



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
DEPARTAMENTO DE ENGENHARIA DE PRODUÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

RAFAEL GOMES NOBREGA PAIVA

**UTILIZAÇÃO DE MINERAÇÃO DE PADRÕES SEQUENCIAIS ATRAVÉS DO
ALGORITMO GSP E ABORDAGEM *SNAPSHOT* PARA O DESENVOLVIMENTO
DE UMA POLÍTICA DE MANUTENÇÃO OPORTUNA**

Recife
2021

RAFAEL GOMES NOBREGA PAIVA

**UTILIZAÇÃO DE MINERAÇÃO DE PADRÕES SEQUENCIAIS ATRAVÉS DO
ALGORITMO GSP E ABORDAGEM *SNAPSHOT* PARA O DESENVOLVIMENTO
DE UMA POLÍTICA DE MANUTENÇÃO OPORTUNA**

Dissertação submetida ao Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal de Pernambuco, para obtenção de grau de mestre em Engenharia de Produção.

Área de concentração: Pesquisa Operacional.

Orientador: Prof. Dr. Cristiano Alexandre Virgínio Cavalcante

Recife

2021

Catálogo na fonte
Bibliotecário Gabriel Luz, CRB-4 / 2222

- P149u Paiva, Rafael Gomes Nobrega
Utilização de mineração de padrões sequenciais através do algoritmo GSP e abordagem snapshot para o desenvolvimento de uma política de manutenção oportuna / Rafael Gomes Nobrega Paiva – Recife, 2021.
89 f.: figs., quads., gráfs., tabs.
- Orientador: Prof. Dr. Cristiano Alexandre Virgínio Cavalcante.
Dissertação (Mestrado) – Universidade Federal de Pernambuco. CTG.
Programa de Pós-Graduação em Engenharia de Produção, 2021.
Inclui referências.
1. Engenharia de Produção. 2. Mineração de padrões sequenciais. 3. Análise snapshot. 4. Política de manutenção oportuna. I. Cavalcante, Cristiano Alexandre Virgínio (Orientador). II. Título.

UFPE

658.5 CDD (22. ed.)

BCTG / 2021 - 136

RAFAEL GOMES NOBREGA PAIVA

**UTILIZAÇÃO DE MINERAÇÃO DE PADRÕES SEQUENCIAIS ATRAVÉS DO
ALGORITMO GSP E ABORDAGEM *SNAPSHOT* PARA O DESENVOLVIMENTO
DE UMA POLÍTICA DE MANUTENÇÃO OPORTUNA**

Dissertação submetida ao Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal de Pernambuco, para obtenção de grau de mestre em Engenharia de Produção.

Aprovada em: 19 / 02 / 2021.

BANCA EXAMINADORA

Prof. Dr. Cristiano Alexandre Virgínio Cavalcante (Orientador)
Universidade Federal de Pernambuco

Prof^a. Dr^a. Caroline Maria de Miranda Mota (Examinadora Interna)
Universidade Federal de Pernambuco

Prof. Dr. Osvaldo Luiz Gonçalves Quelhas (Examinador Externo)
Universidade Federal Fluminense

AGRADECIMENTOS

Agradeço primeiramente a Deus, a Jesus Cristo e ao meu anjo da guarda, por todo cuidado e proteção.

Devo gratidão aos meus pais, a minha mãe que desde pequeno me ajuda nos estudos e mostra o quanto eles são importantes para o meu caráter e crescimento e ao meu pai que é exemplo de um estudioso e curioso sobre as coisas do mundo e da alma.

A toda a minha família, em especial minhas avós Maria da Penha e Zélia, por serem exemplos de mulher, mãe e avó a toda família.

À minha namorada e companheira, Lavínia Maria, que esteve comigo em toda essa jornada, me apoiando, me incentivando. Muito obrigado por tudo, te amo.

Ao meu orientador Prof. Cristiano Cavalcante, pela paciência e compreensão, pelo apoio pleno e dedicação ao nos passar um pouco do seu conhecimento. A meus colegas de laboratório, particularmente a Yan e Vinícius, por todo apoio e ajuda no desenvolvimento deste estudo.

A todos os meus amigos, que de forma direta ou indireta, contribuíram neste mestrado, cada trabalho, cada conversa faz parte da construção de quem eu sou hoje e tem sua parcela de participação nesta conquista.

A todos os professores, por cada ensinamento.

E a todos os servidores da universidade, por cada auxílio e ajuda.

Agradeço por fim a Universidade Federal de Pernambuco e a CAPES por fornecer apoio financeiro ao longo do curso e do período de execução deste estudo.

RESUMO

O gerenciamento da manutenção desde os seus primeiros estudos mostra a necessidade da utilização de dados. Isso, com o intuito de tomar decisões e desenvolver ações mais eficientes. Com a evolução da tecnologia, as indústrias estão utilizando, cada vez mais, dispositivos que permitam a coleta ininterrupta de dados, a exemplo de sensores. Desta forma, o desafio atual é saber como tratar essa gama de informações de forma confiável, isto é, com a representação real do processo. Diante disso, a presente dissertação tem o objetivo de utilizar dois métodos, quais sejam, a mineração de padrões sequenciais e a análise Snapshot, para analisar dados de manutenção de um sistema de usinagem. Ao integrá-las, este estudo, se baseará em seus resultados para desenvolver uma política de manutenção oportuna. Como contribuição metodológica, será apresentado um *framework* que estrutura um sequenciamento de atividades para realização desta análise, desde a coleta de dados até a construção da política de manutenção oportuna. Em relação aos resultados, as informações advindas da mineração de padrões sequenciais corroboram com as encontradas na análise Snapshot, isto é, o subsistema de lubrificação é o mais crítico no sistema de usinagem. Logo, a política de manutenção oportuna desenvolveu-se de forma a melhorar este aspecto. O custo esperado por unidade de tempo no longo prazo será a variável resposta a ser otimizada. Para compor os resultados, foi realizada uma análise de sensibilidade para evidenciar a relação entre a demanda de peças com geometria complexa e o custo por unidade de tempo no estado defeituoso. Observou-se também que o uso da mão-de-obra do operador para ações mais simples de manutenção provoca uma redução de 13,40% no custo total em relação ao cenário no qual todas as atividades são realizadas por uma equipe de manutenção especializada. Outro resultado significativo foi que se as ações de renovação ocorressem sem erros haveria uma redução de 13,93% no custo por unidade de tempo no longo prazo. Por fim, todo o desenvolvimento e resultados deste estudo buscam enfatizar a importância da análise de dados de manutenção. Pois, baseando-se nela, as organizações conseguem obter retorno econômico, a exemplo das oportunidades de redução de custo. Assim como, melhorar o desempenho dos processos ao reduzir o número de paradas.

Palavras-chave: Mineração de padrões sequenciais. Análise snapshot. Política de manutenção oportuna.

ABSTRACT

Maintenance management since its first studies shows the need to use data. This, in order to make decisions and develop more efficient actions. With the evolution of technology, industries are increasingly using devices that allow the uninterrupted collection of data, such as sensors. Thus, the current challenge is to know how to treat this range of information reliably, that is, with the actual representation of the process. Therefore, this dissertation aims to use two methods, namely, the mining sequential patterns and the Snapshot analysis, to analyze maintenance data of a machining system. When integrating them, this study will be based on its results to develop an opportunistic maintenance policy. As a methodological contribution, a framework will be presented that structures sequencing to perform this type of analysis, from data collection to the construction of an opportunistic maintenance policy. Regarding the results, the information derived from the mining sequential patterns corroborates that found in the Snapshot analysis, that is, the lubrication subsystem is the most critical within the machining system. Therefore, the opportunistic maintenance policy was developed in order to improve this aspect. The expected cost per unit of time in the long run will be the response variable to be optimized. To compose the results, a sensitivity analysis was performed to show the relationship between the demand for parts with complex geometry and the cost per unit of time in the defective state. It was also observed that the use of the operator's labor for simpler maintenance actions causes a reduction of 13.40% in the total cost in relation to the scenario in which all actions are performed by a specialized maintenance team. Another significant result was that if the renovation actions occurred without errors, there would be an 13.93% reduction in the cost per unit of time in the long run. Finally, all the development and results of this study seek to emphasize the importance of analyzing maintenance data. Because, based on it, organizations are able to obtain economic return, as in the case of cost reduction opportunities. As well as, improving the performance of processes by reducing the number of stops.

Keywords: Mining sequential patterns. Snapshot analysis. Opportunistic maintenance policy.

LISTA DE FIGURAS

Figura 1 - Representação do <i>Delay Time</i>	24
Figura 2 - Exemplo de gráfico <i>Snapshot</i>	26
Figura 3 - Processo KDD	27
Figura 4 - Etapas da análise do banco de dados e da aplicação prática.....	36
Figura 5 - Representação da chegada do defeito e da falha	56
Figura 6 - Variáveis de Decisão	58
Figura 7 - Cenário 1 - Renovação preventiva: o componente é descoberto como sendo defeituoso na fase de inspeção.....	62
Figura 8 - Cenário 2 - Renovação corretiva: o defeito surge e a falha acontece em seguida, antes da chegada da próxima inspeção	63
Figura 9 - Renovação corretiva: o defeito surge após o período de inspeções, porém a falha ocorreu antes da janela de oportunidade.....	64
Figura 10 - Renovação corretiva: o defeito ocorre entre $K\Delta$ e S e a falha ocorre entre S e T, oportunidade surge após a falha	65
Figura 11 - Renovação corretiva: o defeito e a falha acontecem no intervalo [S,T],mas a oportunidade apenas surge após a falha.....	66
Figura 12 - Renovação oportuna: o defeito ocorre entre $K\Delta$ e S e a falha ocorreria entre S e T, porém uma oportunidade surge antes da falha	67
Figura 13 - Renovação oportuna: o defeito ocorre entre $K\Delta$ e S e a falha ocorreria após T, porém uma oportunidade surge entre S e T	67
Figura 14 - Renovação oportuna: o defeito ocorre entre S e T, assim como a falha também ocorreria, porém uma oportunidade surge antes da falha.....	68
Figura 15 - Renovação oportuna: o defeito e falha ocorriam entre S e T, porém oportunidade surge antes mesmo do defeito.....	69
Figura 16 - Renovação oportuna: o defeito ocorre entre S e T e a falha ocorreria após T, porém uma oportunidade surge entre S e T, após o defeito.....	70
Figura 17 - Renovação oportuna: o defeito ocorreria entre S e T e a falha ocorreria após T, porém uma oportunidade surge antes do defeito	71
Figura 18 - Renovação oportuna: o defeito e a falha ocorreriam após T, uma oportunidade surge entre S e T	72

Figura 19 - Renovação preventiva: o defeito ocorre entre $K\Delta$ e T e a falha ocorreria após T, oportunidade surge após T	73
Figura 20 - Renovação preventiva: o defeito e a falha ocorreriam após T, oportunidade surge após T	74

LISTA DE QUADROS

Quadro 1 - Classificação da Pesquisa.....	35
Quadro 2 - Classificações da análise <i>Snapshot</i>	49
Quadro 3 - Notação das siglas	60

LISTA DE GRÁFICOS

Gráfico 1 - Número de padrões gerados para intervalos de 60, 90 e 120 minutos.....	44
Gráfico 2 - Análise Snapshot – Parte do equipamento e Modo de evitar o evento.....	49
Gráfico 3 - Análise Snapshot – Tipo de Anomalia e Severidade do evento	50
Gráfico 4 - Análise Snapshot – Tipo de Anomalia e Modo de Prevenção.....	51
Gráfico 5 - Análise Snapshot – Parte do equipamento e Causa do evento.....	51
Gráfico 6 - Análise Snapshot – Parte do equipamento e Severidade do evento.....	52

LISTA DE TABELAS

Tabela 1 - Exemplo de dados para regra de associação	31
Tabela 2 - Conjunto de itens candidatos (C) e conjunto de itens frequentes (L)	31
Tabela 3 - Amostra do banco de dados.....	37
Tabela 4 - Lista de Eventos mais frequentes	44
Tabela 5 - Padrões encontrados para o intervalo de tempo de 60 minutos	45
Tabela 6 - Padrões encontrados para o intervalo de tempo de 90 minutos	45
Tabela 7 - Padrões encontrados para o intervalo de tempo de 120 minutos	46
Tabela 8 - Valores dos Parâmetros da Aplicação Numérica	76
Tabela 9 - Resultados para o modelo de minimização de custo.....	76
Tabela 10 - Relação entre demanda de peças com geometria complexa e o custo por unidade de tempo no estado defeituoso	77
Tabela 11 - Análise de sensibilidade do custo por unidade de tempo de permanência no estado defeituoso	77
Tabela 12 - Análise de sensibilidade dos custos relacionados com as ações de manutenção ..	78
Tabela 13 - Análise de sensibilidade da realização de ações de manutenção pela equipe de manutenção ou de operação.....	78
Tabela 14 - Relação entre umidade relativa do ar e a taxa de chegada de oportunidade	79
Tabela 15 - Análise de sensibilidade da taxa de chegada de oportunidade.....	79
Tabela 16 - Análise de sensibilidade dos parâmetros de chegada do defeito e do <i>delay time</i> ..	80

SUMÁRIO

1	INTRODUÇÃO.....	14
1.1	JUSTIFICATIVA E RELEVÂNCIA.....	16
1.2	OBJETIVO.....	17
1.2.1	Objetivo geral	18
1.2.2	Objetivos Específicos	18
1.3	ESTRUTURA DO TRABALHO.....	18
2	REVISÃO DA LITERATURA E REFERENCIAL TEÓRICO.....	20
2.1	MANUTENÇÃO	20
2.1.1	Definição e objetivos	20
2.1.2	Classificação	21
2.1.3	Concepções básicas da manutenção	22
2.1.4	Delay Time	23
2.1.5	Política de manutenção oportuna	24
2.1.6	Snapshot.....	25
2.2	KNOWLEDGE DISCOVERY IN DATABASES (KDD)	27
2.3	MINERAÇÃO DE DADOS	28
2.3.1	Mineração de regras de associação.....	29
2.3.2	Mineração de padrões sequenciais	33
3	METODOLOGIA	35
4	ANÁLISE DE DADOS ATRAVÉS DA MINERAÇÃO DE PADRÕES SEQUENCIAIS E DA ANÁLISE SNAPSHOT	40
4.1	DESENVOLVIMENTO DA MINERAÇÃO DE PADRÕES SEQUENCIAIS ATRAVÉS DO ALGORITMO GSP	40
4.1.1	Coleta dos dados.....	40
4.1.2	Desenvolvimento do objetivo da análise de dados.....	41
4.1.3	Escolha da técnica de mineração de dados	41
4.1.4	Pré-processamento dos dados	42
4.1.5	Escolha das métricas de desempenho.....	43
4.1.6	Mineração de Dados.....	43
4.2	ANÁLISE SNAPSHOT	49

4.3	ANÁLISE E INTEGRAÇÃO DOS RESULTADOS	52
5	DESENVOLVIMENTO DA POLÍTICA DE MANUTENÇÃO OPORTUNA	55
5.1	DESCRIÇÃO DAS CARACTERÍSTICAS DO SISTEMA.....	55
5.2	MODELAGEM DA POLÍTICA OPORTUNA ATRAVÉS DO MODELO ANALÍTICO.....	58
5.3	APLICAÇÃO NUMÉRICA DO MODELO DESENVOLVIDO DA POLÍTICA DE MANUTENÇÃO OPORTUNA	75
5.3.1	Análise de sensibilidade do custo por unidade de tempo de permanência no estado defeituoso	76
5.3.2	Análise de Sensibilidade dos custos de ações de manutenção	77
5.3.3	Análise de sensibilidade da taxa de chegada de oportunidade	79
5.3.4	Análise de sensibilidade da chegada do defeito e do delay time	80
6	CONCLUSÕES.....	82
	REFERÊNCIAS.....	85

1 INTRODUÇÃO

Devido à alta dinamicidade dos negócios, à necessidade de atender de forma rápida as demandas dos clientes e ao desenvolvimento de sistemas cada vez mais automatizados, as organizações estão utilizando técnicas de monitoramento das condições dos equipamentos para executar uma manutenção mais efetiva que diminua o *downtime*, isto é, o tempo de inatividade do sistema, reduzindo os custos totais da operação e maximizando o tempo de vida do dispositivo (BERRADE et al., 2013; CAVALCANTE; LOPES; SCARF, 2018; CHEMWENO et al., 2016).

Os estudos de gerenciamento da manutenção, desde as suas primeiras aparições nas décadas de 1950 e 1960, apontavam a necessidade de possuir dados para definir suas ações. Desta forma, técnicas que os coletassem e os estruturassem começaram a ser desenvolvidas. Um exemplo é o método Snapshot cujo objetivo é investigar as causas, as consequências e os meios de prevenção de falhas. A partir disso, a ferramenta consegue apresentar de forma sintetizada, mediante gráficos, informações primordiais para o desenvolvimento de uma política de manutenção. Por exemplo, a anomalia mais frequente e a prática de prevenção mais eficaz para o aumento da confiabilidade do sistema (CHRISTER; WHITELAW, 1983; DEKKER, 1996; DESA; CHRISTER, 2001).

Dado o crescimento da complexidade dos sistemas produtivos ao decorrer dos anos, surge a necessidade de ações de manutenção cada vez mais eficientes. Neste contexto, inclui-se a política de manutenção oportuna que visa reduzir os custos de manutenção e o número de intervenções a partir do aproveitamento de oportunidades de parada. Ou seja, quando ocorre um reparo ou substituição de um subsistema, a equipe de manutenção utiliza este momento para realizar uma ação em um sistema ou componente crítico que não estava programada para aquele instante (CAVALCANTE; LOPES; SCARF, 2018; DEKKER; SMEITINK, 1991; WANG; SCARF; SMITH, 2000).

Não obstante, a indústria está cada vez mais convergindo à utilização de máquinas e de sistemas que possuam sensores e controladores. Estes dispositivos auxiliam o gerenciamento da manutenção em relação ao monitoramento da condição do equipamento. Junto a isto, surgem novos desafios para esta atividade, a exemplo do tratamento dos dados e da detecção de regras e padrões para o apoio a decisão na função manutenção. Diante da grande massa de dados que os sensores e controladores geram, são necessárias metodologias apropriadas para

tratá-los. Isso, de modo a transformar grandes massas de dados em informações essenciais para suportar a tomada de decisão em tempo hábil. Assim como, evitar graves consequências advindas do funcionamento inadequado do sistema (defeitos), ou, até mesmo, a falha (CHEMWENO *et al.*, 2016).

Esse processo de extração de conhecimento de banco de dados é conhecido por KDD (*Knowledge Discovery Databases*) e visa desenvolver uma forma automatizada de lidar com o grande número de dados, interpretando-os e dando significado aos mesmos. É importante não confundir Mineração de Dados (*Data Mining – DM*) e KDD, visto que KDD é todo o processo até que se chegue ao resultado de um padrão de comportamento das variáveis e a DM é uma das atividades desta metodologia (ANTOMARIONI *et al.*, 2019).

Monitorar continuamente um equipamento é, em geral, custoso. Além disso, em determinados sistemas complexos o acompanhamento ininterrupto é inviável. Nestes casos, pode-se utilizar o acompanhamento de dados discretos. Em comparação com o monitoramento contínuo que necessita de um sensor dedicado, as informações de um evento discreto podem ser gravadas e armazenadas durante a operação da máquina, formando um banco de dados de eventos ou de erros do sistema (LIU *et al.*, 2017; OLINER; GANAPATHI; XU, 2012).

Diversas técnicas computacionais estão sendo discutidas nesse contexto, em particular a mineração de dados a partir de mineração de padrões sequenciais. Esta técnica recebe destaque devido a sua abordagem de inteligência computacional que busca a exploração e identificação de relações entre eventos de falha em grandes bancos de dados. Embora seja amplamente utilizada em áreas do conhecimento como computação e identificação de comportamento de compras, no auxílio à tomada de decisão em manutenção, esta técnica ainda é pouco explorada (CHEMWENO *et al.*, 2016).

Ao contrário de sistemas computacionais, sistemas mecânicos possuem mecanismos de falhas bastante complexos. Isto pode ser atribuído pela natureza do desenho de tais sistemas que geralmente consiste em vários componentes interligados e cada um destes possuem mecanismos de falha exclusivos. Portanto, implementar algoritmos estatísticos ou técnicas de aprendizagem de máquina para explorar associações entre eventos de falha é essencial para uma função manutenção eficaz (CHEMWENO *et al.*, 2016).

1.1 JUSTIFICATIVA E RELEVÂNCIA

Ao analisar bancos de dados de eventos para o gerenciamento eficaz da manutenção, tem-se como premissa que existe um padrão identificável de ocorrência que precede acontecimentos que resultam na falha da máquina. Este padrão ou “assinatura de falha”, é chamado de defeito, segundo o conceito *Delay Time* (CHRISTER 1999). Quando identificado, o padrão fornece informações valiosas para a predição da falha do sistema.

Na prática, os dados discretos de defeitos são analisados manualmente baseados na experiência de especialistas, entretanto este é um processo que requer um tempo considerável de realização e pode se tornar inviável no tocante a um sistema que registra um grande número de dados. Diante disso, nota-se a relevância de utilizar métodos que aprimorem esta análise (LIU *et al.*, 2017).

Diversas técnicas foram utilizadas para lidar com eventos de dados discretos. Li *et al.* (2007) desenvolveram um método de predição de falha baseado no modelo de riscos proporcionais de Cox. Nele, a frequência de falhas é incorporada como covariável do modelo de riscos proporcionais. Em continuação da pesquisa de Li *et al.* (2007), Yuan *et al.* (2011) utilizaram o modelo de riscos proporcionais de Cox para banco de dados de eventos e avaliou a influência dos fatores de covariância para a função *survival* (sobrevivência).

Em ambos os estudos, assume-se que a taxa de falhas do sistema segue o modelo de riscos proporcionais de Cox. Isto, geralmente não condiz com a realidade dos processos fabris. Principalmente em sistemas modernos com alta complexidade (LIU *et al.*, 2017). Uma alternativa que preencheria essa lacuna é o uso de mineração de dados. Isto, por que a partir deste método, a análise dos tempos dos eventos consegue fornecer taxas de falhas sem aproximações matemáticas.

Fronza *et al.* (2013) propuseram um método de predição de falha baseado em um banco de dados, onde um indexador aleatório e um vetor de suporte são empregados para identificar sequências ou padrões nos eventos. Russo *et al.* (2015) desenvolveram um método que integra técnicas de aprendizagem de máquina para predizer resultados, um estudo de caso é analisado em um sistema de telemetria para apresentar a efetividade da proposta metodologia. A máquina de vetor de suporte é efetiva em classificar se os eventos são assinaturas de falhas ou não. Um ponto de atenção destes estudos é que eles não identificam as relações causais entre eventos.

Accorsi *et al.* (2017) utilizaram regras de associação para analisar parâmetros de uma máquina antes da ocorrência de determinadas falhas, os dados utilizados para fazer o estudo consistem em sequências de mensagens de uma *interface* homem-máquina e foram selecionados os eventos mais frequentes que precediam uma falha do sistema.

Antomarioni *et al.* (2019) desenvolveram uma política de manutenção a partir de análises de regras de associação entre dados de paradas de uma usina de refinaria de petróleo e quebras de componentes específicos dentro de um determinado intervalo de tempo para auxiliar a decisão de um gestor de manutenção na escolha de ações corretivas ou preventiva.

Diante do exposto, o presente estudo busca ressaltar a relevância de analisar uma grande massa de dados no gerenciamento da manutenção. Para isto, será empregada a abordagem de mineração de padrões sequenciais para identificar relações entre eventos durante um determinado intervalo de tempo (AGRAWAL; SRIKANT, 1995). Comparado com outros métodos existentes, este se caracteriza pela sua flexibilidade, isto é, são geradas diversas regras e padrões a depender dos parâmetros de entrada. Assim, o gestor da manutenção poderá selecionar as regras que estão relacionadas com as consequências mais graves. Podendo então, priorizar as regras que demandam mais atenção e precisam de um cuidado especial, visto que, os eventos mais frequentes não necessariamente possuem consequências significativas.

Dentre as contribuições desta pesquisa, destaca-se a utilização da técnica mineração de padrões sequenciais em conjunto com a análise Snapshot de modo a desenvolver um panorama que apresente os eventos de um sistema que necessitam de ações de manutenção. Além disso, propõe-se um estudo prático com o desenvolvimento de uma política de manutenção oportuna para um componente crítico, que foi o sistema de lubrificação de um centro de usinagem. Isso, com o intuito de comprovar a aplicabilidade do método de análise.

1.2 OBJETIVOS

A presente seção apresenta os objetivos geral e específicos deste estudo.

1.2.1 Objetivo geral

Este trabalho tem como objetivo geral o desenvolvimento de uma política de manutenção oportuna apoiado na análise de dados de manutenção a partir do uso de mineração de padrões sequenciais e da técnica *Snapshot*.

1.2.2 Objetivos Específicos

- Desenvolver um método de pré-processamento de dados de manutenção;
- Elaborar um *framework* que integre as análises de mineração de padrões sequenciais e a abordagem *Snapshot*;
- Aplicar o *framework* em um estudo de caso de um sistema de lubrificação em um centro de usinagem;
- Desenvolver um modelo analítico da política de manutenção oportuna para minimizar o custo esperado por unidade de tempo no longo prazo;
- Realizar a análise de sensibilidade dos resultados;
- Executar aplicação numérica do modelo de política de manutenção oportuna.

1.3 ESTRUTURA DO TRABALHO

Esta dissertação está estruturada em seis seções: Introdução, Revisão da Literatura e Referencial teórico, Metodologia, Análise de dados através da Mineração de Padrões Sequenciais e da Análise *Snapshot*, Desenvolvimento da Política de Manutenção Oportuna e por fim Conclusões.

Na primeira seção, a Introdução, é descrito o problema que será estudado, apresentado à justificativa e a relevância do estudo, além da descrição do objetivo geral e dos objetivos específicos.

Já na segunda seção, Revisão da Literatura e Referencial teórico, são apresentadas as bases teóricas para o desenvolvimento do estudo, enfatizando tópicos de manutenção, mineração de dados e análise *Snapshot*, além de exemplificar estudos que embasam essa pesquisa relacionado a estes três temas principais.

Na terceira seção, a Metodologia, é desenvolvido um *framework* que integra as técnicas de mineração de padrões sequenciais e análise Snapshot a fim de obter *inputs* para o gerenciamento da manutenção e desenvolvimento de uma política de manutenção.

Na quarta seção, Análise de dados através da Mineração de Padrões Sequenciais e da Análise Snapshot, toda a sequência de passos para realização das análises pela Mineração de Padrões Sequencias e Análise Snapshot são expostos, além que no fim do capítulo é feito um apanhado de *insights* que foram realizados com a junção das informações geradas e que servirão para a escolha do componente crítico que será base para a construção da política de manutenção.

Na quinta seção, o Desenvolvimento da Política Oportuna, serão expostas as características do sistema estudado e das ações de manutenção que serão base para o modelo, também será apresentado a modelagem analítica, com todas as equações de probabilidade, custo esperado e tamanho do ciclo de vida esperado de cada cenário da política, por fim é apresentado o exemplo numérico com a análise de sensibilidade das variáveis de entrada.

Por fim, a Conclusão, que traz as considerações finais, ressalta a relevância do estudo, suas limitações e algumas sugestões para trabalhos futuros.

2 REVISÃO DA LITERATURA E REFERENCIAL TEÓRICO

Esta seção visa fornecer aporte teórico sobre os principais assuntos que embasam esta dissertação, quais sejam, Manutenção e Mineração de dados. Serão abordadas a definição, a classificação, as concepções básicas e as políticas da manutenção, assim como, o *delay time* e o Snapshot. Em seguida, serão apresentados os conceitos referentes à mineração de dados: KDD, regras de associação e mineração de padrões sequenciais.

2.1 MANUTENÇÃO

As décadas de 1950 e 1960 datam os primeiros estudos relacionados ao gerenciamento da manutenção. Estes baseavam-se na manutenção preventiva, isto é, visavam a redução de falhas e do tempo de parada do sistema. Em meados de 1970, a abordagem do monitoramento da condição começou a ganhar destaque no âmbito acadêmico. Esta, foca em técnicas de predição que preveem falhas usando informação do estado atual do equipamento. Na década de 1980, o computador começa a possuir papel fundamental na manutenção. Dos anos 2000 até os dias atuais, vem se destacando o uso de sensores e de controladores. Tais elementos possibilitam o fornecimento de uma gama considerável de dados (DEKKER, 1996; GRABOT, 2020).

2.1.1 Definição e objetivos

Manutenção pode ser definida como a combinação de todos os aspectos técnicos, administrativos e ações gerenciais executadas durante o ciclo de vida de um componente com o fim de mantê-lo ou restaurá-lo em um estado no qual ele possa executar a sua função requerida (DEKKER, 1996).

Wang (2012) afirma que a manutenção é uma função que opera em paralelo à produção e pode trazer um grande impacto na capacidade produtiva e na qualidade dos produtos. De acordo com o estudo de Mobley (2002), entre 15 e 45% do custo total de produção é atribuído às atividades de manutenção em uma fábrica. Löfsten (2000) e Park e Han (2001) acrescentam que após os custos de energia, os custos de manutenção possuem a maior parcela no orçamento operacional.

Os objetivos da manutenção podem ser sintetizados em quatro pilares (DEKKER, 1996):

- Assegurar a função do sistema: para o maquinário, o principal objetivo da manutenção é assegurar a sua função e prover a confiabilidade, a disponibilidade, a eficiência e a capacidade adequada dos sistemas produtivos;
- Garantir a vida útil do sistema: refere-se a manter os sistemas com condições adequadas para a produção de bens ou serviços, em prazos previamente estabelecidos;
- Prover segurança: consiste em evitar falhas que causem consequências graves. Por exemplo, o setor de manutenção de aviões, da indústria nuclear e química é significativamente crítico, dado que acidentes nestas áreas causam danos catastróficos;
- Garantir o bem-estar humano: consiste em assegurar um ambiente de trabalho seguro, com poucos riscos à saúde e integridade do trabalhador.

2.1.2 Classificação

A literatura científica e normativa utiliza e classifica a manutenção em três tipos, quais sejam, manutenção corretiva, manutenção preventiva e manutenção preditiva. Cada uma delas será detalhada a seguir.

- (1) Manutenção Corretiva: trata de ações de manutenção não programadas. Nesta categoria, o ativo (máquinas, equipamentos, etc.) é utilizado até a sua falha. Apenas quando esta última acontece é que surgem as atividades de manutenção que objetivam reparar rapidamente o sistema (GRABOT, 2020; KUMAR; SHANKAR; THAKUR, 2018). É possível afirmar que o custo para a realização da manutenção corretiva é maior que os das manutenções preventiva e preditiva. Isto, porquê além do valor do reparo ou substituição, devem ser acrescidos os custos referentes à permanência inativa do sistema (JIN et al., 2016; JUNCA; SANCHEZ-SILVA, 2013);
- (2) Manutenção preventiva: envolve o reparo e a substituição do equipamento para evitar uma falha não esperada durante a operação. Ou seja, a manutenção é realizada antes que aconteça algum evento crítico que comprometa o ativo ou a

continuidade do processo produtivo. Seu objetivo é minimizar os custos que são provenientes do *downtime* (tempo de parada do sistema). Os programas de manutenção preventiva são baseados no tempo, ou seja, são realizadas substituições em períodos previamente determinados, geralmente de acordo com o valor do tempo médio entre falhas do ativo (JIN et al., 2016; LEE; HAIXIA, 2008; MARSARO; CAVALCANTE, 2017);

- (3) Manutenção preditiva: trata-se do uso de técnicas modernas e sistemáticas de avaliação do estado do equipamento para investigar sua condição, e, desta forma, prover ações mais assertivas de manutenção. Os programas são baseados na condição do equipamento, isto é, a ação de substituir o equipamento consiste na observação de parâmetros, como por exemplo, a temperatura e a vibração (ANTOMARIONI et al., 2019; GRABOT, 2020; JIN et al., 2016; PINTELON; PARODI-HERZ, 2008).

2.1.3 Concepções básicas da manutenção

Existem duas concepções básicas tradicionais consideravelmente difundidas na literatura acadêmica e na indústria, quais sejam, a Manutenção Produtiva Total, do inglês, *Total Productive Maintenance* (TPM) e a Manutenção Centrada em Confiabilidade ou *Reliability-Centred Maintenance* (RCM). Ambas serão detalhadas a seguir.

- (1) Manutenção Produtiva Total (TPM): é um programa de manutenção que visa construir a mentalidade que todos os funcionários são responsáveis pelos equipamentos e fábrica. Objetiva também ter zero interrupções no processo. Ela consiste em uma manutenção preventiva e ativa, com envolvimento total da equipe que se integra à gestão da qualidade total e a filosofia *Just in Time*. A TPM desenvolve técnicas para engajar e envolver os trabalhadores. A partir de suas ações, também permite a estabilidade do processo (DENNIS, 2015; PARK; HAN, 2001; PINTELON; PARODI-HERZ, 2008).
- (2) Manutenção Centrada em Confiabilidade (RCM): consiste em um processo de definição dos requisitos de manutenção dos bens físicos em operação. Tem como objetivo identificar componentes cuja as falhas e degradação resultem em perdas e /ou ineficiências nas funções críticas de um sistema industrial ou que causem

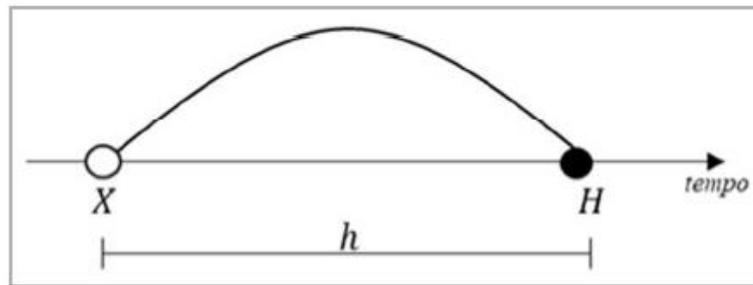
despesas de manutenção consideráveis. O foco desta filosofia está voltado principalmente para a segurança e a confiabilidade, deixando em segundo plano os custos. Esta abordagem estruturada integra também a gestão do conhecimento. Isto, ao reduzir o erro humano, aprimorando a análise da base de dados histórica dos eventos e explorando o conhecimento e expertise dos colaboradores (PINTELON; PARODI-HERZ, 2008).

2.1.4 Delay Time

O *Delay Time (DT)* é um conceito criado para atender problemas vinculados à inspeção e planejamentos de intervenções de manutenção. Modelos baseados neste conceito estão sendo desenvolvidos para determinar estratégias de monitoramento de sistemas produtivos visando detectar defeitos e falhas (AVEN; CASTRO, 2009). Em 1976, Christer foi pioneiro e criador da definição de *delay time*. O autor aplicou tal conceito em um contexto de manutenção predial. Após isso, Christer e Waller (1984) utilizou este mesmo conceito em um problema de manutenção industrial.

Esta definição é amplamente aplicada. Isto, pois consegue modelar a degradação de um sistema. Além disso, possibilita encontrar um tempo de inspeção ótimo que minimize o custo por unidade de tempo no longo prazo (ROSS, 1996; WANG, 1997).

A abordagem do *Delay Time* define que um sistema pode estar em três estados diferentes: bom, defeituoso e falho. O processo de falha ocorre em dois estágios, isto é, antes do componente falhar, ele passa um determinado tempo no estado defeituoso. Assim, um defeito chega ao componente em um determinado tempo “x”. Depois de um intervalo de tempo “h” denominado *Delay Time*, o componente falha. Ou seja, o *Delay Time* é o intervalo de tempo, desde a ocorrência de defeito, até o equipamento falhar (BAKER; WANG, 1993). A Figura 1 representa o período de *DT* “h”.

Figura 1 - Representação do *Delay Time*

Fonte: Wang (2008)

2.1.5 Política de manutenção oportuna

Para a tomada de decisão sobre quais ações de manutenção devem ser aplicadas no processo produtivo, são necessários o desenvolvimento e a aplicação de políticas de manutenção. Esta última pode ser definida como um conjunto de ações que visa manter o sistema operando em um nível de serviço pré-estabelecido (JUNCA; SANCHEZ-SILVA, 2013).

Políticas de manutenção ótimas estão sendo desenvolvidas ao longo das últimas décadas através de diferentes técnicas e métodos. Estes visam proporcionar ao sistema uma maior disponibilidade, melhor confiabilidade, bem como, a minimização dos custos de manutenção (WU; CLEMENTS-CROOME, 2005).

As políticas de manutenção mais tradicionais utilizam apenas um tipo de ação de manutenção. Barlow e Proschan (1966) criaram a política de substituição baseada no tempo, que usa apenas a ação de renovação com base no tempo como manutenção preventiva. Christer (1987) desenvolveu a política de inspeção pura. No decorrer dos anos, autores integraram ações de manutenção diferentes, tornando, assim, essas novas políticas mais generalistas. Como exemplo, tem-se Scarf et al. (2009) que desenvolveu uma política híbrida de substituição baseada no tempo e inspeção.

Fatores de qualidade foram incluídos em políticas mais complexas, tornando-as mais próximas da realidade industrial. Por exemplo, Attardi et al. (2005), Scarf et al. (2009) e Scarf e Cavalcante (2010) incluíram as populações heterogêneas. Estas últimas podem caracterizar fornecedores de insumos, equipes de manutenção que possuem qualidades distintas.

Em sistemas produtivos, a manutenção preventiva de determinados componentes críticos pode ser realizada em paradas de reparo ou substituição de outras peças ou

subsistemas. Assim, é possível obter um custo inferior ou um número menor de interrupções do que a manutenção preventiva programada. Isto caracteriza a política de manutenção oportuna ou oportunística. (CAVALCANTE; LOPES; SCARF, 2018)

Um exemplo de aplicação desta política oportunística é a manutenção de um subsistema de engarrafamento em uma linha de produção de refrigerantes quando o suprimento de água fria é perdido devido à falha da bomba (WANG; SCARF; SMITH, 2000). Ou seja, a intenção da parada foi corrigir o problema da bomba, no entanto, a equipe responsável utilizou tal evento como oportunidade de manutenção do subsistema de engarrafamento.

Este tipo de política foi desenvolvido e aplicado em diversos sistemas técnicos, como por exemplo, em infraestrutura de ferrovias (GARAMBAKI; SENEVIRATNE; KUMAR, 2016), em sistemas de cogeração (CAVALCANTE; LOPES, 2015), sistemas de transporte portuário (XIA et al., 2017) e em turbinas eólicas (YILDIRIM; GEBRAEEL; SUN, 2017). Neste último estudo, o autor desenvolveu uma metodologia de predição da degradação e da vida útil de turbinas eólica. Além disso, realizou um comparativo entre o agendamento de uma manutenção ótima para uma turbina e a manutenção de um grupo destas. Este segundo cenário foi definido por ele como manutenção oportunística.

Frequentemente, em sistemas técnicos, oportunidades surgem de acordo com a interdependência estrutural e econômica de componentes. Entretanto, existe uma distinção entre manutenção oportunística e políticas de manutenção de multicomponentes. Esta última visa otimizar ações de manutenção em um conjunto de peças ou subsistemas. Já a oportunística otimiza ações de manutenção de componentes utilizando parada de outros subsistemas (CAVALCANTE; LOPES; SCARF, 2018; DEKKER; SMEITINK, 1991; WILDEMAN; DEKKER; SMIT, 1997).

Utilizar oportunidades em um contexto de manutenção baseado em inspeção e modelado à base do conceito *Delay Time* foi pouco explorado na literatura. Esta conexão foi desenvolvida apenas por alguns autores (BERRADE; SCARF; CAVALCANTE, 2017; CAVALCANTE; LOPES; SCARF, 2018).

2.1.6 Snapshot

O *Snapshot* é uma abordagem que possibilita a representação de eventos de manutenção dentro de um processo produtivo. Ele é obtido através de dados fornecidos pelo

operador ou pelo maquinário. Ainda, pode fornecer informações que embasem modelos de otimização e auxiliem na decisão de quais subsistemas críticos o planejamento e o controle da manutenção deve investir esforços (CHRISTER; WHITELAW, 1983).

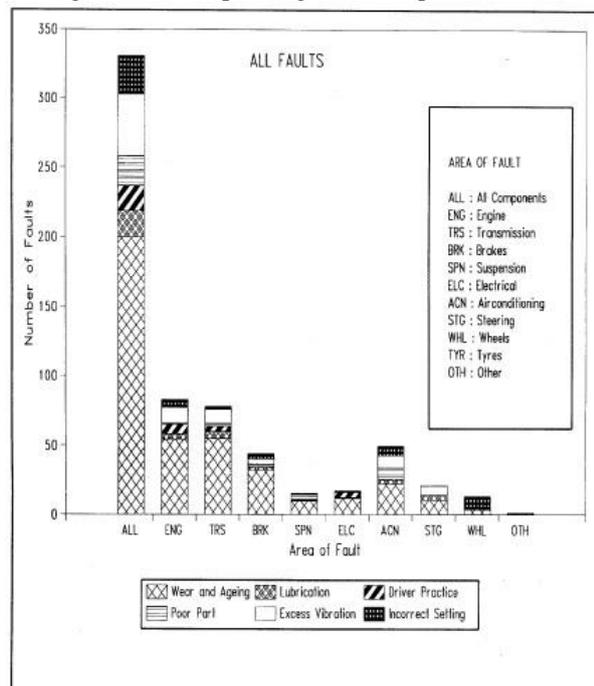
Esta abordagem foi desenvolvida por Christer e Whitelaw (1983) para descrever o setor de manutenção. Para isto, foi desenvolvido um questionário subjetivo onde os funcionários respondiam sobre três aspectos:

- (1) Causa da falha;
- (2) Consequência da falha;
- (3) Meios de prevenção.

A partir destas informações, a função manutenção conseguiu identificar quais foram as causas das falhas mais frequentes, e, com isso, quais os meios de prevenção que deveriam ser utilizados para evitá-las. Não obstante, esta técnica visa obter informações dos sistemas produtivos para embasar ações da gerência de manutenção.

Desa e Christer (2001), utilizaram esta abordagem para analisar as ações de manutenção em uma frota de ônibus. Nele foram redefinidos os serviços de reparo e manutenção, bem como, as suas frequências decorrentes dos dados obtidos a partir dos gráficos do *Snapshot*. A Figura 2 mostra o exemplo de um desses gráficos.

Figura 2 - Exemplo de gráfico Snapshot



Fonte: Desa e Christer (2001)

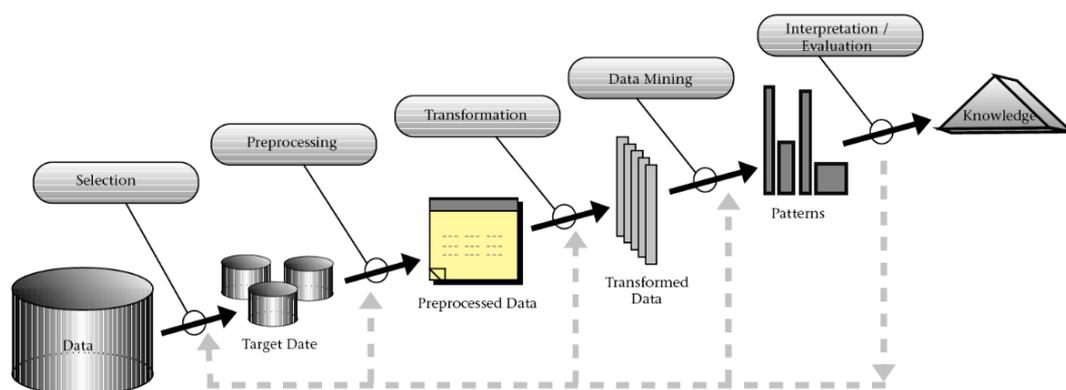
Além desta aplicação, na literatura constam estudos de Snapshot em diversos setores, por exemplo, em equipamentos hospitalares (BAKER; WANG, 1993) e siderurgia (CHRISTER et al., 1997).

2.2 Knowledge Discovery in Databases (KDD)

Em diversas atividades industriais está ocorrendo um aumento na coleta de dados e a necessidade do tratamento deles é um anseio dos gestores e tomadores de decisão, inclusive na área de manutenção. Para isto, nas ciências de dados é bastante utilizado o KDD (*Knowledge Discovery in Databases*) que consiste no desenvolvimento de métodos e técnicas que buscam gerar interpretação prática aos dados (FAYYAD; PIATETSKY-SHAPIRO; SMYTH, 1996).

Um problema que necessita passar pelo processo de KDD, geralmente possui uma grande massa de dados que impossibilita de maneira manual gerar informações e conhecimento que ajudem na tomada de decisão. Então através dos processos de seleção, pré-processamento e transformação dos dados são gerados a partir de técnicas de mineração de dados, padrões e/ou regras que tornam mais compacta e útil as informações contidas naquele banco de dados, este processo está ilustrado na Figura 3. (FAYYAD; PIATETSKY-SHAPIRO; SMYTH, 1996).

Figura 3 – Processo KDD



Fonte: Fayyad et al. (1996)

As etapas do processo KDD são: (1) Seleção dos dados, (2) Pré-processamento dos dados, (3) Transformação dos dados, (4) Mineração de dados e por fim (5) Interpretação e Análise. Primeiramente é feita a escolha de qual parte do banco de dados da empresa será explorada de acordo com o objetivo do processo. No segundo passo, é realizada a limpeza de dados inválidos e repetidos, na terceira etapa os dados são transformados para o formato adequado de acordo com a técnica que será utilizada, na penúltima fase é realizada a mineração de dados, obtendo como resultado regras e/ou padrões que expressem informações úteis à tomada de decisão e por fim é interpretada e analisada a eficácia dessas informações obtidas no contexto prático (FAYYAD; PIATETSKY-SHAPIRO; SMYTH, 1996).

2.3 MINERAÇÃO DE DADOS

No processo KDD, a Mineração de dados é uma etapa primordial, pois nela podem ser utilizados diversas técnicas e algoritmos para extração de regras e padrões pertinentes ao estudo. Aplicações práticas da Mineração de dados são inúmeras e em diversos ramos do conhecimento e atividades industriais e comerciais, como: Detecção de Fraude, Marketing, Investimentos e Telecomunicações (FAYYAD; PIATETSKY-SHAPIRO; SMYTH, 1996). Para cada aplicação, uma necessidade diferente é requerida no processamento e respostas destas técnicas, assim podem-se classificar as tarefas da mineração: (1) Classificação, (2) Agrupamento (*Clustering*), (3) Mineração de Regras de Associação e (4) Mineração de Padrões Sequenciais.

A tarefa de classificação visa categorizar os dados em um conjunto de classes pré-definidas. A tarefa de agrupamento identifica grupos de registros que possuem perfis semelhantes de acordo com seus atributos. Já a tarefa de mineração de regras de associação apresenta as relações entre variáveis de entrada (objetos), onde a ordem dos eventos não é considerada. Por fim, a mineração de padrões sequenciais cujo objetivo é identificar sequências de eventos que ocorrem frequentemente em base de dados temporais (ACCORSI *et al.*, 2017).

Dentre as tarefas de Mineração de dados, a de regra de associação visa determinar quais itens ou objetos tendem a ocorrer em uma mesma transação. Exemplo de aplicação prática clássica é determinar quais itens são comprados por uma mesma pessoa em um

supermercado. Essa categoria de resultado contribui para diversos âmbitos do negócio, como: marketing, logística e vendas (AGRAWAL; SRIKANT, 1994).

A primeira necessidade para o uso desta técnica surgiu para identificar itens que estariam juntos, numa mesma “cesta”, porém algumas aplicações necessitavam da informação da ordem temporal destes itens, de forma que as regras geradas considerassem o momento de tempo que este item ocorreu. Então este algoritmo foi criado e é conhecido como Extração ou Mineração de Padrões Sequenciais (AGRAWAL; SRIKANT, 1995).

2.3.1 Mineração de regras de associação

A mineração por regras de associação é uma poderosa ferramenta de mineração de conhecimento obtida de dados de sistemas fabris (GRABOT, 2020). Esta técnica é baseada em um método de aprendizagem de máquina que identifica relações significativas entre eventos em um grande banco de dados. O resultado desta técnica são algumas regras de alta relevância que fornece informações sobre a operação da máquina e auxilia na tomada de decisão do gestor (CHEMWENO *et al.*, 2016; SARNO *et al.*, 2015).

A descrição formal da aprendizagem por regras de associação é declarada da seguinte forma: Têm-se $\mathbf{I} = \{I_1, I_2, \dots, I_m\}$ como o conjunto de itens e \mathbf{T} como o conjunto de certos itens, chamados de transações, em que, cada transação está associada a uma única *Transaction ID*. A transação T_i consiste em um conjunto de itens, onde $T_i \subseteq \mathbf{I}$. Onde T_i contém X , um conjunto de itens em \mathbf{I} , se $X \subseteq T$. Uma regra de associação de um certo item é denotada como $X \rightarrow Y$, onde $X \subset \mathbf{I}$, $Y \subset \mathbf{I}$ e $X \cap Y = \emptyset$ (ALWATBAN; EMAM, 2014; CHEN; HAN; YU, 1996).

Na mineração por regras de associação, o conhecimento é estruturado em regras de associação do tipo “Se X, então Y”, denominada $X \rightarrow Y$, onde X e Y são conjuntos de itens do banco de dados. X é chamado de precedente e Y de conseqüente de uma regra, porém é importante frisar que a regra não expressa uma relação causal entre X e Y, mas apenas uma co-ocorrência destes itens em transações de um determinado banco de dados (AGRAWAL; SRIKANT, 1994; GRABOT, 2020).

Suporte e confiança são as duas principais medidas das regras de associação. O suporte mensura a frequência de um certo item no banco de dados e é definido como a proporção de

transação $t \in T$ em um certo conjunto T que contém um certo conjunto X , como segue na Equação (1).

$$supp(X) = \frac{|\{t \in T; X \subseteq t\}|}{|T|} \quad (1)$$

A regra $X \rightarrow Y$ possui suporte s se $s\%$ das transações T estão contidas em $X \cup Y$. Confiança mensura a credibilidade da regra. A confiança de uma regra, $X \rightarrow Y$, é definida como a proporção de transações que se o precedente for X haverá uma subsequente Y todo qual a transação precedente é X , representado na Equação (2) (AGRAWAL; SRIKANT, 1994; CHEMWENO *et al.*, 2016).

$$conf(X \rightarrow Y) = \frac{supp(X \rightarrow Y)}{supp(X)} \quad (2)$$

Se os dados da transação forem grandes o suficiente, o suporte poderá ser interpretado como a probabilidade de um determinado conjunto de itens aparecer em uma transação, representação na Equação (3). Já a confiança poderá ser interpretada como a estimativa da probabilidade condicional $P(E_Y|E_X)$, onde $E_X(E_Y)$ denota que o evento do conjunto de itens $X(Y)$ é incluído em uma transação (CHEMWENO *et al.*, 2016; LIU *et al.*, 2017).

$$supp(X \rightarrow Y) = P(X \cup Y) \quad (3)$$

$$conf(X \rightarrow Y) = P(Y|X) = \frac{P(X \cap Y)}{P(X)} \quad (4)$$

Dado um conjunto de dados de transação, o objetivo da aprendizagem de regras de associação é encontrar todas as regras de associação que possuam suporte e confiança maiores que o limiar especificado pelo usuário (gestor). O resultado normalmente aparece da seguinte forma:

- **Se** o evento A ou B ocorrer durante a operação da máquina;
- **Então** o evento C irá ocorrer dentro do Intervalo de Tempo predeterminado com confiança $c\%$.

A aprendizagem de regras de associação geralmente consiste em duas etapas: identificação de grupos de itens grandes e estabelecimento das regras de associação. Diversas abordagens já foram desenvolvidas para descoberta das frequências dos conjuntos de itens, por exemplo: Algoritmo Apriori , Algoritmo Eclat e Algoritmo *frequent-pattern-growth*

(AGRAWAL; SRIKANT, 1994). O Algoritmo Apriori será exemplificado neste estudo por ser a base para algoritmos de mineração de padrões sequenciais.

Adaptado de Chen *et al.* (1996) e Agrawal & Srikant (1994), o exemplo a seguir demonstra como funciona a obtenção de regras de associação através do algoritmo Apriori. Dado um banco de dados de eventos de uma máquina. Onde no intervalo de 30 minutos são coletados os eventos de falha ocorrido no sistema, foram extraídos 5 intervalos diferentes e este equipamento pode sofrer 5 tipos diferentes de falha, como mostrado na Tabela 1.

Seja C_k o conjunto de k conjunto de itens candidatos, onde $k=5$. Cada membro de C_k deste conjunto possui duas informações: seu conjunto de falhas (Cf) e seu contador de suporte (Cs) e L_k é o conjunto de k conjunto de itens frequentes, tanto os conjuntos de itens candidatos quanto os conjuntos de itens frequentes estão representados na Tabela 2.

Tabela 1 - Exemplo de dados para regra de associação

Intervalo de tempo	Tipos de Falha				
	A	B	C	D	E
8:00 - 8:30	1	0	0	1	0
8:30 - 9:00	0	1	1	0	1
9:00 - 9:30	1	0	1	0	1
9:30 - 10:00	0	1	1	0	1
10:00 - 10:30	0	1	1	0	0
Frequência	2	3	4	1	3

Fonte: O autor (2021)

Tabela 2 – Conjunto de itens candidatos (C) e conjunto de itens frequentes (L)

C1		L1		C2		L2		C3		L3	
Cf	Cs	Cf	Cs	Cf	Cs	Cf	Cs	Cf	Cs	Cf	Cs
{A}	2	{A}	2	{AB}	0	{BC}	3	{BCE}	2	{BCE}	2
{B}	3	{B}	3	{AC}	1	{BE}	2				
{C}	4	{C}	4	{AE}	1	{CE}	3				
{D}	1	{E}	3	{BC}	3						
{E}	3			{BE}	2						
				{CE}	3						

Fonte: O autor (2021)

O primeiro passo do algoritmo é contar a frequência dos itens para determinar dos conjuntos com um único item. A posteriori, obtém-se o conjunto de candidatos com apenas

um item, C1, mostrado na Tabela 2. Assumindo um suporte mínimo igual a dois, ou seja, $minsup = 40\%$, L1 será composto pelos elementos de C1 com suporte igual ou maior a 40%. Neste exemplo apenas o conjunto {D} não satisfaz a condição.

Para descobrir o conjunto de itens frequentes com dois tipos de falha, de modo que satisfaça ao suporte mínimo, o algoritmo usa a concatenação $L1*L1$ para gerar os conjuntos candidatos C2. Por exemplo, {A} e {C} geram {AC} e este subconjunto ocorre apenas no intervalo 9:00-9:30, assim sua frequência é igual a um. L2 é determinado a partir do suporte mínimo em relação a cada candidato do C2, assim excluindo os subconjuntos: {AB}, {AC} e {AE}, pois seus suportes são inferiores a dois.

A geração de C3 é obtida a partir de L2 de uma maneira diferente. Os futuros conjuntos de itens candidatos devem manter uma ordem lexicográfica, tal que quando a concatenação $L2*L2$ for feita, o primeiro item de um conjunto de itens seja igual ao primeiro item de outro conjunto de itens e assim sucessivamente. Entretanto, o último item do conjunto deve ser menor, lexicograficamente, que o último item do outro conjunto. Esta regra é demonstrada da seguinte forma:

Dado que:

$$Conj_itens_r = \{r_1, r_2, \dots, r_n\}, Conj_itens_s = \{s_1, s_2, \dots, s_n\} \quad (5)$$

É necessário que:

$$r_1 = s_1, r_2 = s_2, \dots, r_n < s_n \quad (6)$$

No exemplo, o conjunto de itens candidato {BCE}, em C3, foi formado concatenando {BC} com {BE}, pois $B = B$ e $C < E$. Este é o único conjunto possível de ser formado, dado que não existe outra concatenação que satisfaça a condição da equação 6. Exemplificando, a concatenação {BC}*{CE} não satisfaz a equação 6, pois, lexicograficamente, $r_1 = B$ é menor que $s_1 = C$.

A próxima etapa é descobrir as regras de associação. No exemplo, supondo que a confiança mínima de 60% e mantendo o suporte mínimo em 40%, uma regra provável é $BC \rightarrow E$. Para esta regra, a confiança é igual a $supp(BCE)/supp(BC)$, que o resultado é 2/3 ou 66,67%, satisfazendo a confiança mínima.

Para a regra $BC \rightarrow E$, que indica que se ocorreu as falhas B e C no intervalo de tempo antecedente ocorrerá E no intervalo de tempo subsequente, o seu suporte é o percentual de ocorrências de BCE com relação ao total de falhas do exemplo, resultando em 40% ou 2/5. Portanto, está é um regra válida de acordo com os limiares estabelecidos.

Outra provável regra é $B \rightarrow CE$, esta regra possui o mesmo valor de confiança, pois o $\text{supp}(BCE)/\text{supp}(B)$ também é igual a 2/3.

2.3.2 Mineração de padrões sequenciais

A mineração de regras de associação visa encontrar conjuntos de itens que estão em uma mesma transação com determinada mínima frequência em uma base de dados. Entretanto, em algumas aplicações será necessário incluir a ordem temporal dos eventos como informação. Assim, uma massa de dados que possui registros temporais dos eventos necessita de uma abordagem como a mineração de padrões sequenciais, cujo objetivo é encontrar as sequências frequentes de *itemsets*, ordenados no tempo (MOHARANA; SARMAH; RATHORE, 2019).

A declaração formal da mineração de padrões sequenciais é dada da seguinte forma: seja I um conjunto de itens. Uma sequência s é uma lista ordenada de *itemsets* e é chamada por $s = \langle s_1, s_2, \dots, s_n \rangle$, em que cada s_i é um *itemset* e $s_i \subseteq I$.

O algoritmo GSP (*Generalized Sequence Patterns*) foi proposto em Srikant e Agrawal (1996) para mineração de padrões sequenciais e se baseia na propriedade Apriori desenvolvida em Agrawal e Srikant (1994).

GSP é um algoritmo iterativo que busca o conjunto de padrões sequenciais frequentes de comprimento k , denotado por L_k . Cada iteração do algoritmo é realizada em duas etapas: geração de candidatos e cálculo do suporte. A primeira fase é subdividida nas etapas de junção e poda. Na primeira iteração, o GSP encontra o conjunto de todos os itens frequentes no banco de dados (1-sequências). Este conjunto é usado na segunda iteração para o cálculo das 2-sequências candidatas. Uma 2-sequência candidata pode conter dois *itemsets* com um único item frequente ou um *itemset* com dois itens frequentes. Posteriormente, a base de dados é percorrida e o suporte das 2-sequências candidatas é calculada. O algoritmo elimina as sequências candidatas com suporte menor que o limiar mínimo estabelecido como entrada. Da terceira iteração por diante, o conjunto de k -sequências candidatas é gerada a partir da

combinação das $(k-1)$ -sequências frequentes, após isso, as k -sequências candidatas que não são frequentes são podadas e a base de dados é percorrida para o cálculo do suporte das sequências candidatas restantes.

3 METODOLOGIA

O Quadro 1 contém a classificação do presente estudo, conforme a abordagem, objetivos, procedimentos técnicos e natureza:

Quadro 1- Classificação da Pesquisa

ABORDAGEM	Quantitativa e qualitativa
OBJETIVOS	Pesquisa exploratória
PROCEDIMENTOS TÉCNICOS	Pesquisa bibliográfica Estudo de caso
NATUREZA	Pesquisa aplicada

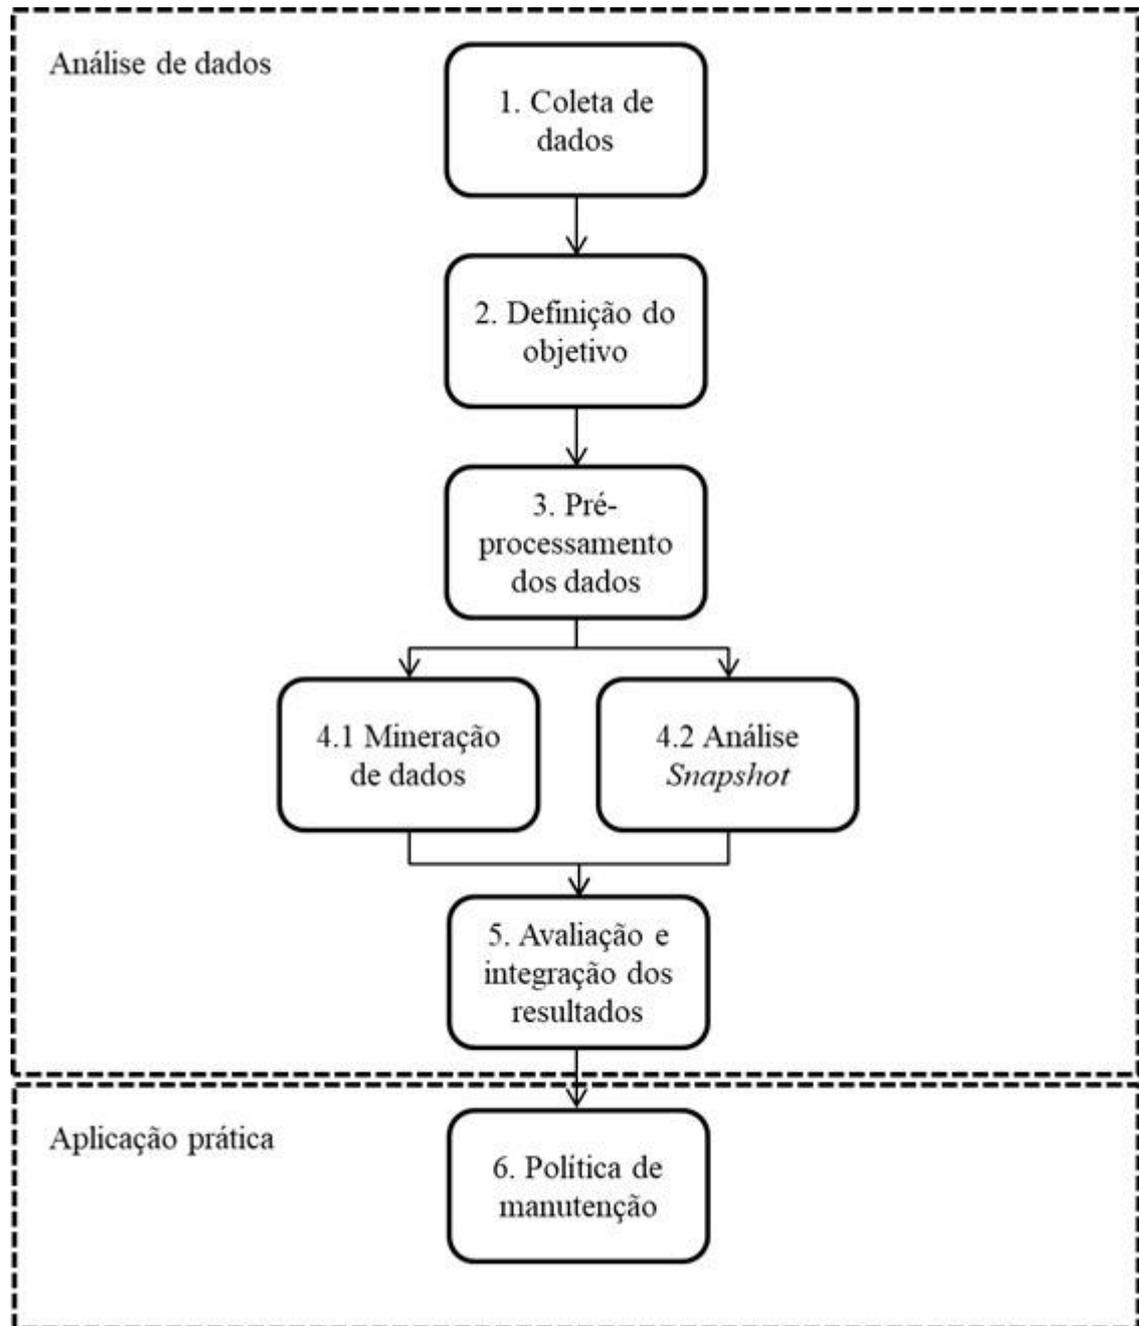
Fonte: O autor (2021)

Este estudo se classifica quanto à abordagem como quantitativa, pois responde questões de pesquisa a partir de dados e métodos matemáticos (HABES *et al.*, 2018). Também, conceitua-se como qualitativo, pois lida com contextos que não podem ser quantificados, mas são igualmente importantes para a análise. Em relação ao objetivo, a pesquisa se classifica como exploratório, pois visa proporcionar maior familiaridade com o problema, adquirir novas percepções (GIL, 2002; SCHOLTEN; BLOK; HAAR, 2015).

Os procedimentos técnicos usados foram pesquisa bibliográfica, pois fornece informações relevantes através de estudos de artigos, livros e teses em banco de dados indexados e estudo de caso, dado que investiga os fenômenos em seu contexto real e objetivo às necessidades imediatas dos diferentes campos da atividade humana (GIL, 2002). No tocante à natureza, esta pesquisa é classificada como aplicada, dado que possui o objetivo de solucionar problemáticas reais (MARCONI; LAKATOS, 2002).

Este estudo compõe-se de duas grandes fases, conforme a Figura 4. A primeira consiste na análise de dados. Ela inicia-se pela coleta de dados, seguindo pela definição do objetivo das análises. Posteriormente, os dados são pré-processados e avaliados conforme a metodologia de mineração de dados e da técnica Snapshot. Finalmente, os resultados serão avaliados e integrados. A segunda grande fase é responsável pelo desenvolvimento da política de manutenção. Cada uma destas etapas será apresentada com mais detalhes no decorrer deste capítulo.

Figura 4 - Etapas da análise do banco de dados e da aplicação prática



Fonte: O autor (2021)

A análise do banco de dados para fim de apoiar decisões no tocante a ações de manutenção será realizada através do processo de Descoberta de Conhecimentos em Banco de Dados (*Knowledge Discovery in Databases – KDD*). Este envolve desde a preparação da base de dados até a apresentação do conhecimento dele extraído pela técnica de mineração. Esse processo não trivial identifica padrões potencialmente úteis e compreensíveis em dados (FAYYAD; PIATETSKY-SHAPIRO; SMYTH, 1996).

Seguindo a primeira etapa, este estudo é realizado a partir de uma base de dados de eventos discretos de uma grande empresa de manufatura na França. Esta empresa trabalha com monitoramento de máquinas utilizando sensores dedicados. Por vezes, este método é custoso e tecnicamente inviável em situações especiais.

O banco de dados fornecido pela companhia foi registrado por um Controlador Lógico Programável (CLP) e por um *Network Control Unit* (NCU). A tabela 3 apresenta uma amostra dos dados coletados com as informações do código do evento, a descrição do evento, a data de ocorrência e o controlador que registrou o evento.

O banco de dados original compõe uma planilha de dados de 23 Mb com quinhentas mil linhas e onze colunas. Isto totaliza cinco milhões e quinhentas mil células, registrando eventos no período entre 7 de Janeiro de 2015 e 6 de Dezembro de 2015.

Tabela 3– Amostra do banco de dados

Código	Descrição do evento	Data	Controlador
510011	Função auxiliar do canal 1 bloqueada	11/06/2015 06:10	CLP
510229	Eixo principal não destravado - freio do eixo em serviço	26/06/2015 21:53	CLP
10208	Para retomar a execução do programa ative o canal 1 'Início do Programa'	07/07/2015 20:24	NCU
601115	O eixo principal não está no modo de operação como eixo C	21/07/2015 12:57	CLP

Fonte: O autor (2021)

A segunda etapa coincide com o objetivo do próprio estudo, que visa identificar relações entre eventos de dados discretos de um sistema fabril para auxiliar na tomada de decisão do gestor de manutenção.

A terceira etapa é o pré-processamento dos dados, que consiste em um dos maiores desafios de trabalhar com *Big Data*, pois os bancos de dados geralmente não são estruturados, o que causa uma dificuldade de extrair informações e conhecimento para tomada de decisão.

Para tornar os dados dos eventos adequados a mineração de padrões sequenciais será necessário seguir os seguintes passos de pré-processamento:

1. Identificar o padrão de como os dados estão organizados;
2. Extrair os dados que estão fora do padrão;
3. Excluir os dados inválidos;
4. Excluir os dados repetidos;
5. Organizar os dados extraídos fora do padrão;
6. Reinsere os dados extraídos, agora dentro do padrão;
7. Criar um dicionário de códigos.

A quarta etapa do estudo divide-se em duas: (1) mineração de dados e (2) a análise *Snapshot*.

Em (1), foi escolhida, através do Algoritmo GSP, o uso de mineração de padrões sequenciais, pois é de fácil implementação e traz flexibilidade em suas respostas. O algoritmo GSP é usado em diversas aplicações de setores distintos da indústria, por exemplo, em análise de mercado, classificação de imagens médicas e análise do uso de dados da internet (HIPP; GÜNTZER; NAKHAEIZADEH, 2000; KUMAR; RUKMANI, 2010).

Embora os dados iniciais dos eventos contenham várias dimensões, os que se fazem necessários para o estudo são: o código do evento e a data de ocorrência associada. A mineração de padrões sequenciais busca tratar os eventos que ocorrem em determinado intervalo de tempo como uma transação. O intervalo de tempo é selecionado de acordo com a frequência em que ocorrem os eventos no sistema, como 60 minutos, 90 minutos, 120 minutos ou outro período escolhido pelo especialista. Dentro de cada intervalo de tempo, eventos idênticos deverão ser mesclados, ou seja, os eventos apenas serão gravados uma vez dentro de cada transação, mesmo que ele ocorra diversas vezes dentro desse intervalo.

Antes de definir os padrões sequenciais é necessário descobrir a frequência dos conjuntos de itens do banco de dados dos eventos discretos. A abordagem *bottom-up* é usada para estender os conjuntos de itens frequentes em um item em cada etapa de geração de candidatos. Ou seja, primeiro verificam-se conjuntos com apenas um elemento, depois dois elementos e assim por diante. O algoritmo é finalizado quando não existe frequência de conjuntos de itens que satisfaçam o limiar mínimo de suporte, definido pelo usuário.

O algoritmo GSP é composto por três etapas. Primeiramente verifica-se a ocorrência dos eventos para determinar todos os conjuntos de eventos com um único item. Posteriormente, no k -ésimo passo, o algoritmo cria todos os conjuntos de itens candidatos C_k se estendendo as frequências dos conjuntos de itens anteriores L_{k-1} pelo julgamento do algoritmo GSP. Por fim, os conjuntos de itens candidatos são removidos aos quais não satisfazem o limite mínimo de suporte.

A segunda etapa da fase 4 é a análise *Snapshot*. Neste estudo, além dos três aspectos da manutenção abordados por Christer e Whitelaw (1983), quais sejam, causa, consequência e meios de prevenção da falha, acrescentaram-se mais dois pontos:

- Parte do equipamento em que ocorreu o evento anômalo;
- Severidade do evento.

Todos os tipos de acontecimentos anômalos do sistema foram associados a cada um desses aspectos. Ou seja, cada evento aconteceu em uma parte do equipamento, teve uma causa associada, gerou um tipo de consequência, possui uma certa severidade e um meio de prevenção específico. Em seguida, com o resultado do pré-processamento, foi possível calcular a quantidade de cada uma dessas classificações para, posteriormente, serem analisadas. Por fim, foram gerados gráficos, que contém informações de pares desses aspectos.

A última etapa da análise de dados consiste na análise e a integração dos resultados da mineração e do Snapshot. Estas informações servirão de base para a parametrização dos dados de entrada do modelo, como o parâmetro de escala da distribuição Weibull, este que representa o intervalo de tempo até a chegada do defeito, escolha do tipo de política de manutenção, na escolha do sistema crítico do centro de usinagem que será estudado nesta política.

Finalmente, para desenvolver a política de manutenção realizaram-se três etapas: (1) descrição das características do sistema, (2) modelagem da política através do modelo analítico e (3) aplicação numérica do modelo desenvolvido. Na etapa (1) é detalhado o maquinário analisado, comportamento da falha do componente, descrição das ações de manutenção que podem ser realizadas e dos respectivos custos associados. Já na etapa (2) são descritas todas as possibilidades de cenários de renovação do ciclo de vida com suas devidas probabilidades, custo e tamanho do ciclo de vida esperados.

Por fim, na etapa (3) a partir dos parâmetros de entrada, será possível minimizar o custo por unidade de tempo no longo prazo, bem como, determinar os valores das variáveis de decisão ótimas (intervalo de tempo entre inspeções, número de inspeções, instante de tempo para abertura da janela de oportunidade e instante de tempo para manutenção preventiva programada). Por fim, é feita a análise de sensibilidade, onde é avaliada a relação entre a produção de peças de geometria complexas e o custo por unidade de tempo do componente no estado defeituoso, também é feita uma comparação entre os custos de renovação feitos por operadores e por uma equipe de manutenção especializada e por fim é analisado os parâmetros das distribuições das sub-populações “forte” e “fraca”, que representam a qualidade na renovação do componente e o parâmetro de mistura.

4 ANÁLISE DE DADOS ATRAVÉS DA MINERAÇÃO DE PADRÕES SEQUENCIAIS E DA ANÁLISE SNAPSHOT

Nesta seção serão demonstrados os passos da mineração de padrões sequenciais, assim como do estudo Snapshot do banco de dados, serão apresentados os resultados e estes serão analisados e servirão de informação para aplicação prática, onde será desenvolvida uma política de manutenção na seção seguinte.

4.1 DESENVOLVIMENTO DA MINERAÇÃO DE PADRÕES SEQUENCIAIS ATRAVÉS DO ALGORITMO GSP

O desenvolvimento da mineração de padrões sequenciais consiste nas seguintes etapas: (1) coleta de dados, (2) desenvolvimento do objetivo da análise de dados, (3) escolha da técnica de mineração de dados, (4) pré-processamento dos dados, (5) escolha das métricas de desempenho, (6) mineração dos dados. O pré-processamento de dados servirá também para análise Snapshot e por fim ocorrerá uma análise e integração dos resultados para obtenção de informações relevantes de modo a modelar uma política de manutenção condizente à realidade desse processo produtivo.

4.1.1 Coleta dos dados

O banco de dados que será estudado é advindo de um centro de usinagem, este que é um sistema que permite realizar desenvolvimento de produtos, dado que desempenha ações de montagem e de criação de peças mecânicas. Engloba, integral ou parcialmente, diversas operações básicas de fabricação, tais como torneamento, fresamento, furação, retificação, etc. Atualmente, é comum encontrar a sigla CNC, “Comando Numérico Computadorizado”, quando se refere a centro de usinagem. Essa tecnologia aprimora o uso do centro de usinagem, uma vez que automatiza as diversas operações básicas e cria um ambiente propício à obtenção de dados. Além disso, traz versatilidade e flexibilidade aos projetos, possibilitando a criação de peças com geometrias complexas e tolerâncias dimensionais reduzidas (WANG; JIA; JIANG, 2001).

Quando se refere à usinagem, é comum citar o termo máquinas ferramentas. Máquinas ferramentas são máquinas que operam na fabricação de peças através da movimentação mecânica de um conjunto de ferramentas. Normalmente, essas ferramentas são citadas como ferramentas de corte e servem para cortar uma variedade de materiais. Elas devem ter dureza maior que a do material a ser cortado e diversos parâmetros operacionais, tais como velocidade de corte e avanço, deve ser definido em cada operação, já que uma má combinação pode gerar na perda do material e na perda da ferramenta de corte (WANG; JIA; JIANG, 2001).

O banco de dados foi extraído de controladores lógico-programáveis (CLP – *Programmable Logic Controllers*) e possui um vasto número de eventos de falhas, reparos/ajustes, erros de programação passíveis de ações de manutenção. Nesta base de dados existem registros destes eventos datados de 7 de Janeiro de 2015 à 7 de Dezembro de 2015, armazenados em um arquivo tipo planilha com 500.000 linhas, 12 colunas e 151 tipos diferentes de eventos.

4.1.2 Desenvolvimento do objetivo da análise de dados

Dado a grande massa de dados de eventos de manutenção em um sistema complexo como um centro de usinagem, o estudo visa encontrar padrões ocultos que auxiliem no gerenciamento da manutenção. Na mineração de dados não é assegurado que em seus resultados existe uma relação de causa e efeito, porém os padrões encontrados com o auxílio de um especialista e do gestor de manutenção podem aprimorar as práticas que garantam uma redução de custos e uma melhor confiabilidade do sistema.

4.1.3 Escolha da técnica de mineração de dados

Para encontrar padrões relacionados com eventos de manutenção é primordial analisá-los a partir da ordem com que esses eventos ocorreram, a hipótese deste estudo é que um evento que ocorre frequentemente antes de outro evento que seja crítico, que induza a falha, em intervalos de tempo diferentes pode ser uma “assinatura de falha”, ou um defeito seguindo a lógica do *delaytime*, esta informação é valiosa para a criação de uma política de manutenção.

Dado esta peculiaridade da análise de eventos de manutenção foi realizada uma pesquisa na literatura e a mineração de padrões sequenciais a partir do algoritmo GSP que é baseado no algoritmo Apriori foi escolhida, dado que possui a capacidade de considerar a ordem dos eventos.

4.1.4 Pré-processamento dos dados

Os eventos armazenados no CLP são como alarmes que quando algo no sistema está anormal e até esta anormalidade ser resolvida o controlador emite diversos alarmes de um mesmo evento seguidamente. Além disso, são armazenados eventos com informações vazias e também com informações deslocadas. Por esses motivos é necessária a realização de um pré-processamento nos dados.

Todo o processo de manipulação dos dados foi realizado através da linguagem de programação Python, mais precisamente utilizando a biblioteca Pandas. Os passos para este pré-processamento foram:

1. Exclusão de colunas não relevantes: para o estudo de mineração de padrões sequenciais serão necessárias apenas as colunas do código do evento, da descrição do evento e a coluna com a data e hora. Assim as demais nove colunas foram excluídas.
2. Identificação do padrão das informações e separação de eventos que estavam fora do padrão: observou-se que alguns eventos como o “6413” estava com as informações de data e hora deslocadas, já que a descrição do evento é extensa e foi automaticamente dividida em duas colunas, ocasionando este erro. Todos os eventos com essa anomalia foram separados, reorganizados e reintegrados ao banco de dados.
3. Exclusão de dados inválidos: dentro da base de dados foram encontradas linhas com informações vazias, preenchidos com o símbolo “+++++++”, estas linhas foram excluídas;
4. Exclusão dos eventos repetidos: dado que o controlador repetia o evento anômalo até este ser resolvido, foi necessária a exclusão das linhas que possuíam o mesmo código e que estavam separadas por um intervalo bem pequeno de tempo, caracterizando a mesma ocorrência do evento.

5. Criação do dicionário de eventos: por fim, foi criado um arquivo tipo planilha com todos os 151 eventos e suas descrições. Assim facilitando a análise a posteriori da possível relação de causa e efeito dos padrões encontrados pela mineração de dados.

4.1.5 Escolha das métricas de desempenho

Para avaliação da relevância dos padrões encontrados é necessário escolher métricas de desempenho destes padrões, a escolha foi realizada visando uma fácil compreensão do significado destas métricas para um especialista no sistema e para um gerente de manutenção. Então serão utilizadas duas métricas: Suporte ou Cobertura e a Confiança.

O Suporte ou Cobertura, que em termos práticos, significa em quantos intervalos de tempo aqueles eventos que estão no padrão aparecem divididos pelo número total de intervalos de tempo estudado, ou seja, se são eventos que aparecem juntos e em determinada ordem de tempo em um grande número de intervalos de tempo. A Confiança, que representa uma probabilidade condicional, dado que o evento precedente aconteceu em quantas ocasiões o evento subsequente ocorreu no mesmo intervalo de tempo.

Estas duas métricas são as mais utilizadas na literatura e são aquelas que apresentam informações práticas para o gerente de manutenção, adicionando a informações de um especialista do sistema para garantia de causa e efeito estes padrões oferecem subsídio importante para desenvolvimento de políticas de manutenção eficientes.

4.1.6 Mineração de Dados

Dado a escolha do uso da mineração de padrões sequenciais como técnica para a análise de dados devido à importância da ordem dos eventos, foi implementado o algoritmo GSP que realiza esta técnica de mineração através da linguagem de programação Python. Para isso foi determinado como suporte mínimo 10%, ou seja, apenas padrões que possuam eventos que juntos e ordenados estão em pelo menos 10% dos intervalos de tempo totais. Além disso, foi gerado padrões para tamanho de intervalos de tempo diferentes: 60 minutos, 90 minutos e 120 minutos. A

Tabela 4 mostra os eventos mais frequentes e o Fonte: O autor (2021)

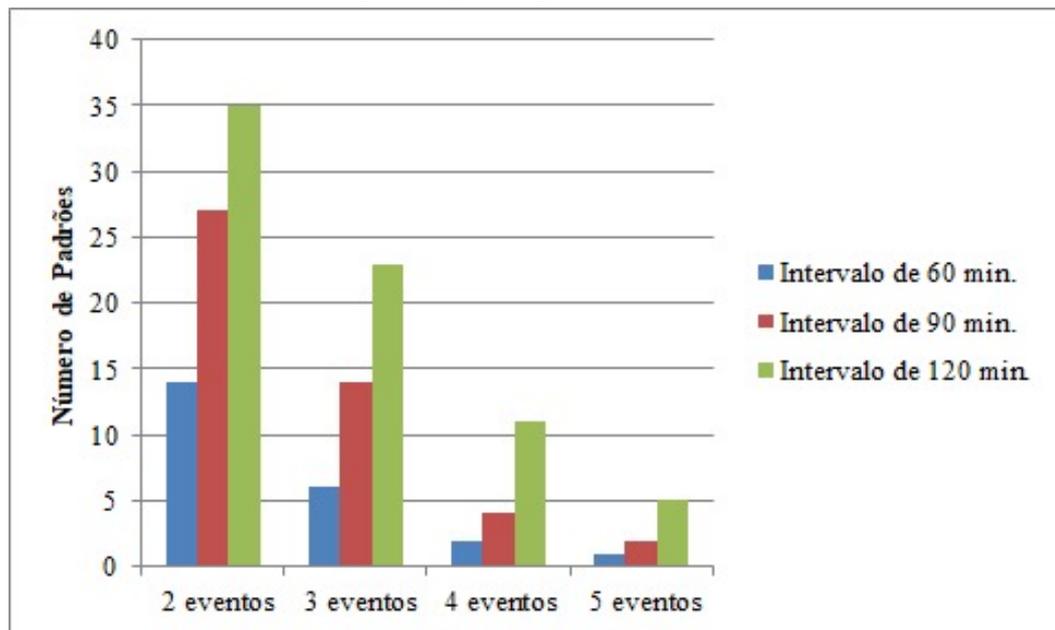
Gráfico 1 demonstra quantos padrões foram gerados com 2, 3, 4 e 5 eventos dentro destes três intervalos diferentes.

Tabela 4 – Lista de Eventos mais frequentes

Código	Descrição do evento	Frequência
[600914]	Acoplamento de Alimentação de Fluido não estanque	80,44%
[6413]	Ferramenta de corte atingiu seu limite de uso	79,78%
[601011]	Mandril porta fresa fora do estado de parada	69,45%
[700025]	Pressão de aperto ausente no painel 2	37,80%
[700704]	Excedida a umidade relativa do ar na caixa elétrica.	28,57%
[601114]	O redutor do eixo principal está ativo	27,25%
[700205]	Temperatura excessiva do óleo hidráulico	24,84%
[510012]	Modo de funcionamento não conforme	22,86%

Fonte: O autor (2021)

Gráfico 1 - Número de padrões gerados para intervalos de 60, 90 e 120 minutos



Fonte: O autor (2021)

Para análise dos padrões relevantes foram escolhidos apenas aqueles que possuem dois eventos, um antecedente e um consequente, pois assim fica mais fácil a interpretação pelo gerente de manutenção e observou-se que a partir dos padrões de três ou mais eventos fica concentrado apenas para os eventos mais frequentes do banco de dados, assim possivelmente representa uma relação de co-ocorrência e não necessariamente de causa e efeito. As tabelas 5, 6 e 7 apresentam quais são os padrões de 2 eventos para os intervalos de tempo de 60, 90 e 120 minutos, respectivamente.

Tabela 5 – Padrões encontrados para o intervalo de tempo de 60 minutos

Antecedente		Consequente		Suporte	Confiança
[601011]	Mandril porta fresa fora do estado de parada	[600914]	Acoplamento de Alimentação de Fluido não estanque	0,6176	0,8892
[700143]	Carro porta luneta 1 acoplado	[700147]	Contra ponto / Cabeçote móvel desbloqueado	0,1055	0,8421
[700146]	Carro porta luneta 1 bloqueado	[700143]	Carro porta luneta 1 acoplado	0,1011	0,8070
[700454]	Porta de segurança da ferramenta de corte aberta	[601011]	Mandril porta fresa fora do estado de parada	0,4110	0,7220
[700704]	Excedida a umidade relativa do ar na caixa elétrica.	[6413]	Ferramenta de corte atingiu seu limite de uso	0,3868	0,5846
[6413]	Ferramenta de corte atingiu seu limite de uso	[700454]	Porta de segurança da ferramenta de corte aberta	0,4374	0,5482
[700025]	Pressão de aperto ausente no painel 2	[6413]	Ferramenta de corte atingiu seu limite de uso	0,1802	0,4767
[700454]	Porta de segurança da ferramenta de corte aberta	[600914]	Acoplamento de Alimentação de Fluido não estanque	0,2132	0,3745
[600914]	Acoplamento de Alimentação de Fluido não estanque	[700454]	Porta de segurança da ferramenta de corte aberta	0,2813	0,3497
[600914]	Acoplamento de Alimentação de Fluido não estanque	[6413]	Ferramenta de corte atingiu seu limite de uso	0,2484	0,3087
[6413]	Ferramenta de corte atingiu seu limite de uso	[601011]	Mandril porta fresa fora do estado de parada	0,2088	0,2617
[700454]	Porta de segurança da ferramenta de corte aberta	[6413]	Ferramenta de corte atingiu seu limite de uso	0,1099	0,1931
[600914]	Acoplamento de Alimentação de Fluido não estanque	[700025]	Pressão de aperto ausente no painel 2	0,1077	0,1339

Fonte: O autor (2021)

Tabela 6- Padrões encontrados para o intervalo de tempo de 90 minutos

Antecedente		Consequente		Suporte	Confiança
[700336]	Parada de teste 1.1 dinamização forçada	[700337]	Parada de teste 1.2 dinamização forçada	0,1235	0,9767
[700337]	Parada de teste 1.2 dinamização forçada	[700338]	Parada de teste 2.2 dinamização forçada	0,1206	0,9318
[601011]	Mandril porta fresa fora do estado de parada	[600914]	Acoplamento de Alimentação de Fluido não estanque	0,7029	0,9228
[700335]	Parada de teste nos eixos 1 ao 8	[700336]	Parada de teste 1.1 dinamização forçada	0,1118	0,8837

[700135]	Contra ponto / Cabeçote móvel acoplado	[700137]	Contra ponto / Cabeçote móvel desbloqueado	0,1235	0,8750
[700146]	Carro porta luneta 1 bloqueado	[700143]	Carro porta luneta 1 acoplado	0,1206	0,8542
[700143]	Carro porta luneta 1 acoplado	[700147]	Contra ponto / Cabeçote móvel desbloqueado	0,1176	0,8333
[700136]	Contra ponto / Cabeçote móvel bloqueado	[700135]	Contra ponto / Cabeçote móvel acoplado	0,1118	0,7917
[700454]	Porta de segurança da ferramenta de corte aberta	[601011]	Mandril porta fresa fora do estado de parada	0,4735	0,7778
[510219]	Reservatório de água filtrada cheio até o nível max	[510219]	Reservatório de água filtrada cheio até o nível max	0,1088	0,6852
[6413]	Ferramenta de corte atingiu seu limite de uso	[700454]	Porta de segurança da ferramenta de corte aberta	0,5000	0,5862
[510011]	Função auxiliar canal 1 bloqueado	[700146]	Carro porta luneta 1 bloqueado	0,1147	0,5652
[700025]	Pressão de aperto ausente no painel 2	[6413]	Ferramenta de corte atingiu seu limite de uso	0,2412	0,5616
[601114]	O redutor do eixo principal está ativo	[6413]	Ferramenta de corte atingiu seu limite de uso	0,1353	0,5476
[700704]	Excedida a umidade relativa do ar na caixa elétrica.	[6413]	Ferramenta de corte atingiu seu limite de uso	0,1588	0,5047
[700454]	Porta de segurança da ferramenta de corte aberta	[600914]	Acoplamento de Alimentação de Fluido não estanque	0,2588	0,4251
[600914]	Acoplamento de Alimentação de Fluido não estanque	[6413]	Ferramenta de corte atingiu seu limite de uso	0,3382	0,3938
[600914]	Acoplamento de Alimentação de Fluido não estanque	[700454]	Porta de segurança da ferramenta de corte aberta	0,3324	0,3870
[700025]	Pressão de aperto ausente no painel 2	[700025]	Pressão de aperto ausente no painel 2	0,1529	0,3562
[6413]	Ferramenta de corte atingiu seu limite de uso	[601011]	Mandril porta fresa fora do estado de parada	0,2559	0,3000
[700025]	Pressão de aperto ausente no painel 2	[700704]	Excedida a umidade relativa do ar na caixa elétrica.	0,1059	0,2466
[700454]	Porta de segurança da ferramenta de corte aberta	[6413]	Ferramenta de corte atingiu seu limite de uso	0,1500	0,2464
[600914]	Acoplamento de Alimentação de Fluido não estanque	[700025]	Pressão de aperto ausente no painel 2	0,1529	0,1781
[6413]	Ferramenta de corte atingiu seu limite de uso	[600914]	Acoplamento de Alimentação de Fluido não estanque	0,1235	0,1448
[6413]	Ferramenta de corte atingiu seu limite de uso	[700704]	Excedida a umidade relativa do ar na caixa elétrica.	0,1176	0,1379
[6413]	Ferramenta de corte atingiu seu limite de uso	[700025]	Pressão de aperto ausente no painel 2	0,1147	0,1345

Tabela 7- Padrões encontrados para o intervalo de tempo de 120 minutos

Antecedente		Consequente		Suporte	Confiança
[700336]	Parada de teste 1.1 dinamização forçada	[700337]	Parada de teste 1.2 dinamização forçada	0,1556	0,9767
[601011]	Mandril porta fresa fora do estado de parada	[600914]	Acoplamento de Alimentação de Fluido não estanque	0,8000	0,9474
[700337]	Parada de teste 1.2 dinamização forçada	[700338]	Parada de teste 2.2 dinamização forçada	0,1519	0,9318
[510308]	Porta de correr esquerda aberta	[510309]	Porta de correr direita aberta	0,1000	0,9000
[700335]	Parada de teste nos eixos 1 ao 8	[700336]	Parada de teste 1.1 dinamização forçada	0,1407	0,8837
[700135]	Contra ponto / Cabeçote móvel acoplado	[700137]	Contra ponto / Cabeçote móvel desbloqueado	0,1370	0,8605
[700143]	Carro porta luneta 1 acoplado	[700147]	Contra ponto / Cabeçote móvel desbloqueado	0,1370	0,8605
[700146]	Carro porta luneta 1 bloqueado	[700143]	Carro porta luneta 1 acoplado	0,1333	0,8372
[700454]	Porta de segurança da ferramenta de corte aberta	[601011]	Mandril porta fresa fora do estado de parada	0,5259	0,8161
[700136]	Contra ponto / Cabeçote móvel bloqueado	[700135]	Contra ponto / Cabeçote móvel acoplado	0,1296	0,8140
[510219]	Reservatório de água filtrada cheio até o nível max	[510219]	Reservatório de água filtrada cheio até o nível max	0,1222	0,6735
[700338]	Parada de teste 2.2 dinamização forçada	[27006]	Eixo MAX1 bloqueio de impulso em andamento	0,1111	0,6667
[6413]	Ferramenta de corte atingiu seu limite de uso	[700454]	Porta de segurança da ferramenta de corte aberta	0,5556	0,6098
[700025]	Pressão de aperto ausente no painel 2	[6413]	Ferramenta de corte atingiu seu limite de uso	0,2778	0,6000
[700704]	Excedida a umidade relativa do ar na caixa elétrica.	[6413]	Ferramenta de corte atingiu seu limite de uso	0,2000	0,5870
[510219]	Reservatório de água filtrada cheio até o nível max	[6413]	Ferramenta de corte atingiu seu limite de uso	0,1037	0,5714
[510011]	Função auxiliar canal 1 bloqueado	[700146]	Carro porta luneta 1 bloqueado	0,1259	0,5574
[67834]	Busca em bloco: controlar a posição: FS1=0	[601114]	O redutor do eixo principal está ativo	0,1000	0,5510
[700454]	Porta de segurança da ferramenta de corte aberta	[600914]	Acoplamento de Alimentação de Fluido não estanque	0,3333	0,5172
[510011]	Função auxiliar canal 1 bloqueado	[700136]	Contra ponto / Cabeçote móvel bloqueado	0,1111	0,4918

[600914]	Acoplamento de Alimentação de Fluido não estanque	[6413]	Ferramenta de corte atingiu seu limite de uso	0,4074	0,4472
[600914]	Acoplamento de Alimentação de Fluido não estanque	[700454]	Porta de segurança da ferramenta de corte aberta	0,3963	0,4350
[10208]	Canal 1 Continue o programa com início de ciclo	[601114]	O redutor do eixo principal está ativo	0,1037	0,4308
[601114]	O redutor do eixo principal está ativo	[6413]	Ferramenta de corte atingiu seu limite de uso	0,1593	0,4019
[6413]	Ferramenta de corte atingiu seu limite de uso	[601011]	Mandril porta fresa fora do estado de parada	0,3000	0,3293
[700205]	Temperatura excessiva do óleo hidráulico	[6413]	Ferramenta de corte atingiu seu limite de uso	0,1074	0,3187
[700704]	Excedida a umidade relativa do ar na caixa elétrica.	[700025]	Pressão de aperto ausente no painel 2	0,1074	0,3152
[700454]	Porta de segurança da ferramenta de corte aberta	[6413]	Ferramenta de corte atingiu seu limite de uso	0,1852	0,2874
[700025]	Pressão de aperto ausente no painel 2	[700704]	Excedida a umidade relativa do ar na caixa elétrica.	0,1259	0,2720
[600914]	Acoplamento de Alimentação de Fluido não estanque	[700025]	Pressão de aperto ausente no painel 2	0,1852	0,2033
[6413]	Ferramenta de corte atingiu seu limite de uso	[600914]	Acoplamento de Alimentação de Fluido não estanque	0,1407	0,1545
[6413]	Ferramenta de corte atingiu seu limite de uso	[700704]	Excedida a umidade relativa do ar na caixa elétrica.	0,1407	0,1545
[6413]	Ferramenta de corte atingiu seu limite de uso	[700025]	Pressão de aperto ausente no painel 2	0,1296	0,1423

Fonte: O autor (2021)

Os padrões sequenciais apresentados nas tabelas acima foram ordenados a partir do parâmetro Confiança. Este indicador representa a probabilidade condicional de: se o evento antecedente ocorrer, então o consequente ocorrerá no mesmo intervalo de tempo. É possível notar que eventos de paradas de teste, alertas ou de pequenos reparos são predominantes nos padrões gerados.

Podem-se destacar alguns eventos relacionados com o sistema de lubrificação da máquina, com ferramenta de corte e com o subsistema que integra o contra ponto, o cabeçote móvel e o carro porta luneta. Possivelmente, alguns destes padrões são evidentes para um especialista em centros de usinagem. No entanto, outros padrões podem revelar a relação que normalmente são ocultas ao profissional. Estas informações serão analisadas em conjunto com o resultado da análise *Snapshot* da próxima seção. Tais resultados servirão de base para a construção da política de manutenção.

4.2 ANÁLISE SNAPSHOT

Os dados advindos do pré-processamento serviram de base da análise do Snapshot. Está foi adaptada do estudo de Christer e Whitelaw (1983) e foram acrescentadas as informações originais: Causa, Consequência e Modo de evitar as falhas, duas novas classificações: Severidade do evento anômalo e Parte do equipamento que necessita da ação de manutenção. O Quadro 2 mostra todas as cinco informações coletadas e suas possíveis respostas.

Quadro 2 – Classificações da análise *Snapshot*

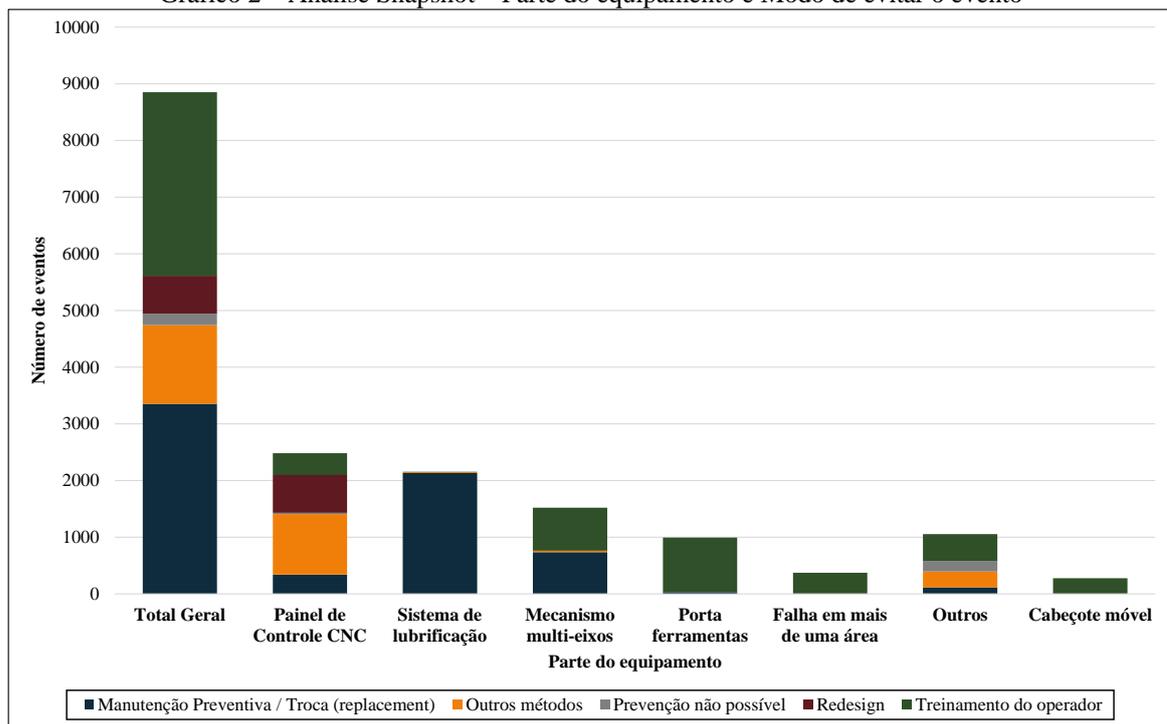
Modo de prevenção	Parte do equipamento	Causa do evento	Severidade do evento	Tipo da Anomalia
Manutenção preventiva/Troca	Paine de Controle CNC	Desgaste ou idade	Ajuste	Elétrica
Prevenção não possível	Hidráulico	Erro de operação	Falha	Hidráulica
Redesign	Mecanismo multi-eixos	Erro de programação	Inspeção	Mecânica
Treinamento do operador	Porta ferramentas	Limpeza	Operação não conforme	Software
Outros métodos	Cabeçote móvel	Outros	Teste	Alerta
	Falha em mais de uma área		Outros	
	Outros			

Fonte: O autor (2021)

Os 151 eventos distintos foram classificados nestas cinco categorias a partir da informação de descrição de cada evento e do Manual do equipamento. Após isso, foram contabilizados os resultados de cada categoria para os 8841 eventos que totalizam o banco de dados após pré-processamento. Assim foi possível gerar os gráficos dos seguintes pares de categorias: (1) Parte do equipamento e Modo de evitar o evento ilustrado no Gráfico 2, (2) Tipo de anomalia e Severidade do evento representado no gráfico 3, (3) Tipo de anomalia e Modo de Prevenção no gráfico 4, (4) Parte do equipamento e Causa do evento no gráfico 5, (5) Parte do Equipamento e Severidade do evento no gráfico 6.

No Gráfico 2, podemos observar que de modo geral, os eventos que necessitam de ações de manutenção, podem ser prevenidos em sua grande parte por manutenção preventiva e treinamento do operador, o primeiro indica a importância da implementação de uma política de manutenção e o segundo pode ser interpretado ou como a necessidade de melhoria dos colaboradores que realizam as ações de manutenção ou a necessidade de contratação de uma equipe de manutenção especializada. Um destaque específico é que a parte hidráulica do equipamento pode ser prevenida quase em sua totalidade por manutenção preventiva.

Gráfico 2 – Análise Snapshot – Parte do equipamento e Modo de evitar o evento



Fonte: O autor (2021)

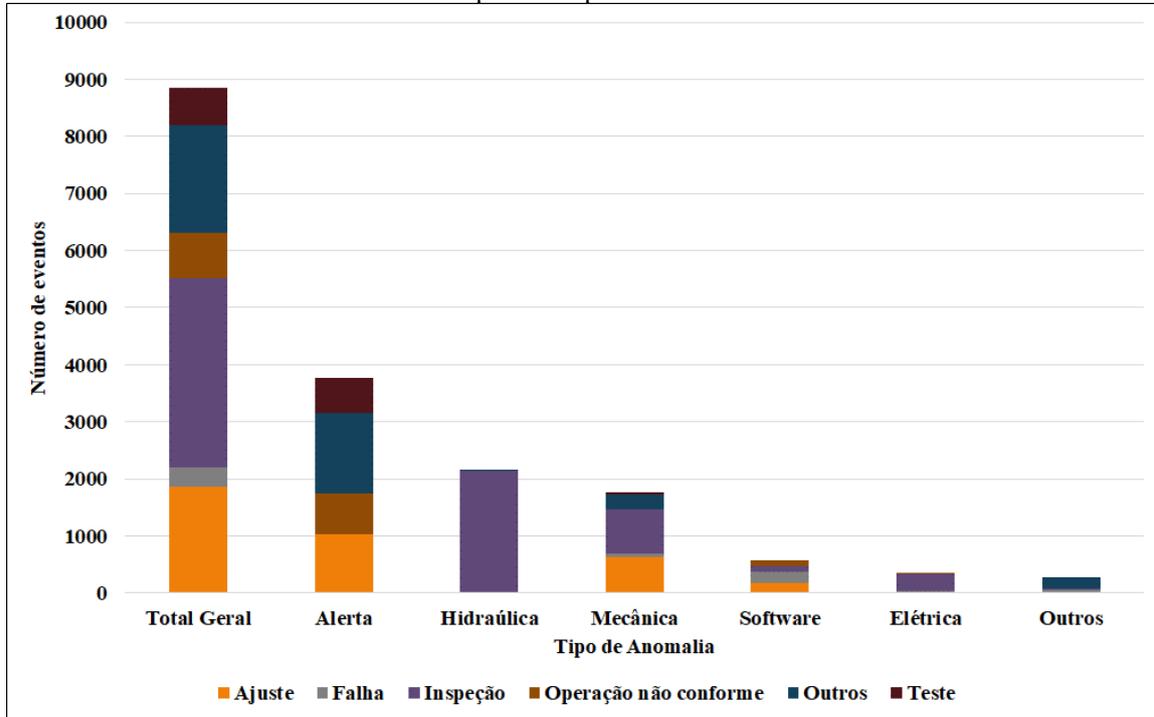
A análise do gráfico 3 indica que relacionado à severidade dos eventos, destaca-se o considerável número de eventos de inspeções rotineiras do centro de usinagem e no tocante ao Tipo de anomalia, seus maiores representantes foram alertas e problemas no sistema hidráulico. Essas informações demonstram que o sistema de coleta de dados está estruturado mais como um dispositivo de alerta para os operadores da máquina do que um sistema de coleta de dados para obtenção de informações úteis no gerenciamento da manutenção.

O gráfico 4 ressalta novamente a grande quantidade de eventos que são alertas e a predominância do modo de prevenção de eventos anômalos relacionados à parte hidráulica a manutenção preventiva. Destaca-se no gráfico 5 como causa predominante dos eventos o erro de operação, de forma marcante no sistema de lubrificação do equipamento, o que condiz com as informações que indicam que o modo de evitar as falhas é o treinamento dos operadores.

Por fim, o gráfico 6 demonstra que as partes do equipamento que mais tiveram eventos anômalos foram Painel de Controle CNC e o Sistema Hidráulico e que ajustes e pequenas inspeções são predominantes nesse banco de dados. Destaca-se que dado que o sistema é complexo e moderno, monitorado por sensores, estes possuem o papel de alertar possíveis anomalias que podem ou não serem críticas ao sistema. Eventos relacionados ao próprio sistema do controlador são frequentes, estes são geralmente erros de programação ou falhas do próprio *software*. Em relação aos sistemas não computacionais, o destaque é para o sistema

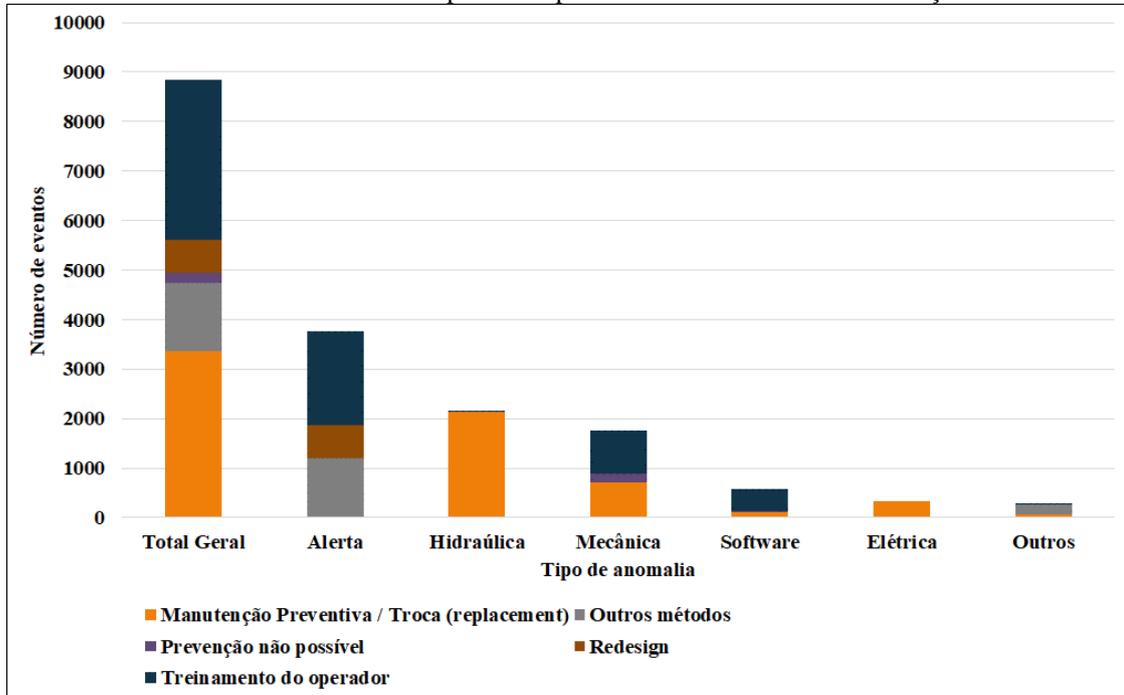
de lubrificação pertencente à parte hidráulica do centro de usinagem e este possui como principal meio de prevenção a manutenção preventiva.

Gráfico 3 – Análise Snapshot – Tipo de Anomalia e Severidade do evento



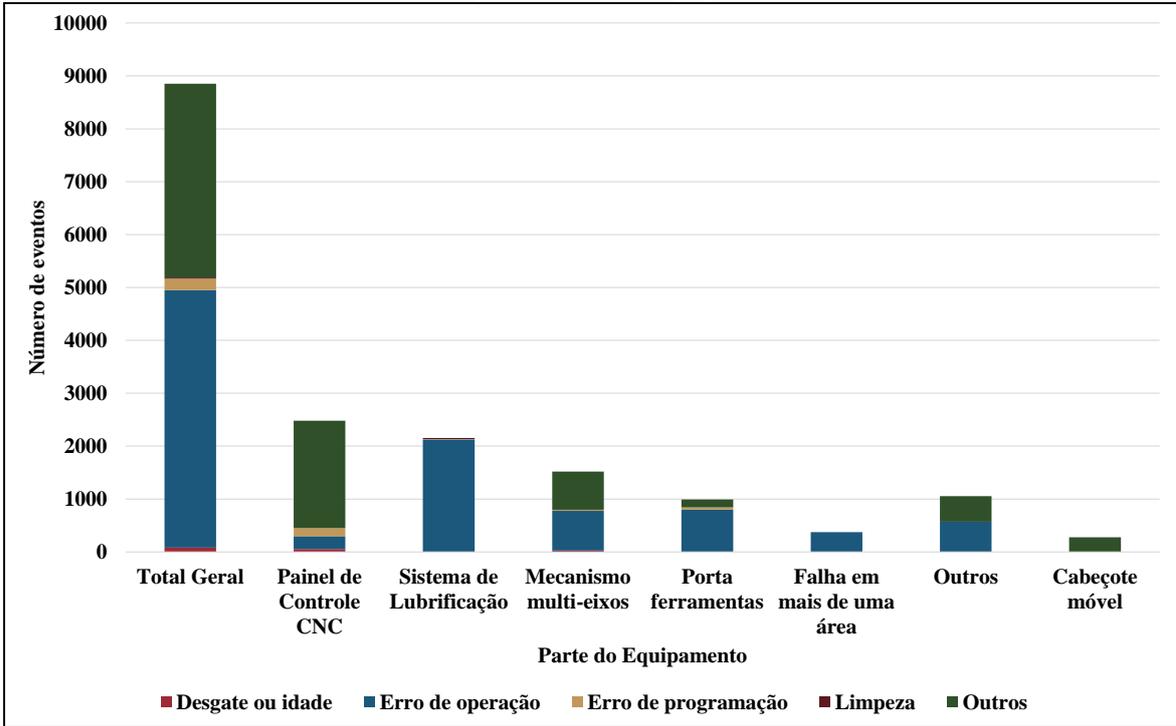
Fonte: O autor (2021)

Gráfico 4 – Análise Snapshot – Tipo de Anomalia e Modo de Prevenção



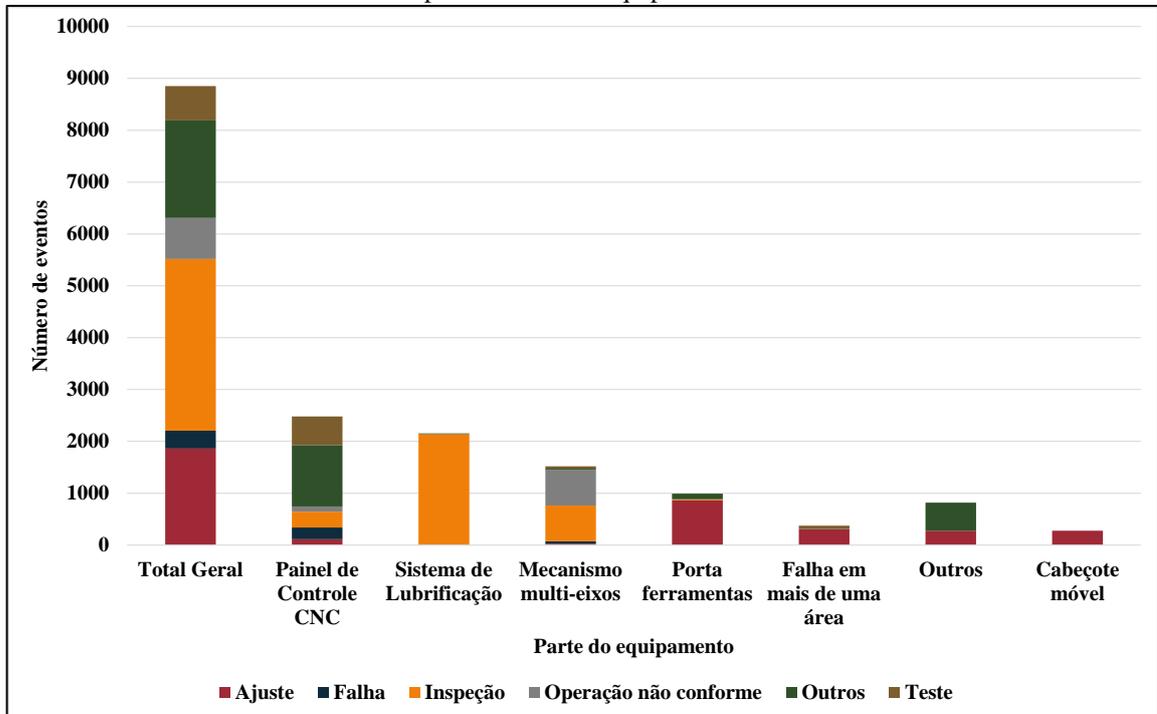
Fonte: O autor (2021)

Gráfico 5 – Análise Snapshot – Parte do equipamento e Causa do evento



Fonte: O autor (2021)

Gráfico 6 – Análise Snapshot – Parte do equipamento e Severidade do evento



Fonte: O autor (2021)

4.3 ANÁLISE E INTEGRAÇÃO DOS RESULTADOS

A partir das análises dos padrões sequenciais e do Snapshot, foi possível identificar um subsistema crítico do centro de usinagem, qual seja, o sistema de lubrificação. De fato, este não só acarreta muitas paradas, como também, acelera o desgaste de outras partes da máquina, como por exemplo, as ferramentas de corte.

Um padrão sequencial gerado que apresenta o fato anteriormente relatado é o “[600914] -> [6413]”. Este pode ser interpretado da seguinte forma: dado que o acoplamento de alimentação de fluido não estanque ocorreu, o evento “ferramenta de corte atingiu o seu limite de uso” aconteceu posteriormente dentro do mesmo intervalo de tempo. O evento antecedente expõe que existe um vazamento no fornecimento de fluido lubrificante, o qual prejudica a operação de corte. Desta forma, ocasiona-se um aumento das tensões mecânicas e da temperatura na ferramenta de corte. O resultado disto é a diminuição da sua vida útil, estando explícito no seu evento consequente.

Na análise *Snapshot* fica evidente o grande número de eventos que ocorreram no sistema de lubrificação. Além disso, mostra que uma grande parte destes pode ser evitada a partir da manutenção preventiva. Tal fato ressalta a importância de um planejamento das ações de manutenção para o sistema de lubrificação a partir de uma política de manutenção. Diante do exposto, uma aplicação prática será desenvolvida no próximo capítulo a fim de trazer melhorias para este sistema crítico. Nesta aplicação, será possível caracterizar a chegada do evento [600914], como um evento de falha. Visto que, é necessário parar a máquina para reparar ou substituir parte do sistema de lubrificação e assim estancar estes vazamentos.

Dado que o sistema de usinagem é complexo, paradas em outros subsistemas se tornam oportunidades de realizar uma ação de manutenção no sistema de lubrificação com o custo reduzido. Um evento que se destaca para esta análise é o [700704]. Este indica uma excessiva humidade relativa do ar na caixa elétrica. Pois, segundo recomendações do fabricante, esse evento pode danificar o sistema elétrico do centro de usinagem como um todo. Para corrigi-lo, é necessário que a máquina esteja completamente desligada com o intuito de evitar riscos ao trabalhador.

Pequenos vazamentos podem ser imperceptíveis aos sensores da máquina que prejudicam a qualidade dos produtos gerados, porém não impedem da máquina continuar em

funcionamento. Esta perda de qualidade gera retrabalho e ocasiona maiores custos da produção.

Os dados após o pré-processamento foram úteis para o levantamento de parâmetros e informações necessárias para a definição de uma Política de Manutenção Oportuna, assim tornando está mais próxima da realidade do processo fabril.

Todas essas informações serviram de *inputs* para a caracterização de uma Política de Manutenção Oportuna que terá como objetivo minimizar os custos totais por unidade de tempo no longo prazo realizando ações de manutenção, como: inspeções, renovação preventiva programada e renovação em oportunidade.

5 DESENVOLVIMENTO DA POLÍTICA DE MANUTENÇÃO OPORTUNA

Esta seção apresentará o desenvolvimento da modelagem matemática de uma Política de Manutenção Oportuna em um estudo de caso do sistema de lubrificação do centro de usinagem do qual foram extraídas as informações pela mineração de padrões sequencias e pela análise Snapshot. O sistema de lubrificação foi considerado crítico, pois este estava presente em mais de um padrão sequencial além de ser destaque como uma região do centro de usinagem que possuía um número considerável de eventos na análise Snapshot. Como oportunidade será considerado o evento de excesso de umidade na caixa elétrica, dado que para reparar essa anomalia é necessário uma equipe especializada e se o sistema de lubrificação estiver em seu estado terminal do ciclo de vida é oportuno repará-lo aproveitando esta mão-de-obra.

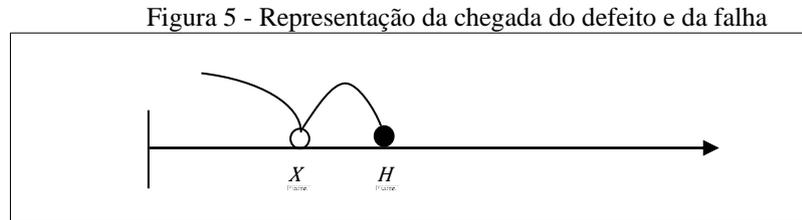
Serão apresentadas as equações matemáticas para cada caso possível de renovação, seja ela: corretiva, preventiva na inspeção, preventiva na substituição programada, ou oportuna. Além disso, serão expostas todas as suposições para o desenvolvimento desta política e por fim será realizada uma análise de sensibilidade para entender o impacto de variações nos dados de entrada na variável resposta que é o custo por unidade de tempo no longo prazo.

5.1 DESCRIÇÃO DAS CARACTERÍSTICAS DO SISTEMA

Este modelo considera o sistema de lubrificação do centro de usinagem como um componente único, porém este está contido em um sistema complexo, composto por vários outros componentes, e é suposto que não existe qualquer tipo de dependência entre as partes. Assim, a parada devido a outros subsistemas do centro de usinagem, proporcionam oportunidades para uma ação de manutenção no componente em estudo com custo reduzido.

Os estágios que o componente pode visitar são três: (1) bom, a partir do momento inicial que o componente começa a funcionar, ele está em perfeito estado, sem qualquer defeito, (2) defeituoso, quando o componente não está em seu perfeito estado, mas ainda sendo possível prover função operacional, será caracterizado por pequenos vazamentos não perceptíveis pelos sensores do CLP, e (3) falho, quando o componente não consegue mais operar suas funções, estágio representado pela ocorrência do alerta de vazamento no sistema

de lubrificação e necessidade de parada da máquina e ação de manutenção imediata pela equipe especializada. A Figura 5 ilustra a chegada do defeito está representada no ponto X e a chegada da falha no ponto H.



Fonte: O autor (2021)

O tempo no estado bom, ou seja, até a chegada do defeito é uma variável aleatória X , sua densidade de probabilidade é representada por $f_X(x)$ que é calculada pela distribuição mista da Equação 7, onde p é o parâmetro de mistura, então o componente chega de uma população mista de subpopulações “fortes” e “fracas”, representando a qualidade da ação de manutenção durante a renovação do ciclo do componente, onde se a qualidade for baixa, isto representará uma diminuição no tamanho esperado do seu ciclo de vida. $F_1(x)$ e $F_2(x)$ seguem a distribuição Weibull com parâmetros de escalas η_1 e η_2 e parâmetros de forma β_1 e β_2 calculadas pelas equações 8 e 9. Por fim, sua função de probabilidade acumulada é representada por $F_X(x)$ e função confiabilidade por $\bar{F}_X(t)$.

$$f_X(x) = pf_1(x) + (1-p)f_2(x) \quad (7)$$

$$f_1(x) = \frac{\beta_1}{\eta_1} \left(\frac{x}{\eta_1} \right)^{\beta_1-1} e^{-\left(\frac{x}{\eta_1} \right)^{\beta_1}} \quad (8)$$

$$f_2(x) = \frac{\beta_2}{\eta_2} \left(\frac{x}{\eta_2} \right)^{\beta_2-1} e^{-\left(\frac{x}{\eta_2} \right)^{\beta_2}} \quad (9)$$

Quando o sistema está no estado defeituoso, sua função operacional continua a funcionar, porém como está ocorrendo pequenos vazamentos no sistema de lubrificação, em demandas de fabricação de peças com geometria mais complexa, a qualidade requerida do produto final não será alcançada e será necessário retrabalho, assim foi atribuído um custo c por unidade de tempo em que o componente permanece no estado defeituoso. O tempo neste

estado é denotado H (o *delay time*) com a função de probabilidade acumulada $F_H(t)$, densidade de probabilidade $f_h(h)$, considerada uma distribuição exponencial e calculada pela Equação 10 e função confiabilidade $\bar{F}_H(t)$. E X e H são estatisticamente independentes.

$$f_h(h) = \lambda e^{-(\lambda h)} \quad (10)$$

A chegada de oportunidade é representada por uma distribuição Poisson, portanto, o tempo entre as chegadas é representado pela distribuição exponencial e calculada através da Equação 11.

$$f_z(z) = \lambda e^{-(\lambda z)} \quad (11)$$

Inspeções periódicas são realizadas pela própria equipe de operação dos centros de usinagem em $i\Delta$ unidades de tempo para verificação do estado do equipamento, se ele está bom ou defeituoso, i variando de $[1, K]$, com um custo C_i . Se o componente estiver defeituoso, está mesma equipe realizará a renovação preventiva, com o custo C_d , sendo $C_d > C_i$. Utilizar a equipe de produção para inspecionar e realizar a ação de manutenção na inspeção, se necessário, segue princípios do TQM, onde os colaboradores são treinados e recebem autonomia pra realizar tarefas mais rotineiras e simples de manutenção.

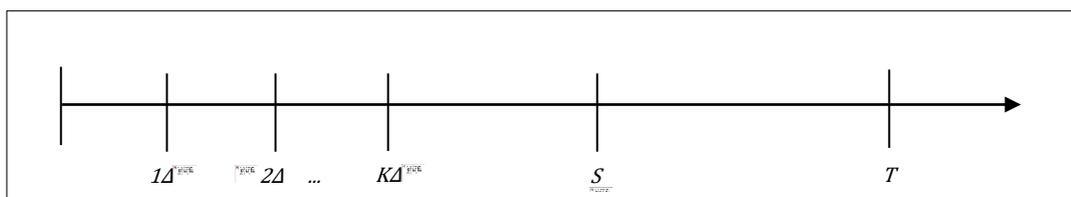
Como o sistema de lubrificação faz parte de um sistema complexo como um centro de usinagem, paradas decorrentes de outros subsistemas podem fornecer uma oportunidade de renovação preventiva com custo reduzido, pois a equipe de manutenção seria melhor utilizada, reduzindo os custos de locomoção e o diminuindo o tempo de inatividade do centro de usinagem. Porém, estas oportunidades podem surgir em tempos curtos ou longos e só será economicamente viável renovar o sistema em estudo a partir de determinado instante de tempo, assim evitando a renovação de maneira precoce. Então, apenas após o instante S , se abre uma janela de oportunidade, onde se ocorrer uma oportunidade neste intervalo, será realizada uma renovação preventiva por uma equipe de manutenção especializada com custo C_o .

E por fim, se o equipamento chegar até um instante T , este será renovado de forma preventiva também por uma equipe de manutenção com custo C_r e se o equipamento falhar ele será renovado de maneira corretiva com custo C_f , este será maior que todos os outros

custos de ação de manutenção dado que além do valor de reparo ou substituição, é acrescido o valor do sistema está parado sem produzir. Assim, temos que $C_f > C_r > C_o > C_d > C_i$.

As variáveis de decisão do modelo são: (1) Δ , que corresponde ao intervalo de tempo entre inspeções, (2) K , que indica o número de inspeções a serem realizadas, (3) S , instante de tempo que se abre a janela de oportunidade e por fim (4) T , instante de tempo que será realizado uma manutenção preventiva sem verificação do estado do equipamento. Este modelo segue como uma melhoria em relação ao desenvolvido por Paiva *et al.* (2019), pois neste novo modelo além das variáveis Δ , K e T é incluído a janela de oportunidade que se inicia em S . Esta melhoria é relevante para sistemas complexos, ao qual, a ação de manutenção em um subsistema pode ser uma oportunidade para renovação do componente crítico, resultando na diminuição do número de paradas da máquina e consequentemente redução do custo total de manutenção. A Figura 6 ilustra as variáveis do estudo.

Figura 6 - Variáveis de Decisão



Fonte: O autor (2021)

Outras hipóteses ou suposições para este modelo são: (1) na renovação do componente seja nas inspeções quando este está no estado defeituoso, em uma falha, em uma oportunidade que surgiu após S ou na manutenção preventiva em T , o sistema é restaurado para uma condição de tão bom quanto novo; (2) as inspeções são perfeitas, ou seja quando o defeito surgir na próxima inspeção ele será descoberto; (3) As oportunidades são independentes de X e H ; (4) O tempo de parada para a realização da inspeção é irrelevante em relação ao tamanho do intervalo entre inspeções.

5.2 MODELAGEM DA POLÍTICA OPORTUNA ATRAVÉS DO MODELO ANALÍTICO

Dado todas as informações descritas na seção anterior, pode-se apresentar o desenvolvimento das equações que representam o modelo de manutenção oportuna, para

assim ser calculada a variável de resposta que é a taxa de custo esperado por unidade de tempo (ROSS, 1996).

A modelagem é iniciada a partir da elucitação dos possíveis cenários de renovação, levando em consideração as detecções de defeitos nas inspeções e a chegada de oportunidade. Assim, os cenários possíveis de renovação são:

1. Renovação preventiva realizado pela equipe de operação: o componente é descoberto como sendo defeituoso na fase de inspeção;
2. Renovação corretiva durante o período de inspeções: o defeito surge e a falha acontece em seguida, antes da chegada da próxima inspeção;
3. Renovação corretiva: o defeito surge após o período de inspeções, porém a falha ocorreu antes da janela de oportunidade;
4. Renovação corretiva: o defeito ocorre entre $K\Delta$ e S e a falha ocorre entre S e T, oportunidade surge após a falha;
5. Renovação corretiva: o defeito e a falha acontecem no intervalo [S,T],mas a oportunidade surge apenas após a falha;
6. Renovação oportuna: o defeito ocorre entre $K\Delta$ e S e a falha ocorreria entre S e T, porém uma oportunidade surge antes da falha;
7. Renovação oportuna: o defeito ocorre entre $K\Delta$ e S e a falha ocorreria após T, porém uma oportunidade surge entre S e T;
8. Renovação oportuna: o defeito ocorre entre S e T, assim como a falha também ocorreria, porém uma oportunidade surge antes da falha;
9. Renovação oportuna: o defeito e falha ocorriam entre S e T, porém oportunidade surge antes mesmo do defeito;
10. Renovação oportuna: o defeito ocorre entre S e T e a falha ocorreria após T, porém uma oportunidade surge entre S e T, após o defeito;
11. Renovação oportuna: o defeito ocorreria entre S e T e a falha ocorreria após T, porém uma oportunidade surge antes do defeito;
12. Renovação oportuna: o defeito e a falha ocorreriam após T, uma oportunidade surge entre S e T;
13. Renovação preventiva: o defeito ocorre entre $K\Delta$ e T e a falha ocorreria após T, oportunidade surge após T;

14. Renovação preventiva: o defeito e a falha ocorreriam após T, oportunidade surge após T.

O desenvolvimento destes cenários esgota todas as possibilidades de renovação de um ciclo de vida do componente, seja de forma preventiva, na inspeção ou na manutenção programada em T, seja oportuna ou na corretiva na ocorrência da falha. A soma das probabilidades de cada um destes cenários resulta em 1 (um), o que confirma que todas as possibilidades foram exauridas. A análise de todos estes cenários embasa o cálculo da taxa de custo total por unidade de tempo, que é calculado pela divisão entre custo esperado por ciclo de renovação e o tamanho esperado do ciclo de vida demonstrado na Equação 12. O Quadro 3 apresenta a notação de todas as siglas que estarão presentes nas equações que representam as probabilidades, custo esperado e tamanho esperado de cada cenário.

$$C(T) = \frac{U(T)}{V(T)} \quad (12)$$

Quadro 3 - Notação das siglas

Sigla	Descrição
Δ	Intervalo de inspeção
K	Número de Inspeções
S	Instante de tempo de abertura da janela de oportunidade
T	Instante de tempo para manutenção preventiva
$f_X(\cdot)$	Função densidade de probabilidade da chegada do defeito
$f_H(\cdot)$	Função densidade de probabilidade do <i>delay time</i>
$f_Z(\cdot)$	Função densidade de probabilidade da chegada da oportunidade
$F_X(\cdot)$	Função distribuição acumulada da chegada do defeito
$F_H(\cdot)$	Função distribuição acumulada da chegada do <i>delay time</i>
$F_Z(\cdot)$	Função distribuição acumulada da chegada da oportunidade
X	Tempo para a chegada do defeito
H	<i>Delay time</i>
Z	Tempo para a chegada da oportunidade

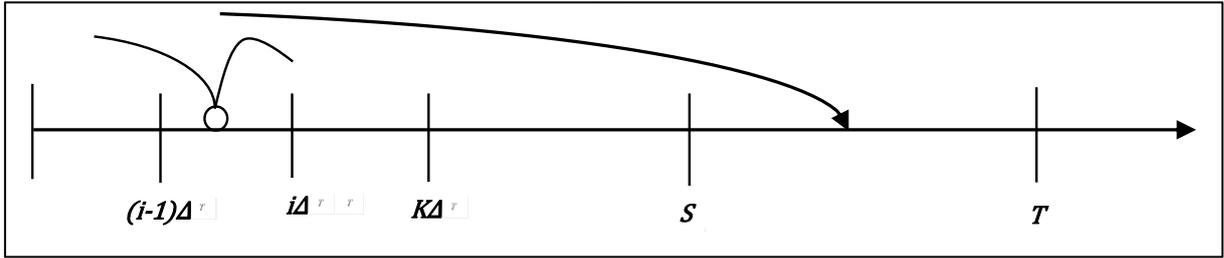
β_i	Parâmetro de forma da Weibull para a sub-população i
η_i	Parâmetro de escala da Weibull para a sub-população i
p	Parâmetro de mistura
C	Custo por unidade de tempo de permanência no estado defeituoso
C_i	Custo de uma inspeção
C_d	Custo de uma renovação na inspeção
C_o	Custo de uma renovação na oportunidade
C_r	Custo de uma renovação na manutenção programada em T
C_f	Custo de uma renovação na falha
U(T)	Custo esperado de um ciclo de renovação
V(T)	Tamanho esperado de um ciclo de renovação
C(T)	Taxa de custo esperado por unidade de tempo

Fonte: O autor (2021)

Caso 1 - Renovação preventiva: o componente é descoberto como sendo defeituoso na fase de inspeção:

Neste cenário, a renovação acontece devido à detecção do estado defeituoso durante uma inspeção, assim a renovação é classificada como preventiva, como é ilustrado na Figura 7. Os custos associados são das inspeções realizadas adicionadas ao custo de manutenção preventiva na inspeção, multiplicados pela probabilidade do cenário, já o tamanho do ciclo de vida é calculado pelo número de inspeções realizadas multiplicadas pelo tamanho do intervalo das inspeções, multiplicado pela probabilidade do caso. As equações da probabilidade do cenário, do custo esperado do cenário e do tamanho do ciclo de vida esperado estão representadas nas Equações 13, 14 e 15:

Figura 7 - Cenário 1 - Renovação preventiva: o componente é descoberto como sendo defeituoso na fase de inspeção



Fonte: O autor (2021)

$$P_1 = \sum_{i=1}^K \int_{(i-1)\Delta}^{i\Delta} \bar{F}_H(i\Delta - x) f_x(x) dx \quad (13)$$

$$U(T)_1 = (C_d + iC_i) \sum_{i=1}^K \int_{(i-1)\Delta}^{i\Delta} \bar{F}_H(i\Delta - x) f_x(x) dx \quad (14)$$

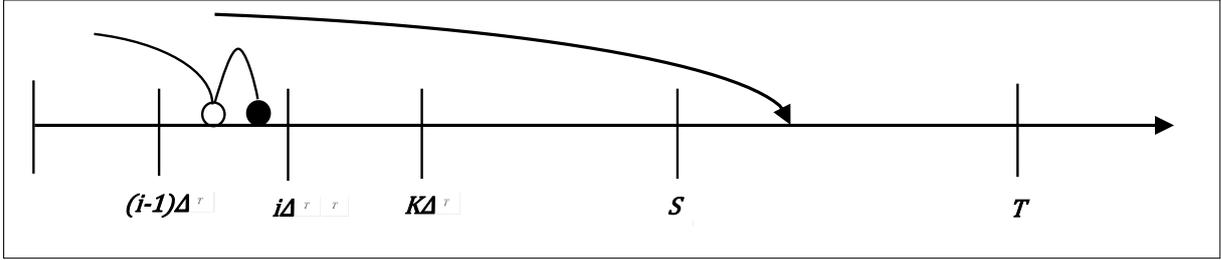
$$+ \sum_{i=1}^K \int_{(i-1)\Delta}^{i\Delta} c(i\Delta - x) \bar{F}_H(i\Delta - x) f_x(x) dx$$

$$V(T)_1 = \sum_{i=1}^K (i\Delta) \int_{(i-1)\Delta}^{i\Delta} \bar{F}_H(i\Delta - x) f_x(x) dx \quad (15)$$

Caso 2 - Renovação corretiva: o defeito surge e a falha acontece em seguida, antes da chegada da próxima inspeção:

No cenário 2, a renovação é corretiva, devido a ocorrência de defeito e falha dentro do mesmo intervalo entre inspeções, a Equação 16 calcula a probabilidade deste caso acontecer e as Equações 17 e 18 demonstram os custos esperado e o tamanho do ciclo de vida esperado. Os custos correspondem a todas as inspeções realizadas anterior a falha e o custo da falha multiplicados pela probabilidade do cenário, já o tamanho esperado é a soma do tempo que o equipamento esteve no estado bom com o *delay time*, multiplicados também pela probabilidade do caso.

Figura 8 - Cenário 2 - Renovação corretiva: o defeito surge e a falha acontece em seguida, antes da chegada da próxima inspeção



Fonte: O autor (2021)

$$P_2 = \sum_{i=1}^K \int_{(i-1)\Delta}^{i\Delta} f_x(x) \int_0^{i\Delta-x} f_h(h) dh dx = \sum_{i=1}^K \int_{(i-1)\Delta}^{i\Delta} F_H(i\Delta-x) f_x(x) dx \quad (16)$$

$$U(T)_2 = (C_f + (i-1)C_i) \sum_{i=1}^K \int_{(i-1)\Delta}^{i\Delta} F_H(i\Delta-x) f_x(x) dx \quad (17)$$

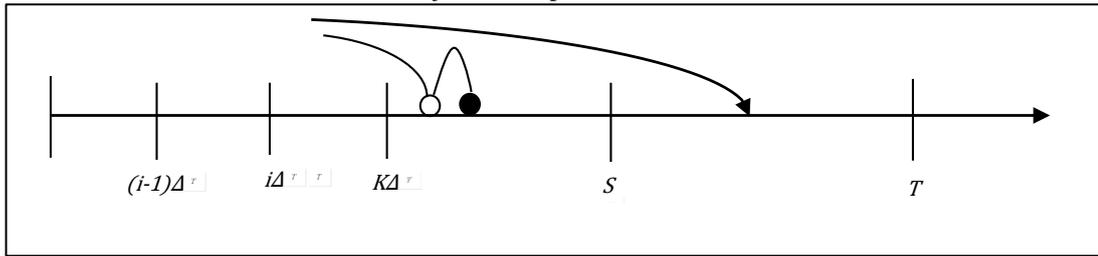
$$+ \sum_{i=1}^K \int_{(i-1)\Delta}^{i\Delta} f_x(x) \int_0^{i\Delta-x} (ch) f_h(h) dh dx$$

$$V(T)_2 = \sum_{i=1}^K \int_{(i-1)\Delta}^{i\Delta} f_x(x) \int_0^{i\Delta-x} (x+h) f_h(h) dh dx \quad (18)$$

Caso 3 – Renovação corretiva: o defeito surge após o período de inspeções, porém a falha ocorreu antes da janela de oportunidade:

Neste cenário também ocorre uma renovação corretiva, porém o defeito e a falha ocorrem no intervalo entre $K\Delta$ e S , os custos são calculados somando os custos de K inspeções e o custo da falha, já o tamanho esperado possui o mesmo cálculo no cenário 2, porém multiplicado pela probabilidade deste caso. As Equações 19, 20 e 21 calculam a probabilidade, o custo esperado e o tamanho esperado por ciclo de vida, respectivamente.

Figura 9 - Renovação corretiva: o defeito surge após o período de inspeções, porém a falha ocorreu antes da janela de oportunidade



Fonte: O autor (2021)

$$P_3 = \int_{K\Delta}^S f_x(x) \int_0^{S-x} f_h(h) dh dx = \int_{K\Delta}^S F_H(S-x) f_x(x) dx \quad (19)$$

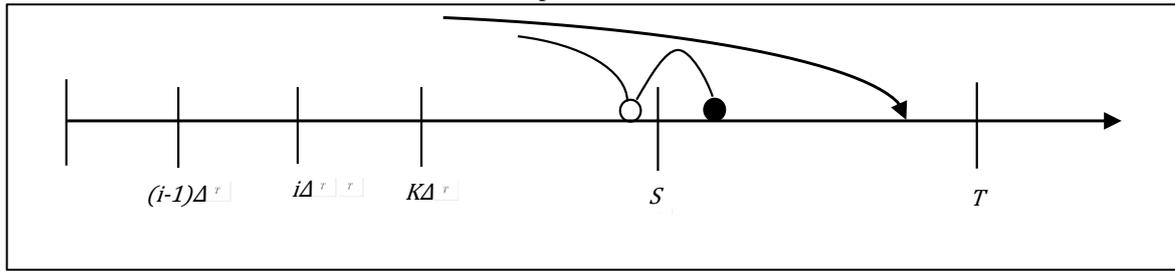
$$U(T)_3 = (C_f + KC_i) \int_{K\Delta}^S F_h(S-x) f_x(x) dx + \int_{K\Delta}^S (ch) F_h(S-x) f_x(x) dx \quad (20)$$

$$V(T)_3 = \int_{K\Delta}^S f_x(x) \int_0^{S-x} (x+h) f_h(h) dh dx \quad (21)$$

Caso 4 – Renovação corretiva: o defeito ocorre entre $K\Delta$ e S e a falha ocorre entre S e T , oportunidade surge após a falha:

Neste cenário, a ação de manutenção corretiva ocorre devido a uma falha que ocorre dentro da janela de oportunidade, ou seja, entre S e T , e o defeito acontece entre $K\Delta$ e S , a oportunidade só surgiria após a ocorrência da falha, representado pela equação $e^{-\mu(x+h-S)}$, os custos são idênticos ao caso 3, porém multiplicados pela probabilidade deste caso, o tamanho esperado do ciclo de vida é calculado de forma similar aos casos 3 e 4, entretanto é multiplicado pela probabilidade deste cenário. Probabilidade, custo esperado e tamanho do ciclo de vida estão demonstrados nas Equações 22, 23 e 24.

Figura 10 - Renovação corretiva: o defeito ocorre entre $K\Delta$ e S e a falha ocorre entre S e T , oportunidade surge após a falha



Fonte: O autor (2021)

$$P_4 = \int_{K\Delta}^S f_x(x) \int_{S-x}^{T-x} e^{-\mu(x+h-S)} f_h(h) dh dx \quad (22)$$

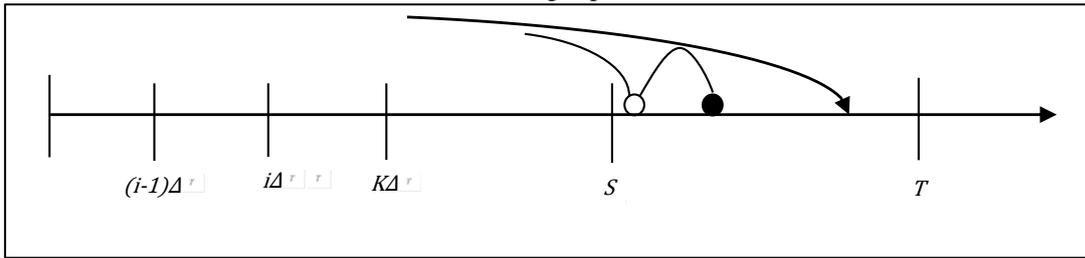
$$U(T)_4 = (C_f + KC_i) \int_{K\Delta}^S f_x(x) \int_{S-x}^{T-x} e^{-\mu(x+h-S)} f_h(h) dh dx \\ + \int_{K\Delta}^S f_x(x) \int_{S-x}^{T-x} (ch) e^{-\mu(x+h-S)} f_h(h) dh dx \quad (23)$$

$$V(T)_4 = \int_{K\Delta}^S f_x(x) \int_{S-x}^{T-x} (x+h) e^{-\mu(x+h-S)} f_h(h) dh dx \quad (24)$$

Caso 5 – Renovação corretiva: o defeito e a falha acontecem no intervalo $[S, T]$, mas a oportunidade apenas surge após a falha:

Neste cenário, a falha é que ocasiona a ação de manutenção corretiva, os custos e tamanho de vida esperado são calculados de forma semelhante ao caso 4, porém multiplicados pela probabilidade deste cenário que é diferente, pois o defeito ocorre assim como a falha dentro da janela de oportunidade, entre S e T . Probabilidade, custo esperado e tamanho do ciclo de vida esperado são calculados através das Equações 25, 26 e 27.

Figura 11 - Renovação corretiva: o defeito e a falha acontecem no intervalo [S,T],mas a oportunidade apenas surge após a falha



Fonte: O autor (2021)

$$P_5 = \int_S^T f_x(x) \int_0^{T-x} e^{-\mu(x+h-S)} f_h(h) dh dx \quad (25)$$

$$U(T)_5 = (C_f + KC_i) \int_S^T f_x(x) \int_0^{T-x} e^{-\mu(x+h-S)} f_h(h) dh dx$$

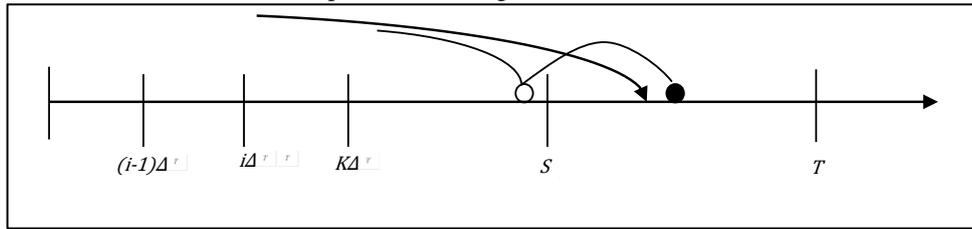
$$+ \int_S^T f_x(x) \int_0^{T-x} (ch) e^{-\mu(x+h-S)} f_h(h) dh dx \quad (26)$$

$$V(T)_5 = \int_S^T f_x(x) \int_0^{T-x} (x+h) e^{-\mu(x+h-S)} f_h(h) dh dx \quad (27)$$

Caso 6 – Renovação oportuna: o defeito ocorre entre $K\Delta$ e S e a falha ocorreria entre S e T , porém uma oportunidade surge antes da falha

Neste cenário, a renovação é oportuna, dado que ela é realizada através de uma oportunidade que aconteceu entre S e T . O defeito ocorre entre $K\Delta$ e S , já a falha ocorreria dentro da janela de oportunidade, porém o componente é renovado antes devido à oportunidade. Probabilidade, custo esperado e tamanho de ciclo esperado são calculados através das Equações 28, 29 e 30.

Figura 12 - Renovação oportuna: o defeito ocorre entre $K\Delta$ e S e a falha ocorreria entre S e T , porém uma oportunidade surge antes da falha



Fonte: O autor (2021)

$$P_6 = \int_{K\Delta}^S f_x(x) \int_{S-x}^{T-x} f_h(h) \int_S^{x+h} \mu e^{-\mu(z-S)} dz dh dx \quad (28)$$

$$U(T)_6 = (C_o + KC_i) \int_{K\Delta}^S f_x(x) \int_{S-x}^{T-x} f_h(h) \int_S^{x+h} \mu e^{-\mu(z-S)} dz dh dx$$

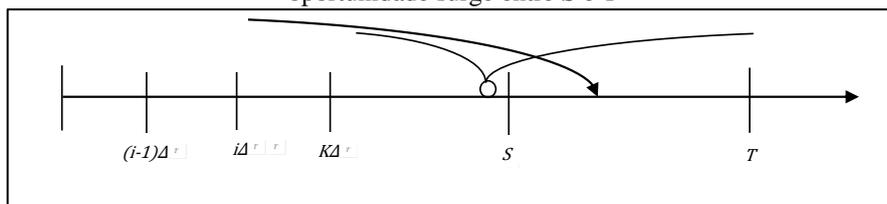
$$+ \int_{K\Delta}^S f_x(x) \int_{S-x}^{T-x} f_h(h) \int_S^{x+h} c(z-x) \mu e^{-\mu(z-S)} dz dh dx \quad (29)$$

$$V(T)_6 = \int_{K\Delta}^S f_x(x) \int_{S-x}^{T-x} f_h(h) \int_S^{x+h} (z) \mu e^{-\mu(z-S)} dz dh dx \quad (30)$$

Caso 7 – Renovação oportuna: o defeito ocorre entre $K\Delta$ e S e a falha ocorreria após T , porém uma oportunidade surge entre S e T :

Este cenário é semelhante ao caso anterior, porém a falha só iria acontecer após T , isso muda a probabilidade e consequentemente os cálculos do custo e do tamanho do ciclo de vida, as Equações 31, 32 e 33 demonstram os cálculos da probabilidade, custo e tamanho esperado, respectivamente.

Figura 13 - Renovação oportuna: o defeito ocorre entre $K\Delta$ e S e a falha ocorreria após T , porém uma oportunidade surge entre S e T



Fonte: O autor (2021)

$$P_7 = \int_{K\Delta}^S f_x(x) \int_{T-x}^{\infty} f_h(h) \int_S^T \mu e^{-\mu(z-S)} dz dh dx \quad (31)$$

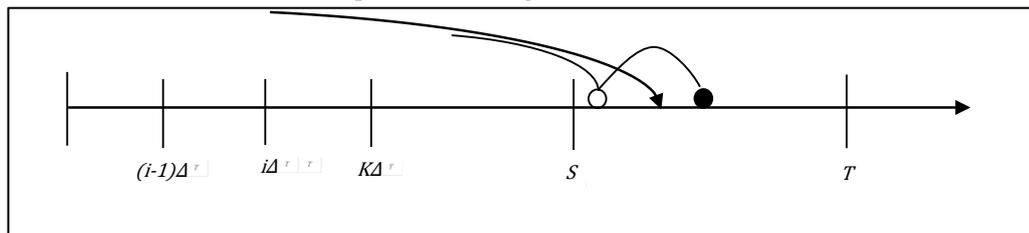
$$U(T)_7 = (C_o + KC_i) \int_{K\Delta}^S \int_S^T (\mu e^{-\mu(z-S)}) \bar{F}_H(T-x) f_x(x) dz dx \\ + \int_{K\Delta}^S \int_S^T c(z-x) (\mu e^{-\mu(z-S)}) \bar{F}_H(T-x) f_x(x) dz dx \quad (32)$$

$$V(T)_7 = \int_{K\Delta}^S \int_S^T (z) (\mu e^{-\mu(z-S)}) \bar{F}_H(T-x) f_x(x) dz dx \quad (33)$$

Caso 8 – Renovação oportuna: o defeito ocorre entre S e T, assim como a falha também ocorreria, porém uma oportunidade surge antes da falha;

Este cenário é semelhante ao caso 6, em ambos ocorre renovação oportuna, porém neste o defeito ocorre dentro da janela de oportunidade, ou seja, entre S e T. Isto modifica a probabilidade do caso, expressa na Equação 34 e assim muda também os cálculos do custo e do tamanho demonstradas nas Equações 35 e 36, respectivamente.

Figura 14 - Renovação oportuna: o defeito ocorre entre S e T, assim como a falha também ocorreria, porém uma oportunidade surge antes da falha



Fonte: O autor (2021)

$$P_8 = \int_S^T f_x(x) \int_0^{T-x} f_h(h) \int_x^{x+h} (\mu e^{-\mu(z-S)}) dz dh dx \quad (34)$$

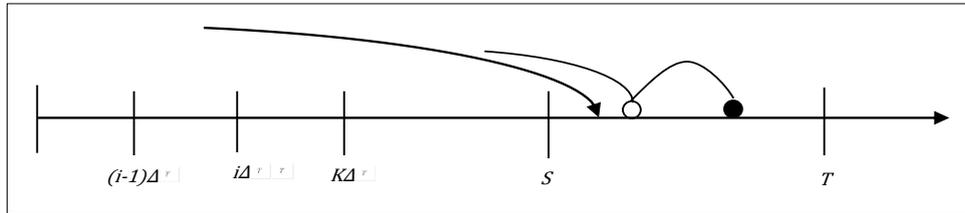
$$\begin{aligned}
U(T)_8 &= (C_o + KC_i) \int_S^T f_x(x) \int_0^{T-x} f_h(h) \int_x^{x+h} (\mu e^{-\mu(z-S)}) dz dh dx \\
&+ \int_S^T f_x(x) \int_0^{T-x} f_h(h) \int_x^{x+h} c(z-x) (\mu e^{-\mu(z-S)}) dz dh dx
\end{aligned} \tag{35}$$

$$V(T)_8 = \int_S^T f_x(x) \int_0^{T-x} f_h(h) \int_x^{x+h} (z) (\mu e^{-\mu(z-S)}) dz dh dx \tag{36}$$

Caso 9 – Renovação oportuna: o defeito e falha ocorriam entre S e T, porém oportunidade surge antes mesmo do defeito

Neste cenário a renovação é oportuna dado que a oportunidade surge anterior a chegada da falha, e o defeito e a falha ocorrem após a oportunidade dentro do intervalo [S,T]. As equações de probabilidade, custo e tamanho de ciclo de vida esperado estão demonstrados nas Equações 37, 38 e 39.

Figura 15 - Renovação oportuna: o defeito e falha ocorriam entre S e T, porém oportunidade surge antes mesmo do defeito



Fonte: O autor (2021)

$$P_9 = \int_S^T f_x(x) \int_0^{T-x} f_h(h) \int_S^x (\mu e^{-\mu(z-S)}) dz dh dx \tag{37}$$

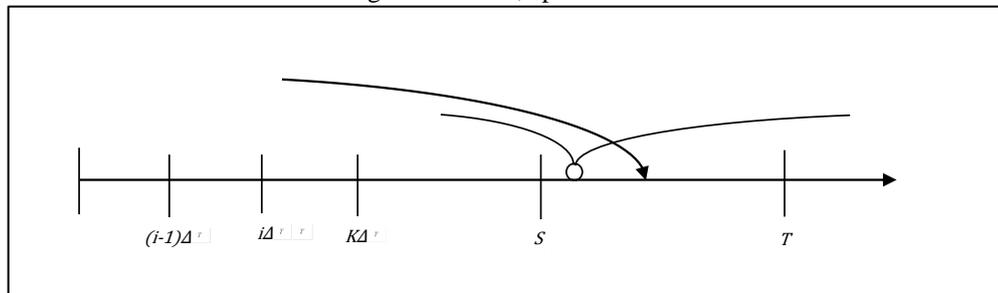
$$U(T)_9 = (C_o + KC_i) \int_S^T f_x(x) \int_0^{T-x} f_h(h) \int_S^x (\mu e^{-\mu(z-S)}) dz dh dx \tag{38}$$

$$V(T)_9 = \int_S^T f_x(x) \int_0^{T-x} f_h(h) \int_S^x (z) (\mu e^{-\mu(z-S)}) dz dh dx \tag{39}$$

Caso 10 – Renovação oportuna: o defeito ocorre entre S e T e a falha ocorreria após T, porém uma oportunidade surge entre S e T, após o defeito:

Este caso se assemelha ao cenário 7, porém o defeito em vez de ocorrer antes de S, acontece entre S e T e precede o acontecimento da oportunidade, as equações de probabilidade expressa na Equação 40, custo e tamanho de ciclo de vida esperado nas Equações 41 e 42 são semelhantes ao do caso 7, porém a probabilidade se modifica pela localização do defeito.

Figura 16 - Renovação oportuna: o defeito ocorre entre S e T e a falha ocorreria após T, porém uma oportunidade surge entre S e T, após o defeito



Fonte: O autor (2021)

$$P_{10} = \int_S^T f_x(x) \int_{T-x}^{\infty} f_h(h) \int_x^T \mu e^{-\mu(z-S)} dz dh dx = \int_S^T f_x(x) \int_x^T \mu e^{-\mu(z-S)} \bar{F}_H(T-x) dz dx \quad (40)$$

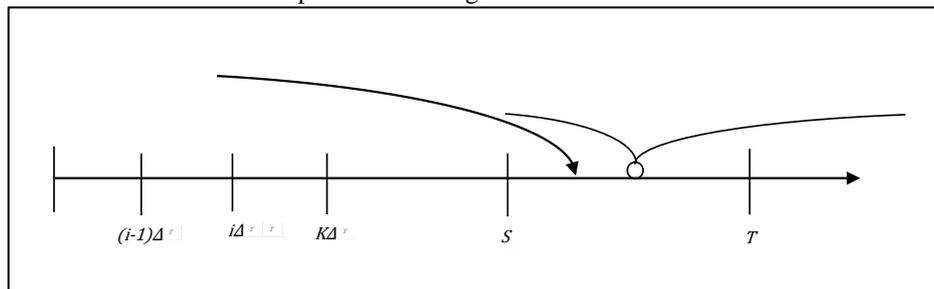
$$U(T)_{10} = (C_o + KC_i) \int_S^T f_x(x) \int_x^T \mu e^{-\mu(z-S)} \bar{F}_H(T-x) dz dx + \int_S^T f_x(x) \int_x^T c(z-x) \mu e^{-\mu(z-S)} \bar{F}_H(T-x) dz dx \quad (41)$$

$$V(T)_{10} = \int_S^T f_x(x) \int_x^T (z) \mu e^{-\mu(z-S)} \bar{F}_H(T-x) dz dx \quad (42)$$

Caso 11 – Renovação oportuna: o defeito ocorreria entre S e T e a falha ocorreria após T, porém uma oportunidade surge antes do defeito:

Neste cenário é semelhante ao caso 10, já que ocorre a renovação oportuna e a falha só ocorreria após T, porém neste, o defeito acontece após a oportunidade, isso modifica a probabilidade, expressa na Equação 43, e conseqüentemente as equações de custo esperado e tamanho do ciclo de vida, calculadas nas Equações 44 e 45, respectivamente.

Figura 17 - Renovação oportuna: o defeito ocorreria entre S e T e a falha ocorreria após T, porém uma oportunidade surge antes do defeito



Fonte: O autor (2021)

$$P_{11} = \int_S^T f_x(x) \int_{T-x}^{\infty} f_h(h) \int_S^x \mu e^{-\mu(z-S)} dz dh dx = \int_S^T f_x(x) \int_S^x \mu e^{-\mu(z-S)} \bar{F}_H(T-x) dz dx \quad (43)$$

$$U(T)_{11} = (C_o + KC_i) \int_S^T f_x(x) \int_S^x \mu e^{-\mu(z-S)} \bar{F}_H(T-x) dz dx \quad (44)$$

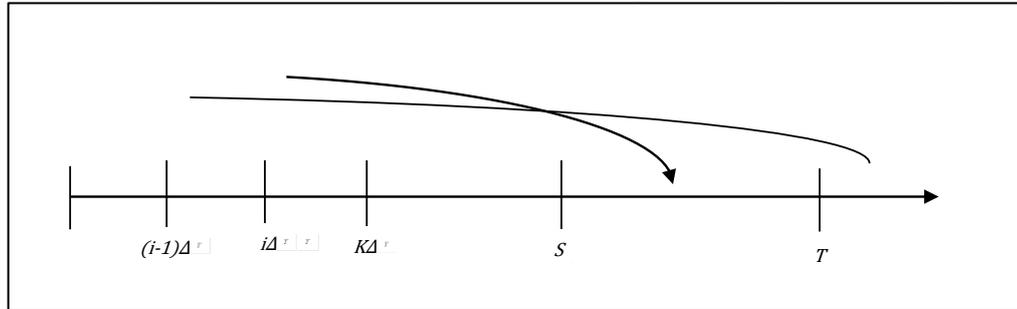
$$V(T)_{11} = \int_S^T f_x(x) \int_S^x (z) \mu e^{-\mu(z-S)} \bar{F}_H(T-x) dz dx \quad (45)$$

Caso 12 – Renovação oportuna: o defeito e a falha ocorreriam após T, uma oportunidade surge entre S e T:

Neste caso, a renovação é oportuna, dado que surgiu uma oportunidade entre S e T, e defeito e falha só ocorreriam após T. O custo é calculado pela soma do custo das K inspeções e do custo da renovação oportuna multiplicado pela probabilidade e o tamanho do ciclo de

vida é calculado pelo tamanho entre o início do ciclo de vida e a ocorrência da oportunidade multiplicada pela probabilidade do caso. Probabilidade, custo e tamanho do ciclo de vida estão expressos nas Equações 46, 47 e 48.

Figura 18 - Renovação oportuna: o defeito e a falha ocorreriam após T, uma oportunidade surge entre S e T



Fonte: O autor (2021)

$$P_{12} = \int_T^{\infty} f_x(x) \int_S^T \mu e^{-\mu(z-S)} dz dx = \bar{F}_X(T) \int_S^T \mu e^{-\mu(z-S)} dz \quad (46)$$

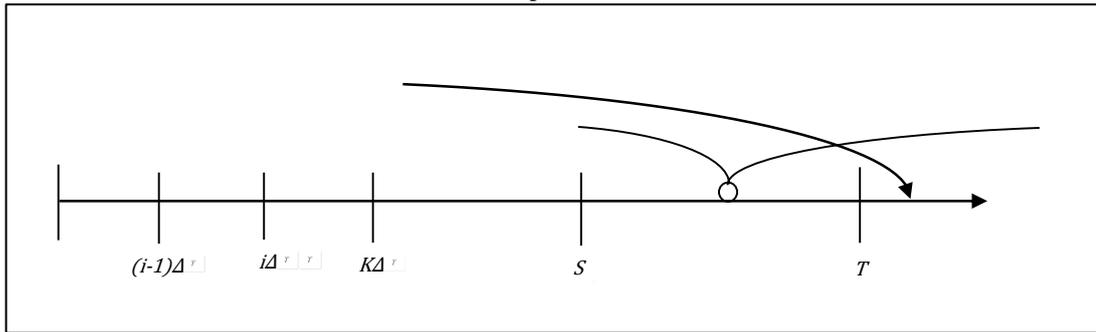
$$U(T)_{12} = (C_o + KC_i) \bar{F}_X(T) \int_S^T \mu e^{-\mu(z-S)} dz \quad (47)$$

$$V(T)_{12} = \bar{F}_X(T) \int_S^T (z) \mu e^{-\mu(z-S)} dz \quad (48)$$

Caso 13 – Renovação preventiva: o defeito ocorre entre $K\Delta$ e T e a falha ocorreria após T , oportunidade surge após T :

Neste cenário a renovação é preventiva e ocorre na data de manutenção programada T , o defeito surge entre S e T e a falha só ocorreria após T . Custo é calculado pela soma do custo das K inspeções e do custo da manutenção preventiva multiplicados pela probabilidade do caso, já o tamanho esperado é calculado pela multiplicação entre a probabilidade do cenário e o valor de T . As equações de probabilidade, custo esperado e tamanho do ciclo de vida esperado estão expressas nas Equações 49, 50 e 51, respectivamente.

Figura 19 - Renovação preventiva: o defeito ocorre entre $k\Delta$ e T e a falha ocorreria após T , oportunidade surge após T



Fonte: O autor (2021)

$$P_{13} = \int_{k\Delta}^T f_x(x) \int_{T-x}^{\infty} f_h(h) e^{-\mu(T-S)} dh dx \quad (49)$$

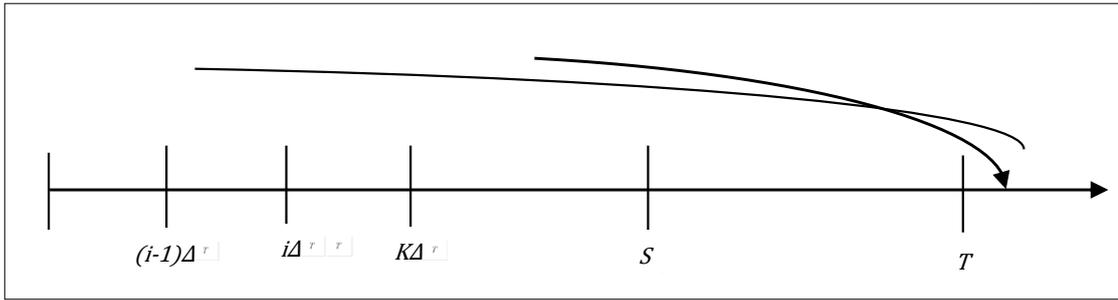
$$U(T)_{13} = (C_r + KC_i) \int_{k\Delta}^T f_x(x) \int_{T-x}^{\infty} f_h(h) e^{-\mu(T-S)} dh dx \\ + \int_{k\Delta}^T f_x(x) \int_{T-x}^{\infty} c(T-x) f_h(h) e^{-\mu(T-S)} dh dx \quad (50)$$

$$V(T)_{13} = \int_{k\Delta}^T f_x(x) \int_{T-x}^{\infty} (T) f_h(h) e^{-\mu(T-S)} dh dx \quad (51)$$

Caso 14 – Renovação preventiva: o defeito e a falha ocorreriam após T , oportunidade surge após T

Por fim, este último cenário representa outra renovação no tempo de manutenção preventiva programada, em T , porém tanto o defeito, quanto a falha e a oportunidade só aconteceriam após T . As equações da probabilidade, do custo esperado, do tamanho do ciclo de vida esperado estão apresentadas nas equações 52, 53 e 54, respectivamente.

Figura 20 -Renovação preventiva: o defeito e a falha ocorreriam após T, oportunidade surge após T



Fonte: O autor (2021)

$$P_{14} = \int_T^{\infty} f_x(x) e^{-\mu(T-S)} dx \quad (52)$$

$$U(T)_{14} = (C_r + KC_i) \int_T^{\infty} f_x(x) e^{-\mu(T-S)} dx \quad (53)$$

$$V(T)_{14} = \int_T^{\infty} (T) f_x(x) e^{-\mu(T-S)} dx \quad (54)$$

O custo esperado por ciclo, $U(T)$, é obtido através da soma de todos os custos esperados de cada cenário ponderados pela probabilidade de seus respectivos cenários, como mostra a Equação 55.

$$U(T) = \sum_{i=1}^{14} U(T)_i \quad (55)$$

Já o tamanho esperado por ciclo, $V(T)$, é calculado pela soma de todos os tamanhos esperado de cada cenário ponderados pelas suas probabilidades, como demonstrado na equação 56.

$$V(T) = \sum_{i=1}^{14} V(T)_i \quad (56)$$

Com o objetivo da obtenção do valor ótimo para as variáveis de decisão do modelo, a variável de resposta $C(T)$ deverá ser minimizada a fim de encontrar o ponto ao qual o custo por unidade de tempo no longo prazo seja o menor possível. A variável de resposta é calculada a partir da equação 57.

$$C(T) = \frac{U(T)}{V(T)} \quad (57)$$

Todas as equações foram desenvolvidas na linguagem de programação *Phyton*, e dadas às informações de entrada utilizando a biblioteca *Scipy*, foi possível a obtenção dos valores ótimos para a minimização da variável de resposta.

5.3 APLICAÇÃO NUMÉRICA DO MODELO DESENVOLVIDO DA POLÍTICA DE MANUTENÇÃO OPORTUNA

Esta aplicação numérica do modelo matemático exposto na seção anterior visa observar o efeito das novas variáveis desta política inéditas em relação ao modelo de Cavalcante *et al.* (2018), como: (1) o custo por unidade de tempo que o equipamento permanece no estado defeituoso e (2) o custo da ação de substituição preventiva na inspeção que se diferencia do custo da preventiva na manutenção programada em T. Além disso, será realizada uma análise de sensibilidade de todos os parâmetros de entrada para entender o comportamento do modelo. Os valores dos parâmetros utilizados nesta aplicação são adaptados de Berrade *et al.* (2013) e Scarf e Cavalcante (2010) e estão apresentados na Tabela 8, onde o tempo é dado em semanas.

A partir destes parâmetros de entrada foi otimizado o modelo para minimizar a taxa de custo por unidade de tempo no longo prazo e obtiveram-se os resultados presentes na Tabela 9, estes resultados indicam que a política ótima de manutenção deve conter seis inspeções com intervalo de tempo de 0,24 semana, a janela de oportunidade deve ser iniciada após 1,46 semana e a manutenção preventiva programada ficará agendada para 1,58 semana, assim a taxa de custo por unidade de tempo é igual a \$1,0822.

Visando uma compreensão mais clara do comportamento do modelo e assim obter *insights* para o gerenciamento da manutenção foi realizada uma análise de sensibilidade dos resultados, dividida em: (1) análise do custo por unidade de tempo de permanência no estado defeituoso, (2) análise dos demais custos, (3) análise da taxa de chegada da oportunidade, (4) análise dos parâmetros de chegada do defeito e *delay time*.

Tabela 8 - Valores dos Parâmetros da Aplicação Numérica

Sigla	Descrição	Valor
η_1	Parâmetro de escala da Weibull da sub-população "fraca"	0,4
β_1	Parâmetro de forma da Weibull da sub-população "fraca"	2,5
η_2	Parâmetro de escala da Weibull da sub-população "forte"	1,8
β_2	Parâmetro de forma da Weibull da sub-população "forte"	5,0
p	Parâmetro de mistura	0,1
μ	Taxa de chegada da oportunidade	1
λ	Inverso da média da distribuição do delay time	1
c	Custo por unidade de tempo de permanência no estado defeituoso	\$5/semana
C_i	Custo de uma inspeção	\$0,05
C_d	Custo de uma renovação na inspeção	\$0,6
C_o	Custo de uma renovação na oportunidade	\$0,7
C_r	Custo de uma renovação na manutenção programada em T	\$1
C_f	Custo de uma renovação na falha	\$5

Fonte: O autor (2021)

Tabela 9 - Resultados para o modelo de minimização de custo

Parâmetros de entrada												Valores ótimos das variáveis de decisão				Critério de decisão ótimo	
η_1	β_1	η_2	β_2	p	μ	λ	c	C_i	C_d	C_o	C_r	C_f	K	Δ	S	T	C(T)
0,4	2,5	1,8	5,0	0,1	1,0	5	0,05	0,6	0,7	1	5	5	6	0,2426	1,4558	1,5808	1,0822

Fonte: O autor (2021)

5.3.1 Análise de sensibilidade do custo por unidade de tempo de permanência no estado defeituoso

O que caracteriza o componente está no estado defeituoso nesse estudo de caso são pequenos vazamentos no sistema de lubrificação que não são detectados pelo sensor do CLP, porém esses vazamentos interferem na qualidade dos produtos, principalmente daqueles que possuem geometria mais complexas. Esta análise de sensibilidade relaciona os custos de manutenção e as demandas de produção, onde a porcentagem de demanda de peças com geometria complexa em relação à demanda total corresponde ao custo por unidade de tempo do componente permanecer no estado defeituoso, ou seja, se a demanda deste tipo de peças for zero, o custo correspondente será também zero, pois pequenos vazamentos interferem apenas em peças complexas. Como suposição do modelo, se a demanda for correspondente a 30% da total de produção este custo será de \$5 por semana que o componente permanece com

tal defeito. A Tabela 10 demonstra a relação entre o custo por unidade de tempo e a demanda por peças com geometria complexa.

Tabela 10 - Relação entre demanda de peças com geometria complexa e o custo por unidade de tempo no estado defeituoso

Demanda de peças com geometria complexa (%)	Custo por unidade de tempo (\$/semana)
0	0
10%	1
20%	3
30%	5
50%	10
75%	15

Fonte: O autor (2021)

Então para entender melhor o impacto desta relação entre demandas de produção e a política de manutenção foi gerado os valores ótimos para cada um destes cenários, análise representada na Tabela 11. Onde pode-se afirmar que a porcentagem de demanda de peças com geometria complexa impacta substancialmente na taxa de custo por unidade de tempo no longo prazo, em relação ao caso base, onde a demanda é de 30% com o custo por unidade de tempo de \$5/semana tem-se uma variação entre 19,58% de economia quando a demanda equivale a 0% e de um aumento de 21,54% quando a demanda por este tipo de peça é de 75%.

Tabela 11 - Análise de sensibilidade do custo por unidade de tempo de permanência no estado defeituoso

Parâmetro de entrada c	Demanda de peças complexas (%)	Valores ótimos das variáveis de decisão				Critério de decisão ótimo C(T)	Diferença com o caso base (%)
		K	Δ	S	T		
0	0%	10	0,2280	2,2800	2,3239	0,8703	-19,58%
1	10%	10	0,2095	2,0947	2,1490	0,9286	-14,19%
3	20%	6	0,2592	1,5554	1,6769	1,0144	-6,27%
5	30%	6	0,2426	1,4558	1,5808	1,0822	0,00%
10	50%	6	0,2179	1,3074	1,4365	1,2133	12,11%
15	75%	7	0,1821	1,2750	1,3871	1,3153	21,54%

Fonte: O autor (2021)

5.3.2 Análise de Sensibilidade dos custos de ações de manutenção

Uma outra peculiaridade deste estudo em relação ao modelo de Cavalcante *et al.* (2018) é a distinção entre o custo de renovação preventiva na inspeção e na manutenção programada, isto é significativo neste modelo, porque ações de manutenção mais simples

como a inspeção e a renovação na inspeção quando detectado o estado defeituoso são realizadas pelos operadores de produção, condizentes com o conceito de manutenção autônoma do TPM, já as renovações oportuna e preventiva programada serão realizadas por uma equipe de manutenção especializada. Na Tabela 12, faz-se uma análise de sensibilidade de cada um dos custos referentes às ações de manutenção, já a Tabela 13 analisa quanto é economizado por essa divisão de trabalho e autonomia do operador realizar pequenas ações de prevenção e inspeção em sua máquina.

Tabela 12 - Análise de sensibilidade dos custos relacionados com as ações de manutenção

Parâmetros de entrada					Valores ótimos das variáveis de decisão				Critério de decisão ótimo	Diferença com o caso base (%)
C_i	C_d	C_o	C_r	C_f	K	Δ	S	T	C(T)	
0,05	0,6	0,7	1	5	6	0,2426	1,4558	1,5808	1,0822	0,00%
0,02	0,6	0,7	1	5	8	0,1906	1,5246	1,6200	0,9388	-13,25%
0,1	0,6	0,7	1	5	2	0,5501	1,1001	1,4037	1,1876	9,74%
0,05	0,5	0,7	1	5	7	0,2234	1,5641	1,6595	1,0563	-2,39%
0,05	0,7	0,7	1	5	5	0,2702	1,3508	1,5131	1,1022	1,85%
0,05	0,6	0,6	1	5	5	0,2712	1,3558	1,5239	1,0750	-0,67%
0,05	0,6	0,8	1	5	6	0,2452	1,4711	1,5835	1,0872	0,46%
0,05	0,6	0,7	0,8	5	4	0,3114	1,2457	1,4091	0,9894	-8,58%
0,05	0,6	0,7	1,2	5	10	0,1855	1,8552	1,9183	1,1370	5,06%
0,05	0,6	0,7	1	3	6	0,2592	1,5554	1,6769	1,0144	-6,27%
0,05	0,6	0,7	1	10	6	0,2179	1,3074	1,4365	1,2133	12,11%

Fonte: O autor (2021)

Da Tabela 12, pode-se observar alta variância nos custos de inspeção, de renovação preventiva programada e nos custos de falha, um dado que se destaca é que a diminuição dos custos de renovação preventiva programada é mais relevante (-8,58%) do que o aumento da respectiva ação de manutenção (5,06%), sendo um indicativo que a melhoria neste tipo de ação, evitando desperdícios acarretaria numa economia de recursos financeiros. Outro ponto, é evidenciar a gerência de manutenção a importância de evitar a falha neste sistema e isso reforça a relevância do desenvolvimento desta política e mais ainda, da necessidade de segui-la na prática.

Tabela 13- Análise de sensibilidade da realização de ações de manutenção pela equipe de manutenção ou de operação

Parâmetros de entrada					Valores ótimos das variáveis de decisão				Critério de decisão ótimo	Diferença com o caso base (%)
C_i	C_d	C_o	C_r	C_f	K	Δ	S	T	C(T)	
0,05	0,6	0,7	1	5	6	0,2426	1,4558	1,5808	1,0822	0,00%
0,05	1	0,7	1	5	3	0,3737	1,1211	1,4050	1,1467	5,96%
0,1	1	0,7	1	5	1	0,5300	0,8648	1,3273	1,2272	13,40%

Fonte: O autor (2021)

A Tabela 13 mostra que se a renovação preventiva na inspeção fosse realizada por uma equipe de manutenção existiria um aumento de 5,96% no custo por unidade de tempo no longo prazo e se todas as ações fossem realizadas pela mesma equipe de manutenção, assim evitando a manutenção autônoma do TQM, onde o operador tem autonomia e treinamento para realizar ações de manutenção (mesmo que seja apenas as mais simples), o aumento no custo equivale a 13,40% do custo final.

5.3.3 Análise de sensibilidade da taxa de chegada de oportunidade

Neste estudo de caso, a oportunidade ocorre quando o alerta de excessiva umidade relativa do ar na caixa elétrica, pois é necessária a parada imediata da máquina para solucionar esse problema que pode acarretar danos severos ao sistema elétrico do centro de usinagem. Então a chegada desta oportunidade está atrelada a um fator ambiental que fica mais intenso ou não de maneira sazonal, assim modelam-se as variações da taxa de chegada da oportunidade pela época do ano que a umidade relativa do ar é alta, regular ou baixa. Como descrita na Tabela 14.

Já o impacto desta variação no custo por unidade de tempo no longo prazo está explícita na
Fonte: O autor (2021)

Tabela 15. E conclui-se que mesmo com variações menores que um por cento na variação deste parâmetro, observa-se que quando diminui a taxa de chegada das oportunidades é recomendado um menor número de inspeções e o tempo para a manutenção programada preventiva é encurtado.

Tabela 14 - Relação entre umidade relativa do ar e a taxa de chegada de oportunidade

Umidade Relativa do ar	Taxa de chegada de oportunidade (semanas)
Alta	1,5
Regular	1
Baixa	0,5

Fonte: O autor (2021)

Tabela 15 - Análise de sensibilidade da taxa de chegada de oportunidade

Parâmetro de entrada	Umidade Relativa do ar	Valores ótimos das variáveis de decisão				Critério de decisão ótimo	Diferença com o caso base (%)
		K	Δ	S	T		
μ					C(T)		
1,5	Alta	6	0,2426	1,4558	1,5808	1,0822	0,00%
1	Regular	6	0,2459	1,4754	1,5827	1,0891	0,64%
0,5	Baixa	4	0,3165	1,2660	1,4792	1,0737	-0,79%

Fonte: O autor (2021)

5.3.4 Análise de sensibilidade da chegada do defeito e do delay time

Por fim, foi realizado a análise de sensibilidade do parâmetro de mistura e dos parâmetros de escala e forma da distribuição Weibull das sub-populações “fraca” e “forte”, a primeira representa a possibilidade da execução da ação de manutenção que realiza a renovação do ciclo de vida ser imperfeita e assim o próximo ciclo terá uma alta probabilidade de ocorrer mortalidade infantil, ou seja, a falha do componente ocorrer precocemente. Já o segundo, corresponde a uma renovação com vida útil estendida. Os resultados da análise estão expostos na Tabela 16.

Tabela 16 - Análise de sensibilidade dos parâmetros de chegada do defeito e do *delay time*

Caso	Parâmetros de entrada					Valores ótimos das variáveis de decisão				Critério de decisão ótimo	Diferença com o caso base (%)
	η_1	β_1	η_2	β_2	p	K	Δ	S	T		
1	0,4	2,5	1,8	5,0	0,1	6	0,2426	1,4558	1,5808	1,0822	0,00%
2	0,15	2,5	1,8	5	0,1	8	0,1994	1,5949	1,6864	1,0962	1,29%
3	0,65	2,5	1,8	5	0,1	6	0,2420	1,4523	1,5774	1,0686	-1,26%
4	0,4	1	1,8	5	0,1	6	0,2416	1,4497	1,5763	1,0856	0,31%
5	0,4	3,5	1,8	5	0,1	6	0,2426	1,4556	1,5808	1,0819	-0,03%
6	0,4	2,5	1,2	5	0,1	7	0,1634	1,1440	1,2025	1,4535	34,31%
7	0,4	2,5	2,4	5	0,1	5	0,3415	1,7073	1,9286	0,8709	-19,53%
8	0,4	2,5	1,8	4	0,1	9	0,1872	1,6852	1,7755	1,1196	3,46%
9	0,4	2,5	1,8	6	0,1	4	0,3311	1,3244	1,4983	1,0438	-3,55%
10	0,4	2,5	1,8	5	0	0	0,0000	0,7683	1,2744	0,9314	-13,93%
11	0,4	2,5	1,8	5	0,05	3	0,4059	1,2176	1,4290	1,0230	-5,47%
12	0,4	2,5	1,8	5	0,15	8	0,1990	1,5917	1,6861	1,1307	4,48%

Fonte: O autor (2021)

Da Tabela 16, pode-se concluir que quando se diminui o tamanho o tempo de chegada do defeito, aumenta-se a taxa de custo (casos 2 e 6), destacando o aumento de 34,31% quando diminuiu o parâmetro de escala da sub-população “forte”. Já o efeito contrário é verdadeiro, mas nem tão impactante nos custos, quando aumenta o tempo de chegada do defeito, existe

uma diminuição nos custos por unidade de tempo, principalmente na sub-população “forte”, com redução de 19,53% (casos 3 e 7). Se a distribuição de chegadas do defeito está mais dispersa, o custo total tende a crescer (casos 4 e 8) e se sua chegada for mais concentrada, a taxa de custo reduz (casos 5 e 9). A qualidade das ações de manutenção são primordiais para evitar custos excessivos, isso fica evidente no caso 10, ao qual o percentual da sub-população “fraca” é igual a zero, ocorreu uma redução significativa de 13,93%. Já se for reduzido para 5%, a redução é de 5,47% (caso 11) e no inverso, for acrescido 5% de itens “fracos” há um aumento de 4,48% da taxa de custo por unidade de tempo no longo prazo.

6 CONCLUSÕES

Em um contexto histórico, os primeiros estudos que visavam a modelagem da manutenção carenciam de dados para embasar seus estudos. Atualmente, com o avanço da eletrônica e da utilização de microcomponentes, como sensores e controladores, uma grande massa de dados tem sido coletada. Logo, o desafio agora é saber como tratar esses dados, de forma a obter informações corretas e fieis a realidade do processo. Isso, porque muitas delas são base para tomadas de decisões críticas.

O centro de usinagem é uma das mais completas máquinas da engenharia para uma linha produtiva. É um equipamento de manufatura avançada e que emprega alto nível de automação e flexibilização aos processos produtivos, engloba subsistemas mecânicos, elétricos, hidráulicos e outros. Uma das falhas mais comuns em centros de usinagem ocorrem por vazamentos de fluidos em diferentes partes da máquina, sendo caracterizado pela má qualidade dos óleos e das conexões. É um dos sistemas mais importantes, desempenha atribuições vitais, sendo responsável pela movimentação mecânica de múltiplos componentes, pelo resfriamento dos sistemas e pela lubrificação (WANG; JIA; JIANG, 2001).

Diante disso, o presente estudo teve o objetivo de integrar o uso de mineração de padrões sequenciais e a técnica *Snapshot* a fim analisar dados de manutenção, bem como, apoiar o desenvolvimento de uma política de manutenção oportuna do sistema de lubrificação de um centro de usinagem.

De forma mais detalhada, foi realizado um pré-processamento de um extenso banco de dados de uma empresa francesa. Nesse sentido, foram eliminadas as informações que não eram relevantes para o estudo, como por exemplo, eventos repetidos em um pequeno espaço de tempo, bem como, dados inválidos. Após isso, foi elaborado um *framework* que conseguiu estruturar um sequenciamento de ações que integram os métodos de mineração de padrões sequenciais e *Snapshot*.

Mediante esta metodologia, foi possível realizar o estudo de caso do centro de usinagem. Os resultados da mineração de dados não garantem apresentar uma relação causa e efeito. No entanto, os padrões encontrados conseguiram expor co-ocorrências que com o auxílio da expertise de uma especialista fornecem informações que apoiam a tomada de decisão no que concerne o gerenciamento da manutenção. Observou-se, a partir dos padrões

gerados, que os problemas no sistema de lubrificação causam diversas paradas e ocasionam uma diminuição significativa na vida útil das ferramentas de corte.

A partir da análise Snapshot foi possível observar que a maioria dos eventos do banco de dados são alertas, testes e pequenos reparos. Vale ressaltar também que os dois sistemas que mais geraram eventos que necessitavam de ações de manutenção foram o painel de controle CNC e o sistema hidráulico. Estas informações corroboram com os resultados obtidos através dos padrões sequenciais, concluindo assim que o sistema de lubrificação se beneficiará de uma política de manutenção, no caso deste estudo, oportuna.

Assim, desenvolveu-se tal política oportuna com o objetivo de minimizar o custo esperado por unidade de tempo no longo prazo. Os resultados desta pesquisa mostram que o modelo analítico conseguiu elaborar um planejamento de ações de manutenção como inspeções no início do ciclo de vida, uma janela de oportunidades e uma manutenção programada.

Finalmente, é importante ressaltar que este estudo tem contribuições em três aspectos: econômico, social e ambiental. Em relação ao âmbito econômico, o desenvolvimento da política de manutenção conseguiu trazer resultados que reduzem os custos relativos à manutenção. Isto se torna atrativo para aplicações industriais, pois, diante da alta competitividade do mercado é necessário reduzir os custos das mais diversas atividades fabris para conseguir garantir o lucro. Do ponto de vista social, o desenvolvimento de uma política de manutenção flexível que pode representar cenários que necessitem apenas de inspeções, manutenção preventiva programada e oportunidades ou combinações destas ações de manutenção, proporciona aos mantenedores e a gerência de manutenção uma ferramenta eficiente para gerir e reparar os equipamentos fabris. Por fim, no âmbito ambiental, como o caso do estudo é um sistema de lubrificação, têm-se que, evitar vazamentos corresponde a uma diminuição do uso de materiais de origem fóssil, diminuindo assim, os impactos ambientais causados pelo processo produtivo.

6.1 TRABALHOS FUTUROS

Para trabalhos futuros, sugere-se a análise de dados de manutenção em outros processos industriais. Além disso, recomenda-se o desenvolvimento de políticas que se adaptem a tais contextos, pois cada situação tem as suas particularidades. O desenvolvimento

de um estudo mais avançado relacionado a influência da qualidade do serviço de manutenção por colaboradores de operação e seu impacto no ciclo de vida do equipamento. Por fim, a inclusão de outras variáveis de resposta, além do custo esperado por unidade de tempo, em modelos de política de manutenção oportuna.

REFERÊNCIAS

- ACCORSI, R. et al. Data mining and machine learning for condition-based maintenance. *Procedia Manufacturing*, v. 11, n. June, p. 1153–1161, 2017.
- AGRAWAL, R.; SRIKANT, R. Fast Algorithms for Mining Association Rules. *Proc. of 20th International Conference on Very Large Data Bases, {VLDB'94}*, p. 487–499, 1994.
- AGRAWAL, R.; SRIKANT, R. Mining sequential patterns. *Proceedings - International Conference on Data Engineering*, p. 3–14, 1995.
- ALWATBAN, I. S.; EMAM, A. Z. Comprehensive Survey on Privacy Preserving Association Rule Mining: Models, Approaches, Techniques and Algorithms. *International Journal on Artificial Intelligence Tools*, v. 23, n. 5, p. 1–28, 2014.
- ANTOMARIONI, S. et al. Defining a data-driven maintenance policy: an application to an oil refinery plant. *International Journal of Quality and Reliability Management*, v. 36, n. 1, p. 77–97, 2019.
- ATTARDI, L.; GUIDA, M.; PULCINI, G. A mixed-Weibull regression model for the analysis of automotive warranty data. *Reliability Engineering and System Safety*, v. 87, p. 265–273, 2005.
- AVEN, T.; CASTRO, I. T. A delay-time model with safety constraint. *Reliability Engineering and System Safety*, v. 94, p. 261–267, 2009.
- BAKER, R. D.; WANG, W. Developing and Testing the Delay-Time Model. *The Journal of the Operational Research Society*, v. 44, n. April, p. 361–374, 1993.
- BARLOW, R. E.; PROSCHAN, F. *Mathematical theory of reliability*. Society for Industrial and Applied Mathematics. Anais...1966
- BERRADE, M. D. et al. Imperfect inspection and replacement of a system with a defective state: A cost and reliability analysis. *Reliability Engineering and System Safety*, v. 120, p. 80–87, 2013.
- BERRADE, M.; SCARF, P.; CAVALCANTE, C. A study of postponed replacement in a delay time model. *Reliability Engineering and System Safety*, v. 168, 2017.
- CAVALCANTE, C. A. V.; LOPES, R. S. Multi-criteria model to support the definition of opportunistic maintenance policy: A study in a cogeneration system. *Energy*, v. 80, p. 32–40, 2015.
- CAVALCANTE, C. A. V.; LOPES, R. S.; SCARF, P. A. A general inspection and opportunistic replacement policy for one-component systems of variable quality. *European Journal of Operational Research*, v. 266, n. 3, p. 911–919, 2018.
- CHEMWENO, P. et al. I-RCAM: Intelligent expert system for root cause analysis in

maintenance decision making. *2016 IEEE International Conference on Prognostics and Health Management, ICPHM 2016*, p. 1–7, 2016.

CHEN, M.-S.; HAN, J.; YU, P. S. Data mining:: an overview from a database perspective. *IEEE Transactions on Knowledge and Data Engineering*, v. 8, p. 911–922, 1996.

CHRISTER, A. A. H.; WHITELAW, J. An Operational Research Approach to Breakdown Maintenance : Problem Recognition Published. *The Journal of the Operational Research Society*, v. 34, n. 11, p. 1041–1052, 1983.

CHRISTER, A. H. Delay-Time Model of Reliability of Equipment Subject to Inspection Monitoring. *Journal of the Operational Research Society*, v. 38, n. 4, p. 329–334, 1987.

CHRISTER, A. H. et al. Stochastic Maintenance Modelling of High-tech Steel. *Stochastic Modelling in Innovative Manufacturing*, 1997.

CHRISTER, A. H.; WALLER, W. M. An Operational Research Approach to Planned Maintenance : Modelling P . M . for a Vehicle Fleet. *Journal of the Operational Research Society*, v. 35, n. Ii, p. 967–984, 1984.

DEKKER, R. Applications of maintenance optimization models : a review and analysis. *Reliability Engineering and System Safety*, v. 51, p. 229–240, 1996.

DEKKER, R.; SMEITINK, E. Opportunity-based block replacement. *European Journal of Operational Research*, v. 53, p. 46–63, 1991.

DENNIS, P. *Lean Production Simplified - A Plain-Language Guide to the World's Most Powerful Production System*. Third Edit ed. Boca Raton: CRC Press, 2015.

DESA, M. I.; CHRISTER, A. H. Modelling in the absence of data : a case study of \bar{e} eet maintenance in a developing country. *Journal of Operational Research Society*, p. 247–260, 2001.

FAYYAD, U.; PIATETSKY-SHAPIO, G.; SMYTH, P. From Data Mining to Knowledge Discovery in Databases. *AI Magazine*, v. 17, 1996.

FRONZA, I. et al. The Journal of Systems and Software Failure prediction based on log files using Random Indexing and Support Vector Machines. *The Journal of Systems & Software*, v. 86, n. 1, p. 2–11, 2013.

GARAMBAKI, A. H. S.; SENEVIRATNE, A. M. N. D. B.; KUMAR, U. Opportunistic inspection planning for Railway eMaintenance. *IFAC-PapersOnLine*, v. 49, n. 28, p. 197–202, 2016.

GIL, A. C. *Como elaborar projetos de pesquisa*. São Paulo: Atlas, 2002.

GRABOT, B. Rule mining in maintenance: Analysing large knowledge bases. *Computers and Industrial Engineering*, v. 139, n. November 2018, p. 105501, 2020.

HABES, M. et al. The role of modern media technology in improving collaborative learning

of students in Jordanian universities. *International Journal of Information Technology and Language Studies*, v. 2, p. 71–82, 2018.

HIPP, J.; GÜNTZER, U.; NAKHAEIZADEH, G. Algorithms for Association Rule Mining – A General Survey and Comparison. *ACM sigkdd explorations newsletter*, v. 2, p. 58–64, 2000.

JIN, X. et al. The present status and future growth of maintenance in US manufacturing : results from a pilot survey. *Manufacturing Review*, v. 3, 2016.

JUNCA, M.; SANCHEZ-SILVA, M. Optimal maintenance policy for permanently monitored infrastructure subjected to extreme events. *Probabilistic Engineering Mechanics*, v. 33, p. 1–8, 2013.

KUMAR, A.; SHANKAR, R.; THAKUR, L. S. A big data driven sustainable manufacturing framework for condition-based maintenance prediction. *Journal of Computational Science*, v. 27, p. 428–439, 2018.

KUMAR, B. S.; RUKMANI, K. V. Implementation of Web Usage Mining Using APRIORI and FP Growth Algorithms. *Int. J. of Advanced networking and Applications*, v. 404, n. 06, p. 400–404, 2010.

LEE, J.; HAIXIA, W. *New Technologies for Maintenance*. NFC Center for Intelligent Maintenance Systems. *Anais...2008*

LI, Z. et al. Failure event prediction using the Cox proportional hazard model driven by frequent failure signatures. *IIE transactions*, p. 303–315, 2007.

LIU, B. et al. A study on the use of discrete event data for prognostics and health management : discovery of association rules. *PHM Society European Conference*, p. 1–7, 2017.

LÖFSTEN, H. Measuring maintenance performance - in search for a maintenance productivity index. *Int. J. Production Economics*, v. 63, 2000.

MARCONI, M. DE A.; LAKATOS, E. M. *Técnicas de Pesquisa* • Vol. 2 ed. São Paulo: [s.n.].

MARSARO, F.; CAVALCANTE, C. A. V. Mônica Frank Marsaro Random preventive maintenance policy based on inspection for a multicomponent system using simulation Oparta na przeglądach polityka losowej konserwacji zapobiegawczej systemu wieloelementowego z wykorzystaniem symulacji. *Eksploatacja i Niezawodność - Maintenance and Reliability*, v. 19, n. 4, p. 552–559, 2017.

MOBLEY, R. K. *An introduction to predictive maintenance*. Second Edi ed. Nova York: [s.n.].

MOHARANA, U. C.; SARMAH, S. P.; RATHORE, P. K. Application of data mining for spare parts information in maintenance schedule: a case study. *Journal of Manufacturing Technology Management*, v. 30, n. 7, p. 1055–1072, 2019.

- OLINER, A.; GANAPATHI, A.; XU, W. Advances and Challenges in Log Analysis. *Communications of the ACM*, v. 55, n. 2, p. 55–61, 2012.
- PARK, K. S.; HAN, S. W. TPM — Total Productive Maintenance : Impact on Competitiveness and a Framework for Successful Implementation. *Human Factors and Ergonomics in Manufacturing*, v. 11, n. 4, p. 321–338, 2001.
- PINTELON, L.; PARODI-HERZ, A. *Maintenance : An Evolutionary Perspective*. (Springer, Ed.)Complex system maintenance handbook. *Anais...*London: 2008
- ROSS, S. M. *Stochastic processes*. Second edi ed. Berkeley: [s.n.].
- RUSSO, B.; SUCCI, G.; PEDRYCZ, W. Mining system logs to learn error predictors : a case study of a telemetry system. *Empirical Software Engineering*, p. 879–927, 2015.
- SARNO, R. et al. Hybrid Association Rule Learning and Process Mining for Fraud Detection. *IAENG International Journal of Computer Science*, p. 59–73, 2015.
- SCARF, P. A. et al. An age-based inspection and replacement policy for heterogeneous components. *IEEE Transactions on Reliability*, v. 58, n. 4, p. 641–648, 2009.
- SCARF, P. A.; CAVALCANTE, C. A. V. Hybrid block replacement and inspection policies for a multi-component system with heterogeneous component lives. *European Journal of Operational Research*, v. 206, n. 2, p. 384–394, 2010.
- SCHOLTEN, K.; BLOK, C. DE; HAAR, R. *How Flexibility Accommodates Demand Variability in a Service Chain: Insights from Exploratory Interviews in the Refugee Supply Chain*. [s.l: s.n.].
- SRIKANT, RAMAKRISHNAN; AGRAWAL, R. *Mining sequential patterns: Generalizations and performance improvements*. International Conference on Extending Database Technology. *Anais...*Berlin: Springer, 1996
- WANG, W. Subjective estimation of the delay time distribution in maintenance modelling. *European Journal of Operational Research*, v. 00, n. 1992, 1997.
- WANG, W. Delay time modelling. In: *Complex system maintenance handbook*. Springer ed. London: [s.n.]. p. 345–370.
- WANG, W. An overview of the recent advances in delay-time-based maintenance modelling. *Reliability Engineering and System Safety*, v. 106, p. 165–178, 2012.
- WANG, W.; SCARF, P. A.; SMITH, M. A. J. On the application of a model of condition-based maintenance. *Journal of the Operational Research Society*, v. 51, p. 1218–1227, 2000.
- WANG, Y.; JIA, Y.; JIANG, W. Early failure analysis of machining centers : a case study. *Reliability Engineering and System Safety*, v. 72, p. 91–97, 2001.
- WILDEMAN, R. E.; DEKKER, R.; SMIT, A. C. J. M. A dynamic policy for grouping maintenance activities. *European Journal of Operational Research*, v. 99, p. 530–551, 1997.

WU, S.; CLEMENTS-CROOME, D. Optimal Maintenance Policies Under Different Operational Schedules. *IEEE Transactions on Reliability*, v. 54, n. 2, p. 338–346, 2005.

XIA, T. et al. Reconfiguration-oriented opportunistic maintenance policy for reconfigurable manufacturing systems. *Reliability Engineering and System Safety*, v. 166, n. November 2016, p. 87–98, 2017.

YILDIRIM, M.; GEBRAEEL, N. Z.; SUN, X. A. Integrated Predictive Analytics and Optimization for Opportunistic Maintenance and Operations in Wind Farms. *IEEE Transactions on Power Systems*, v. 32, n. 6, p. 4319–4328, 2017.

YUAN, Y. et al. Event log modeling and analysis for system failure prediction Event log modeling and analysis for system failure prediction. *IIE Transactions*, v. 8830, 2011.