

2.3 Mineração de dados

O *data mining* é o processo de descoberta de padrões interessantes e conhecimento a partir de grandes quantidades de dados. As fontes de dados podem incluir *databases*, *data warehouses*, *web*, outros repositórios de informações, ou dados que são transmitidos para o sistema dinamicamente [4].

Neste estudo, serão utilizados os modelos voltados para a gestão da manutenção, de forma que possamos obter de forma dinâmica uma avaliação, através de indicadores e técnicas, integrada aos dados de processo gerados pelo sistema SCADA.

2.3.1 Tempo Médio Entre Falhas

O tempo médio entre falhas, do inglês *Mean Time Between Failures* – MTBF, é definido pelo valor médio da distância de tempo entre falhas consecutivas, contabilizadas como a razão do tempo total observado pelo total de falhas, dada na Equação 1.

$$MTBF = \frac{T}{k} \quad (1)$$

Onde:

- MTBF = Tempo médio entre falhas;
- T = Período observado;
- k = Quantidade de falhas do período observado.

2.3.2 Taxa de Falhas

De forma análoga e inversa, a taxa de falhas λ , é definida como a razão entre o número total de falhas e o tempo acumulado total observado, Equação 2.

$$\lambda = \frac{k}{T} \quad (2)$$

Onde:

- λ = Taxa de falhas;
- T = Período observado;
- k = Quantidade de falhas do período observado.

2.3.2 Tempo Médio de Reparo

O tempo médio de reparo, *Mean Time To Repair* – MTTR, é a razão entre o tempo médio acumulado de manutenções corretivas e o número total de falhas observadas, conforme apresentado na Equação 3.

$$MTTR = \frac{M}{k} \quad (3)$$

Onde:

- MTTR = Tempo médio de reparo;
- M = Tempo medio acumulado de manutenções corretivas;
- k = Quantidade de falhas do período observado.

2.3.4 Diagrama *Jack-Knife*

O método *Jack-Knife* foi desenvolvido e aplicado primeiramente pelo Professor Dr. Peter Knights, em seu artigo *Downtime Priorities, Jack-Knife Diagrams, and the Business Cycle* [7]. O diagrama tem como objetivo categorizar as falhas por prioridade, levando em conta a quantidade e o tempo médio de reparo da natureza da falha, conforme ilustrado na Figura 5.

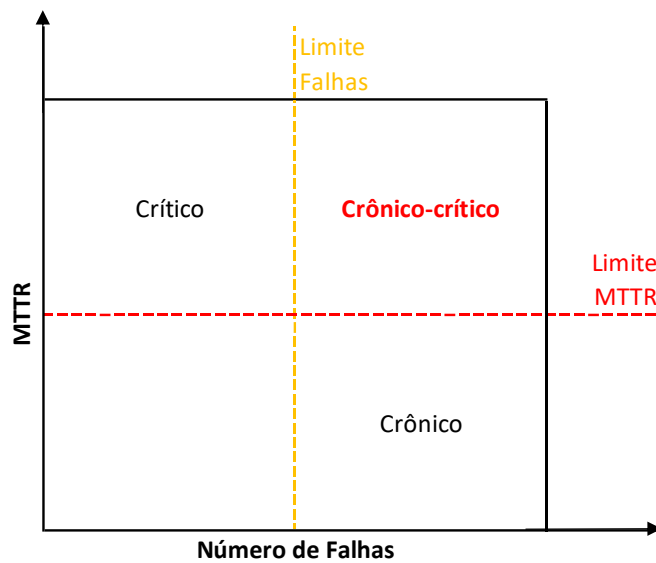


Figura 5: Exemplo do modelo de representação do diagrama *jack-knife*. (Autoria Própria)

A obtenção dos limites é obtida dinamicamente através do tamanho da amostra, a duração dos eventos e a natureza – eventos de códigos de falhas distintos – durante o período observado. O limite para falhas críticas é dado pela Equação 4:

$$Lim_{MTTR} = \frac{D}{k} \quad (4)$$

Onde:

- Lim_{MTTR} = Limite de falhas críticas do período observado;
- D = Tempo total não operativo;
- k = Quantidade de falhas do período observado.

E o limite para as falhas crônicas é dado pela Equação 5:

$$Lim_k = \frac{k}{Q} \quad (5)$$

Onde:

- Lim_{FALHAS} = Limite de falhas crônicas do período observado;
- Q = Quantidade de falhas por natureza;
- k = Quantidade total de falhas do período observado.

Para uma melhor visualização, recomenda-se a visualização em escala logarítmica de base 10, devido a característica hiperbólica das curvas para *downtimes* constantes, conforme apresentado na Equação 6.

$$\log_{10}(Downtime_i) = \log_{10}(k_i) \times \log_{10}(MTTR_i) \quad (6)$$

Onde:

- $Downtime_i$ = Tempo não operativo do i -ésimo evento;
- $MTTR_i$ = Tempo médio de reparo do i -ésimo evento;
- k_i = Quantidade de falhas do i -ésimo evento.

3. RESULTADOS

Para fins deste artigo, foi tomado como base os registros operacionais de falha do ano 2020 de um parque eólico, localizado no Rio Grande do Norte, contendo 10 aerogeradores. A turbina eólica foi segmentada nos seguintes subsistemas:

1. Sistema Hidráulico
2. Yaw
3. Controle
4. Gerador
5. Multiplicadora
6. Nacele
7. Rotor
8. Transformador
9. Conversor

Desta forma, é possível agrupar os indicadores por níveis e subníveis, observando quais os equipamentos e componentes apresentaram uma baixa confiabilidade durante o período observado.

3.1 Indicadores de manutenção

Os dados apresentados na Tabela 1 foram calculados a partir dos registros de falha. Outrossim, é possível observar que apesar dos Tempos Médios Entre Falhas de cada subcomponente ser bastante elevado, o resultado do conjunto é aquém ao esperado – em torno de 138 horas.

Subsistema	#Falhas	MTBF (horas)	λ	MTTR (horas)
Sistema Hidráulico	79	1111,90	8,99E-04	4,60
Yaw	12	7320,00	1,37E-04	4,72
Controle	78	1126,15	8,88E-04	3,48
Gerador	10	8784,00	1,14E-04	7,77
Multiplicadora	66	1330,91	7,51E-04	1,75
Nacele	290	302,90	3,30E-03	0,96
Rotor	48	1830,00	5,46E-04	23,82
Transformador	1	87840,00	1,14E-05	1,07
Conversor	49	1792,65	5,58E-04	5,19

Tabela 1: Indicadores de manutenção do parque eólico durante entre 1/1/20 e 31/12/20. (Autoria própria)

Realizando um *benchmarking* da Tabela 1 com o relatório de confiabilidade de subsistemas de turbinas eólicas, publicado pelo *National Renewable Energy Laboratory* – NREL [10], pode-se observar que os subsistemas com maior índice de falha são análogos.

Apesar disso, os indicadores de MTBF, MTTR e λ darem bastante informação da condição do ativo, ainda é insuficiente no sentido de tomada de decisão. É de suma importância mapear as falhas que ocasionam as maiores perdas numa planta eólica. Desta forma, utilizou-se a técnica conhecida como diagrama de *Jack-Knife* para categorização das falhas.

3.2 Aplicação do Jack-Knife

Na Tabela 2 são apresentados os resultados, crônicos e críticos, da aplicação do método para a população de dez turbinas do parque eólico. Além da visualização gráfica, é possível gerar um alerta sobre a atual condição das falhas.

Código	Descrição	Subsistema	Dt (horas)	MTTR (horas)	#Falhas	Status
733	Alta temperatura do óleo da caixa de engrenagens	Multiplicadora	44,08	0,76	58	Crônico
748	Sem detecção de velocidade TOG > 50% da velocidade	Controle	29,75	1,49	20	Crônico
767	Operação do sistema de pitch não está OK	Controle	100,63	6,71	15	Crônico-crítico
777	Erro de módulos de hardware	Controle	21,15	1,92	11	Crônico
792	Anemômetro em falha	Nacele	18,25	0,51	36	Crônico
1808	SSD de alto nível de vibração (choque)	Nacele	237,65	0,95	250	Crônico
4014	Can 3 Master Error	Hidráulico	110,78	3,08	36	Crônico
4016	Evolução de ataque incoerente	Rotor	51,48	2,57	20	Crônico
4029	Nível baixo de óleo de freio hidráulico	Hidráulico	103,82	7,42	14	Crônico-crítico
4031	Baixo nível de óleo hidráulico	Hidráulico	73,83	8,20	9	Crônico-crítico

Tabela 2: Falhas crônicas e críticas identificadas no parque eólico. (Autoria própria)

Após aplicação do método identificou-se três falhas crônico-críticas e crônicas que representaram, respectivamente, 10% e 20% da indisponibilidade anual do parque eólico.

Conforme mostrado por Knights [7], as falhas crônicas têm alta significância, pois geralmente são falhas sistêmicas e que possuem alta recorrência, levando a baixa confiabilidade do sistema. Falhas crônico-críticas, além da alta recorrência, possuem elevados tempos de reparo, que interferem diretamente com a manutenibilidade e disponibilidade do sistema.

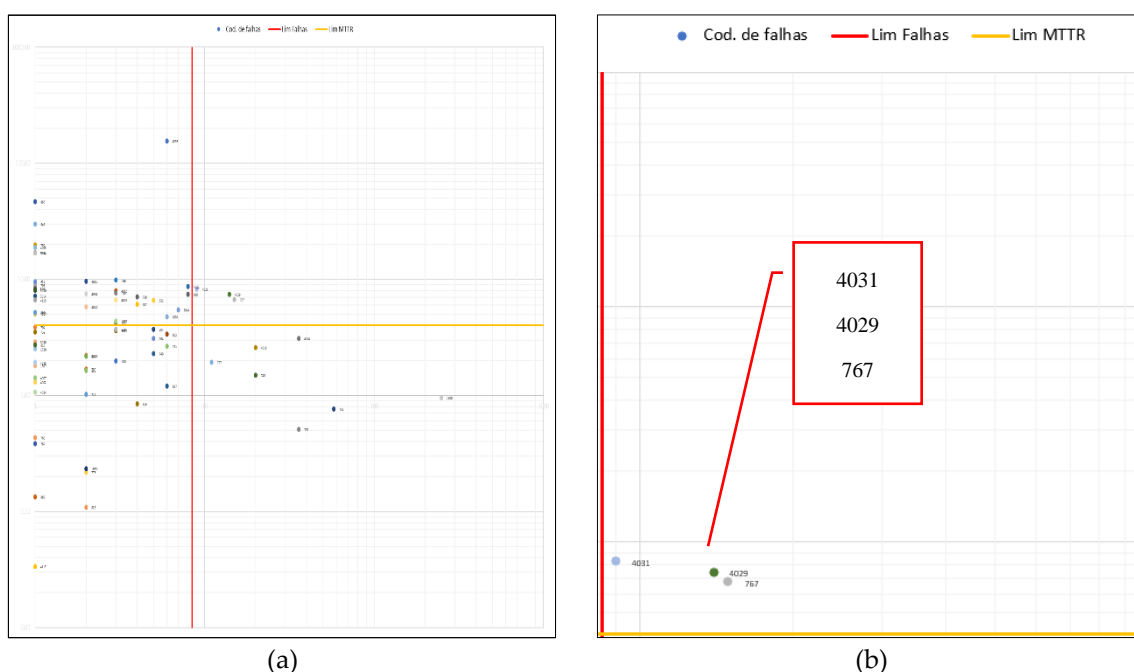


Figura 6: Diagrama de *Jack Knife* aplicado a frota de 10 aerogeradores. Onde (a) apresenta todas os quadrantes / falhas e (b) apenas o quadrante com as falhas crônico-críticas. (Autoria Própria)

Na Figura 6 (a) é possível observar a distribuição de todos os registros de falhas, bem como a classificação de cada falha dentro de seus respectivos quadrantes, definido pelos limites de falhas críticas e crônicas. Para o período e população estudado, os limites de falha crítica e crônica são, respectivamente, 8,44 e 4,05.




Figura 7: Tendência anual das falhas crônico-críticas de código 767, 4029 e 4031. (Autoria Própria)

Outrossim, conforme proposto por Seecharan [12], verificando periodicamente os índices, é possível observar a tendência das falhas dentro do método proposto. Na Figura 7 foram destacadas as falhas crônico-críticas, alta recorrência e indisponibilidade, para o ano de 2020. Identifica-se claramente que nenhuma ação foi tomada para mitigar a falha de código 767, mal funcionamento do sistema de acionamento das pás.

4. CONCLUSÃO

Este artigo teve como principal ideia introduzir, de forma sucinta, a gestão integrada de indicadores através da coleta de dados e eventos dos sistemas SCADA de usinas eólicas. Além disso, apresentar os conceitos dos principais indicadores de manutenção utilizados no trabalho e abordagem do diagrama *Jack-Knife*.

Como pode ser observado, o acompanhamento dos indicadores traz à tona os principais problemas existentes dentro de um processo produtivo. Auxiliado de técnicas, como o *Jack-Knife*, que sintetiza as falhas em quatro categorias, é possível identificar quais os pontos de maior atenção e, também, a eficiência das ações aplicadas.

A metodologia proposta visou a integração autônoma, sem necessidade de intervenção humana durante o processo de classificação, agrupamento para reconhecimento das falhas e cálculo dos índices. Todavia, foram identificadas algumas limitações intrínsecas do processo, tais como:

- Distinção entre itens reparáveis e não reparáveis (MTBF e MTTF)
- Alocação errônea de eventos x subsistema
- Falhas de comunicação do SCADA

Uma possível solução para sanar as atuais limitações seria aplicar uma segunda camada de interface com o usuário para correção manual dos eventos e/ou classificação.

REFERÊNCIAS

- [1] ABNT NBR5462. Confiabilidade e manutenibilidade, 1994.
- [2] FAYYAD, U.M. et al. *Advances in Knowledge Discovery and Data Mining*. California: AAAI Press, 1996b.
- [3] GOLDSCHMIDT, Ronaldo. *Data Mining: Conceitos, Técnicas, Algoritmos, Orientações e Aplicações*. Editora LTC, segunda edição.
- [4] HAN, Jiawei; KAMBER, Micheline; PEI, Jian. *Data Mining: Concepts and Techniques*. The Morgan Kaufmann Series in Data Management Systems, Third Edition.

- [5] MARCOVICZ, Fabio. Aplicação do método jack-knife para determinar falhas críticas em uma mandrilhadora. Monografia de especialização, Programa de especialização em Gerência de Manutenção da Universidade Tecnológica Federal do Paraná – UTFPR, 2018.
- [6] MCCUE, C. Data Mining and Predictive Analysis - Intelligence Gathering and Crime Analysis. Elsevier, 2007.
- [7] KNIGHTS, Peter F. Downtime Priorities, Jack-Knife Diagrams, and the Business Cycle. Maintenance Journal. V. 17, p. 14 - 21, 2001.
- [8] SFERRA, Heloisa; CORRÊA, Ângela Jorge. Conceitos e Aplicações de Data Mining. Revista de ciência & tecnologia, V. 11, Nº 22 – pp. 19-34.
- [9] SIMATIC WinCC V7. Disponível online: <https://new.siemens.com/global/en/products/automation/industry-software/automation-software/scada/simatic-wincc-v7.html> (Acesso em 17/04/2021)
- [10] SHENG, Shuangwen. Report on Wind Turbine Subsystem Reliability – A Survey of Various Databases. NREL, PR-5000-59111, 2013.
- [11] SMITH, Dr. David J. Reliability, Maintainability and Availability, Eighth Edition. Elsevier Editor, United States, 2011.
- [12] SEECHARAN, Turuna; LABIB, Ashraf; JARDINE, Andrew. Maintenance Strategies: Decision Making Grid vs. Jack-Knife Diagram. Journal of Quality in Maintenance Engineering, V. 24, p. 61-78, 2018.