isec Engenharia

MESTRADO EM ENGENHARIA E GESTÃO INDUSTRIAL

Manutenção Preditiva Baseada em Cadeias de Markov

Autor

Rithiel do Amaral

Orientador

Prof. Dr. José Manuel Torres Farinha

Coimbra, abril de 2021

INSTITUTO POLITÉCNICO DE COIMBRA

INSTITUTO SUPERIOR DE ENGENHARIA DE COIMBRA

DEPARTAMENTO DE ENGENHARIA QUÍMICA E BIOLÓGICA

Manutenção Preditiva Baseada em Cadeias de Markov

Dissertação para a obtenção do grau de Mestre em Engenharia e Gestão Industrial

Autor

Rithiel do Amaral

Orientador

Prof. Dr. José Manuel Torres Farinha

Coimbra, abril de 2021

INSTITUTO POLITÉCNICO
DE COIMBRA

INSTITUTO SUPERIOR
DE ENGENHARIA
DE COIMBRA

AGRADECIMENTOS

É sempre difícil agradecer o apoio e a colaboração de todos os que motivaram e contribuíram para a realização do presente trabalho. No entanto não posso deixar de agradecer primeiramente a Deus que me ajudou nas horas difíceis desta árdua, mas proveitosa caminhada.

À minha Família, Amigos e Namorada, meus sinceros agradecimentos pelo apoio e motivação.

Em particular, agradeço a prestável colaboração do Professor e Orientador Doutor José Torres Farinha, pelo seu empenho, conselhos e acompanhamento com uma dedicação sempre presente neste projeto.

Assim como a ajuda fundamental nas explicações e fundamentações do Professor Mestre Rolando Restany, ao longo deste trabalho.

RESUMO

A manutenção preditiva em ativos físicos é feita através da análise de inúmeras variáveis nesses ativos e nos processos onde se inserem.

Essas variáveis devem ser cuidadosamente analisadas, pois permitem diagnosticar, quer o estado da condição dos ativos em cada instante quer futuras avarias e paragens de produção, através de técnicas de predição. Adicionalmente, permitem ainda uma correta programação das paragens de manutenção, bem como da racionalização dos custos operacionais.

A presente dissertação foca-se no diagnóstico da condição e na previsão do estado dos ativos físicos através das Cadeias de Markov; a validação do modelo foi feita através de uma base de dados de livre acesso da *Microsoft*, a qual reúne elementos referentes a dados recolhidos de muitos casos de manutenção condicionada, sendo os próprios dados criados por métodos de simulação.

O principal objetivo é prever qual a probabilidade de uma máquina falhar num futuro próximo devido a algum componente e qual; a partir desta inferência é possível decidir qual a melhor política de manutenção a adotar para atingir a disponibilidade desejada.

Para ir ao encontro dos objetivos traçados utilizou-se a base de dados atrás referida e diversas simulações.

No final chegou-se a conclusão de que, para além do diagnóstico realizado pelo método das Cadeias de Markov, uma correta tomada de decisão na gestão de manutenção, implica ter em mãos dados robustos de valores dos equipamentos e os seus componentes, tempo de reparação, de reposição, do *stock* e importância dos mesmos na linha de produção.

Palavras-Chave: Cadeias de Markov; Manutenção condicionada; Manutenção preditiva; Diagnóstico de falhas

ABSTRACT

Predictive maintenance on physical assets is done through the analysis of numerous variables in these assets and in the processes where they are inserted.

These variables must be carefully analyzed, as they allow diagnosing both the state of the condition of the assets at each moment and future breakdowns and production stops, through prediction techniques. In addition, they also allow a correct programming of maintenance stops, as well as the rationalization of operating costs.

This dissertation focuses on diagnosing the condition and predicting the state of physical assets through Markov Chains; the validation of the model was made through a database of free access from Microsoft, which gathers elements referring to data collected from many cases of conditioned maintenance, the data itself being created by simulation methods.

The main objective is to predict how likely a machine is to fail in the near future due to some component and which; from this inference it is possible to decide which is the best maintenance policy to adopt to achieve the desired availability.

To meet the objectives outlined, the aforementioned database and several simulations were used.

In the end, it was concluded that, in addition to the diagnosis made by the Markov Chains method, correct decision making in maintenance management implies having robust data on the values of the equipment and its components, repair time , replacement, stock and importance in the production line.

Keywords: Markov chains; Conditioning maintenance; Predictive maintenance; Fault diagnosis

Índice

ÍNDICE DE FIGURAS v
ÍNDICE DE TABELAS vi
ACRÓNIMOS vii
1 INTRODUÇÃO 1
2 ENQUADRAMENTO TEÓRICO 3
2.1 – Processo estocástico 3
2.2 – Processos Markovianos 3
2.3 Cadeias de Markov Regulares 4
2.3.1 – Distribuição Estacionária 4
2.3.2 – Convergência das Cadeias Regulares 5
2.4 Cadeias de Markov Absorventes 8
2.5 Cadeias de Markov Irredutíveis e Aperiódicas 8
2.6 Cadeias de Markov Reversíveis 10
2.7 Cadeias de Markov Homogéneas 10
2.7.1 – Ergodicidade da Cadeia 12
2.8 Cadeias de Markov Não-Homogéneas 12
2.9 Cadeias de Markov Escondidas 14
2.9.1 – Problemas canónicos 15
2.9.2 – Índice de perplexidade 16
2.10 Manutenção 17
2.11 Manutenção Corretiva 18
2.12 Manutenção Preventiva 19
2.13 Manutenção Preditiva 21
2.14 Manutenção Condicionada 23
2.15 *Reliability Centered Maintenance (RCM)* 24
3 Estudo de Caso 26
3.1 – Apresentação da base de dados 26
3.2 – Análise das máquinas 26
3.2 – Análise dos componentes 35
3.3 Inferência dos resultados na política de manutenção dos equipamentos 38
CONCLUSÃO 40
REFERÊNCIAS BIBLIOGRÁFICAS 42
ANEXOS 44

ÍNDICE DE FIGURAS

Figura 1 – Fases da Manutenção preditiva……..…….23

Figura 2 - *Reliability Centered Maintenance (RCM)*……..……..……25

Figura 3 – Grafo dos estados da Cadeia de Markov para a Máquina 01.....28

Figura 4 – Grafo dos estados da Cadeia de Markov para a Máquina 05…….……...30

Figura 5 – Grafo dos estados da Cadeia de Markov para a Máquina 07……...…....32

Figura 6 – Grafo dos estados da Cadeia de Markov para a Máquina 10…….…..…....33

Figura 7 – Grafo dos estados da Cadeia de Markov para a Máquina 13……..…....35

Figura 8 – Grafo dos estados da Cadeia de Markov para os componentes……..……...……..….36

ÍNDICE DE TABELAS

Tabela 1 – Número de ocorrências para a Máquina 01 ao longo do ano……..27
Tabela 2 – Matriz de frequências de mudanças de estados da Máquina 01 ao longo do ano…....27
Tabela 3 – Representação da Cadeia de Markov para a Máquina 01……...27
Tabela 4 – Matriz de distribuições de probabilidades de estado equilíbrio para Máquina 01.....28
Tabela 5 – Número de ocorrências para a Máquina 05 ao longo do ano……...30
Tabela 6 – Matriz de frequências de mudanças de estados da Máquina 05 ao longo do ano…...30
Tabela 7 – Representação da Cadeia de Markov para a Máquina 05.....30
Tabela 8 – Matriz de distribuições de probabilidades de estado equilíbrio para Máquina 05….....31
Tabela 9 – Número de ocorrências para a Máquina 07 ao longo do ano…….…….....31
Tabela 10 – Matriz de frequências de mudanças de estados da Máquina 07 ao longo do ano…..31
Tabela 11 – Representação da Cadeia de Markov para a Máquina 07……...32
Tabela 12 – Matriz de distribuições de probabilidades de estado equilíbrio para Máquina 07…....32
Tabela 13 – Número de ocorrências para a Máquina 10 ao longo do ano…….....33
Tabela 14 – Matriz de frequências de mudanças de estados da Máquina 10 ao longo do ano..…33
Tabela 15 – Representação da Cadeia de Markov para a Máquina 10……....33
Tabela 16 – Matriz de distribuições de probabilidades de estado equilíbrio para Máquina 10….....34
Tabela 17 – Número de ocorrências para a Máquina 13 ao longo do ano…….....34
Tabela 18 – Matriz de frequências de mudanças de estados da Máquina 13 ao longo do ano.....35
Tabela 19 – Representação da Cadeia de Markov para a Máquina 13…….....35
Tabela 20 – Matriz de frequências de mudanças de estados dos componentes ao longo do ano..36
Tabela 21 – Representação da Cadeia de Markov para os componentes…….…36
Tabela 22 – Matriz de distribuições de probabilidades de estado equilíbrio para componentes….37
Tabela 23 – Diferenças de dias de ocorrências da máquina 1 e componente 1……....38
Tabela 24 – MTTF das máquinas e componentes…….……..38
Tabela 25 – Base de dados de livre acesso da Microsoft……..……ANEXO
Tabela 26 – Sequência de ocorrências dos componentes……ANEXO

ACRÓNIMOS

EN – Norma Europeia

HMM – Hidden Markov Models

NP – Norma Portuguesa

RCM – Reliability Cantered Maintenance

1 INTRODUÇÃO

A globalização é, atualmente, responsável pela habilidade e rapidez de inovar e efetuar melhorias, no que concerne à economia. As organizações procuram novas formas de gestão, com o intuito de garantir uma maior competitividade através da produtividade e qualidade dos seus serviços, produtos e processos (Kardec & Nascif, 2012). Segundo este autor, a necessidade de flexibilidade colocada às organizações implica, cada vez mais, eficácia na tomada de decisão por parte destas mesmas organizações.

A manutenção é, assim, responsável pela disponibilidade dos ativos, o que representa uma importância capital nos resultados da empresa: quanto mais eficaz for a gestão da manutenção melhores serão os resultados.

Entre os vários tipos e denominações, a manutenção preditiva procura antecipar-se às anomalias, maximizando a disponibilidade dos equipamentos, tendo em consideração as mudanças dos valores dos parâmetros de desempenho, i.e., de condição dos equipamentos; ou seja, se houver indícios de um mau funcionamento ou queda de rendimento pressupõe-se que o mesmo esteja com uma propensão evolutiva do defeito e, por consequência, se não for prevista a condição limite de funcionamento, o equipamento terá uma quebra, tendo de recorrer-se a uma intervenção corretiva.

Este tipo de manutenção quebra o paradigma, pois tenta antever uma possível paragem catastrófica de forma precisa, antecipando ações de correção através de monitorizações suportadas em equipamentos de medida e teste e de sensores.

Para auxiliar este diagnóstico, continuam a ser desenvolvidos estudos utilizando redes neuronais para antevisão de falhas, de séries temporais ou, até mesmo, de sistemas de Inteligência Artificial, tal como relata Simeón (2008).

Esta dissertação centra-se no estudo das Cadeias de Markov para dar suporte à manutenção preditiva.

As Cadeias de Markov correspondem a processos estocásticos que permitem calcular a probabilidade condicional de determinado evento no futuro, sendo independente o evento passado e depender exclusivamente do estado presente.

O presente relatório encontra-se estruturado da seguinte forma:

- Primeiro é feita uma abordagem introdutória a todo o documento, apresentando informação relevante e diversos conteúdos abordados ao longo do documento.
- Posteriormente, é feita uma abordagem às Cadeias de Markov e Manutenção, com referência a diversas publicações científicas.
- A aplicação dos dados é feita no terceiro capítulo, o qual se subdivide em duas seções: na primeira é exposta a análise exploratória de dados, exemplificando

a partir de uma determinada máquina e, na segunda, expõem-se outros exemplos, assim como a análise aprofundada dos seus componentes.

- O último capítulo apresenta as conclusões desta dissertação, identificando todas as limitações e dificuldades encontradas na execução da mesma; este capítulo termina com sugestões para desenvolvimentos futuros.

2 ENQUADRAMENTO TEÓRICO

2.1 – Processo estocástico

Um processo estocástico é definido como um conjunto de variáveis aleatórias { $X(t)$}, ajustadas por um parâmetro t respeitante a um conjunto T.

Usualmente, T é utilizado como um conjunto de inteiros não-negativos e $X(t)$ uma função do tempo t. Estes tipos de processos são de bastante interesse para definir o procedimento de um sistema, incidindo sobre um certo período de tempo; isto é, $X(t)$ é função aleatória do tempo t; logo, podemos concluir que $X(t)$ é caracterizada por um espaço, designado Espaço de Estados.

Os Processos Estocásticos têm diversas classificações, tais como:

- Em relação ao Tempo Discreto - t é finito;
- Se o Tempo for Contínuo - t é infinito.

Alguns exemplos de Processos Estocásticos são os seguintes:

- Número de carros presentes numa fila de trânsito num determinado instante - Estado Discreto e Tempo Contínuo;
- Índice de meteorologia diário - Estado Contínuo e Tempo Discreto;
- Números de dias ensolarados - Estado Discreto e Tempo Discreto.

Pelo precedente pode constatar-se que existem vários tipos de Processos Estocásticos; contudo, nesta dissertação será apenas abordado um tipo, denominado Processo Markoviano, bem como as suas implicações e aplicações.

2.2 – Processos Markovianos

Segundo Bressan (2002), processo Estocástico diz-se Markoviano se:

$$P\{X(t_{k+1}) \leq x_{k+1} \mid X(t_k) = x_k, X(t_{k-1}) = x_{k-1}, \ldots, X(t_1) = x_1, X(t_0) = x_0\} = P\{X(t_{k+1}) \leq x_{k+1}, X(t_k) = x_k\} \quad (1)$$

para $t_0 \leq t_1 \leq \ldots t_k \leq t_{k+1}$, $k=0,1,\ldots$

e toda a sequência $k_0, k_1, \ldots, k_{t-1}, k_t, k_{t+1}$

Sendo,

P a probabilidade de transição;

$X(t_k)$ um estado presente de acordo com o tempo k;

k um instante de tempo.

Assim sendo, um Processo Estocástico pode ser visto como um Processo Markoviano, se o estado futuro depender só e exclusivamente do estado presente e não dos estados passados. Estes processos são também designados por *memoryless processes* (processo sem memória), pois, tal como referido atrás, o passado aproxima-se. A probabilidades condicional Equação (2),

$$P\{X(t_{k+1})=x_{k+1}|X(t_k)=x_k\} \tag{2}$$

denominada Probabilidade de Transição, representa a probabilidade do estado $X(t_{k+1})$ no instante t_{k+1}, dado que o estado $X(t_k)$ é x_k (Bondavalli, 2010).

2.3 Cadeias de Markov Regulares

Este tipo de cadeias têm um papel crucial devido à sua distribuição estacionária de probabilidades e à convergência que é alcançada através de operações matriciais elementares efetuadas nas matrizes de transição, que são facilmente programadas, fato importante nas aplicações das cadeias regulares.

2.3.1 – Distribuição Estacionária

Uma distribuição é dita estacionária, regular se, e apenas se, a partir de um estado inicial aleatório é possível aceder a qualquer tipo de estado após um determinado tipo de passos (Magela, 2015); ou seja, se a sua matriz de transição P for estocástica regular.

Supondo P uma matriz de transição de ordem R, onde todas as entradas são positivas. Considerando também um vetor coluna x com r coordenadas, então:

$$M1 \leq M0,\ m0 \leq m1 \tag{3}$$

$$M1 - m1 \leq (1-2\in)\ (M0 - m0) \tag{4}$$

Sendo,

$M0$ a maior coordenada;

$m0$ a menor coordenada;

$M1$ a maior coordenada do vetor Px;

$m1$ a menor coordenada do vetor Px;

ϵ é a menor entrada da matriz P, sendo > 0.

2.3.2 – Convergência das Cadeias Regulares

Magela (2015) apresenta o Teorema Fundamental: sendo P uma matriz de transição regular, as potências P^n aproximam-se da matriz estocástica A, assim como todas as linhas são iguais ao ponto fixo w da matriz P.

Assim, como A tem o mesmo vetor de probabilidade de w, isto quer dizer que

$$A = w\mathcal{E} \tag{5}$$

Sendo,

A uma matriz estocástica;

W um ponto fixo;

$\mathcal{E}$ um vetor linha com todas as componentes iguais a 1.

Pelo Teorema Fundamental temos que presumir que P não tem entrada zero[1], então:

$$M_n - m_n \leq (1-2\mathcal{E})(M_{n-1} - m_{n-1}) \qquad \forall n \geq 1 \tag{6}$$

Se tomarmos

$$d_n = M_n - m_n \tag{7}$$

Isto implica que

$$d_n \leq (1-2\mathcal{E})^n d_0 = (1-2\mathcal{E})^n \tag{8}$$

[1] Todos os valores da matriz são > 0.

Sendo,

$\mathcal{E}$ a menor entrada da matriz de transição;

M_n o maior valor de entre as coordenadas do vetor $P^n\rho_j$;

m_n o menor valor de entre as coordenadas do vetor $P^n\rho_j$;

$M1$ a maior coordenada do vetor Px;

$m1$ a menor coordenada do vetor Px.

Desde que

$$P^n\rho_j = PP^{n-1}\rho_j \tag{9}$$

Sendo,

ρ_j um vetor coluna com 1 na j-ésima coordenada e 0 nas restantes.

segue o lema precedente, em que

$M_1 \geq M_2 \geq M_3 \geq \cdots$ e $m_1 \leq m_2 \leq m_3 \leq$

Logo, quando n se estende ao infinito, dn tende a zero, M_n e m_n aproximam-se de um limite semelhante, logo, $P^n\rho_j$ tende para o vetor desde que quaisquer dos seus constituintes sejam iguais.

Seja w_j esse valor comum; obviamente que, $\forall n$, $m_n \leq w_j \leq M_n$.

Em especial, desde que

$0 < m_1$ e $M_1 < 1$,

tem-se que

$0 < w_j < 1$.

Agora $P^n\rho_j$ é a j-ésima coluna de P^n.

Assim, a j-ésima coluna de P^n tende para o vetor com todos os elementos iguais ao valor w_j, ou seja, P^n tende para a matriz A em que todas as linhas são equivalentes ao vetor

$$w = (w_1, \cdots, w_r) \tag{10}$$

A partir do momento em que as somas das componentes dos vetores linhas da matriz P^n sejam sempre iguais a 1, o mesmo deve acontecer com o limite.

Com o precedente conclui-se a demonstração para o caso em que todas as entradas da matriz são positivas.

Considere-se agora que P é regular. Seja N tal que qualquer potência P^n não tenha entradas zero. Utilizando a principal parte da demonstração para a matriz P^n , vem,

$$d_{kN} \leq (1-2\epsilon*)^n \tag{11}$$

Sendo,

$$d_{kn} = M_n - m_n \tag{12}$$

o valor superior menos o valor inferior de entre as coordenadas do vetor $P^n\rho_j$.

Logo, a sequência d_n, que não é gradual, usufrui de uma subsequência tendendo para zero. O resto da demonstração é análoga à demonstração para a matriz com todas as entradas positivas, pois d_n tende a zero.

Portanto, a sequência $P, P^2, P^3, \ldots, P^n, \cdots$ das potências de P estende-se à matriz em que todas as colunas são equivalentes ao vetor de probabilidade fixa w.

A presença de um procedimento acessível para demarcar o vetor de probabilidade fixa de uma matriz de transição de uma cadeia de Markov é assegurado por este teorema. Ao tomarmos uma potência P^n, com n suficientemente grande, obtemos o vetor de probabilidade fixa.

O vetor de probabilidade fixa w é designado por vetor da distribuição estacionária da cadeia de Markov regular, definida pela matriz de transição P.

Consideremos que uma cadeia de Markov é regular. Segundo o Teorema da Convergência, a sequência das matrizes de transição, para n estágios, P^n, tende para a matriz T, em que as linhas são todas idênticas ao vetor singular de probabilidade fixa w de P. Portanto, a probabilidade $w_{ij}^{(n)}$ de que o estado j aconteça, para n suficientemente grande, é autónomo do estado inicial i e tende para a constituinte w_i

de w. Ou seja, a longo prazo, a verosimilhança de que algum estado j suceda é sensivelmente equivalente à componente w_i do único vetor de probabilidade fixa w de P.

Face ao precedente, conseguimos observar que a influência do estado inicial se reduz de acordo com o aumento do número de estágios do processo. Além disso, toda a sequência de repartição de probabilidades tende para o vetor de probabilidade fixa de P, o qual apresenta a distribuição estacionária de uma cadeia de Markov.

Dito isto, esta característica particular das cadeias de Markov Regulares, são um bom modelo de modelação matemática para o estudo de previsões a longo prazo.

2.4 Cadeias de Markov Absorventes

Um estado i de uma cadeia de Markov é designado de absorvente se $p_{ii} = 1$.

Segundo Magela (2015), as cadeias de Markov são ditas absorvente, se e somente se existir, no mínimo, um estado absorvente e, se for permissível a partir de qualquer estado arbitrário, haver uma sequência de transições até se obter um estado absorvente.

Um estado i é absorvente se a i-ésima linha da matriz de transição P tem a componente na diagonal principal igual a 1, e zeros nas outras posições.

Os estados que não são denominados absorventes, são chamados de estados de transição.

Tendo uma matriz estocástica de ordem n ≥ 2 tem 1 na diagonal primordial, então P não é regular. Ou seja, se uma cadeia de Markov usufrui, no mínimo, de um estado absorvente, então a cadeia não é regular.

Supondo que s_j um estado absorvente de uma cadeia de Markov com matriz de transição P, logo, para i, a probabilidade de transição depois de n estágios é $p_{ij}^{(n)} = 0$ (13), $\forall n$. Em suma, alguma potência de P tem um constituinte nulo. Logo, P não é regular.

2.5 Cadeias de Markov Irredutíveis e Aperiódicas

De acordo com Silva (2017), se “todos os estados da cadeia podem ser alcançados por todos os outros”, designam-se por propriedade da Irredutibilidade.

Portanto, uma Cadeia de Markov ($X_0, X_1, ...$), com espaço de estado $S = \{s_1, ..., s_k\}$ e matriz de transição P é considerada irredutível se, para todo s_i, s_j pertencem a S, então s_i é s_j; caso isto não aconteça, a cadeia é redutível.

Uma observação feita é que uma cadeia só é dita irredutível se, e apenas se, para todo o conjunto s_i, s_j pertence a S, e existe n tal que $(P^n)_{i,j} > 0$.

Seja $S = \{s_1, ..., s_k\}$, o período $p(s_i)$ de um estado s_i que pertence a S é definido como:

$$p(s_i) = mdc\{n \geq 1 : (P^n)_{i,j} > 0\} \tag{14}$$

Sendo,

mdc = é o maior divisor comum do conjunto de vezes que a cadeia pode retornar;

P = uma matriz de transição;

$P(s_i)$ = período de tempo.

Dito de outra forma, o período s_i tem a probabilidade positiva de retorno, ou seja, é o maior divisor comum do conjunto de vezes que a cadeia pode regressar a s_i, visto que começa com $X_0 = s_i$. Se $p(s_i)=1$ diz-se que o estado s_i é aperiódico.

As cadeias de Markov são consideradas aperiódicas se todos os estados são igualmente aperiódicos. Caso tal não ocorra é chamada de periódica (Silva, 2017).

Vamos supor que uma Cadeia de Markov é irredutível e, ao mesmo tempo, aperiódica ($X_0, X_1, ...$), com espaço de estado $s = \{s_1, ..., s_k\}$ e matriz de transição P. Então, existe um $N < \infty$ tal que,

$$(P^n)_{i,j} > 0 \qquad \forall i \in \{1, 2, ..., n\} \text{ e } \forall n \geq N. \tag{15}$$

Sendo,

$\forall$ = quantificador universal; “para todo”;

$\in$ = pertence ao conjunto.

2.6 Cadeias de Markov Reversíveis

Seja ($X_0, X_1, ...$) uma Cadeia de Markov com espaço de estado $S = \{s_1, ..., s_k\}$ e matriz de transição P. Uma distribuição de probabilidade π em S é considerada reversível para a cadeia (ou matriz de transição p) se $\forall i, j$ pertence a $\{1, ..., k\}$, tem-se:

$$\pi_i P_{i,j} = \pi_j P_{j,i} \tag{16}$$

Se a cadeia começa com a distribuição reversível, então, olhando para a equação acima, o lado esquerdo pode ser visto como o valor da probabilidade que flui no tempo 1 do estado si para o estado s_j. De igual forma, o lado direito é o valor da probabilidade que fluí de s_j para s_i; com isto pode observar-se um grande equilíbrio.

Considerando ($X_0, X_1, ...$) uma Cadeia de Markov com espaço de estado

$$S=\{s_1, ..., s_k\} \tag{17}$$

e a matriz de transição kP, caso π seja uma distribuição reversível da cadeia, então também é considerada uma distribuição estacionária na cadeia, (Silva, 2017).

2.7 Cadeias de Markov Homogéneas

Uma Cadeia de Markov é considerada homogénea ou estacionária no tempo, se e só se a possibilidade de ir de um estado a outro é autónoma do tempo em que o passo é dado; ou seja, para todos os estados $i, j \in S$, tem-se:

$$P\,(X_n = j|X_{n-1} = i) = P\,(X_{n+k} = j|X_{n+k-1} = i) \tag{18}$$

Para $k = -(n-1), -(n-2), ..., -1,0,1,2, \ldots$

Contudo, se a condição de estacionariedade não resultar, então a Cadeia é considerada não-estacionária ou não homogénea.

Tendo uma cadeia homogénea com espaço de estados $S = \{a, b, ..., j\}$, organizam-se as probabilidades pij numa matriz de $n \times n$ onde pij ocupa a i-ésima linha e a j-ésima

coluna desta matriz, que é designada por matriz de transição de probabilidade da cadeia.

$$P = \begin{bmatrix} p_{11} & p_{12} & \cdots & p_{1n} \\ p_{21} & p_{22} & \cdots & p_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ p_{n1} & p_{n2} & \cdots & p_{nn} \end{bmatrix} \tag{19}$$

Algumas das propriedades deste tipo de matriz são:

- Todas as entradas são positivas;
- A soma das entradas em cada linha é um.

Esta matriz de transição tem toda a informação que é necessária para explicar o movimento da cadeia ao longo dos estados em S.

Ao pretenderem-se as probabilidades de transição de n passos, essas mesmas probabilidades são dadas pela matriz P^n, onde os elementos de P^n são dados por

$$p_{ij}^{(n)} = (P_{n+k} = j | X_k = i) \tag{20}$$

Para analisar onde se encontra um processo num determinado instante de tempo, deve saber-se onde esse processo começa.

Um vetor $p^{(0)} = (p^{(0)}, p^{(0)}{}_2, \ldots, p^{(0)}{}_n)$, dado por uma distribuição de probabilidade sobre os estados, é dito de vetor inicial se,

$$p_i^{(0)} = P\,(X_0 = i) \geq 0, e \sum_{i=1}^{n} p_i^{(0)} = 1 \tag{21}$$

Ao ter-se o vetor inicial e a matriz de transição, consegue-se calcular qualquer probabilidade sobre as variáveis do processo,

$$P\,(X_n = j) = (p^{(0)} P^n)_j \tag{22}$$

Para se saber onde está o processo depois de n passos, visto que o vetor inicial foi $p(0)$, aplica-se a Equação (23):

$$p^{(n)} = p^{(0)}P^n \tag{23}$$

onde o j-ésimo elemento de $p^{(n)}$ é dado por

$$pj^{(n)} = P\ (Xn = j) \tag{24}$$

2.7.1 – Ergodicidade da Cadeia

Considerando P uma matriz de transição de uma cadeia de Markov, se para todo $j \in S$, tem-se que $lim_{n\to\infty}\ p_{ij}^n = \pi j$ existe autonomamente de $i \in S\ e\ \Sigma i \in S\ \pi i = 1$; neste caso diz-se que a cadeia é ergódica.

Para n, a probabilidade $P(X_n = j)$ corresponde a uma situação como se a cadeia tivesse entrado em harmonia, ou seja, está adjacente a um valor π_j. Por isso, $\{\pi_j;\ j \in S\}$ é chamada distribuição limite da cadeia ou distribuição de equilíbrio (Neto, 2010).

Seja $\{X_n\}n \geq 0$ uma cadeia de Markov, irredutível, aperiódica e recorrente positiva. Então,

$$\pi_j > 0, \Sigma_{j\in S}\ \pi_j = 1 \quad e \quad \pi_j\ = \Sigma_{i\in S}\ \pi_i p_{ij}, \forall\ j \in S \tag{25}$$

Sendo,

$P(X_n)$ = uma probabilidade Xn;

π = distribuição exclusiva estacionária.

Toda a cadeia de Markov homogénea, para ser convergente, precisa ser irredutível e aperiódica, com espaço de estados finito.

2.8 Cadeias de Markov Não-Homogéneas

Uma cadeia de Markov não-homogênea é definida por um vetor inicial $f(0)$ e por uma continuação de matrizes de transição $\{P_k\}\infty k = 1$. Sejam $P_1, P_2, \ldots$ matrizes de transição de uma cadeia de Markov não-homogénea, com vetor inicial $f(0)$:

$$p^{(k)} = p^{(0)} * P_1 * P_2 * \ldots * P_k, e\ p^{(m,k)} = p^{(0)} * P_{m+1} * P_{m+2} * \ldots * P_k \tag{26}$$

Define-se o j-ésimo elemento de $p^{(k)}$ por

$$p_j^{(k)} = P(X_k = j) \tag{27}$$

e o *(i,j)-ésimo* elemento por

$$P^{(m,k)} = P_{m+1} * P_{m+2} * \ \dots * P_k \text{ por } p_{ij}^{(m,k)} = P(X_k = j | X_m = i) \tag{28}$$

O principal objetivo é estudar o comportamento de $p^{(k)}$ e $p^{(m,k)}$, quando $k \to \infty$. É provável que o vetor $p^{(k)}$ conflua para o mesmo vetor q, autonomamente do vetor inicial utilizado, ou seja, o limite do vetor vai sempre existir independentemente da seleção do vetor inicial. Com isso, o efeito do vetor inicial é perdido ao longo do tempo, ou seja, $p^{(k)}$, para k grande, e dando quase ou nenhuma informação sobre $p^{(0)}$, por isso o conceito ser comumente designado de *processo de perda de memória*. Quando $lim\ p^{(m,k)}{}_{k \to \infty}\ p^{(m,k)} = q$, para todo o m, separadamente de $p^{(0)}$, tem-se a junção e a *perda de memória*, podendo afirmar-se que a cadeia é bastante ergódica. Contudo, se tiver *perda de memória* em relação à distribuição inicial, a cadeia já é pouco ergódica (Neto, 2010).

A partir daqui pode definir-se que uma cadeia de Markov não homogénea é chamada de fracamente ergódica, se para todo o m,

$$\lim_{k \to \infty} sup_{p(0),g(0)} || \, p^{(m,k)} \ - \ g^{(m,k)} || = 0 \tag{29}$$

Sendo,

p e g = vetores independentes.

Já para ser considerada fortemente ergódica é necessário existir um vetor $q=(q1, q2, \dots)$, onde $q=1$ e $q \geq 0$, para $i = 1, 2, 3\dots$, se, para todo o m,

$$\lim_{k \to \infty} sup_{p(0)} || \, p^{(m,k)} \ - \ q || = 0 \tag{30}$$

Sendo,

p e q = vetores independentes.

A regra empregue é mais redutora do que a convergência coordenada. Com a finalidade de ter ergodicidade fraca ou forte, é necessário ter,

$$\lim_{n\to\infty} \sum_{i=1}^{\infty} |p_i^{(m,n)} - g_i^{(m,n)}| = 0 \tag{31}$$

$$\lim_{n\to\infty} \sum_{i=1}^{\infty} |p_i^{(m,n)} - q_i| = 0 \tag{32}$$

Sendo,

p, g e q = vetores independentes.

2.9 Cadeias de Markov Escondidas

Comumente chamadas de Ocultas ou *HMM* (*Hidden Markov Models*), estes tipos de cadeias são definidos como modelos Markovianos, em que a análise do progresso do sistema dá-se de forma indireta e continua, que oculta a evolução da Cadeia de Markov que gere o método. Ou seja, não existem fundamentos exatos que levam a certa observação, baseado no seguinte:

- A distribuição de probabilidade de transição entre estados $\alpha = (a_{ij})$,
  - *tal que* $a_{ij} = P(q_t = s_j \mid q_{t-1} = s_i)$
- A distribuição de probabilidade inicial para cada estado $\beta = (b_i)$,
  - *tal que* $b_i = P(q_0 = s_i)$;
- A distribuição de probabilidade de observação $\varepsilon = [e_{ij}(k)]$,
  - tal que $e_{ij}(k) = P(O_t = y_k \mid q_{t-1} = s_i, q_t = s_j)$, está associada a transições do estado s_i para s_j.

Sendo,

α, β e ε = distribuições de probabilidade.

Jelinek (1998) afirma que existem três definições que podem explicar o formalismo dos Modelos Ocultos de Markov:

- A primeira definição, que foi utilizada pelo próprio autor, diz respeito aos dados observáveis como função das transições entre os estados da Cadeia Oculta de Markov;
- A segunda definição, adotada por Rabiner (1989), trata dos dados observáveis como função dos próprios estados de Markov;
- A última definição é muito utilizada em modelos acústicos.

Quando se trata de mais de uma variante de processos Markovianos, quaisquer equações usadas nas Cadeias de Markov também são aplicáveis aos Modelos Ocultos de Markov.

Para Jelinek (1998), para além dos autómatos, utiliza-se outro artificio gráfico, para auxiliar na compreensão das *HMM*. É conhecido como *trellis* e ajuda no cálculo da probabilidade de uma sequência de estados observáveis $P\ (y_1, y_2, y_3, \ldots y_k)$, dando evidência à evolução temporal do processo que originou essa sequência. Tem ainda como objetivo o encadeamento dos estágios elementares, um a um, a cada estado observável.

2.9.1 – Problemas canónicos

A modelação de um sistema físico é uma versão simplificada da realidade propriamente dita. Dito isto, não existe um modelo absoluto, mas sim modelos adequados para cada sistema. Tendo isto em consideração, o processo de modelação pode ser composto por duas etapas: o ajuste do modelo através da resolução de problemas-controlo; e a definição dos parâmetros do modelo (Espindola, 2009).

Existem, assim, três problemas que têm de ser resolvidos antes da utilização do modelo, que são os seguintes:

- Probabilidade de uma sequência de estados observáveis.
  - Com o modelo $\lambda = (\hat{A}, \hat{E}, \pi)$ e a sequência de observáveis $O = O_1, O_2, \ldots O_T$.
  - O problema a ser resolvido é como calcular de forma eficiente a probabilidade dessa sequência ser gerada pelo modelo $P(O|\ \lambda)$.
- Sequência ótima de estados
  - Com o modelo $\lambda = (\hat{A}, \hat{E}, \pi)$ e a sequência de observáveis $O = O_1, O_2, \ldots O_T$.
  - O problema a ser resolvido é de qual é a sequência mais provável de estados que poderá ser gerada na sequência de observáveis.
- Maximização da probabilidade de uma sequência de observáveis
  - O problema a ser resolvido é o ajuste dos parâmetros $\lambda = (\hat{A}, \hat{E}, \pi)$ do modelo para maximizar $P(O|\ \lambda)$.

2.9.2 – Índice de perplexidade

Existem duas formas de serem medidas o desempenho do modelo *HMM*:

- Uma por classificação;
- Outra por perplexidade;
    - Esta última, prevê quantos vetores dos estados escondidos estão corretas, dividido pelo total de estados ocultos em análise. Contudo, calcularmos a precisão para um conjunto de estados que se considera pequeno; pode não ser o mais adequado, pois uma amostra pode apenas ser atribuída a uma classe; então, a perplexidade do conjunto dos dados de teste é a melhor medida que se pode utilizar.

A Equação (33) permite calcular a probabilidade do sistema estar no estado i e tempo t:

$$Perplex_{qi} = e^{-\frac{1}{N_S}\sum_{k=1}^{N_S} L_{k,i}} \tag{33}$$

Sendo,

$L_{k,i}$ = função da média das probabilidades do logaritmo;

N_s = diversas sequências de dados.

A confiança das previsões é calculada pela perplexidade, que também é considerada como uma função das probabilidades do logaritmo e das inúmeras sequências de dados, que findam no estado q_i. Utiliza-se a Equação (34):

$$L_{k,i} = log[p(S_{tk} = q_i | O^K_{1,\dots,T_{k,i}}, \lambda] \tag{34}$$

Sendo,

$O^K_{1,\dots,T_{k,i}}$= a kth sequência de observações de comprimento t_{ki};

q_i = a classe de estados escondidos, especificamente de forma genérica;

N_s = o número de sequências;

λ = os parâmetros do modelo.

1 é o resultado da melhor perplexidade que se pode esperar; já uma perplexidade de valor 3 remete-nos para uma suposição aleatória cuja probabilidade é de 1/3 para os diversos estados ocultos.

2.10 Manutenção

A Manutenção industrial tem como principal objetivo “garantir a disponibilidade da função dos equipamentos e instalações de modo a atender a um processo de produção e à preservação do meio ambiente, com fiabilidade, segurança, a custos adequados” (Kardec & Nascif, 2012).

Segundo Monchy (1987), historicamente “o termo manutenção tem origem na palavra militar, onde o sentido era manter nas unidades de combate o efetivo e o material num nível constante de aceitação”.

Tendo em consideração a norma portuguesa NP EN 13306:2007, manutenção é a “combinação de todas as ações técnicas, administrativas e de gestão, durante o ciclo de vida de um determinado bem, visando mantê-lo ou repô-lo num estado em que pode executar a função requerida”.

Segundo Farinha (2011), a necessidade de reparar regularmente as máquinas surgiu na Revolução Industrial do Século XIX; contudo, essas intervenções eram deixadas a cargo dos próprios operadores. Só a partir da 1ª Guerra Mundial a indústria foi pressionada a atingir padrões mínimos de produção, levando à constituição de equipas especializadas para reparar as avarias, de forma apenas corretiva, no menor tempo possível.

Nos dias de hoje, a manutenção tem um papel crucial na indústria; esta deixou de estar associada a custos e passou a ser apreciada como uma mais-valia para conservar a competitividade das empresas. Devido a esta importância que a manutenção passou a exibir para as companhias, ao longo do tempo foram aparecendo vários tipos e técnicas de gestão da manutenção, com aplicabilidades mais precisas e eficientes (Santos, 2018).

A área de manutenção influencia de forma direta os resultados operacionais e, com isso, a rentabilidade das empresas. Sendo assim, os resultados serão tanto melhores quanto mais infalível for a gestão dos procedimentos da manutenção (Souza, 2008).

Segundo Patton (2004), existem diversas abordagens de manutenção, que se explicam pela forma como se aplicam no sistema produtivo, aquando do instante da ocorrência ou da antevisão da falha.

Existem dois tipos principais de intervenções de manutenção:

- corretiva
- preventiva

- sistemática
- condicionada
    - Preditiva

Embora também possam haver outras denominações ou complementaridades entre ambas, há macro abordagens que procuram conseguir complementaridades entre todas, investigando sempre a mais fiável e com menor custo para a empresa, ou seja, a estratégia mais eficaz para cada equipamento ou processo, tal como a *Reliability Centered Maintenance (RCM)*, traduzida para Manutenção Centrada na Fiabilidade (Marques, 2017).

Numa empresa pode aplicar-se apenas um tipo de intervenção ou intervenções diferentes para equipamentos distintos. Segundo Branco Filho (2008), a decisão de escolher qual será a melhor forma de manutenção a ser utilizada cabe ao gestor de manutenção, com base na importância que o equipamento tem no processo em que atua, bem como os tempos de reparação, entre outros aspetos.

Há também indicadores de desempenho que auxiliam na tomada de decisão, tais como o *MTTF* (*Mean Time To Failure*) e o *MTTR* (*Mean Time to Repair*). Estes conceitos estão diretamente relacionados com a engenharia de manutenção.

O *MTTF*, conforme o nome diz, corresponde ao tempo médio entre falhas, ou seja, é o tempo de uma falha para outra. Já o *MTTR* é o tempo médio de reparação, uma medida da capacidade de manutenção de um item reparável, que informa o tempo médio necessário para reparar um item ou componente específico e retorná-lo ao funcionamento normal de trabalho; levando em consideração a notificação inicial da falha, o tempo necessário para enviar o equipamento para reparação, o diagnóstico, o tempo real de reparação, a montagem, a calibração, o teste e, por fim, tornar o mesmo operacional no seu processo.

2.11 Manutenção Corretiva

É considerada a visão mais tradicional da manutenção, “combate a incêndios” – ou seja, de intervir apenas quando avaria. Existem inúmeros inconvenientes desta abordagem, tais como:

- As quebras não calculadas traduzem-se por uma paragem inesperada, acarretando altos prejuízos devidos às perdas de produção;
- O custo de manutenção aumenta à medida que os equipamentos vão envelhecendo.

A manutenção corretiva tem bastante impacto nos custos de manutenção de uma empresa, pois estão relacionados com os maiores custos da manutenção devido a:

- elevado tempo de paralisação da máquina;
- altos custos de *stock* de peças sobressalentes;
- baixa disponibilidade de produção;
- altos custos de trabalho extra e,
- as elevadas perdas resultantes da indisponibilidade dos equipamentos.

A decisão da gestão pode ser a de deixar o equipamento funcionar até à quebra, onde o planeamento pode ser feito quando a falha ocorrer. Contudo, pode substituir-se o equipamento por outro idêntico, i.e., ter um *kit* de reparação rápido, por exemplo.

Com o objetivo de minimizar o impacto sobre a produção criada por anomalias imprevistas das máquinas, o setor da manutenção tem de estar habilitado a reagir prontamente a todas as falhas da máquina, o que leva a um alto custo de mão-de-obra. O estudo dos custos da manutenção desenvolvido por de Almeida (2007) indica que uma reparação executada no modo corretivo-reativo terá, em média, um custo cerca de três vezes superior quando comparado com a mesma reparação feito de modo programado ou preventivo.

Na manutenção corretiva, o equipamento pode ser desmontado e inspecionado para avaliar as reparações necessárias para a sua reposição ao serviço. Se as peças de reserva não existirem em *stock*, elas devem ser encomendadas, a custo de mercado, e deve ser pedido o seu envio expedito. Mesmo quando as peças de reparação já se encontram em stock na empresa, os funcionários da manutenção devem desmontar a máquina para identificar a causa do problema que deu origem à falha. Supondo que reconhecem corretamente o problema, o tempo e o custo necessários para desmontar, reparar, e remontar a máquina será maior do que teria sido se fosse de uma intervenção planeada. Com um tempo de reparação maior, as carências relacionadas com as paragens da máquina serão naturalmente maiores (Souza, 2008).

2.12 Manutenção Preventiva

Neste tipo de manutenção, com o uso de critérios estatísticos, os conselhos do fabricante e saberes práticos sobre o equipamento, é instituído um programa de inspeções e intervenções com intervalos fixos.

Contrariamente à Manutenção Corretiva, a Manutenção Preventiva procura evitar o surgimento de falhas, ou seja, tem como objetivo prevenir. Em certos setores, como

na aviação, a utilização de manutenção preventiva é obrigatória para determinados componentes ou sistemas, pois o fator segurança sobrepõe-se aos restantes.

Para (Arato, 2004), a utilização da manutenção preventiva real varia abundantemente. Alguns programas são bastante reduzidos e constam de lubrificação e pequenos ajustes. Os programas mais abrangentes de manutenção preventiva projetam ajustes, reparações, lubrificação e recondicionamento de máquinas para todos os ativos da unidade industrial. O fator comum para todos estes programas de manutenção preventiva é a programação da manutenção *versus* tempo.

Os fabricantes nem sempre fornecem dados objetivos para a elaboração dos planos de manutenção preventiva. Para além disso, as condições operacionais e ambientais têm bastante influência na expectativa da degradação dos equipamentos. A substituição deve ser ajustada para cada instalação ou unidades industriais similares, devendo ser operadas em condições similares. Isto origina situações diferentes na fase inicial de operação:

- Arranque do equipamento/reposição de componentes prematuramente;
- Ao longo da vida útil do equipamento não pode ser observada a falha entre duas intervenções preventivas, o que, logicamente, levará a uma ação corretiva;
- Acontecimento de falhas antes de concluir o período avaliado, pelo responsável da manutenção.

Existem alguns fatores que devem ser tidos em consideração na criação de uma política de manutenção preventiva:

- Na ocasião em que os equipamentos têm uma atividade operacional difícil;
- Tudo o que esteja relacionado com a segurança pessoal ou da instalação que tornam fundamental a intervenção;
- Quando a manutenção preditiva não é possível.

Quanto mais elevados forem os custos de falhas, quanto maior for a dificuldade na reposição, quanto mais falhas afetarem a produção e quanto maiores forem as implicações das falhas na segurança pessoal e operacional, mais importante é a manutenção preventiva.

A manutenção preventiva, por um lado, oferece um saber adiantado das ações, dando origem a uma boa gestão das atividades e, além da previsibilidade de consumo de materiais e sobressalentes, por outro, retira o sistema ou equipamento de operação para a realização dos serviços programados (Souza, 2008).

Assim:

- Seja por quebras ou pela síndrome da precaução, a desmontagem de um equipamento estimula a substituição de peças. Contudo, a experiência da desmontagem/montagem aumenta o risco de novas avarias;
- O modo de operação e as variáveis específicas da unidade industrial são alguns dos fatores que afetam diretamente a vida operacional regular da maquinaria.

Tendo em consideração as condições operacionais de um determinado equipamento, a manutenção prevista pode ser completamente inútil, desperdiçando não só mão-de-obra e material, como pode falhar num intervalo de tempo menor do que o esperado, o que obriga à aplicação de técnicas corretivas para a reparação.

2.13 Manutenção Condicionada

Este tipo de manutenção, também conhecida por Manutenção com Base no Estado do Equipamento é a ação concretizada tendo em conta a mudança de parâmetros de desempenho ou condição.

Na manutenção condicionada, as inspeções periódicas limitam-se a monitorizar as normas que designam o estado operacional de um equipamento ou sistema. Se houver indícios de um mau funcionamento, supõe-se a propensão evolutiva do defeito e com isso origina-se uma paragem para a respetiva correção.

Este tipo de manutenção quebra o grande paradigma na Manutenção e, quanto maior for o desenvolvimento do conhecimento tecnológico mais este se intensifica, acabando por serem desenvolvidos equipamentos que consintam uma avaliação fiel das instalações e sistemas operacionais em funcionamento (Nepomuceno, 2014).

Ao escolhermos esta manutenção, haverá uma intervenção de forma condicionada sobre uma máquina se, e só se, os parâmetros de controlo progredirem significativamente para graus que são considerados não admissíveis. Dito isto, a Manutenção Preditiva não defende a ação nos sistemas ou equipamentos, pois, tanto as verificações como as medições são feitas com o equipamento a produzir (Marques, 2017).

Algumas outras vantagens são:

- Decrescimento do custo de cada intervenção;
- Diminuição do *stock* de peças de reserva;
- Exclusão da substituição de elementos em estado operacional;
- Ampliação do tempo médio entre cada intervenção;
- Eliminação de defeitos.

Contudo, existem condições necessárias e básicas para se poder adotar uma política de Manutenção Condicionada:

- As falhas devem ser provenientes de causas que possam ser analisadas e monitorizadas de forma a ter a sua progressão acompanhada;
- O sistema, equipamento ou instalação, utilizam este tipo de manutenção em função dos custos envolvidos;
- Estabelecimento de um programa de análise, diagnóstico e acompanhamento;
- A instalação, sistema ou equipamento reconhecem consentir algum tipo de monitorização/medição.

A implementação de uma política de manutenção condicionada e, eventualmente, preditiva, implica três fases:

- deteção do defeito;
- estabelecimento de um diagnóstico;
- e estabelecimento de um prognóstico (Arato, 2004).

O resultado da análise dos valores dos critérios de acompanhamento deve-se ao estabelecimento do diagnóstico, tendo em consideração modelos de desgaste e informação anterior sobre o equipamento, bem como a gravidade dos seus prováveis defeitos e a sua origem.

Instituir um prognóstico consta em alargar o diagnóstico e prever quanto tempo se tem antes da paragem obrigatória pela quebra literalmente dita, bem como determinar quais serão as futuras consequências ao se adiar um defeito acidental.

Existe ainda outra proposta que foi abordada por Simeón (2008), em que este sugere a utilização de redes neuronais ao sistema inteligente de Balbina para antevisão, através de séries temporais (Figura 1).

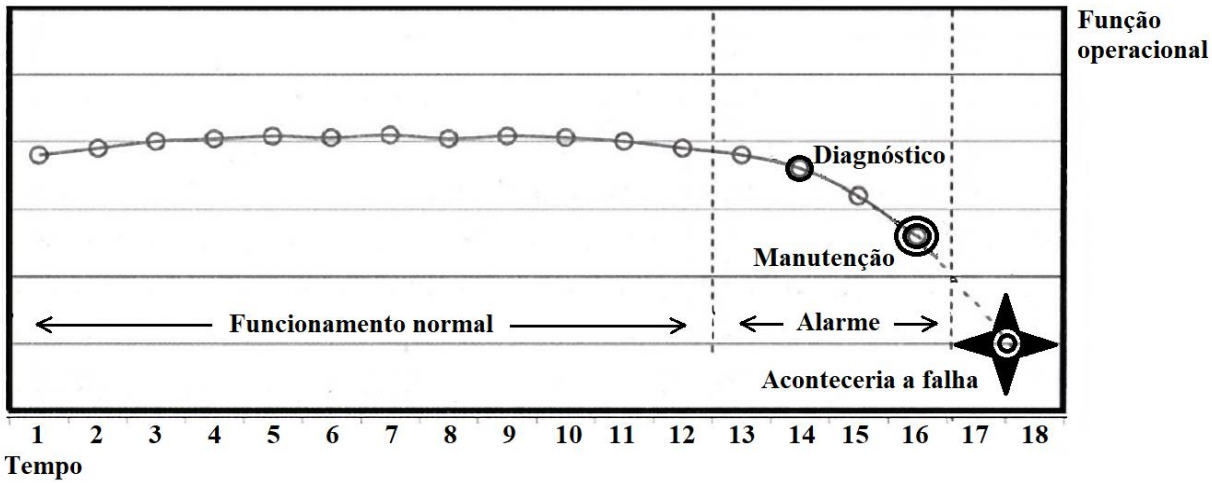

Figura 1 – Fases da Manutenção Condicionada/Preditiva (Curva P-F). Adaptado de Arato (2004).

2.14 Manutenção Preditiva

Na manutenção condicionada, quando existe uma certeza de uma avaria iminente, é tomada uma decisão de intervenção, realizada em função do estado dos componentes do equipamento. Também podemos referir como manutenção inteligente, pois só quando existe necessidade é que se faz uma intervenção.

É uma manutenção do tipo preventiva, secundária a um tipo de acontecimento preestabelecido (autodiagnóstico), a uma medida de um desgaste, à informação de outro indicador que possa divulgar o estado de degradação do equipamento. A intervenção da manutenção é programada quando se alcançam os valores de alarme. Alguns exemplos deste tipo de manutenção são referentes ao controlo do nível do óleo ou à troca das pastilhas de travão. São os sinais luminosos que informam se está a atingir o nível de utilização das pastilhas ou que se atingiu o nível mínimo de óleo (Nancabú, 2011).

As máquinas que são essenciais para a produção, os equipamentos que apresentam avarias frequentes são o alvo desta intervenção.

Alguns métodos para determinar o estado de condição são: Monitorização de partículas (ferrografia, raios-x); Monitorização dinâmica (vibrações, emissão acústica); Monitorização química (cromatografia gasosa e líquida, espectrometria de óleos); Monitorização dos efeitos físicos (líquidos penetrantes, ressonância ultrassónica, raios-x); Monitorização de efeitos elétricos (resistência elétrica, potencial e corrente); Monitorização de temperatura (termografia e temperatura de pintura).

Segundo Nancabú (2011), a principal vantagem deste tipo de manutenção é o aumento da durabilidade dos equipamentos, o custo menor de restauro, o aumento de produtividade e o controlo mais eficiente de peças de reserva e sua limitação.

A partir do acompanhamento de condição, através de algoritmos baseados em séries temporais, de redes neuronais e de Cadeias de Markov, incluindo HMM, ferramentas de suporte à Manutenção Preditiva, pode prognosticar-se o tempo mais adequado à intervenção de manutenção, antes da falha ocorrer.

2.15 Reliability Centered Maintenance (RCM)

Tendo em consideração Siqueira (2009), a *Reliability Centered Maintenance (RCM)*, traduzida como Manutenção Centrada na Fiabilidade, foi concebida no fim da década de 60. Inicialmente era utilizada na indústria aeronáutica, com o intuito de levar os esforços da manutenção nos sistemas onde, para haver uma grande eficácia do equipamento, acreditando no seu desempenho, segurança e proteção do ambiente e um melhor custo-benefício, era essencial existir bastante fiabilidade.

Moss (1985) refere que a *RCM* está organizada com o primórdio básico de que toda a tarefa da manutenção tem de ser fundamentada, antes de ser efetuada. O critério de justificação deve adequar-se à disponibilidade, à segurança, e à economia, ao alongar ou antever um modo característico de falha.

Partindo de uma apreciação apurada dos cargos desempenhados, são instituídas as tarefas de manutenção mais apropriadas para a garantia do desempenho funcional da instalação. Dito isto, o critério de justificação abrange a principal característica da aplicação da RCM, acima mencionada.

Fleming (1997) resume a *RCM* como uma estratégia de manutenção que implica uma ponderação metódica das funções do sistema, a maneira como estas funções falham e, principalmente, um critério de priorização claro apoiado em fatores operacionais, de segurança e económicos para o reconhecimento das tarefas de manutenção que são mais adequadas e robustas.

Rausand (1998) assevera que o principal objetivo da *RCM* é diminuir o custo de manutenção. Para isso centraliza o foco nos serviços essenciais ao sistema e, com isso, evita ações de manutenção que são desnecessárias. Se já existe um programa de manutenção, o efeito da análise *RCM* excluirá tarefas que são inúteis na manutenção preventiva.

Os estudos e a literatura consideram a *RCM* como uma metodologia organizada, que projeta as melhores competências da manutenção nos equipamentos ou sistemas, designadamente a segurança, a fiabilidade e a diminuição de custos.

Segundo Backlund (2003), a *RCM* restringe a habilidade infalível da manutenção com o intuito de minorar as consequências e efeitos significativos de uma falha.

Coloca-se como prioridade as carências do método de produção e não do elemento ou equipamento de forma separada, com o objetivo de assegurar a fiabilidade de um sistema através da sua manutenção. Deve também ser garantida a qualidade da operação do equipamento com o menor custo possível, assegurando funcionamento do equipamento de forma eficaz.

A *RCM* (Figura 2) tem como resultado o aumento da produtividade e da segurança humana e ambiental, a redução das atividades de manutenção com um planeamento adequado, e a redução dos riscos e os gastos com a manutenção (Moubray, 1997).

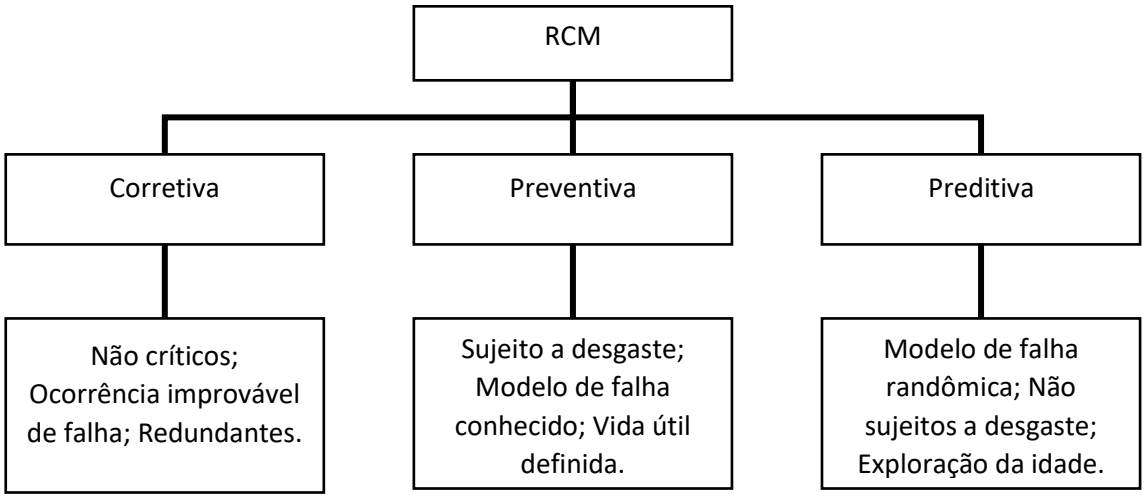

Figura 2 - *Reliability Centered Maintenance (RCM)*. Adaptado de Diniz (2016).

3 Estudo de Caso

3.1 – Apresentação da base de dados

Um dos grandes problemas enfrentado por indústrias, são os custos significativos associados a atrasos no processo de produção devido a problemas mecânicos. A maioria dessas empresas está interessada em prever esses problemas com antecedência, para que possam preveni-los de forma proactiva antes que ocorram, o que reduzirá o impacto dispendioso causado pelo tempo de inatividade.

A base de dados[2] estudada é de livre acesso, fornecida pela Microsoft e reúne elementos de dados comuns observados entre muitos casos de uso de manutenção preditiva e os próprios dados são criados por métodos de simulação de dados.

O objetivo é prever problemas causados por falhas de componentes, tais como: "Qual é a probabilidade de uma máquina falhar num futuro próximo devido à falha de um determinado componente?". O problema é formatado como um problema de classificação de várias classes e um algoritmo de aprendizagem de máquina que compreende os dados históricos recolhidos das máquinas, tais como:

- Histórico de falhas - O histórico de falhas de uma máquina ou componente da máquina;
- Histórico de manutenção - O histórico de reparações de uma máquina, por exemplo, códigos de erro, atividades de manutenção anteriores ou substituições de componentes.

3.2 – Análise das máquinas

Utilizamos as Cadeias de Markov para representar a transição entre estados de quebra, falhas ou manutenção de um conjunto de máquinas estudadas isoladamente ao longo de um ano.

Os dados foram obtidos a partir de duas folhas de cálculo:

- uma que calculava o número de falhas detetados nas máquinas ao longo de um ano específico e,
- outra que calculava as paragens por quebra/falha ou manutenção programada. Os dados foram cruzados para que não ocorresse duplicidade nos mesmos, afetando assim os resultados.

[2] Base de dados: Microsoft Azure Notebooks - Online Jupyter Notebooks. Notebooks.azure.com. (2018). Retrieved 26 July 2020,from https://notebooks.azure.com/Microsoft/projects/PredictiveMaintenance.

A partir de dados recolhidos (Tabela 25 do anexo), calculou-se o número de ocorrências (frequência simples de quebra/falha/paragem) em cada mês do ano observado. Para a Máquina 01 os dados são ilustrados na Tabela 1.

Tabela 1 – Número de ocorrências para a Máquina 01 ao longo do ano.

Jan.	Fev.	Mar.	Abr.	Mai.	Jun.	Jul.	Ago.	Set.	Out.	Nov.	Dez.
4	3	2	2	3	3	2	1	3	4	3	3

Em seguida, construímos uma matriz de frequência de transição de estados s_i para s_j, na qual os números sinalizados no lado esquerdo e na parte superior determinam o número de ocorrências registadas ao longo do ano. Para a Máquina 01, este número variou entre 1 e 4 ocorrências (Tabela 2).

Tabela 2 – Matriz de frequências de mudanças de estados da Máquina 01 ao longo do ano.

	1	**2**	**3**	**4**
1	0	0	1	0
2	1	1	1	0
3	0	2	2	1
4	0	0	2	0

Nesta matriz P, podemos então observar como ocorreram as transições entre o número de ocorrências ao longo do ano (estados possíveis). Por exemplo, o número de vezes no qual ocorreram 3 quebras no mês vigente e, no mês seguinte, esse número de quebras passou para 2, foram de duas vezes (3→2 = 2). Observamos também que ocorreu uma única vez, em que o número de quebras do mês vigente passou de 3 para 4 no mês seguinte (3→4 = 1).

A partir dessa matriz, encontramos a Cadeia de Markov para a máquina 01 (Tabela 3).

Tabela 3 – Representação da Cadeia de Markov para a Máquina 01.

	1	**2**	**3**	**4**
1	0	0	1	0
2	0,3333	0,3333	0,3333	0
3	0	0,4	0,4	0,2
4	0	0	1	0

Esta matriz P apresenta as probabilidades de transição entre os diferentes números de quebras da Máquina 01 ao longo do ano observado. Estas probabilidades foram

calculadas dividindo cada frequência, calculada isoladamente pelo somatório da linha correspondente. Note-se que a soma das probabilidades encontradas é igual a 1 ($\sum_i \pi_i = 1$).

Desta forma, utilizando a mesma construção do raciocínio anterior, observamos que existe 40% de probabilidade do número de quebras passar de 3 no mês atual, para 2 no mês seguinte; existe 20% de probabilidade do número de quebras passar de 3 no mês atual, para 4 no mês seguinte (Figura 3).

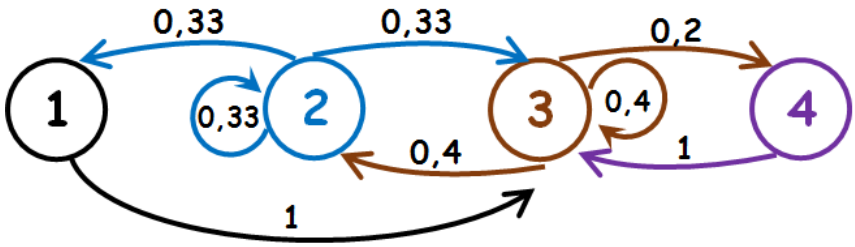

Figura 3 – Grafo dos estados da Cadeia de Markov para a Máquina 01.

O grafo ilustrado na Figura 3 para a Máquina 01 indica que todos os estados são comunicáveis e, portanto, recorrentes. Nota-se também, que é possível retornar a cada um dos estados 2, 3 e 4 em apenas um passo (ou um período; k=1), sendo, portanto, estados aperiódicos. Podemos retornar ao estado 1 em k=3 e k=4 passos, portanto, é um estado periódico. Nestas condições, a Cadeia de Markov associada à máquina 01 é uma Cadeia de Markov ergódica.

Com isto, podemos calcular a matriz de distribuições de probabilidades de estado no equilíbrio para a Máquina 01 (Tabela 4).

Tabela 4 – Matriz de distribuições de probabilidades de estado no equilíbrio para a Máquina 01.

	1	2	3	4
1	0,1	0,3	0,5	0,1
2	0,1	0,3	0,5	0,1
3	0,1	0,3	0,5	0,1
4	0,1	0,3	0,5	0,1

Esta matriz é obtida pela aplicação do seguinte teorema:

- Se todos os estados de uma Cadeia de Markov são recorrentes, aperiódicos e comunicáveis, esta cadeia é chamada de ergódica. Seja *P* a matriz de transição para uma cadeia ergódica com S estados, então existe um vetor *P*, para um estado estacionário $\pi = (\pi_1, \pi_2, \ldots, \pi_s)$, tal que:

$$\lim_{n\to\infty} P^n = \begin{bmatrix} \pi_1 & \pi_2 & & \pi_s \\ \pi_1 & \pi_2 & \vdots & \pi_s \\ \vdots & \vdots & \vdots & \vdots \\ \pi_1 & \pi_2 & & \pi_s \end{bmatrix}$$, na qual $\pi_1 + \pi_2 + \ldots + \pi_s = 1 \rightarrow \pi = \pi \times P$.

Observando a equação precedente, constata-se que as probabilidades π permanecem inalteradas após uma transição e, por esta razão, representam a distribuição no estado no equilíbrio. Este determina que à medida que aumenta o número de transições, as probabilidades tendem a permanecer inalteradas; por esta razão representam a distribuição do estado no equilíbrio. Obtemos o mesmo resultado, calculando-se sucessivamente P^n até se observarem os vetores de probabilidade todos idênticos. Estes valores também são obtidos resolvendo-se o seguinte sistema:

$$(\pi_1\ \pi_2\ \pi_3\ \pi_4) = (\pi_1\ \pi_2\ \pi_3\ \pi_4) \times \begin{bmatrix} 0 & 0 & 1 & 0 \\ 0{,}3333 & 0{,}3333 & 0{,}3333 & 0 \\ 0 & 0{,}4 & 0{,}4 & 0{,}2 \\ 0 & 0 & 1 & 0 \end{bmatrix}$$

que dá como resultado o seguinte conjunto de equações:

$\pi_1 = 0{,}3333\pi_2$

$\pi_2 = 0{,}3333\pi_2 + 0{,}4\pi_3$

$\pi_3 = \pi_1 + 0{,}3333\pi_2 + 0{,}4\pi_3 + \pi_4$

$\pi_4 = 0{,}2\pi_3$

Adicionalmente, tem-se que

$\pi_1 + \pi_2 + \pi_3 + \pi_4 = 1.$

A solução obtida são as probabilidades apresentadas na matriz acima:

$\pi_1 = 0{,}1$

$\pi_2 = 0{,}3$

$\pi_3 = 0{,}5$

$\pi_4 = 0{,}1$

O que estas probabilidades dizem é que, no longo prazo, a probabilidade da máquina 01 apresentar 01 única falha por mês ao longo do ano é de 9,99%; apresentar 02 falhas é de 29,99%; apresentar 03 falhas é de 49,99% e apresentar 04 falhas é de 9,99%.

Isto pode replicar-se para todas as restantes máquinas da base de dados, com o intuito de se obterem as probabilidades das suas respetivas falhas.

No entanto, para reforçar esta abordagem, neste estudo será trabalhado, de forma aleatória, o caso de mais quatro equipamentos. São esses as máquinas 05, 07, 10 e 13.

Máquina 05.

Tabela 5 – Número de ocorrências para a Máquina 05 ao longo do ano.

Jan.	Fev.	Mar.	Abr.	Mai.	Jun.	Jul.	Ago.	Set.	Out.	Nov.	Dez.
2	3	2	3	2	2	2	3	4	3	3	2

Tabela 6 – Matriz de frequências de mudanças de estados da Máquina 05 ao longo do ano.

	2	**3**	**4**
2	2	3	0
3	3	1	1
4	0	1	0

Tabela 7 – Representação da Cadeia de Markov para a Máquina 05.

	2	**3**	**4**
2	0,4	0,6	0
3	0,6	0,2	0,2
4	0	1	0

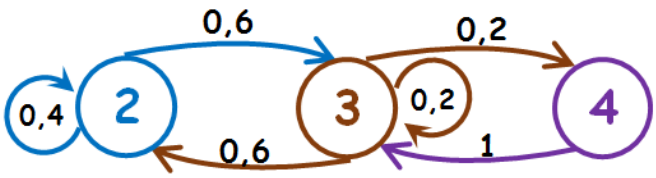

Figura 4 – Grafo dos estados da Cadeia de Markov para a Máquina 05.

O grafo ilustrado na Figura 4, para a Máquina 05, indica que todos os estados são comunicáveis e, portanto, recorrentes. Nota-se também, que é possível retornar a cada um dos estados 2 e 3 em apenas um passo (ou um período; k=1), sendo,

portanto, estados aperiódicos. Podemos retornar ao estado 1 em k=3 e k=4 passos, portanto, tem-se um estado periódico. O mesmo é observado com o estado 4; podemos retornar a este em k=2 e k=3 passos, portanto é um estado periódico. Nestas condições, a Cadeia de Markov associada à máquina 05 é uma Cadeia de Markov ergódica. Baseado no precedente, podemos calcular a matriz de distribuições de probabilidades de estado no equilíbrio para a Máquina 05 (Tabela 8).

Tabela 8 – Matriz de distribuições de probabilidades de estado no equilíbrio para a Máquina 05.

	2	**3**	**4**
2	0,4545	0,4545	0,0909
3	0,4545	0,4545	0,9090
4	0,4545	0,4545	0,9090

A solução obtida são as probabilidades apresentadas na matriz acima:

$\pi_2 = 0{,}4545$

$\pi_3 = 0{,}4545$

$\pi_4 = 0{,}0909$

Este resultado final significa que, no longo prazo, a probabilidade da máquina 05 de apresentar 02 falhas é de 45,45%; de apresentar 03 falhas é de 45,45% e de apresentar 04 falhas é de 9,09%.

Máquina 07.

Tabela 9 – Número de ocorrências para a Máquina 07 ao longo do ano.

Jan.	**Fev.**	**Mar.**	**Abr.**	**Mai.**	**Jun.**	**Jul.**	**Ago.**	**Set.**	**Out.**	**Nov.**	**Dez.**
2	4	3	2	4	3	3	1	3	3	3	2

Tabela 10 – Matriz de frequências de mudanças de estados da Máquina 07 ao longo do ano.

	1	**2**	**3**	**4**
1	0	0	1	0
2	0	0	0	2
3	1	2	3	0
4	0	0	2	0

Tabela 11 – Representação da Cadeia de Markov para a Máquina 07.

	1	2	3	4
1	0	0	1	0
2	0	0	0	1
3	0,16666	0,33333	0,5	0
4	0	0	1	0

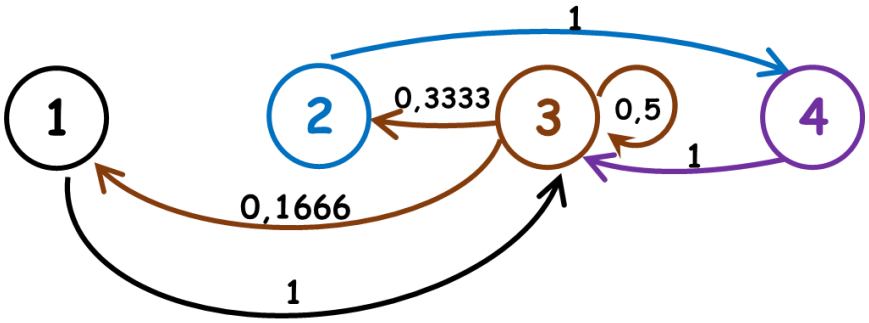

Figura 5 – Grafo dos estados da Cadeia de Markov para a Máquina 07.

O grafo ilustrado na Figura 5, para a Máquina 07, indica que todos os estados são comunicáveis e, portanto, recorrentes. Nota-se, também, que é possível retornar ao estado 3 em apenas um passo (ou um período; k=1), sendo, portanto, estado aperiódico. Podemos retornar ao estado 1 em k=2 e k=3 passos, portanto, é um estado periódico. O mesmo é observado com o estado 2 e 4; podemos retornar a estes em k=3 e k=4 passos, portanto, são estados periódicos; nestas condições, a Cadeia de Markov associada à máquina 07 é uma Cadeia de Markov ergódica. Baseado no precedente, podemos calcular a matriz de distribuições de probabilidades de estado no equilíbrio para a Máquina 07 (Tabela 12).

Tabela 12 – Matriz de distribuições de probabilidades de estado equilíbrio para a Máquina 07.

	1	2	3	4
1	0,0909	0,1818	0,5454	0,1818
2	0,0909	0,1818	0,5454	0,1818
3	0,0909	0,1818	0,5454	0,1818
4	0,0909	0,1818	0,5454	0,1818

A solução obtida são as probabilidades apresentadas na matriz acima:

$\pi_1 = 0{,}0909$

$\pi_2 = 0{,}1818$

$\pi_3 = 0{,}5454$

$\pi_4 = 0{,}1818$

Este resultado significa que, no longo prazo, a probabilidade da máquina 07 apresentar 01 única falha por mês ao longo do ano é de 9,09%; de apresentar 02 falhas é de 18,18%; de apresentar 03 falhas é de 54,54% e de apresentar 04 falhas é de 18,18%.

Máquina 10.

Tabela 13 – Número de ocorrências para a Máquina 10 ao longo do ano.

Jan.	Fev.	Mar.	Abr.	Mai.	Jun.	Jul.	Ago.	Set.	Out.	Nov.	Dez.
3	2	3	2	2	3	3	2	4	5	3	2

Tabela 14 – Matriz de frequências de mudanças de estados da Máquina 10 ao longo do ano.

	2	**3**	**4**	**5**
2	1	2	1	0
3	4	1	0	0
4	0	0	0	1
5	0	1	0	0

Tabela 15 – Representação da Cadeia de Markov para a Máquina 10.

	2	**3**	**4**	**5**
2	0,25	0,5	0,25	0
3	0,8	0,2	0	0
4	0	0	0	1
5	0	1	0	0

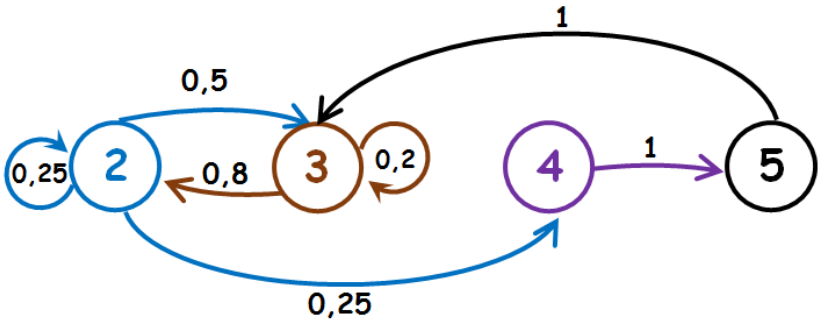

Figura 6 – Grafo dos estados da Cadeia de Markov para a Máquina 10.

O grafo ilustrado na Figura 6, para a Máquina 10, indica que todos os estados são comunicáveis e, portanto, recorrentes. Nota-se, também, que é possível retornar a cada um dos estados 2 e 3 em apenas um passo (ou um período; k=1), sendo, portanto, estados aperiódicos. Podemos retornar ao estado 4 em k=4 e k=5 passos, portanto, é um estado periódico. O mesmo é observado com o estado 5; podemos retornar a este em k=4 e k=5 passos, portanto, é um estado periódico. Nestas condições a Cadeia de Markov associada à máquina 10 é uma Cadeia de Markov ergódica. Baseado no precedente, podemos calcular a matriz de distribuições de probabilidades de estado no equilíbrio para a Máquina 10 (Tabela 16).

Tabela 16 – Matriz de distribuições de probabilidades de estado equilíbrio para a Máquina 10.

	2	**3**	**4**	**5**
2	0,4102	0,3846	0,1026	0,1025
3	0,4102	0,3846	0,1026	0,1025
4	0,4102	0,3846	0,1026	0,1025
5	0,4102	0,3846	0,1026	0,1025

A solução obtida são as probabilidades apresentadas na matriz acima:

$\pi_2 = 0{,}4102$

$\pi_3 = 0{,}3846$

$\pi_4 = 0{,}1026$

$\pi_5 = 0{,}1025$

Este resultado final significa que, no longo prazo, a probabilidade da máquina 10 apresentar 01 única falha por mês ao longo do ano é de 41,02%; de apresentar 02 falhas é de 38,46%; de apresentar 03 falhas é de 10,26% e de apresentar 04 falhas é de 10,25%.

Máquina 13.

Tabela 17 – Número de ocorrências para a Máquina 13 ao longo do ano.

Jan.	**Fev.**	**Mar.**	**Abr.**	**Mai.**	**Jun.**	**Jul.**	**Ago.**	**Set.**	**Out.**	**Nov.**	**Dez.**
0	2	1	4	2	4	2	3	3	2	3	3

Tabela 18 – Matriz de frequências de mudanças de estados da Máquina 13 ao longo do ano.

	0	**1**	**2**	**3**	**4**
0	0	0	1	0	0
1	0	0	0	0	1
2	0	1	0	2	1
3	0	0	1	2	0
4	0	0	2	0	0

Tabela 19 – Representação da Cadeia de Markov para a Máquina 13.

	0	**1**	**2**	**3**	**4**
0	0	0	1	0	0
1	0	0	0	0	1
2	0	0,25	0	0,5	0,25
3	0	0	0,3333	0,6666	0
4	0	0	1	0	0

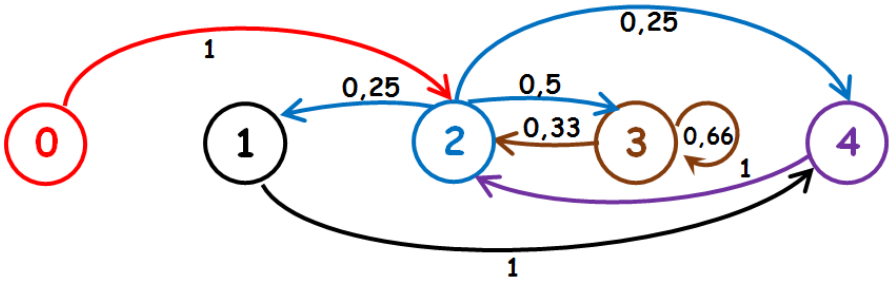

Figura 7 – Grafo dos estados da Cadeia de Markov para a Máquina 13.

O grafo ilustrado na figura 7, para a Máquina 13, indica que todos os estados são comunicáveis, com exceção do estado 0 que se comunica apenas com o estado 2, não havendo possibilidades de comunicação dos outros estados para o estado 0. Logo, o mesmo não é recorrente e, portanto, esta cadeia de Markov não é ergódica. Por consequência, não se consegue encontrar a matriz de estado no equilíbrio.

3.2 – Análise dos componentes

Assim como na análise do conjunto e máquinas estudadas, utilizamos as Cadeias de Markov para representar a transição entre estados de quebra, falhas ou manutenção do conjunto de componentes utilizados nas respetivas máquinas.

Os dados foram obtidos a partir de duas folhas de cálculo:

- uma que calculava o número de falhas detetados nas máquinas ao longo de um ano específico e,
- outra que calculava as paragens por quebra/falha ou manutenção programada. Os dados também foram cruzados para que não ocorresse duplicidade nos mesmos, afetando assim o resultado a ser obtido.

Todas as máquinas do estudo utilizam os mesmos componentes básicos: 01, 02, 03 e 04. Através desta parte do estudo, podemos verificar se existe ou não um ou mais componentes com mais falha do que os restantes, necessitando assim de uma política de manutenção diferenciada. Para tanto foram utilizados os componentes básicos apenas das máquinas 01, 05, 07, 10 e 13, conforme a sequência de ocorrências dos componentes da Tabela 26 do anexo.

Tabela 20 – Matriz de frequências de mudanças de estados dos componentes ao longo do ano.

	Comp.1	Comp.2	Comp.3	Comp.4
Comp.1	2	6	6	6
Comp.2	8	5	10	8
Comp.3	4	14	2	8
Comp.4	8	7	6	1

Tabela 21 – Representação da Cadeia de Markov para os componentes.

	Comp.1	Comp.2	Comp.3	Comp.4
Comp.1	0,1000	0,3000	0,3000	0,3000
Comp.2	0,2581	0,1613	0,3226	0,2581
Comp.3	0,1429	0,5000	0,0714	0,2857
Comp.4	0,3636	0,3182	0,2727	0,0455

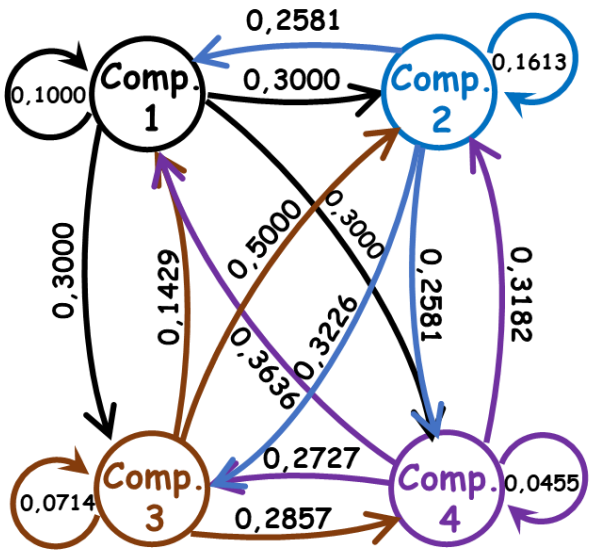

Figura 8 – Grafo dos estados da Cadeia de Markov para os componentes.

Analisando o grafo (Componentes) ilustrado na Figura 8, verifica-se que todos os estados são comunicáveis, ou seja, existe um caminho de ida e volta de todos os estados para todos, isto é, uma sequência de arcos que leva e traz de um estado i para todos os outros estados j. Se todos os estados são comunicáveis, implica que também são recorrentes, uma vez que um eventual retorno a esse mesmo estado é assegurado pela propriedade anterior. Observa-se ainda, no grafo da Figura 8, que é possível retornar a cada um dos estados em apenas um passo (ou um período; k=1), sendo, portanto, estados aperiódicos.

Como todos os estados atendem às três condições listadas anteriormente, então, a Cadeia de Markov associada ao grafo estudado é dita ergódica. Assim, podemos calcular a matriz de distribuições de probabilidades de estado no equilíbrio para a Máquina 10 (Tabela 22).

Tabela 22 – Matriz de distribuições de probabilidades de estado equilíbrio para componentes.

	Comp. 1	**Comp. 2**	**Comp. 3**	**Comp. 4**
Comp.1	0,2192	0,3102	0,2450	0,2261
Comp.2	0,2192	0,3102	0,2450	0,2261
Comp.3	0,2192	0,3102	0,2450	0,2261
Comp.4	0,2192	0,3102	0,2450	0,2261

A solução obtida são as probabilidades apresentadas na matriz acima:

$\pi_1 = 0{,}2192$

$\pi_2 = 0{,}3102$

$\pi_3 = 0{,}2450$

$\pi_4 = 0{,}2261$

Este resultado final diz que, no longo prazo, a probabilidade do componente 01 apresentar falha/defeito e precisar de ser substituído é de 21,92%; para o componente 02 essa probabilidade é de 31,02%; para o componente 03 é de 24,50% e para o componente 04 é de 22,61%. Com este resultado, não há nenhum componente que se destaque face aos restantes, estando todos em proporções iguais de falha/defeito.

3.3 Inferência dos resultados na política de manutenção dos equipamentos

Conforme o desenvolvimento teórico, para uma tomada de decisão é preciso, para além das probabilidades de quebras, ter como base outros aspetos, bem como a importância que o equipamento tem no processo em que atua, e ainda os tempos de reparação, entre outros.

Foram então verificados os *MTTF* para os equipamentos estudados e os seus componentes. Com o *MTTF* é possível verificar o tempo médio em dias entre as falhas.

Para calcular o *MTTF* é necessário fazer a média das diferenças entre datas em que ocorreu uma falha de um componente em uma máquina específica. Como por exemplo para a Máquina 01 e componente 01:

Tabela 23 – Diferenças de dias de ocorrência da máquina 1 e componente 1.

Data	Diferença em dias	Máquina	Comp.
05/01/2015	-	1	comp1
20/01/2015	15	1	comp1
06/03/2015	45	1	comp1
21/03/2015	15	1	comp1
19/06/2015	90	1	comp1
19/07/2015	30	1	comp1
03/08/2015	15	1	comp1
02/09/2015	30	1	comp1
02/10/2015	30	1	comp1
31/12/2015	90	1	comp1

Ao calcularmos a média para a diferença de dias, chegamos ao resultado de 40 dias de tempo médio entre falhas.

Com isso, chega-se aos seguintes resultados.

Tabela 24 – *MTTF* das máquinas e componentes.

	Máq. 1	Máq. 5	Máq. 7	Máq. 10	Máq. 13
Comp. 1	40	47,5	52,5	45	78,7
Comp. 2	30	30	23,8	21,9	42,9
Comp. 3	52,5	45	40	57,5	28,1
Comp. 4	49,3	51	63	55	40

A base de dados do estudo carece do tempo de reparação utilizado, não sendo possível a verificação dos *MTTR*.

Também foi verificado que não há parâmetros de importância dos equipamentos para a empresa, por exemplo, se há ou não equipamentos redundantes para que não tenha interrupção do processo.

Contudo, podemos dar alguma atenção, por exemplo ao componente 2, que tem a maior probabilidade de quebra, de 31,02%, obtida na Tabela 22 e com um *MTTF* de 21,9 dias na máquina 10, conforme Tabela 24, tornando-se o caso mais crítico para o estudo.

CONCLUSÕES

A dissertação focou-se em ferramentas matemáticas de suporte a uma política de manutenção de equipamentos, baseada em Cadeias de Markov.

O caso de estudo centrou-se nas máquinas de uma fábrica, mais especificamente de turbinas, baseada na monitorização de condição através da análise das falhas e quebras de componentes. A correta previsão destes eventos pode maximizar a sua vida útil, reduzindo os custos de manutenção, bem como diminuir os custos adicionais ligados aos ativos, aumentando, deste modo, a sua fiabilidade, assim como o seu ciclo de vida.

O estudo mostra como é que a previsão, através de Cadeias de Markov, pode contribuir para a prevenção de falhas ou avarias, possibilitando uma intervenção precoce antes que as avarias ou as falhas aumentem dramaticamente.

A previsão oferece enormes vantagens para as empresas que implementem corretamente esse método, dado que uma política de manutenção preditiva tende a minorar o tempo de indisponibilidade das máquinas na linha de produção.

Nas componentes específicas das máquinas estudadas não se obteve nenhum destaque, com relação ao número de falhas e quebras, para uma política de manutenção diferenciada. No entanto, isso varia conforme as máquinas aplicadas. Contudo conforme a teoria estudada, faltariam também dados, tais como tempos de reparação das máquinas e componentes e a sua importância na linha de produção da fábrica.

O modelo matemático utilizado tem o potencial de apoiar as empresas, de forma generalizada, uma vez que fornece informação de fácil interpretação, e que ajuda as mesmas na tomada de decisão sobre qual o determinado período em que a máquina ou os componentes da mesma poderá haver uma determinada falha.

No âmbito desta dissertação, constatou-se ainda que as maiores dificuldades encontradas foram a falta de dados monetários e de importância para os equipamentos, devido ao estudo se basear numa fonte de dados abertos.

Relativamente aos desenvolvimentos futuros, poder prever quando uma falha de um componente pode acontecer, podendo com isso aplicar o melhor tipo de manutenção, diminui os custos na gestão da manutenção, além de maximizar o tempo de vida útil do equipamento e, ao mesmo tempo, evitar que estes sejam usados até ao limite da quebra de um determinado componente.

Mas, para que essa previsão seja possível nas máquinas, é necessário o desenvolvimento de uma probabilidade com base nos dados disponíveis, para as tomadas de decisão estratégicas da manutenção.

Aplicar esta metodologia, juntamente com variáveis monetárias e de importância dos equipamentos para a organização, é fundamental para o desenvolvimento da correta política de manutenção.

Para o futuro propõe-se a aglutinação de dados mais robustos, fora do contexto apenas dos equipamentos. Dados, tais como valores dos equipamentos e os seus componentes, tempo de reparação, de reposição, do *stock* e importância dos mesmos na linha de produção são imprescindíveis.

Por fim, salienta-se também que a previsão não basta, é necessária uma correta ação no presente com as melhores práticas e políticas e manutenção.

REFERÊNCIAS BIBLIOGRÁFICAS

Almeida, M. (2007). Manutenção preditiva: confiabilidade e qualidade. Revista Indústria Em Foco, pp. 01-05.

Amari, S.V. & McLaughlin, L. (2004), "*Optimal design of a condition-based maintenance model*," *Annual Symposium Reliability and Maintainability*, RAMS, Los Angeles, CA, USA, 2004, pp. 528-533, doi: 10.1109/RAMS.2004.1285501.

Arato Jr., A. (2004). Manutenção preditiva: Usando análise de vibrações (4th ed., pp. 156-195). Ed. Manole.

Billingsley, P. (1961). Statistical Methods in Markov Chains. *The Annals of Mathematical Statistics*, 32(1), 12-40. Retrieved October 22, 2020, from http://www.jstor.org/stable/2237603.

Bondavalli, A., Montecchi, L., & Lollini, P. (2010). *Un modello intermedio di dependability integrabile in un processo di model-driven engineering* (Dissertação de Licenciatura). Universita degli Studi di Firenze.

Branco Filho, G., 2008. A Organização, O Planejamento E O Controle Da Manutenção. 1ª Edição. Rio de Janeiro (RJ): Ciência Moderna, pp.32-48.

Bressan, G. (2002). Noções de processos estocásticos e Cadeias de Markov. Retrieved 19 August 2020, from https://docs.ufpr.br/~benitoag/modsim04.pdf.

Diniz, C. (2016). Aplicação do World Class Maintenance (WCM) na manutenção de máquinas de colheita da madeira (Dissertação de Mestrado). Universidade Estadual do Centro Oeste.

Espindola, L. (2009). Um Estudo sobre Modelos Ocultos de Markov HMM - Hidden Markov Model (Dissertação de Pós-Graduação). Pontifícia Universidade Católica do Rio Grande do Sul.

Farinha, J. M. T. (2011). Manutenção – A terologia e as novas ferramentas de gestão. Lisboa: 1ª Edição, Monitor – Projecto e Edições, Lda.

Jelinek, F. (1998). *Hidden Markov Models. Statistical Methods for Speech Recognition*, (1th ed., pp. 15-37). Ed. Bradford Book.

Kardec, A., & Nascif, J. (2012). Manutenção-função estratégica, (3th ed., pp. 18-77). Ed. Qualitymark Editora Ltda.

Magela, M. M. (2015). Teoria basica das cadeias de Markov (Dissertação de Mestrado). Universidade Federal do Esprito Santo.

Marques, G. R. (2017). Manutenção centrada em confiabilidade: estudo de caso da eficácia dos equipamentos industriais (Dissertação de Graduação). Universidade Federal de Uberlândia.

Monchy, F. (1987). *La fonction maintenance* (1th ed., pp. 21-87). Ed. Masson.

Nancabú, P. (2011). Procedimento para manutenção preventiva na empresa de resíduos sólidos urbanos do centro “ERSUC” (Dissertação de Mestrado). Universidade de Coimbra.

Nepomuceno, L. X. (2014). Técnicas de manutenção preditiva-vol. 1 (1th ed., pp. 35-97). Ed. Blucher.

Neto, R., & Cecílio, J. (2010). Modelagem dos algorítmos genético simples e simulated annealing por cadeias de Markov (Dissertação de Mestrado). Universidade Federal do Rio Grande do Norte).

Patton Jr., J. (2004). *Preventive Maintenance* (3th ed., pp. 42-107). Ed. ISA.

Rabiner, L. (1989). *A tutorial on hidden Markov models and selected applications in speech recognition*. Proceedings Of The IEEE, 77(2), 257-286. https://doi.org/10.1109/5.18626

Santos, M., Araújo, M., & Lima, A. (2018). Manutenção preditiva: contribuindo para a melhoria dos processos e para a redução dos custos de operação. In Sustentabilidade e Meio ambiente (pp. 342-358). São Cristóvão / SE; X SIMPROD. Retrieved 27 June 2020, from https://core.ac.uk/download/pdf/197147185.pdf.

Silva, L. M. D. (2017). Cadeias de Markov e aplicações (Dissertação de Graduação). Universidade Federal Fluminense.

Simeón, E. J. A. (2008). Aplicação de técnicas de inteligência artificial no desenvolvimento de um sistema de manutenção baseada em condição (Dissertação de Mestrado). Universidade de Brasília.

Souza, R. D. Q. (2008). Metodologia e desenvolvimento de um sistema de manutenção preditiva visando a melhoria da confiabilidade de ativos de usinas hidrelétricas (Dissertação de Mestrado). Universidade de Brasília.

ANEXOS

A Tabela 25 ilustra os registos de manutenção programada e não programada que correspondem às falhas. Um registo é gerado se um componente for substituído durante a inspeção programada ou substituído devido a uma avaria. Os dados de manutenção têm registos somente das cinco máquinas analisadas no ano de 2015.

Tabela 25 – Base de dados de livre acesso da Microsoft

datetime	machineID	comp
05/01/2015 06:00	1	comp4
05/01/2015 06:00	1	comp1
20/01/2015 06:00	1	comp3
20/01/2015 06:00	1	comp1
04/02/2015 06:00	1	comp4
04/02/2015 06:00	1	comp3
19/02/2015 06:00	1	comp3
06/03/2015 06:00	1	comp1
21/03/2015 06:00	1	comp1
05/04/2015 06:00	1	comp3
20/04/2015 06:00	1	comp2
05/05/2015 06:00	1	comp3
05/05/2015 06:00	1	comp2
20/05/2015 06:00	1	comp2
04/06/2015 06:00	1	comp3
19/06/2015 06:00	1	comp1
19/06/2015 06:00	1	comp4
04/07/2015 06:00	1	comp2
19/07/2015 06:00	1	comp1
03/08/2015 06:00	1	comp1
02/09/2015 06:00	1	comp1
02/09/2015 06:00	1	comp4
17/09/2015 06:00	1	comp2
02/10/2015 06:00	1	comp4
02/10/2015 06:00	1	comp1

17/10/2015 06:00	1	comp4
17/10/2015 06:00	1	comp2
01/11/2015 06:00	1	comp4
01/11/2015 06:00	1	comp2
16/11/2015 06:00	1	comp2
01/12/2015 06:00	1	comp3
16/12/2015 06:00	1	comp4
31/12/2015 06:00	1	comp1
09/01/2015 06:00	5	comp2
24/01/2015 06:00	5	comp2
08/02/2015 06:00	5	comp3
23/02/2015 06:00	5	comp4
23/02/2015 06:00	5	comp1
10/03/2015 06:00	5	comp4
25/03/2015 06:00	5	comp4
09/04/2015 06:00	5	comp1
24/04/2015 06:00	5	comp3
24/04/2015 06:00	5	comp2
09/05/2015 06:00	5	comp4
24/05/2015 06:00	5	comp2
08/06/2015 06:00	5	comp3
23/06/2015 06:00	5	comp2
08/07/2015 06:00	5	comp2
23/07/2015 06:00	5	comp2
07/08/2015 06:00	5	comp3
07/08/2015 06:00	5	comp2
22/08/2015 06:00	5	comp3
06/09/2015 06:00	5	comp2
06/09/2015 06:00	5	comp1
21/09/2015 06:00	5	comp4
21/09/2015 06:00	5	comp1
06/10/2015 06:00	5	comp2
06/10/2015 06:00	5	comp1
21/10/2015 06:00	5	comp3

05/11/2015 06:00	5	comp3
05/11/2015 06:00	5	comp4
20/11/2015 06:00	5	comp1
05/12/2015 06:00	5	comp1
20/12/2015 06:00	5	comp3
24/01/2015 06:00	7	comp2
24/01/2015 06:00	7	comp4
08/02/2015 06:00	7	comp1
08/02/2015 06:00	7	comp2
23/02/2015 06:00	7	comp1
23/02/2015 06:00	7	comp2
10/03/2015 06:00	7	comp2
25/03/2015 06:00	7	comp3
25/03/2015 06:00	7	comp2
09/04/2015 06:00	7	comp2
24/04/2015 06:00	7	comp1
09/05/2015 06:00	7	comp1
09/05/2015 06:00	7	comp4
24/05/2015 06:00	7	comp2
24/05/2015 06:00	7	comp3
08/06/2015 06:00	7	comp3
08/06/2015 06:00	7	comp2
23/06/2015 06:00	7	comp3
08/07/2015 06:00	7	comp2
23/07/2015 06:00	7	comp2
23/07/2015 06:00	7	comp3
22/08/2015 06:00	7	comp2
06/09/2015 06:00	7	comp1
21/09/2015 06:00	7	comp1
21/09/2015 06:00	7	comp4
06/10/2015 06:00	7	comp3
21/10/2015 06:00	7	comp2
21/10/2015 06:00	7	comp4
05/11/2015 06:00	7	comp2

05/11/2015 06:00	7	comp4
20/11/2015 06:00	7	comp3
05/12/2015 06:00	7	comp4
20/12/2015 06:00	7	comp1
04/01/2015 06:00	10	comp4
19/01/2015 06:00	10	comp3
19/01/2015 06:00	10	comp2
03/02/2015 06:00	10	comp2
18/02/2015 06:00	10	comp2
05/03/2015 06:00	10	comp1
05/03/2015 06:00	10	comp2
20/03/2015 06:00	10	comp1
04/04/2015 06:00	10	comp2
19/04/2015 06:00	10	comp4
19/05/2015 06:00	10	comp2
19/05/2015 06:00	10	comp4
03/06/2015 06:00	10	comp1
18/06/2015 06:00	10	comp3
18/06/2015 06:00	10	comp2
03/07/2015 06:00	10	comp2
18/07/2015 06:00	10	comp4
18/07/2015 06:00	10	comp2
02/08/2015 06:00	10	comp2
17/08/2015 06:00	10	comp4
01/09/2015 06:00	10	comp1
01/09/2015 06:00	10	comp3
16/09/2015 06:00	10	comp2
16/09/2015 06:00	10	comp1
01/10/2015 06:00	10	comp2
16/10/2015 06:00	10	comp1
16/10/2015 06:00	10	comp2
31/10/2015 06:00	10	comp3
31/10/2015 06:00	10	comp2
15/11/2015 06:00	10	comp4

15/11/2015 06:00	10	comp3
30/11/2015 06:00	10	comp4
15/12/2015 06:00	10	comp3
30/12/2015 06:00	10	comp3
10/02/2015 06:00	13	comp1
25/02/2015 06:00	13	comp2
27/03/2015 06:00	13	comp1
11/04/2015 06:00	13	comp3
11/04/2015 06:00	13	comp4
26/04/2015 06:00	13	comp3
26/04/2015 06:00	13	comp4
11/05/2015 06:00	13	comp4
26/05/2015 06:00	13	comp2
10/06/2015 06:00	13	comp2
10/06/2015 06:00	13	comp3
25/06/2015 06:00	13	comp4
25/06/2015 06:00	13	comp3
10/07/2015 06:00	13	comp2
25/07/2015 06:00	13	comp4
09/08/2015 06:00	13	comp2
24/08/2015 06:00	13	comp3
24/08/2015 06:00	13	comp1
08/09/2015 06:00	13	comp2
23/09/2015 06:00	13	comp3
23/09/2015 06:00	13	comp4
08/10/2015 06:00	13	comp3
23/10/2015 06:00	13	comp1
07/11/2015 06:00	13	comp3
07/11/2015 06:00	13	comp2
22/11/2015 06:00	13	comp3
07/12/2015 06:00	13	comp4
22/12/2015 06:00	13	comp1
22/12/2015 06:00	13	comp2

Tabela 26 – Sequência de ocorrências dos componentes

Máquina	Mês	Sequência ----->				
Máquina 1	Jan	comp4	comp1	comp3	comp1	
Máquina 1	Fev	comp4	comp3	comp3		
Máquina 1	Mar	comp1	comp1			
Máquina 1	Abr	comp3	comp2			
Máquina 1	Mai	comp3	comp2	comp2		
Máquina 1	Jun	comp3	comp1	comp4		
Máquina 1	Jul	comp2	comp1			
Máquina 1	Ago	comp1				
Máquina 1	Set	comp1	comp4	comp2		
Máquina 1	Out	comp4	comp1	comp4	comp2	
Máquina 1	Nov	comp4	comp2	comp2		
Máquina 1	Dez	comp3	comp4	comp1		
Máquina 5	Jan	comp2	comp2			
Máquina 5	Fev	comp3	comp4	comp1		
Máquina 5	Mar	comp4	comp4			
Máquina 5	Abr	comp1	comp3	comp2		
Máquina 5	Mai	comp4	comp2			
Máquina 5	Jun	comp3	comp2			
Máquina 5	Jul	comp2	comp2			
Máquina 5	Ago	comp3	comp2	comp3		
Máquina 5	Set	comp2	comp1	comp4	comp1	
Máquina 5	Out	comp2	comp1	comp3		
Máquina 5	Nov	comp3	comp4	comp1		
Máquina 5	Dez	comp1	comp3			
Máquina 7	Jan	comp2	comp4			
Máquina 7	Fev	comp1	comp2	comp1	comp2	
Máquina 7	Mar	comp2	comp3	comp2		
Máquina 7	Abr	comp2	comp1			
Máquina 7	Mai	comp1	comp4	comp2	comp3	
Máquina 7	Jun	comp3	comp2	comp3		
Máquina 7	Jul	comp2	comp2	comp3		
Máquina 7	Ago	comp2				
Máquina 7	Set	comp1	comp1	comp4		
Máquina 7	Out	comp3	comp2	comp4		
Máquina 7	Nov	comp2	comp4	comp3		
Máquina 7	Dez	comp4	comp1			
Máquina 10	Jan	comp4	comp3	comp2		
Máquina 10	Fev	comp2	comp2			
Máquina 10	Mar	comp1	comp2	comp1		
Máquina 10	Abr	comp2	comp4			
Máquina 10	Mai	comp2	comp4			
Máquina 10	Jun	comp1	comp3	comp2		

Máquina 10	Jul	comp2	comp4	comp2		
Máquina 10	Ago	comp2	comp4			
Máquina 10	Set	comp1	comp3	comp2	comp1	
Máquina 10	Out	comp2	comp1	comp2	comp3	comp2
Máquina 10	Nov	comp4	comp3	comp4		
Máquina 10	Dez	comp3	comp3			
Máquina 13	Jan					
Máquina 13	Fev	comp1	comp2			
Máquina 13	Mar	comp1				
Máquina 13	Abr	comp3	comp4	comp3	comp4	
Máquina 13	Mai	comp4	comp2			
Máquina 13	Jun	comp2	comp3	comp4	comp3	
Máquina 13	Jul	comp2	comp4			
Máquina 13	Ago	comp2	comp3	comp1		
Máquina 13	Set	comp2	comp3	comp4		
Máquina 13	Out	comp3	comp1			
Máquina 13	Nov	comp3	comp2	comp3		
Máquina 13	Dez	comp4	comp1	comp2		