

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
DEPARTAMENTO DE ENGENHARIA QUÍMICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA

**DETERMINAÇÃO DO TEMPO DE VIDA ÚTIL REMANESCENTE
EM PROCESSOS CÍCLICOS**

DISSERTAÇÃO DE MESTRADO

Leonardo Mandler De Marco

Porto Alegre

2019

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
DEPARTAMENTO DE ENGENHARIA QUÍMICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA

DETERMINAÇÃO DO TEMPO DE VIDA ÚTIL REMANESCENTE EM PROCESSOS CÍCLICOS

Leonardo Mandler De Marco

Dissertação de Mestrado apresentada como requisito parcial para obtenção do título de Mestre em Engenharia

Área de concentração: Pesquisa e Desenvolvimento de Processos

Linha de Pesquisa: Projeto, Simulação, Modelagem, Controle e Otimização de Processo Químicos e Bioprocessos.

Orientadores:

Prof. Dr. Jorge Otávio Trierweiler

Prof. Dr. Marcelo Farenzena

Porto Alegre

2019

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
DEPARTAMENTO DE ENGENHARIA QUÍMICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA

A Comissão Examinadora, abaixo assinada, aprova a Dissertação *Determinação do Tempo de Vida Útil Remanescente em Processos Cíclicos*, elaborada por Leonardo Mandler De Marco, como requisito parcial para obtenção do Grau de Mestre em Engenharia.

Comissão Examinadora:

Profª. Dra. Luciane Ferreira Trierweiler

Prof. Dr. Marcio Schwaab

Prof. Dr. Rubem da Cunha Reis

Resumo

A análise da Vida Útil Remanescente (VUR) de sistemas e equipamentos permite a prevenção de falhas, de modo que uma manutenção efetiva possa ser realizada em tempo de corrigir falhas que estão próximas de acontecer. O sinal de degradação de uma ou mais variáveis pode servir como base para estimar a VUR de um determinado sistema, desde que este sinal seja modelado matematicamente de forma correta. Neste trabalho, se analisa a VUR de processos cíclicos, sendo determinado então o Número de Ciclos Remanescentes (NCR) de forma a maximizar a produção garantindo a segurança operacional. Para isso serão consideradas duas abordagens: Metodologia Bayesiana e Séries Temporais. A metodologia Bayesiana está baseada em Inferência Bayesiana para atualizar os valores do parâmetro estocástico, proporcionando uma maior representatividade na estimativa do NCR. Os parâmetros determinísticos e os hiperparâmetros na distribuição *a priori* do parâmetro estocástico são estimados através do método da estimativa por máxima verossimilhança (EMV), enquanto o parâmetro estocástico no modelo de degradação de um sistema pode ser atualizado a cada instante em que um novo dado de degradação é obtido. Por outro lado, as Séries Temporais se baseiam em conjuntos de Treino para poder ajustar um modelo que se aproxime do conjunto utilizado para validação. Na estimativa do NCR serão considerados modelos estacionários (Suavização Exponencial Simples), não-estacionários (Suavização Exponencial Dupla e ARIMA) e modelos que utilizam o componente de sazonalidade (Suavização Exponencial Tripla e SARIMA). Um Estudo de Caso de uma unidade *Temperature Swing Adsorption* (TSA) para desidratação do gás natural será utilizada para avaliar estas duas abordagens na previsão do NCR em processos cíclicos. Os resultados sugerem que a metodologia bayesiana é a mais indicada na estimativa do NCR, enquanto que as Séries Temporais são adequadas para identificar o padrão cíclico do processo.

Abstract

The analysis of Remaining Useful Life (RUL) of systems and equipment enables the prevention of failures, so that effective maintenance can be performed in time to correct failures that are close to happening. The degradation signal of a variable can be used as a basis for estimating the RUL of a given system since this signal is modeled mathematically correctly. In this paper, the RUL of cyclic processes is analyzed with the determination of the Number of Remaining Cycles (NRC) in order to maximize production, guaranteeing operational safety. Two approaches will be considered: Bayesian Methodology and Time Series. The Bayesian methodology is based on Bayesian Inference to update the stochastic parameter, providing a greater representativeness in the estimation of the NRC. The deterministic parameters and the hyperparameters in the prior distribution of the stochastic parameter are estimated through the maximum likelihood estimation (MLE) method, while the stochastic parameter in the degradation model of a system can be updated every time a new degradation data is obtained. On the other hand, the Time Series are based on Training sets to be able to fit a model that is similar to the set used for validation. In the estimation of NRC will be considered stationary models (Simple Exponential Smoothing), non-stationary (Double Exponential Smoothing and ARIMA) and models that consider the component of seasonality (Triple Exponential Smoothing and SARIMA). A Case Study of a Temperature Swing Adsorption (TSA) unit for natural gas dehydration will be used to evaluate these two approaches in predicting NRC in cyclic processes. The results suggest that the Bayesian Methodology is the most indicated in the NCR estimation, while the Time Series are adequate to identify the cyclic pattern of the process.

*“Para nós, os grandes homens não são aqueles que resolveram os problemas, mas aqueles que os descobriram”.
(Albert Schweitzer)*

Agradecimentos

Agradeço à minha família por sempre me apoiar, por estar sempre ao meu lado e por me incentivar nas minhas decisões. Em especial aos meus avós, à minha mãe e à minha “dinda”.

Aos meus orientados Prof. Dr. Jorge Otávio Trierweiler e Prof. Dr. Marcelo Farenzena, por me apoiarem e incentivarem para que eu realizasse este trabalho. Obrigado por sempre estarem a disposição para esclarecer minhas dúvidas.

A todos os professores que passaram no meu caminho pelo conhecimento que me proporcionaram.

Por fim, agradeço aos meus amigos, principalmente os amigos do GIMSCOP/UFRGS, pelas conversas, pelos conselhos e pelo companheirismo, sem eles, a realização deste trabalho não seria possível.

SUMÁRIO

Capítulo 1 – Introdução	1
1.1 Motivação.....	1
1.2 Objetivos do trabalho.....	3
1.3 Estrutura da dissertação	3
Capítulo 2 – Fundamentação Teórica.....	5
2.1 Metodologia Bayesiana	5
2.1.1 Modelo de Degradação	6
2.1.2 Distribuição do Tempo de Vida	7
2.1.3 Estimativa da Vida Útil Remanescente	7
2.1.4 Estimação de parâmetros.....	9
2.1.5 Atualização do parâmetro estocástico	10
2.2 Séries Temporais	11
2.2.1 Estacionariedade	13
2.2.2 Suavização Exponencial Simples.....	14
2.2.3 Suavização Exponencial Dupla.....	15
2.2.4 Modelo ARIMA	15
2.2.5 Suavização Exponencial Tripla	16
2.2.6 Modelo SARIMA.....	17
Capítulo 3 – Revisão Bibliográfica.....	19
3.1 Tempo de Vida Útil Remanescente	19
3.2 Processos Cíclicos	21
3.3 Séries Temporais	21
Capítulo 4 – Metodologia	23
4.1 Metodologia Bayesiana	24
4.2 Séries Temporais	25
Capítulo 5 – Estudo de Caso	28
5.1 Processo TSA	28
5.2 Unidade TSA para Desidratação.....	29
5.3 Medições Disponíveis.....	31
5.4 Forma de Operação.....	31
Capítulo 6 – Resultados e Discussões.....	32
6.1 Dados Simulados	32
6.2 Previsão do NCR da Unidade TSA de Desidratação	35
6.2.1 Metodologia Bayesiana	41
6.2.2 Séries Temporais.....	45
6.2.2.1 Suavização Exponencial Simples	49
6.2.2.2 Suavização Exponencial Dupla.....	52
6.2.2.3 Modelo ARIMA.....	55
6.2.2.4 Suavização Exponencial Tripla	58
6.2.2.5 Modelo SARIMA	61
6.3 Metodologia Bayesiana vs Séries Temporais	64
Capítulo 7 – Conclusões e Trabalhos Futuros.....	66
Referências	68
Apêndice A – FDP condicional ao tempo de vida	72

Apêndice B – FDP do tempo de vida remanescente	73
Apêndice C – Código em Python da Metodologia Bayesiana.....	74
Apêndice D – Código em Python das Séries Temporais.....	77
Apêndice E – Modelos ARIMA	82
Apêndice F – Modelos SARIMA.....	84

LISTA DE FIGURAS

Figura 1.1: Principais métodos para estimativa da Vida Útil Remanescente (adaptado de SIKORSKA; HODKIEWICZ; MA (2011)).	2
Figura 2.1: Representação do conceito de Vida Útil Remanescente (adaptado de SI et al. (2012)).	9
Figura 2.2: Dados de degradação de baterias de íons de Lítio (adaptado de WANG et al. (2014)).	11
Figura 2.3: a) Concentração de CO ₂ de 1974 a 1987; b) Concentração de CO ₂ entre 1980 e 1981 (adaptado de PAL; PRAKASH (2017)).	12
Figura 2.4: Série não-estacionária quanto ao nível e a inclinação (adaptado de MORETTIN; TOLOI (2006)).	13
Figura 4.1: Variação de pressão em um ciclo de adsorção-regeneração: a) com a presença de <i>outliers</i> ; b) sem <i>outlier</i> .	24
Figura 4.2: Etapas para a aplicação da metodologia Bayesiana na estimativa da VUR (adaptado de WANG; HU; FAN (2018)).	25
Figura 4.3: Etapas para a aplicação de Séries Temporais na estimativa da VUR.	26
Figura 5.1: Exemplo de perfil de temperatura em um processo TSA.	29
Figura 5.2: Unidade TSA para desidratação do GN com 3 colunas utilizando peneiras moleculares como adsorventes.	30
Figura 6.1: Curvas de degradação simuladas.	33
Figura 6.2: FDPs previstas para VUR da curva simulada de número 5.	34
Figura 6.3: Valores previstos de VUR em cada ponto de MC analisado.	34
Figura 6.4: Fator de Resistência ao Escoamento da Coluna A.	36
Figura 6.5: Fator de Resistência ao Escoamento da Coluna B.	36
Figura 6.6: Fator de Resistência ao Escoamento da Coluna C.	37
Figura 6.7: Padrão cíclico do fator de resistência ao escoamento.	37
Figura 6.8: Separação dos ciclos utilizando a derivada do fator de resistência.	38
Figura 6.9: Ciclos de adsorção-regeneração da Coluna A.	38
Figura 6.10: Ciclos de adsorção-regeneração da Coluna B.	39
Figura 6.11: Ciclos de adsorção-regeneração da Coluna C.	39
Figura 6.12: Tempo de duração dos ciclos de adsorção-regeneração para as 3 colunas da unidade TSA de desidratação.	40
Figura 6.13: Fator de resistência ao escoamento em função do ciclo em 30% da etapa de adsorção.	40
Figura 6.14: Fator de resistência ao escoamento em função do ciclo em 50% da etapa de adsorção.	41
Figura 6.15: Fator de resistência ao escoamento em função do ciclo em 75% da etapa de adsorção.	41
Figura 6.16: FDPs previstas para o NCR da Coluna A em 30% da etapa de adsorção.	42
Figura 6.17: FDPs previstas para o NCR da Coluna A em 50% da etapa de adsorção.	43
Figura 6.18: FDPs previstas para o NCR da Coluna A em 75% da etapa de adsorção.	43
Figura 6.19: Valores previstos de NCR em cada ciclo de MC analisado em 30% da etapa de adsorção.	44
Figura 6.20: Valores previstos de NCR em cada ciclo de MC analisado em 50% da etapa de adsorção.	44
Figura 6.21: Valores previstos de NCR em cada ciclo de MC analisado em 75% da etapa de adsorção.	45
Figura 6.22: Separação do conjunto de Treino e Teste da Coluna A para 30% da etapa de adsorção.	46

Figura 6.23: Separação do conjunto de Treino e Teste da Coluna A para 50% da etapa de adsorção.	46
Figura 6.24: Separação do conjunto de Treino e Teste da Coluna A para 75% da etapa de adsorção.	47
Figura 6.25: ACF e PACF para 30% da etapa de adsorção.....	47
Figura 6.26: ACF e PACF para 50% da etapa de adsorção.....	48
Figura 6.27: ACF e PACF para 75% da etapa de adsorção.....	48
Figura 6.28: Conjuntos de Treino, Teste e modelo SES ajustado para 30% da etapa de adsorção.	50
Figura 6.29: Conjuntos de Treino, Teste e modelo SES ajustado para 50% da etapa de adsorção.	50
Figura 6.30: Conjuntos de Treino, Teste e modelo SES ajustado para 75% da etapa de adsorção.	51
Figura 6.31: a) Resíduos entre o modelo SES ajustado e o conjunto de Teste em 30% da etapa de adsorção; b) Distribuição dos Resíduos.	51
Figura 6.32: a) Resíduos entre o modelo SES ajustado e o conjunto de Teste em 50% da etapa de adsorção; b) Distribuição dos Resíduos.	52
Figura 6.33: a) Resíduos entre o modelo SES ajustado e o conjunto de Teste em 50% da etapa de adsorção; b) Distribuição dos Resíduos.	52
Figura 6.34: Conjuntos de Treino, Teste e modelo SED ajustado para 30% da etapa de adsorção.	53
Figura 6.35: Conjuntos de Treino, Teste e modelo SED ajustado para 50% da etapa de adsorção.	53
Figura 6.36: Conjuntos de Treino, Teste e modelo SED ajustado para 75% da etapa de adsorção.	54
Figura 6.37: a) Resíduos entre o modelo SED ajustado e o conjunto de Teste em 30% da etapa de adsorção; b) Distribuição dos Resíduos.	54
Figura 6.38: a) Resíduos entre o modelo SED ajustado e o conjunto de Teste em 50% da etapa de adsorção; b) Distribuição dos Resíduos.	55
Figura 6.39: a) Resíduos entre o modelo SED ajustado e o conjunto de Teste em 75% da etapa de adsorção; b) Distribuição dos Resíduos.	55
Figura 6.40: : Conjuntos de Treino, Teste e modelo ARIMA ajustado para 30% da etapa de adsorção.	56
Figura 6.41: Conjuntos de Treino, Teste e modelo ARIMA ajustado para 50% da etapa de adsorção.	57
Figura 6.42: Conjuntos de Treino, Teste e modelo ARIMA ajustado para 75% da etapa de adsorção.	57
Figura 6.43: a) Resíduos entre o modelo ARIMA ajustado e o conjunto de Teste em 30% da etapa de adsorção; b) Distribuição dos Resíduos.....	58
Figura 6.44: a) Resíduos entre o modelo ARIMA ajustado e o conjunto de Teste em 50% da etapa de adsorção; b) Distribuição dos Resíduos.....	58
Figura 6.45: a) Resíduos entre o modelo ARIMA ajustado e o conjunto de Teste em 75% da etapa de adsorção; b) Distribuição dos Resíduos.....	58
Figura 6.46: Conjuntos de Treino, Teste e modelo SET ajustado para 30% da etapa de adsorção.	59
Figura 6.47: Conjuntos de Treino, Teste e modelo SET ajustado para 50% da etapa de adsorção.	59

Figura 6.48: Conjuntos de Treino, Teste e modelo SET ajustado para 75% da etapa de adsorção.	60
Figura 6.49: a) Resíduos entre o modelo SET ajustado e o conjunto de Teste em 30% da etapa de adsorção; b) Distribuição dos Resíduos.	60
Figura 6.50: a) Resíduos entre o modelo SET ajustado e o conjunto de Teste em 50% da etapa de adsorção; b) Distribuição dos Resíduos.	61
Figura 6.51: a) Resíduos entre o modelo SET ajustado e o conjunto de Teste em 75% da etapa de adsorção; b) Distribuição dos Resíduos.	61
Figura 6.52: Conjuntos de Treino, Teste e modelo SARIMA ajustado para 30% da etapa de adsorção.	62
Figura 6.53: Conjuntos de Treino, Teste e modelo SARIMA ajustado para 50% da etapa de adsorção.	63
Figura 6.54: Conjuntos de Treino, Teste e modelo SARIMA ajustado para 75% da etapa de adsorção.	63
Figura 6.55: a) Resíduos entre o modelo SARIMA ajustado e o conjunto de Teste em 30% da etapa de adsorção; b) Distribuição dos Resíduos.....	64
Figura 6.56: a) Resíduos entre o modelo SARIMA ajustado e o conjunto de Teste em 50% da etapa de adsorção; b) Distribuição dos Resíduos.....	64
Figura 6.57: a) Resíduos entre o modelo SARIMA ajustado e o conjunto de Teste em 75% da etapa de adsorção; b) Distribuição dos Resíduos.....	64
Figura 6.58: Previsão do padrão cíclico utilizando o modelo SARIMA	65
Figura E.1: Conjuntos de Treino, Teste e modelo ARIMA ajustado para 50% da etapa de adsorção.	83
Figura E.2: Conjuntos de Treino, Teste e modelo ARIMA ajustado para 75% da etapa de adsorção.	83
Figura F.1: Conjuntos de Treino, Teste e modelo SARIMA ajustado para 30% da etapa de adsorção.	85
Figura F.2: Conjuntos de Treino, Teste e modelo SARIMA ajustado para 50% da etapa de adsorção.	85
Figura F.3: Conjuntos de Treino, Teste e modelo SARIMA ajustado para 50% da etapa de adsorção.	86
Figura F.4: Conjuntos de Treino, Teste e modelo SARIMA ajustado para 75% da etapa de adsorção.	86

LISTA DE TABELAS

Tabela 6.1: Parâmetros estimados pelo método da EMV	33
Tabela 6.2: Valores de REMQ e EMA para a previsão da VUR dos dados simulados	35
Tabela 6.3: Parâmetros estimados para informação <i>a priori</i> da degradação da Coluna A	42
Tabela 6.4: Teste ADF para os três casos estudados.	49
Tabela 6.5: Valores da constante de suavização e da REMQ para os casos estudados.	49
Tabela 6.6: Valores das constantes de suavização e da REMQ para os casos estudados. .	52
Tabela 6.7: Modelo ARIMA (1, 0, 1) ajustado para 30% da etapa de adsorção.	55
Tabela 6.8: Modelo ARIMA (5, 0, 0) ajustado para 50% da etapa de adsorção.	55
Tabela 6.9: Modelo ARIMA (1, 0, 4) ajustado para 50% da etapa de adsorção.	56
Tabela 6.10: REMQ para os modelos SET	59
Tabela 6.11: Modelo SARIMA (0, 1, 1)(1,0,1) ₁₂ ajustado para 30% da etapa de adsorção.	61
Tabela 6.12: Modelo SARIMA (0, 1, 1)(1,0,1) ₁₂ ajustado para 50% da etapa de adsorção.	62
Tabela 6.13: Modelo SARIMA (0, 1, 1)(1,0,1) ₁₂ ajustado para 75% da etapa de adsorção.	62
Tabela E.1: Modelo ARIMA (1, 0, 1) ajustado para 50% da etapa de adsorção.	82
Tabela E.2: Modelo ARIMA (1, 0, 1) ajustado para 75% da etapa de adsorção.	82
Tabela F.1: Modelo SARIMA (0, 1, 1)(0,0,0) ₁₂ ajustado para 30% da etapa de adsorção. .	84
Tabela F.2: Modelo SARIMA (0, 1, 1)(3,0,1) ₁₂ ajustado para 50% da etapa de adsorção. .	84
Tabela F.3: Modelo SARIMA (0, 1, 1)(0,0,0) ₁₂ ajustado para 50% da etapa de adsorção. .	84
Tabela F.4: Modelo SARIMA (0, 1, 0)(0,0,0) ₁₂ ajustado para 75% da etapa de adsorção. .	84

NOTAÇÃO E SIMBOLOGIA

<i>PHM</i>	<i>Prognostic and Health Management</i>
<i>VUR</i>	Vida Útil Remanescente
<i>MC</i>	Monitoramento da condição
<i>TSA</i>	<i>Temperature Swing Adsorption</i>
<i>PSA</i>	<i>Pressure Swing Adsorption</i>
<i>NCR</i>	Número de Ciclos Remanescentes
<i>EMV</i>	Estimativa por Máxima Verossimilhança
$X(t)$	Degradação no tempo t
σ_B	Coefficiente de difusão do movimento Browniano
$B(t)$	Movimento Browniano
$\mu(\tau; \beta)$	Parcela não-linear do modelo de degradação
α	Parâmetro estocástico do modelo de degradação
$\mu_{\alpha,0}$	Média inicial do parâmetro estocástico
$\sigma_{\alpha,0}^2$	Variância inicial do parâmetro estocástico
β	Parâmetro determinístico do modelo de degradação
<i>FDP</i>	Função densidade de probabilidade
<i>PTP</i>	Primeiro Tempo de Passagem
T	Tempo de vida do sistema
X_f	Limite aceitável de degradação
$f_{T \alpha}(t \alpha)$	FDP para o tempo de vida T condicionada ao parâmetro estocástico
$f_T(t)$	FDP para o tempo de vida T
$f(\alpha)$	FDP do parâmetro estocástico
L_k	VUR/NCR no tempo t_k
x_k	Degradação no tempo t_k
$f_{Lk}(l_k)$	FDP da(o) VUR/NCR
$\mu_{\alpha,k}$	Média do parâmetro estocástico no tempo t_k
$\sigma_{\alpha,k}^2$	Variância do parâmetro estocástico no tempo t_k
$E(L_k)$	VUR/NCR média(o)
α_0	Informação <i>a priori</i> do parâmetro estocástico
$Z(t_{i,j})$	j -ésimo dado de degradação do i -ésimo sistema no tempo $t_{i,j}$
μ_i	Média da degradação do i -ésimo sistema

Σ_i	Matriz de covariância da degradação do i-ésimo sistema
$l(\Theta Z_{1:M})$	Logaritmo da função de verossimilhança
$Z_{1:M}$	Degradação de M sistemas similares
$\pi(\alpha_0)$	Distribuição <i>a priori</i> do parâmetro estocástico
$p(x_{1:k} \alpha)$	Função de verossimilhança da distribuição <i>posteriori</i> de α
$p(\alpha x_{1:k})$	Distribuição <i>posteriori</i> do parâmetro estocástico
x_t	Valor da série temporal no tempo t
Te_t	Tendência da série temporal
Sa_t	Sazonalidade da série temporal
C_t	Componente cíclico da série temporal
E_t	Variações inesperadas da série temporal
ACF	Função Autocorrelação
PACF	Função Autocorrelação Parcial
ADF	<i>Augmented Dickey-Fuller</i>
x_t'	Diferenciação de primeira ordem de uma série temporal x_t
SES	Suavização Exponencial Simples
a_s	Constante de suavização de nível
F_t	Valor futuro da série
SED	Suavização Exponencial Dupla
b_s	Constante de suavização de tendência
T_t	Tendência estimada
ARIMA	<i>Auto-Regressive Integrated Moving Average</i>
p	Ordem auto-regressiva
q	Ordem dos termos de média móvel
d	Ordem do termo integrador
φ_i	Coefficiente auto-regressor
δ	Interceptação média
ϑ_i	Coefficiente de média móvel
ARMA	<i>Auto-Regressive Moving Average</i>
SET	Suavização Exponencial Tripla
S_t	Sazonalidade estimada
x_{t+h}	Valor futuro da série em t+h
γ_s	Constante de suavização de sazonalidade
m	Tamanho do período sazonal
P	Ordem auto-regressiva da componente sazonal
Q	Ordem dos termos de média móvel sazonal

D	Ordem da diferenciação sazonal
φ_{im}	Coefficiente auto-regressor sazonal
ϑ_{im}	Coefficiente de média móvel sazonal
<i>PTSA</i>	<i>Pressure-Temperature Swing Adsorption</i>
<i>SVM</i>	<i>Support Vector Machines</i>
<i>REMQ</i>	Raiz do erro médio quadrático
N	Tamanho da amostra
x_p	Valor previsto
x_o	Valor observado
<i>AIC</i>	<i>Akaike Information Criterion</i>
<i>BIC</i>	<i>Bayesian Information Criterion</i>
L	Valor maximizado da verossimilhança para o modelo M
Γ	Parâmetros que maximizam a função de verossimilhança do modelo M
q	Número de parâmetros a serem estimados
n	Número de dados observados
<i>GN</i>	Gás Natural
CO_2	Dióxido de carbono
R_i	Fator de Resistência ao Escoamento do Leito i
ΔP_i	Varição de Pressão do Leito i
F_i	Vazão de gás natural no Leito i
F	Vazão total de gás natural
<i>EMA</i>	Erro Médio Absoluto
Pa	Pascal

Capítulo 1 – Introdução

1.1 Motivação

A deterioração de um sistema frequentemente se manifesta na degradação da performance do mesmo, gerando uma deterioração física, danos, risco à segurança, etc. Para equipamentos críticos, como por exemplo na indústria de aviação, é necessária uma estimativa antecipada e precisa da falha para evitar danos ao equipamento, perda de vidas humanas e desastres ambientais (SI et al., 2012).

A metodologia usada para avaliar a confiabilidade, a segurança e a eficiência do sistema sob determinadas condições é chamada de “*Prognostics and Health Management*” (PHM). O PHM é tratado como a solução para aprimorar a segurança do processo, aumentando a sua confiabilidade, diminuindo manutenções desnecessárias reduzindo, desta forma, os custos envolvidos no processo (WANG et al., 2014). Esta metodologia consiste em monitorar e analisar o desempenho do sistema para determinar a Vida Útil Remanescente (VUR) do equipamento, definida como sendo o tempo de vida, a partir do presente, até o fim da vida útil deste equipamento (SI et al., 2013). A importância da VUR é nítida, pois a partir dela, pode-se definir o tempo de manutenção, intervalo de inspeção de modo a minimizar os custos econômicos e diminuir os riscos da falha acontecer (HU et al., 2018).

Como para sistemas críticos os dados de falha são geralmente escassos devido a não ser possível esperar a falha acontecer, a análise da degradação pode ser útil para determinar a VUR. O ponto chave da análise de degradação consiste em monitorar ao longo do tempo uma variável responsável pela deterioração do sistema e partir disto aplicar metodologia PHM para a tomada de decisão (NIKULIN et al., 2010; WANG et al., 2014).

Em geral, na literatura dois métodos para a estimativa da VUR são usados com maior frequência: métodos baseados na dinâmica da falha e métodos baseados na coleta de dados. Métodos baseados na coleta de dados são mais utilizados na área de confiabilidade pela dificuldade em obter o comportamento dinâmico da falha, enquanto que os dados de monitoramento da condição (MC) de um determinado dispositivo (comprimento da fratura, vibração, tempo de abertura da válvula, etc.) podem ser medidos facilmente (SI et al., 2012, 2013; WANG; HU; FAN, 2018). Entre os métodos de coleta de dados, encontram-se ferramentas que levam em consideração apenas o

comportamento determinístico do processo e outras que levam também em consideração o comportamento estocástico do processo. A parte determinística é referente aos efeitos que são comuns a todos equipamentos semelhantes, enquanto que a parte estocástica é exclusiva a um equipamento individual (GEBRAEEL et al., 2005; SI et al., 2012; WANG; HU; FAN, 2018).

Para estimar o término da vida útil de um sistema é relevante considerar a natureza probabilística do processo, então métodos que conciliam o comportamento determinístico e o comportamento estocástico se tornam úteis. A Figura 1.1 ilustra as principais categorias para estimativa da VUR, desde os métodos mais simples, até modelos mais complexos. Este trabalho utilizará uma metodologia Bayesiana que é um Modelo baseado na Expectativa de Vida que mistura característica estocástica e estatística, e uma metodologia baseada em Séries Temporais que se baseia apenas em dados estatísticos.

Conforme a Figura 1.1, além de métodos baseados na coleta de dados e na dinâmica da falha, existem modelos que consideram o conhecimento do processo que são mais simples, entretanto dependem de conhecimentos de especialistas no assunto e exigem que a base do conhecimento se mantenha atualizada. E por fim, a estimativa da VUR utilizando Redes Neurais, que permite a modelagem de sistemas não-lineares assim como não necessita do comportamento dinâmico do sistema, porém requer uma quantidade significativa de dados para ajustar o modelo e a determinação do modelo mais apropriado pode demorar, pois esta etapa é, em grande parte, tentativa e erro (SIKORSKA; HODKIEWICZ; MA, 2011).

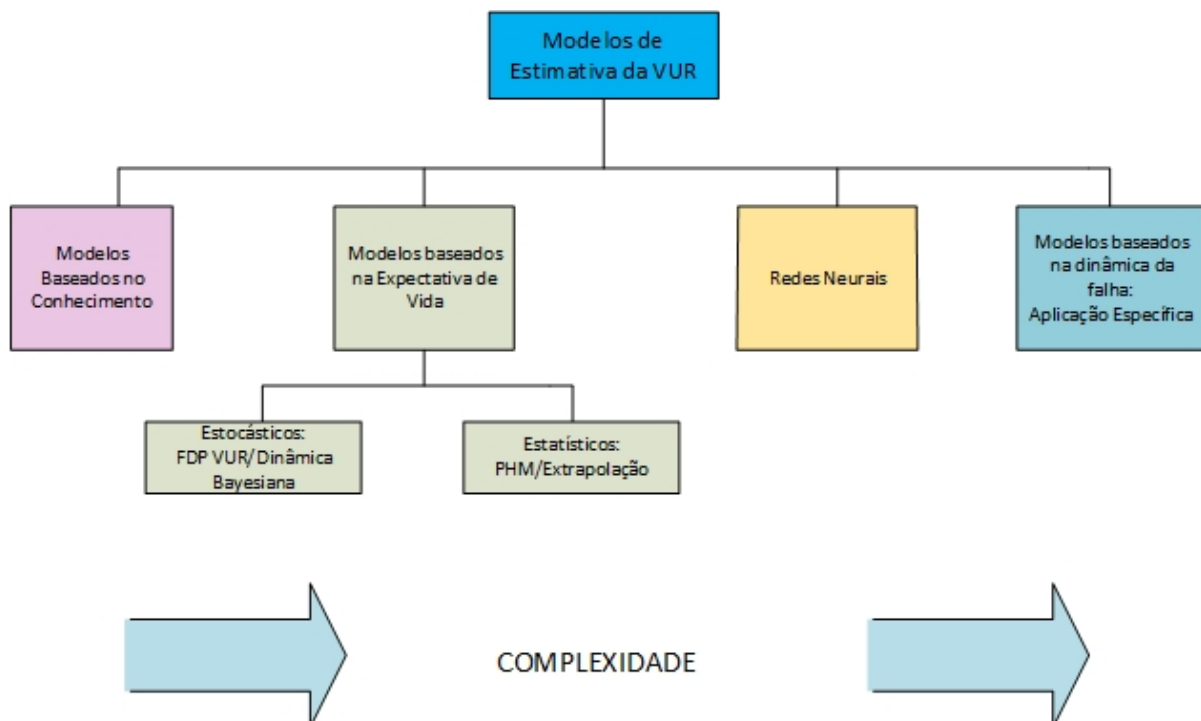


Figura 1.1: Principais métodos para estimativa da Vida Útil Remanescente (adaptado de SIKORSKA; HODKIEWICZ; MA (2011)).

Em processos em que o tempo de operação é muito longo, como o tempo para carga e descarga de baterias ou o tempo das etapas de adsorção e regeneração em um processo *Temperature Swing Adsorption* (TSA) e *Pressure Swing Adsorption* (PSA), a análise do ciclo de operação se torna interessante. Através do monitoramento da degradação ao longo dos ciclos pode-se então determinar o Número de Ciclos Remanescentes (NCR) para o fim da vida útil de um sistema ou equipamento. Em baterias o monitoramento pode ser realizado através da variação da capacitância ao longo dos ciclos (LIU et al., 2010; SI, 2015; WANG et al., 2014) e em processos TSA e PSA o monitoramento pode ser feito por meio da medida do fator de Resistência ao escoamento ao longo do leito, como será proposto e ilustrado nesta dissertação.

1.2 Objetivos do trabalho

O objetivo geral desta dissertação é o desenvolvimento de uma metodologia para determinar a VUR e o NCR em processos cíclicos. Para tanto os seguintes objetivos específicos nortearão o desenvolvimento desta dissertação:

- Analisar a degradação de Processos Cíclicos e a importância da análise do NCR na determinação da VUR;
- Avaliar a relevância de levar em consideração o comportamento estocástico de uma variável responsável pela degradação de um sistema;
- Comparar a metodologia Bayesiana, em que se leva em consideração o efeito estocástico, reduzindo a incerteza em relação a este efeito, de forma a atualizar o parâmetro estocástico a cada novo ciclo de operação, com a metodologia baseada em Séries Temporais, que são fundamentadas apenas em efeitos determinísticos;
- Determinar qual destes dois métodos se ajusta melhor para determinar o NCR em Processos Cíclicos.

1.3 Estrutura da dissertação

Esta dissertação está dividida em 7 capítulos. Neste capítulo foi apresentada a proposta geral deste trabalho, assim como as motivações e os principais objetivos para realização do mesmo.

O Capítulo 2 apresenta a fundamentação teórica que serviu como base para a pesquisa, apresentando conceitos envolvidos para avaliar a degradação de um sistema, além de ilustrar os princípios da metodologia Bayesiana e de Séries Temporais para avaliar o NCR em Processos Cíclicos

No Capítulo 3 é realizada a revisão bibliográfica referente aos conceitos e informações sobre a determinação do tempo de vida de um sistema e técnicas de previsões de valores futuros.

Essa divisão, um capítulo sobre a fundamentação teórica seguido de uma revisão bibliográfica, foi escolhida com o intuito de facilitar o entendimento do leitor a respeito das metodologias apresentadas neste trabalho.

O Capítulo 4 detalha as metodologias propostas para avaliar o número de ciclos remanescentes. Para a metodologia bayesiana, é apresentado o meio para a obtenção

dos parâmetros determinísticos e estocásticos, e para a metodologia baseada em Séries Temporais, a maneira de ajustar os modelos é detalhada.

No Capítulo 5 se discute o Estudo de Caso em que as metodologias apresentadas no Capítulo 4 são aplicadas para avaliar suas eficiências. Os resultados obtidos e a análise dos mesmos, são apresentados no capítulo 6.

O Capítulo 7 apresenta as conclusões finais e sugestões para trabalhos futuros.

Capítulo 2 – Fundamentação Teórica

Este capítulo apresenta o embasamento teórico necessário para o desenvolvimento deste trabalho. O Capítulo está dividido em duas subseções: Metodologia Bayesiana e Séries Temporais. A subseção “Metodologia Bayesiana” apresenta todo o desenvolvimento para o cálculo da Vida Útil Remanescente, que pode ser aplicado em processos cíclicos e em processos que se propagam no tempo, utilizando a Inferência Bayesiana para atualizar o efeito aleatório envolvido no processo. Na subseção “Séries Temporais” é introduzido primeiramente a definição de série temporal e seus principais componentes, após é definido o conceito de estacionariedade e, por último, são apresentados alguns modelos para ajustar a série temporal e realizar previsão de valores futuros, para o propósito deste trabalho, prever o final da vida útil de um processo cíclico.

2.1 Metodologia Bayesiana

Neste trabalho, utiliza-se um modelo de degradação não-linear utilizando a Inferência Bayesiana segundo o modelo proposto por WANG; HU; FAN (2018). Esta abordagem considera a natureza probabilística do processo, avaliando o efeito estocástico a cada novo dado de MC obtido para que possa ser realizada uma predição razoável da vida residual do equipamento em análise. Por isto, a Inferência Bayesiana se torna um método interessante, ajustando as novas informações obtidas com a informação prévia (*a priori*), proporcionando uma atualização do efeito estocástico, reduzindo a incerteza presente no comportamento aleatório (COLAÇO et al., 2012). Na sequência é apresentado o modelo de degradação baseado na coleta de dados proposto por WANG; HU; FAN (2018), levando em consideração a parte determinística e a parte estocástica do processo. Os parâmetros determinísticos e os hiperparâmetros da distribuição *a priori* do parâmetro estocástico serão estimados utilizando o método da Estimativa por Máxima Verossimilhança (EMV) baseados nos dados históricos de degradação de sistemas similares e o parâmetro estocástico será atualizado a cada novo dado de degradação obtido no sistema de interesse.

2.1.1 Modelo de Degradação

Entre os métodos de coleta de dados mais utilizados para ajustar o modelo de degradação, estão o processo de Wiener, o processo Gamma e cadeia de Markov (HU et al., 2018). Pela capacidade de identificar as características comuns e individuais dos sistemas, o modelo de degradação baseado no processo de Wiener tem sido bastante utilizado (GEBRAEEL et al., 2005; SI et al., 2012). Essencialmente os modelos de degradação baseados no processo de Wiener se constituem de duas partes: determinística e estocástica. O modelo de degradação baseado no processo de Wiener com característica não-linear é dado por:

$$X(t) = X(0) + \alpha \int_0^t \mu(\tau; \beta) d\tau + \sigma_B B(t) \quad (2.1)$$

sendo $X(t)$ a degradação de um sistema qualquer no tempo t . Para processos cíclicos se pode considerar t como sendo a degradação em um determinado ciclo, neste caso $X(0)$ é a degradação no ciclo inicial, σ_B é o coeficiente de difusão do movimento Browniano representado por $B(t)$, $\mu(\tau; \beta)$ é a parcela responsável pela não-linearidade do modelo, caso $\mu(\tau; \beta)$ seja uma constante, o modelo em (2.1) representará um caso de degradação linear. O parâmetro α é encarregado pelo efeito estocástico, enquanto σ_B e β são os parâmetros determinísticos. Assume-se que $X(0) = 0$ e $\alpha \sim N(\mu_\alpha, \sigma_\alpha^2)$ e que α e $B(t)$ são estatisticamente independentes (GEBRAEEL et al., 2005; SI et al., 2012, 2013; WANG et al., 2014). Este modelo de degradação, baseado no processo de Wiener, tem sido amplamente utilizado para medição da vibração de rolamentos, comprimento de fratura de algum metal, na medida de capacitância de baterias, sendo útil tanto para processos cíclicos, quanto para processos com medição ao longo do tempo.

Os benefícios em usar o modelo apresentado pela Equação (2.1) são que primeiro, os sistemas podem apresentar taxas de degradação que variam em diferentes condições de operações. E segundo, que como abordado anteriormente, pode representar casos lineares e não lineares (SI, 2015).

O processo de movimento Browniano, também chamado de Processo de Wiener, é apropriado para casos em que os erros de leitura de sensor são correlacionados, e possui valor $W(t)$ para $t \geq 0$, com as seguintes propriedades (GEBRAEEL et al., 2005):

1. $W(t)$ possui incrementos independentes, ou seja, se $t_0 < t_1 < \dots < t_n$, então $W(t_0)$, $W(t_1 - t_0)$, ..., $W(t_n - t_{n-1})$ são mutuamente independentes;
2. O incremento $W(s + t) - W(s)$ é normalmente distribuído com média zero e variância t ;
3. $W(t)$ normalmente apresenta trajetória contínua.

Por possuir estas propriedades, o modelo Browniano é utilizado em (2.1) para representar os possíveis ruídos de medição sendo o termo $\sigma_B B(t)$ responsável pela modelagem destes ruídos com média 0 e variância $\sigma_B^2 t$; caso $\sigma_B = 0$, o modelo de degradação em (2.1) assume que não há ruídos de informação sensorial e a equação se torna o modelo de degradação puro (GEBRAEEL et al., 2005; SI et al., 2013; WANG; HU;

FAN, 2018). DURRETT (2010) aborda o processo do movimento Browniano e suas propriedades de forma mais completa.

2.1.2 Distribuição do Tempo de Vida

Para representar a natureza probabilística e a incerteza do processo, é necessário se obter a função densidade de probabilidade (FDP) do tempo de vida. Para obter a FDP do tempo de vida de um sistema qualquer, é interessante, primeiramente, aplicar o conceito de Primeiro Tempo de Passagem (PTP). O PTP é definido como o tempo em que o sinal de degradação ultrapassa um limite aceitável pré-definido, sendo este limite obtido através de conhecimento, manuais de sistemas, base de dados pregressa, entre outras. O PTP é reconhecido como uma definição do tempo de vida para modelos que consideram o efeito estocástico (LEE; WHITMORE, 2006; LEE et al., 2009; SI et al., 2013; WANG; HU; FAN, 2018). A Equação (2.2) apresenta a definição do PTP para um tempo de vida T:

$$T = \inf\{t: X(t) \geq X_f | X(0) < X_f\} \quad (2.2)$$

onde X_f é o limite pré-definido do sistema. Quando $X(t)$ alcança este limite X_f , é estabelecido como o fim do tempo de vida do sistema em análise. Em equipamentos críticos, o conceito de PTP é posto em prática, quando a degradação observada alcança, ou supera, o limite, o equipamento deve ser parado (SI et al., 2012).

Devido à presença da parcela não linear $\mu(\tau; \beta)$ no modelo de degradação, é difícil obter a solução exata da FDP do tempo de vida T definido na Equação (2.2), por isto, seguindo o método desenvolvido por SI et al. (2012), é possível obter uma aproximação analítica da FDP para o tempo de vida T. Então a FDP condicional do tempo de vida, definido na Equação (2.2), pode ser equacionada como:

$$f_{T|\alpha}(t|\alpha) \cong \frac{X_f - \alpha \int_0^t \mu(\tau; \beta) d\tau + \alpha \mu(\tau; \beta) t}{\sigma_B t \sqrt{2\pi t}} \exp \left\{ - \frac{[X_f - \alpha \int_0^t \mu(\tau; \beta) d\tau]^2}{2\sigma_B^2 t} \right\} \quad (2.3)$$

A dedução da Equação (2.3) se encontra no Apêndice A e a partir desta Equação, observa-se que a FDP do tempo de vida T é condicional ao parâmetro α , porém, como α é o parâmetro estocástico do modelo de degradação, é necessário considerar o seu comportamento aleatório para obter a distribuição do tempo de vida T mais próxima da realidade. Para isso, com base na lei da probabilidade total, relaciona-se a probabilidade do parâmetro estocástico com a probabilidade condicional do tempo de vida T conforme a Equação (2.4):

$$f_T(t) = \int_{\Omega} f_{T|\alpha}(t|\alpha) f(\alpha) d\alpha \quad (2.4)$$

onde $f(\alpha)$ é a FDP do parâmetro estocástico α e que pode ser obtida através do processo de estimação de parâmetros que será explicado na sequência.

2.1.3 Estimativa da Vida Útil Remanescente

Com a FDP do tempo de vida obtida na Equação (2.4), a FDP da VUR do sistema a ser analisado pode ser estimada analogamente. Sendo t_k o tempo atual de observação da degradação do sistema de interesse, ou para casos em que o processo seja cíclico, t_k representa o ciclo atual de observação da degradação do sistema, e L_k representa a VUR em t_k , ou NCR para processos cíclicos, então $l_k = t - t_k$, considerando que o sistema alcança

o limite X_f no tempo t e que após alcançar este limite X_f , é definido o fim da vida útil do sistema e levando em consideração as propriedades do Movimento Browniano, a seguinte equação pode ser obtida a partir da Equação (2.1):

$$Y(l_k) = Y(0) + \alpha \int_{t_k}^{t_k+l_k} \mu(\tau; \beta) d\tau + \sigma_B W(l_k) \quad (2.5)$$

onde $Y(0) = 0$, e:

$$W(l_k) = B(t_k + l_k) - B(t_k) \quad (2.6)$$

$$Y(l_k) = X(t_k + l_k) - X(t_k) \quad (2.7)$$

Com estas definições, a FDP da VUR do sistema de interesse, ou FDP do NCR para processos cíclicos é obtida em um tempo t_k de observação da degradação:

$$\begin{aligned} f_{L_k}(l_k) &\cong \frac{1}{\sqrt{2\pi l_k^2 \left[\sigma_{\alpha,k}^2 \left(\int_{t_k}^{t_k+l_k} \mu(\tau; \beta) d\tau \right)^2 + \sigma_B^2 l_k \right]}} \\ &\times \left\{ \begin{aligned} &X_f - x_k - \left[\int_{t_k}^{t_k+l_k} \mu(\tau; \beta) d\tau - \mu(l_k + t_k; \beta) l_k \right] \\ &\times \frac{\sigma_{\alpha,k}^2 (X_f - x_k) \int_{t_k}^{t_k+l_k} \mu(\tau; \beta) d\tau + \mu_{\alpha,k} \sigma_B^2 l_k}{\sigma_{\alpha,k}^2 \left(\int_{t_k}^{t_k+l_k} \mu(\tau; \beta) d\tau \right)^2 + \sigma_B^2 l_k} \end{aligned} \right\} \quad (2.8) \\ &\times \exp \left\{ - \frac{\left[X_f - x_k - \mu_{\alpha,k} \int_{t_k}^{t_k+l_k} \mu(\tau; \beta) d\tau \right]^2}{2 \left[\sigma_{\alpha,k}^2 \left(\int_{t_k}^{t_k+l_k} \mu(\tau; \beta) d\tau \right)^2 + \sigma_B^2 l_k \right]} \right\} \end{aligned}$$

O valor de VUR média, ou seja, o valor esperado da variável L_k , é definido pela Equação (2.9):

$$VUR_{m\u00e9dia} = E(L_k) = \int_0^{+\infty} l_k f_{L_k}(l_k) dl_k \quad (2.9)$$

A obtenção da Equação (2.8) é apresentada no Apêndice B e a partir desta Equação é possível perceber que para o cálculo da FDP da VUR, leva-se em consideração x_k , que é a degradação do sistema/equipamento analisado em t_k , e a atualização da média e variância do parâmetro α no tempo t_k , $\mu_{\alpha,k}$ e $\sigma_{\alpha,k}^2$, respectivamente, assim é possível atualizar, a cada instante em que um novo dado de MC for obtido, a Vida Útil Remanescente associada ao equipamento em análise (WANG; HU; FAN, 2018). A Figura 2.1 ilustra o conceito e a definição da previsão da VUR, que tem como finalidade prever quando o sistema analisado alcançará o limite aceitável X_f . As curvas vermelha, azul e verde representam a degradação a partir do tempo t_k . A curva vermelha atinge o limite aceitável antes das outras duas curvas, assim como a curva verde é a última a atingir este limite.




Figura 2.1: Representação do conceito de Vida Útil Remanescente (adaptado de SI et al. (2012)).

2.1.4 Estimação de parâmetros

Os parâmetros a serem estimados são os parâmetros determinísticos (β , σ_B) que representam um efeito de degradação com sistemas semelhantes e os hiperparâmetros ($\mu_{\alpha,0}$, $\sigma_{\alpha,0}^2$) da distribuição *a priori* do parâmetro estocástico α . O método utilizado para obter estes parâmetros é a EMV e consiste na maximização da probabilidade de os parâmetros representarem os dados experimentais (FOGLIATTO; RIBEIRO, 2009).

Baseando-se nos desenvolvimentos apresentados por SI et al. (2012) e WANG; HU; FAN (2018), assumindo a existência de dados históricos de degradação de M sistemas similares ao sistema a ser analisado e com N_i ($1 \leq i \leq M$) dados de degradação do sistema i . Sendo $Z(t_{i,j})$ como o j -ésimo dado de degradação do i -ésimo sistema no tempo $t_{i,j}$, com $1 \leq j \leq N_i$, a Equação (2.1) pode ser representada como:

$$Z(t_{i,j}) = z_{i,0} + \alpha_0 \int_0^{t_{i,j}} \mu(\tau; \beta) d\tau + \sigma_B B(t_{i,j}) \quad (2.10)$$

onde α_0 é a informação *a priori* de α com $\pi(\alpha_0) \sim N(\mu_{\alpha,0}, \sigma_{\alpha,0}^2)$, e $Z_{i,0}$ é a degradação inicial do i -ésimo sistema e igual à 0, como definido em 2.1.1. Assumindo também, que os dados de degradação entre os sistemas diferentes são estatisticamente independentes, porém para M sistemas similares, os dados são estatisticamente dependentes, caracterizados por uma matriz de covariância. De acordo com a Equação (2.1) e as propriedades do movimento Browniano, todos os dados de degradação do i -ésimo sistema, isto é, $Z_i = (Z_{i,1}, Z_{i,2}, \dots, Z_{i,N_i})'$, seguem uma distribuição Gaussiana multivariável com média e matriz de covariância apresentadas abaixo:

$$\mu_i = \mu_{\alpha,0} I_i \quad (2.11)$$

$$\Sigma_i = \sigma_{\alpha,0}^2 I_i I_i' + \sigma_B^2 K_i \quad (2.12)$$

onde:

$$I_i = \left(\int_0^{t_{i,1}} \mu(\tau; \beta) d\tau, \int_0^{t_{i,2}} \mu(\tau; \beta) d\tau, \dots, \int_0^{t_{i,N_i}} \mu(\tau; \beta) d\tau \right)' \quad (2.13)$$

$$K_i = \begin{bmatrix} t_{i,1} & t_{i,1} & \cdots & t_{i,1} \\ t_{i,1} & t_{i,2} & \cdots & t_{i,2} \\ \vdots & \vdots & \ddots & \vdots \\ t_{i,1} & t_{i,2} & \cdots & t_{i,N_i} \end{bmatrix} \quad (2.14)$$

Como o logaritmo da função de verossimilhança apresenta o mesmo máximo que a função de verossimilhança, ele é usado em alguns casos, pois em geral é mais fácil de resolver a derivada do logaritmo (FOGLIATTO; RIBEIRO, 2009). Então, o logaritmo da função de verossimilhança para os dados de degradação dos M sistemas em função de $\Theta = (\mu_{\alpha,0}, \sigma_{\alpha,0}, \beta, \sigma_B)'$ é dado por:

$$l(\Theta|Z_{1:M}) = -\frac{1}{2}\ln(2\pi) \sum_{i=1}^M N_i - \frac{1}{2} \sum_{i=1}^M \ln|\Sigma_i| - \frac{1}{2} \sum_{i=1}^M (Z_i - \mu_i)' \Sigma_i^{-1} (Z_i - \mu_i) \quad (2.15)$$

onde $Z_{1:M} = (Z_1, Z_2, \dots, Z_M)$ representa todo o histórico de degradação dos M sistemas similares. Utilizando a derivada parcial da Equação (2.15) com relação aos parâmetros Θ , obtêm-se os parâmetros ótimos.

2.1.5 Atualização do parâmetro estocástico

Com os parâmetros *a priori* obtidos, a distribuição do parâmetro estocástico α pode ser atualizada a cada vez que um novo dado de MC x_k , no tempo t_k , do sistema/equipamento de interesse for observado. O parâmetro estocástico pode ser atualizado no tempo t_k utilizando a Inferência Bayesiana levando em consideração todas as observações $x_{1:k} = (x_1, x_2, \dots, x_k)$, onde $x_{1:k}$ representa todos os dados de MC no intervalo de tempo de t_1 até t_k .

A distribuição *posteriori* de α , condicionada à observação $x_{1:k}$, seguindo a regra Bayesiana é apresentada na Equação (2.16):

$$p(\alpha|x_{1:k}) \propto p(x_{1:k}|\alpha)\pi(\alpha_0) \quad (2.16)$$

onde $p(x_{1:k}|\alpha)$ representa a função de verossimilhança da distribuição *posteriori* de α , e a distribuição *a priori* $\pi(\alpha_0)$ é obtida através do método da EMV apresentado em 2.1.4. Por meio das propriedades do movimento Browniano e da Equação (2.1), $p(x_{1:k}|\alpha)$ pode ser formulada como:

$$p(x_{1:k}|\alpha) = \frac{1}{\prod_{q=1}^k \sqrt{2\pi\sigma_B^2(t_q - t_{q-1})}} \exp \left\{ - \sum_{q=1}^k \frac{\left[x_q - x_{q-1} - \alpha \int_{t_{q-1}}^{t_q} \mu(\tau; \beta) d\tau \right]^2}{2\sigma_B^2(t_q - t_{q-1})} \right\}, \quad (2.17)$$

sendo a degradação inicial x_0 e o tempo inicial t_0 iguais a zero.

Como $p(x_{1:k}|\alpha)$ e $\pi(\alpha_0)$ são distribuições Gaussianas, $p(\alpha|x_{1:k})$ também é uma distribuição Gaussiana, sendo possível obter a média e a variância de $p(\alpha|x_{1:k})$ se baseando nas equações (2.16) e (2.17).

$$\mu_{\alpha,k} = \frac{(C+D)}{(A+B)} \quad (2.18)$$

$$\sigma_{\alpha,k}^2 = \frac{1}{(A+B)} \quad (2.19)$$

$$A = \sum_{q=1}^k \left[\frac{\left(\int_{t_{q-1}}^{t_q} \mu(\tau; \beta) d\tau \right)^2}{\sigma_B^2 (t_q - t_{q-1})} \right] \quad (2.20)$$

$$B = \frac{1}{\sigma_{\alpha,0}^2} \quad (2.21)$$

$$C = \frac{\mu_{\alpha,0}}{\sigma_{\alpha,0}^2} \quad (2.22)$$

$$D = \sum_{q=1}^k \left\{ \frac{\left[(X_q - X_{q-1}) \int_{t_{q-1}}^{t_q} \mu(\tau; \beta) d\tau \right]}{\sigma_B^2 (t_q - t_{q-1})} \right\} \quad (2.23)$$

Por fim, com os parâmetros ótimos encontrados pelo método da EMV e pela Inferência Bayesiana, é possível calcular a FDP da VUR obtida na Equação (2.8) cada vez que um novo dado de degradação for observado. A Figura 2.2 ilustra a importância de estimar o efeito estocástico em processos.




Figura 2.2: Dados de degradação de baterias de íons de Lítio (adaptado de WANG et al. (2014)).

A Figura 2.2 apresenta 4 baterias de íons de Lítio que funcionam à temperatura ambiente (NASA, 2019; WANG et al., 2014). À medida de capacitância de baterias pode ser utilizada para medir a degradação do equipamento ao longo dos ciclos de carga-descarga, o tempo de vida útil da bateria é definido como o número de ciclos de operação em que a capacitância é maior que 1,4 Ah (WANG et al., 2014). Na Figura 2.2 as baterias B06 e B18 possuem um comportamento próximo da linearidade, enquanto as baterias B05 e B07 possuem um comportamento exponencial, isto salienta a importância de estimar o efeito estocástico no processo e a natureza probabilística.

2.2 Séries Temporais

Séries Temporais são definidas como observações sucessivas ao longo do tempo e possuem aplicações que englobam áreas da engenharia, economia e finanças, previsão tempo, entre outras. Esta metodologia consiste em prever valores futuros de um

processo se baseando em valores passados, explorando a dependência entre as sucessivas observações, autocorrelação e autocorrelação parcial, ao longo do tempo. Utilizar séries temporais se torna vantajoso em casos que o conjunto de dados observados apresentam mudanças estruturais constantes, isto é, quando os componentes internos de uma série temporal possuem variabilidade constante (BOX; JENKINS; REINSEL, 2008; TAY, 2017).

Em geral, uma série temporal é decomposta da seguinte forma:

$$x_t = Te_t + Sa_t + C_t + E_t \quad (2.24)$$

onde Te_t é a tendência da série temporal, Sa_t a sazonalidade, C_t o componente cíclico, semelhante à sazonalidade, porém menos frequente, e E_t é o termo que representa as variações inesperadas, também conhecido como resíduo, que deve possuir um comportamento similar ao ruído branco com média 0 (PAL; PRAKASH, 2017; TAY, 2017).

A tendência se faz presente em uma série temporal, quando há movimento de acréscimo ou decréscimo do valor de uma função ao longo do tempo. A maneira mais simples de verificar a presença de tendência em uma série temporal é através da análise visual do gráfico da variável observada ao longo do tempo, porém em uma base de dados pequena, os efeitos da sazonalidade e de variações inesperadas podem ocultar a característica de tendência da série temporal (PAL; PRAKASH, 2017). A Figura 2.3 ilustra tal comportamento, onde duas bases de dados de Concentração de CO₂ ao longo dos anos de 1974 a 1987 são apresentadas.




Figura 2.3: a) Concentração de CO₂ de 1974 a 1987; b) Concentração de CO₂ entre 1980 e 1981 (adaptado de PAL; PRAKASH (2017)).

A Figura 2.3(a) apresenta a concentração de CO₂ entre os anos de 1974 até 1987, é possível constatar a tendência de aumento de concentração com o passar dos anos, em contrapartida, a Figura 2.3(b) representa a concentração de CO₂ durante alguns meses, entre 1980 e 1981, com esta base menor de dados, não é possível afirmar que exista tendência de aumento de concentração de gás carbônico com o passar dos anos, apesar do comportamento cíclico.

Uma regressão no tempo, ou outra variável em que a série se propaga, como o ciclo para processos cíclicos, pode ser usada para ajustar a tendência de uma série temporal. Esta regressão tem aplicação na previsão de valores futuros, em que havendo resíduos, a série temporal deve ser melhor analisada, indicando a presença de componentes de sazonalidade, comportamento cíclico e variações irregulares (PAL; PRAKASH, 2017).

A componente de sazonalidade está presente na série temporal quando a mesma apresenta movimentos periódicos repetitivos, sendo modelados como ondas senoidais de período conhecido m . Pela autocorrelação é possível conhecer o tamanho do período m , pois séries sazonais apresentam alta autocorrelação em *lags* múltiplos do período m , sendo um dos objetivos da análise de séries temporais, procurar periodicidade relevante nos dados (MORETTIN; TOLOI, 2006). Na Figura 2.3, a concentração de CO₂ apresenta tanto tendência como sazonalidade. A seguir são apresentados cinco métodos para modelagem da série temporal que consideram as componentes de tendência e sazonalidade. Primeiro será apresentado o conceito de Estacionariedade, após será apresentado um método simples que é o Método da Suavização Exponencial Simples, seguido do Método da Suavização Exponencial Dupla e o modelo ARIMA que capturam a característica da tendência e, por fim, o Método da Suavização Exponencial Tripla e o modelo SARIMA, que englobam tanto a tendência da série temporal quanto a componente sazonal (MORETTIN; TOLOI, 2006).

2.2.1 Estacionariedade

No ajuste de séries temporais, uma das considerações mais importantes é a de que ela possui a característica estacionária, se desenvolvendo no tempo aleatoriamente ao redor de uma média constante, ou seja, apresentando um equilíbrio. Porém, na prática a grande parte das séries temporais apresentam não-estacionariedade de alguma forma, apresentando tendência linear nos casos mais simples, ou comportamento exponencial em casos mais complexos (MORETTIN; TOLOI, 2006). A Figura 2.4 apresenta uma série em que há mudança de nível e a presença de tendência, sendo então uma série não-estacionária quanto ao nível e a inclinação.




Figura 2.4: Série não-estacionária quanto ao nível e a inclinação (adaptado de MORETTIN; TOLOI (2006)).

Para modelos de ajuste de séries temporais que consideram as mesmas estacionárias, é preciso transformar os dados originais em estacionários. Um destes procedimentos pode ser visto no Modelo ARIMA, discutido na seção 2.2.4 deste trabalho.

Algumas ferramentas são utilizadas para identificar se um processo é estacionário ou não, entre eles está a função de autocorrelação, que representa a dependência linear de uma série temporal, indicando a correlação da série com ela mesma, defasada em h instantes de tempo, isto é, representa a dependência linear da série no tempo t e no tempo $t-h$ ou $t+h$. A autocorrelação analisada em *lag* igual a 0 indica a autocorrelação da observação com ela mesma, por isto a autocorrelação neste *lag* é sempre igual a 1 (PAL; PRAKASH, 2017).

Autocorrelação parcial é semelhante, porém removendo a influência das variáveis intermediárias, por exemplo, a correlação no *lag* 3 é entre os valores em tempo igual a t e $t+3$, removendo os efeitos dos valores em $t+1$ e $t+2$ (TAY, 2017).

Outro método para identificar um processo estacionário é o teste *Augmented Dickey-Fuller* (ADF). O teste ADF assume que na presença de autocorrelação, a diferenciação de primeira ordem, x'_t de uma série temporal x_t , pode ser expressa como uma regressão linear de instantes de tempo anteriores e das diferenças de primeira ordem até uma defasagem de k instantes de tempo (PAL; PRAKASH, 2017).

$$x'_t = Ax_{t-1} + B_1x'_{t-1} + B_2x'_{t-2} + \dots + B_kx'_{t-k} + E_t \quad (2.25)$$

$$A = (-1 + \sum_{i=1}^k \phi_i) \quad (2.26)$$

onde ϕ_i são os coeficientes de auto-regressão do modelo, conforme será apresentado adiante.

Uma série não-estacionária apresenta uma raiz unitária na equação (2.26), e a hipótese nula é aceita. Caso contrário, a hipótese nula é rejeitada e a série é dita estacionária (PAL; PRAKASH, 2017).

2.2.2 Suavização Exponencial Simples

O método da Suavização Exponencial Simples (SES) se baseia na ponderação exponencial de valores da série temporal, com atribuição de pesos maiores aos dados mais recentes e menores aos dados mais antigos, sendo utilizado em cenários onde a série temporal apresenta variância constante e não apresenta sazonalidade (LIMA et al., 2015; PAL; PRAKASH, 2017). O modelo de Suavização Exponencial Simples pode ser formulado segundo a Equação (2.27):

$$x_{t+1} = a_s x_t + a_s(1 - a_s)x_{t-1} + a_s(1 - a_s)^2 x_{t-2} + \dots \quad (2.27)$$

onde a_s é a constante de suavização de nível e que varia de 0 a 1, quando o valor de a_s for mais próximo de 1, maior é o peso dado a valores mais recentes e menor a valores mais antigos. Se a_s for próximo de 0 maior é o peso dado a valores antigo e menor a valores recentes. A Equação (2.27) também pode ser escrita da seguinte forma:

$$F_1 = x_1 \quad (2.28)$$

$$F_2 = a_s x_1 + (1 - a_s) F_1 \quad (2.29)$$

$$F_t = a_s x_t + (1 - a_s) F_{t-1} \quad (2.30)$$

A Equação (2.30) é a forma geral para realizar previsões utilizando o método da Suavização Exponencial Simples, onde F_t representa o valor futuro e F_{t-1} representa o último valor predito.

A Suavização Exponencial Simples possui como vantagem um fácil entendimento e aplicação simples, porém não pode ser aplicada em uma série que apresente tendência (MORETTIN; TOLOI, 2006).

2.2.3 Suavização Exponencial Dupla

A Suavização Exponencial Dupla (SED), também conhecida como método de Holt, tem o objetivo de resolver a desvantagem da Suavização Exponencial Simples na impossibilidade de modelar séries que apresentam tendência. Para isso, o método de Holt adiciona uma segunda constante de suavização responsável por ajustar a tendência da série (MORETTIN; TOLOI, 2006; PAL; PRAKASH, 2017). A Equação (2.31) apresenta a soma do nível F_t com a tendência T_t para previsão do valor futuro da série temporal.

$$x_{t+h} = F_t + hT_t \quad (2.31)$$

$$F_t = a_s x_t + (1 - a_s)(F_{t-1} + T_{t-1}) \quad (2.32)$$

$$T_t = b_s(F_t - F_{t-1}) + (1 - b_s) T_{t-1} \quad (2.33)$$

onde b_s é o fator de suavização de tendência, F_t e T_t é o nível estimado e a tendência estimada, respectivamente, para a série no tempo t , F_{t-1} e T_{t-1} representam os últimos valores preditos de nível e tendência, respectivamente e x_{t+h} na Equação (2.31) representa o valor futuro da série em $t+h$.

As vantagens são semelhantes ao modelo da Suavização Exponencial Simples, porém a desvantagem é a complexidade em determinar as constantes a_s e b_s (MORETTIN; TOLOI, 2006).

2.2.4 Modelo ARIMA

Os modelos ARIMA (*Auto-Regressive Integrated Moving Average*) são modelos auto-regressores que incluem termos auto-regressivos de ordem p e termos de média móvel de ordem q , além de um termo integrador de ordem d que tem como função converter a série em estacionária. A classe dos modelos ARIMA é eficiente em ajustar séries estacionárias de maneira satisfatória e séries não-estacionárias, desde que estas não apresentem comportamento muito oscilatório (MORETTIN; TOLOI, 2006; PAL; PRAKASH, 2017).

Um modelo auto-regressivo é uma abordagem em que a regressão é realizada através da defasagem, *lag*, da série temporal. A notação deste modelo é definida como AR(p), onde p é a ordem do modelo auto-regressivo, sendo descrito pela seguinte Equação (PARMEZAN; SOUZA; BATISTA, 2019):

$$x_t = \delta + \sum_{i=1}^p \phi_i x_{t-i} + E_t \quad (2.34)$$

No modelo apresentado na Equação (2.34), E_t representa o erro medido no tempo t , ϕ_i é o coeficiente auto-regressor e δ representa a interceptação média do modelo.

Os modelos com média móvel se concentram na dependência entre erros residuais para prever valores futuros. São modelos indicados para ajustar eventos imprevisíveis, como eventos catastróficos que podem alterar o comportamento padrão da série temporal (PAL; PRAKASH, 2017). Um modelo MA de ordem q , é descrito pela seguinte Equação:

$$x_t = \delta + \sum_{i=1}^q \theta_i E_{t-i} + E_t \quad (2.35)$$

Na Equação (2.35), θ_i é o coeficiente de média móvel e δ representa a interceptação média.

Os modelos ARIMA incorporam estas características auto-regressivas e de média móvel, assim como os modelos ARMA (*Auto-Regressive Moving Average*), com a diferença de incluir um componente de integração que tem como objetivo converter a série em estacionária. Este componente tem o objetivo de diferenciar a série, o número de vezes necessário, para diminuir o caráter não estacionário da mesma (HYNDMAN; ATHANASOPOULOS, 2018). Os valores de integração d , se comportam da seguinte maneira:

$$d = 0 : x_t = x_t \quad (2.36)$$

$$d = 1 : x_t = x_t - x_{t-1} \quad (2.37)$$

$$d = 2 : x_t = (x_t - x_{t-1}) - (x_{t-1} - x_{t-2}) = x_t - 2x_{t-1} + x_{t-2} \quad (2.38)$$

Com base nas Equações e definições anteriormente, um modelo ARIMA (p, d, q) de ordem auto-regressiva p , de integração d e média móvel de ordem q é representado da seguinte forma:

$$\Delta_d x_t = \delta + \sum_{i=1}^p \Delta_d \phi_i x_{t-i} + \sum_{i=1}^q \theta_i E_{t-i} + E_t \quad (2.39)$$

A Equação (2.39) apresenta a união dos termos auto-regressivos e de média móvel, juntamente com o termo integrador Δ_d para tornar a parte auto-regressiva da série, estacionária.

2.2.5 Suavização Exponencial Tripla

A Suavização Exponencial Tripla (SET), também conhecida como Método de Holt-Winters, adiciona a componente de sazonalidade na Equação (2.31), permitindo incorporar o componente sazonal com o nível e a tendência. Para tanto, existem dois procedimentos: multiplicativo e aditivo (LIMA et al., 2015; PARMEZAN; SOUZA; BATISTA, 2019).

O modelo multiplicativo possui variação da amplitude do ciclo sazonal de forma multiplicativa, enquanto a tendência permanece aditiva e é representado pelas seguintes equações e a componente da tendência é ajustada pela Equação (2.33) (MORETTIN; TOLOI, 2006):

$$F_t = a_s \frac{x_t}{S_{t-m}} + (1 - a_s)(F_{t-1} + T_{t-1}) \quad (2.40)$$

$$S_t = \gamma_s \frac{x_t}{F_t} + (1 - \gamma_s)S_{t-m} \quad (2.41)$$

$$x_{t+h} = (F_t + hT_t)S_{t-m+h} \quad (2.42)$$

onde F_t é a componente de nível, T_t é a componente de tendência, S_t a componente de sazonalidade da série, x_{t+h} é o valor futuro em $t+h$, a_s é a constante de suavização para estimativa de nível variando entre 0 e 1, b_s é a constante de suavização para estimativa de tendência variando entre 0 e 1, γ_s é a constante de suavização para estimativa da sazonalidade também variando entre 0 e 1, x_t é o valor observado em tempo igual a t e m é o tamanho do período sazonal. As Equações (2.40), (2.33) e (2.41) estimam o nível, tendência e sazonalidade, respectivamente, no tempo atual da análise.

O modelo sazonal aditivo é utilizado quando a amplitude sazonal permanece constante ao longo do tempo (LIMA et al., 2015; PARMEZAN; SOUZA; BATISTA, 2019). As seguintes equações descrevem a Suavização Exponencial Tripla aditiva, sendo a componente de tendência ajustada pela Equação (2.33):

$$F_t = a_s(x_t - S_{t-m}) + (1 - a_s)(F_{t-1} + T_{t-1}) \quad (2.43)$$

$$S_t = \gamma_s(x_t - F_t) + (1 - \gamma_s)S_{t-m} \quad (2.44)$$

$$x_{t+h} = F_t + hT_t + S_{t-m+h} \quad (2.45)$$

As vantagens e desvantagens da Suavização Exponencial Tripla são semelhantes as da Suavização Exponencial Dupla, com a diferença que o método de Holt-Winters é adequado para à análise de séries com padrão de comportamento mais geral, porém se torna um pouco mais complexo pois se adiciona a componente de sazonalidade no modelo (MORETTIN; TOLOI, 2006).

2.2.6 Modelo SARIMA

Os modelos SARIMA são uma variação dos modelos ARIMA considerando um componente sazonal para a parte auto-regressiva, para a média móvel e para a diferenciação, tendo o objetivo de realizar previsões em séries que apresentam a componente sazonal (HYNDMAN; ATHANASOPOULOS, 2018). A equação (2.46) representa um modelo SARIMA $(p, d, q)(P, D, Q)_m$, onde P representa a ordem da auto-regressão sazonal, D representa a ordem da diferenciação sazonal, Q a ordem da média móvel e m o tamanho do período sazonal, é apresentada a seguir (PARMEZAN; SOUZA; BATISTA, 2019):

$$\Delta_D \Delta_d x_t = \delta + \sum_{i=1}^p \Delta_d \phi_i x_{t-i} + \sum_{i=1}^p \Delta_D \hat{\phi}_{im} x_{t-im} + \sum_{i=1}^q \theta_i E_{t-i} + \sum_{i=1}^Q \hat{\theta}_{im} E_{t-im} + E_t \quad (2.46)$$

Na Equação (2.46) foram adicionados coeficientes auto-regressores e de média móvel relacionados à componente sazonal, além da parte integradora, também relacionada ao efeito da sazonalidade de período m .

Capítulo 3 – Revisão Bibliográfica

Neste capítulo é realizado um levantamento bibliográfico dos principais temas utilizados para desenvolvimento deste trabalho. O capítulo está dividido em 3 subseções. Primeiramente, será abordado de forma geral e cronológica os desenvolvimentos para estimar o tempo de Vida Útil Remanescente de um equipamento e sua distribuição de probabilidade. Após é realizado um levantamento sobre Processos Cíclicos, onde são abordados temas como o cálculo do Número de Ciclos Remanescentes em Processos Cíclicos e a dinâmica envolvida nestes processos. Por último, são apresentadas algumas aplicações para Séries Temporais, mostrando a abrangência desta metodologia.

3.1 Tempo de Vida Útil Remanescente

GEBRAEEL et al. (2005) desenvolveram métodos Bayesianos que utilizam dados de MC em tempo real para atualizar o parâmetro estocástico de modelos de degradação exponenciais, utilizando estes modelos para formular uma distribuição de VUR para o dispositivo monitorado. GEBRAEEL et al. (2005) ainda compararam o modelo de degradação utilizando erros multiplicativos aleatórios com o movimento Browniano para representar o ruído do sinal de degradação. Por fim, aplicaram estes modelos em testes de rolamentos. O modelo de degradação utilizando o movimento Browniano se mostrou superior ao modelo com erros multiplicativos aleatórios.

SIKORSKA; HODKIEWICZ; MA (2011) abordam os problemas que devem ser considerados na seleção de um modelo apropriado para aplicar a metodologia “*Prognostic and Health Management*” (PHM). Também apresenta tabelas e diagramas de processo para auxiliar empresas e pesquisadores a selecionar o melhor modelo de prognóstico para prever a VUR de dispositivos de engenharia dentro da sua área específica. SIKORSKA; HODKIEWICZ; MA (2011) exploram os pontos positivos e negativos dos princípios modelos de PHM para tornar claro e compreensível os modelos que se ajustam melhor que outras para certas aplicações e sintetiza como cada um tem sido aplicado na engenharia.

SI et al. (2011) desenvolvem uma revisão centrada em métodos baseados em dados estatísticos para estimar a Vida Útil Remanescente, que dependem apenas de dados do passado observados e modelos estatísticos. A abordagem desta revisão é classificada em dois grupos gerais de modelos, os que dependem de informações de estado diretamente observadas e aqueles que não dependem.

SI et al. (2012) apresentam um modelo não-linear para estimar a VUR de um sistema se baseando no sinal de degradação que está sendo monitorado, e utilizando um modelo de degradação baseado no Processo de Wiener com um coeficiente não linear e com um limite aceitável de degradação constante. Para estimar a VUR, foi feita uma aproximação analítica da distribuição do PTP do processo de degradação cruzando o limite aceitável através de uma transformação de tempo-espaco sob uma suposição simples. Para estimar os parâmetros desconhecidos do modelo, SI et al. (2012) utilizou o método da Estimativa por Máxima Verossimilhança (EMV). Os resultados encontrados salientam a importância de considerar a não-linearidade em um processo de degradação.

SI et al. (2013) desenvolvem uma abordagem para estimativa da VUR combinando a atualização Bayesiana e o algoritmo de maximização de expectativa. O uso desta combinação se justifica na atualização dos parâmetros do modelo de degradação baseado no Processo de Wiener e da distribuição da VUR no tempo de análise. Dois casos específicos são considerados por SI et al. (2013): modelo de degradação linear e um modelo de degradação exponencial. Por fim são apresentados exemplos numéricos e um caso de estudo prático para ilustrar a abordagem da estimativa da VUR combinando a Inferência Bayesiana com o algoritmo de maximização de expectativa.

HU et al. (2018) propõem um novo modelo de degradação e de estimação da VUR considerando a influência de atividades de manutenção imperfeitas, tanto no nível de degradação quanto na taxa de degradação. Primeiramente é construído um modelo de degradação que considera estas atividades de manutenção imperfeitas, após é obtida a FDP da VUR sob o conceito do PTP. Para aplicar o modelo desenvolvido, são utilizados os métodos da EMV e da Inferência Bayesiana. Os resultados mostram que o método pode melhorar a estimativa da VUR em sistemas sujeitos a atividades de manutenção imperfeitas.

WANG; HU; FAN (2018) apresentam um novo método *online* para a predição da VUR através de um modelo não-linear geral de degradação baseado no Processo de Wiener com parâmetros determinísticos e estocásticos. Se baseando em dados históricos de equipamentos similares, os parâmetros determinísticos e os hiperparâmetros da distribuição *a priori* do parâmetro estocástico são estimados pela EMV, enquanto o parâmetro estocástico é atualizado pela Inferência Bayesiana a cada novo dado de MC, fazendo com que a estimativa da Vida Útil Remanescente dependa do monitoramento em tempo real da degradação do sistema em análise. Resultados mostram que estimar a VUR *online* melhora a precisão da previsão, em comparação com métodos que estimam a VUR *off-line*, isto é, sem atualizar o efeito estocástico a cada novo dado de MC.

3.2 Processos Cíclicos

DAIGLE; GOEBEL (2011) desenvolveram uma metodologia de prognósticos baseada em modelo geral dentro de uma estrutura probabilística robusta usando filtro de partículas. Como caso de estudo, DAIGLE; GOEBEL (2011) utilizaram uma válvula pneumática e um modelo baseado na dinâmica dos ciclos de abertura e fechamento desta válvula. Por fim, realizaram simulações abrangentes para ilustrar a dinâmica das falhas possíveis nos ciclos de abertura e fechamento de uma válvula pneumática, avaliando a eficácia e robustez do modelo desenvolvido.

WANG et al. (2014) aplicam a metodologia PHM em baterias de íon Lítio avaliando a degradação das mesmas por meio dos ciclos de operação utilizando um modelo baseado no Processo de Wiener com erro de medição. O método da EMV é utilizado para obter os parâmetros necessários e a combinação da atualização Bayesiana com o algoritmo de maximização de expectativa é feita para prever em tempo real a VUR, ou como é um processo cíclico de carga-descarga, prever em tempo real o NCR. Resultados comprovam a precisão do modelo desenvolvido.

SI (2015) utilizou o modelo de degradação baseado no Processo de Wiener para estimar a VUR em dados de bateria. Um modelo utilizando Filtro de Kalman e EMV foi aplicado para estimar a Vida Útil Remanescente de baterias a partir da avaliação de ciclos de carga-descarga. Através dos resultados obtidos por SI (2015) é possível constatar a precisão do método na estimativa dos ciclos remanescentes de operação destas baterias.

NASTAJ; AMBROZEK (2015) apresentam uma análise teórica da secagem por adsorção de misturas gasosas, contendo vapor de água e compostos orgânicos voláteis, em um sistema TSA cíclico. O sistema é constituído por duas colunas de leito fixo que contém, cada uma, três camadas de diferentes adsorventes. As primeiras duas camadas consistem de sílica gel e o zeólita como adsorventes do vapor de água, e a terceira camada consiste de carvão ativado para adsorver o componente orgânico. Um modelo foi desenvolvido para simular o desempenho da unidade TSA de desidratação.

SANTOS et al. (2017) avalia o impacto do teor de dióxido de carbono do gás natural no desempenho do ponto de orvalho da água através da adsorção de água em leitos de peneiras moleculares. Simulações do ciclo de adsorção variando pressão e teor de dióxido de carbono no gás natural, indicam que, embora a etapa de adsorção atenda à especificação de remoção de água em uma operação livre de condensação, a alta fugacidade do dióxido de carbono interfere no desempenho da desidratação.

ALEGHAFOURI; DAVOUDI (2018) modelaram um processo de *Pressure-Temperature Swing Adsorption* (PTSA) em um sistema de adsorção de duas camadas durante uma operação cíclica para remoção de água do gás natural. As influências dos parâmetros do processo foram avaliadas através da análise paramétrica de eficiência do processo. Visando a economia de energia, foram propostas algumas sugestões para atualizar o processo sem efeitos significantes no desempenho da purificação.

3.3 Séries Temporais

TAY (2017) demonstra uma nova opção para o uso de séries temporais com um caso de estudo de metáforas usadas em sessões de psicoterapias. Um esboço de como as

características de uma série podem ser aplicadas à componentes de discurso é apresentado. Limitações da análise e futuras pesquisas são discutidas.

CORTADI et al. (2018) têm a finalidade de otimizar a produtividade e custos de processos para a fabricação de peças cilíndricas, para isso propõem uma metodologia que incorpora a modelagem do comportamento normal do processo e a previsão. A previsão é realizada utilizando um modelo ARIMA e mostram que etapas de pré-processamento de dados são necessárias para que se obtenha a maior precisão na previsão de valores futuros para este processo.

SINGH DOORGA et al (2019) desenvolve uma ferramenta de previsão utilizando a Suavização Exponencial Dupla. O desempenho do modelo desenvolvido é melhor quando comparado com a precisão alcançada por vários outros modelos empregados na literatura. Por fim, a ferramenta desenvolvida é empregada no fornecimento de energia e instalações de gerenciamento de rede.

HENRIQUE; SOBREIRO; KIMURA (2019) propõe técnicas que são aplicadas na literatura sobre Aprendizado de Máquina para previsão de valores de mercado financeiro, resultando numa revisão bibliográfica dos mais importantes estudos sobre este assunto. Os modelos mais comuns para predição envolvem *Support Vector Machines (SVM)* e redes neurais.

PARMEZAN; SOUZA; BATISTA (2019) apresenta uma avaliação experimental extensa, imparcial e compreensiva, de 95 conjuntos de dados. PARMEZAN; SOUZA; BATISTA (2019) relata lições aprendidas e recomendações sobre as vantagens e desvantagens e as melhores condições para o uso de cada modelo, sendo o modelo SARIMA o único método estatístico capaz de superar, porém sem uma diferença estatística, alguns algoritmos de Aprendizado de Máquina.

ORDÓÑEZ et al. (2019) propõem um algoritmo que combina métodos de séries temporais para previsão de valores de uma determinada variável utilizando técnicas de aprendizado de máquina. Primeiro utiliza um modelo ARIMA para prever os valores desta variável e após um modelo SVM prevê a VUR. Resultados comprovam a eficiência do algoritmo desenvolvido.

Capítulo 4 – Metodologia

Neste capítulo é descrita a metodologia proposta para determinar a Vida Útil Remanescente em Processos Cíclicos. Para isto, são propostas duas técnicas, a primeira baseada na Inferência Bayesiana, em que o efeito estocástico é atualizado a cada novo dado de degradação do sistema a ser analisado, e a segunda fundamentado em Séries Temporais. Para ambas, alguns procedimentos devem ser realizados antes de aplicar as duas metodologias, visando aumentar sua acurácia:

1. Definição da variável crítica para a degradação do sistema em análise baseado no conhecimento e sobre a importância de cada variável no processo. Em baterias, a medida da capacitância é crítica para determinar a vida útil, em uma válvula pneumática o tempo de abertura da válvula é importante, pois se a válvula demorar para abrir pode indicar um vazamento;
2. Remoção dos *outliers*, que são pontos atípicos ou inconsistentes, do sistema a ser analisado para que não haja resultados discrepantes e que a análise não seja prejudicada. Neste trabalho, os *outliers* são substituídos pelo valor médio da variável ao longo do ciclo;
3. Em processos cíclicos, realizar a separação e empacotamento dos ciclos de forma que todos os ciclos tenham o mesmo tempo inicial para que seja possível analisar o Número de Ciclos Remanescentes. Este empacotamento pode ser realizado utilizando informações do Processo, como por exemplo quando uma válvula é aberta indica o início de um ciclo e quando esta válvula se fecha significa o final do ciclo, ou também, através do método das derivadas, em que a mudança do sinal da derivada informa a duração do ciclo;
4. Definição do limite aceitável que a variável crítica para o desempenho do equipamento pode alcançar baseado em conhecimentos específicos e manuais de equipamentos.

A Figura 4.1 a) apresenta a variação de pressão em um ciclo de adsorção-regeneração em um processo de desidratação do gás natural, com início em $t=0$ e com a presença de *outliers*, enquanto que a Figura 4.1 b) ilustra a mesma variação de pressão, porém com os *outliers* removidos. A seguir são apresentados os passos para aplicar a metodologia Bayesiana e a metodologia baseada em Séries Temporais.




Figura 4.1: Variação de pressão em um ciclo de adsorção-regeneração: a) com a presença de *outliers*; b) sem *outlier*.

4.1 Metodologia Bayesiana

A metodologia Bayesiana é, essencialmente, dividida em duas fases: *off-line* e *online* sendo o algoritmo, baseado na metodologia de WANG; HU; FAN (2018), desenvolvido em *Python* e detalhado no Apêndice C. Os passos para a aplicação desta metodologia são apresentados a seguir:

1. Fase *off-line*: estimação dos hiperparâmetros da distribuição *a priori* do parâmetro estocástico α e dos parâmetros determinísticos baseados nos dados históricos de degradação de M sistemas similares ao analisado maximizando a Equação (2.15). Nesta etapa se define a parcela responsável pela não-linearidade que ajustará o modelo de degradação do sistema segundo a Equação (2.1);
2. Fase *online*: atualização de $\mu_{\alpha,k}$ e $\sigma_{\alpha,k}$ cada vez que um novo dado de degradação x_k do sistema de interesse através das Equações (2.18) e (2.19), respectivamente;
3. Fase *online*: previsão da VUR, ou NCR para processos cíclicos, do sistema de interesse no tempo t_k utilizando a Equação (2.8) substituindo os parâmetros estimados no passo 1 e atualizados no passo 2;
4. Voltar para o passo 2 a cada novo dado de degradação do sistema de interesse obtido, ou seja, x_{k+1} no tempo t_{k+1} , e repetir os passos acima.

A Figura 4.2 esquematiza as etapas para aplicar a metodologia Bayesiana na estimativa da VUR de um equipamento.

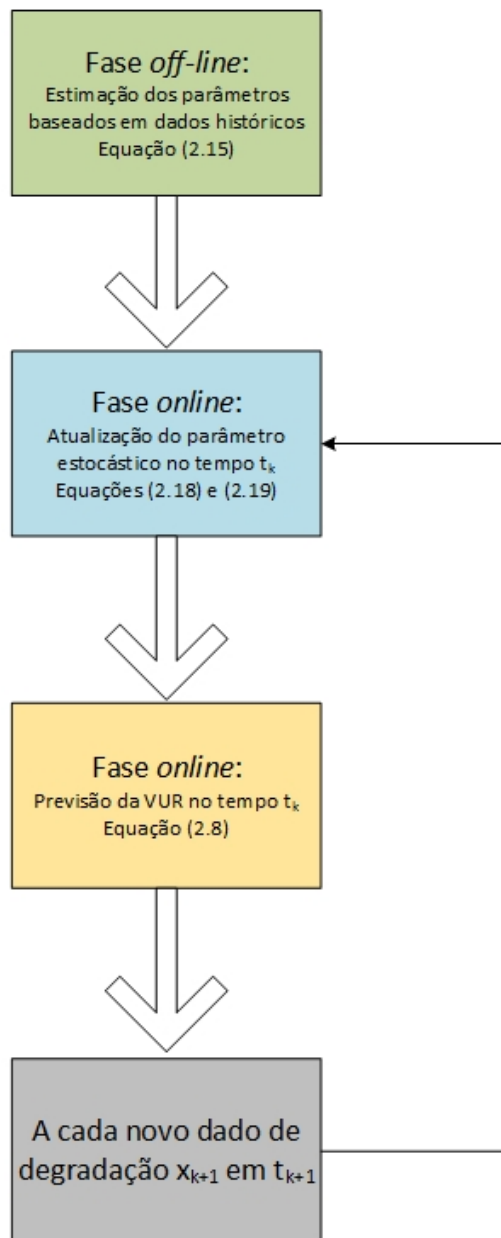


Figura 4.2: Etapas para a aplicação da metodologia Bayesiana na estimativa da VUR (adaptado de WANG; HU; FAN (2018)).

4.2 Séries Temporais

As etapas para utilização das Séries Temporais para estimativa da Vida Útil Remanescente de um equipamento são descritas abaixo. O algoritmo desenvolvido em *Python* é apresentado no Apêndice D.

1. A primeira etapa consiste em visualizar a série temporal, no caso deste trabalho a degradação do sistema de interesse ao longo dos ciclos em processos cíclicos, e identificar os componentes internos (tendência, sazonalidade, componente cíclico). Estes componentes podem ser determinados através da função de autocorrelação;
2. Após identificados os componentes internos da série temporal, deve-se determinar se a série é estacionária ou não. Para isso, se aplica o teste ADF

- apresentado em 2.2.1. Estas duas etapas iniciais são importantes para a definição dos modelos de Séries Temporais que serão utilizados na previsão de valores futuros;
3. Separar os dados em conjuntos de treino e teste. A base de treino é utilizada no ajuste dos modelos apresentados na seção 2.2, enquanto a base de teste tem a responsabilidade de verificar se a predição obteve bons resultados;
 4. Verificar a precisão do modelo ajustado com o conjunto de teste. A comparação entre o modelo ajustado e o conjunto de teste é realizada através de métricas de precisão, como por exemplo a Raiz do Erro Médio Quadrático (REMQ). Quanto menor for o valor da REMQ, melhor é a qualidade do modelo ajustado. Outra forma de verificar a precisão do modelo ajustado é avaliar os resíduos entre este modelo e a base de teste, onde resíduos mais próximos de zero indicam a qualidade do ajuste.

A Figura 4.3 sintetiza as etapas para utilizar Séries Temporais na previsão da VUR.




Figura 4.3: Etapas para a aplicação de Séries Temporais na estimativa da VUR

Para encontrar os parâmetros ótimos de nível, tendência e sazonalidade, dos modelos de Suavização Exponencial Simples, Dupla e Tripla, a REMQ pode ser utilizada (SINGH, 2018). O modelo que produzir a menor REMQ, em comparação com o conjunto de teste, possuirá os parâmetros ótimos dos métodos de Suavização Exponencial. A Equação da REMQ é dada por:

$$REMQ = \left[\frac{\sum_{i=1}^N (x_{pi} - x_{oi})^2}{N} \right]^{\frac{1}{2}} \quad (4.1)$$

onde N é o tamanho da amostra, x_p é o valor previsto e x_o é o valor observado.

Para definir a ordem dos modelos ARIMA e SARIMA, é interessante utilizar dois critérios: o critério de AIC (*Akaike Information Criterion*) e o critério de BIC (*Bayesian Information Criterion*). O critério AIC é uma estimativa de uma constante mais a distância relativa entre a função de verossimilhança desconhecida dos dados e a função de verossimilhança ajustada do modelo, ou seja, um AIC mais baixo, representa um modelo mais próximo da realidade. O critério BIC consiste em uma função da probabilidade *posteriori* de um modelo ser verdadeiro, de forma que, assim como o critério AIC, um BIC baixo, significa um modelo mais próximo da realidade (CENTER; WU, 2019). Os critérios AIC e BIC são calculados através das seguintes equações:

$$AIC = -2 \log(L) + 2q \quad (4.2)$$

$$BIC = -2 \log(L) + q \log(n) \quad (4.3)$$

$$L = p(x_o | \Gamma, M) \quad (4.4)$$

onde L é o valor que maximiza a verossimilhança para o modelo M , Γ são os parâmetros que maximizam a função de verossimilhança, q é o número de parâmetros a serem estimados e n é o número de dados observados. Os termos $2q$ e $q \cdot \log(n)$ penalizam um modelo com um grande número de parâmetros, mostrando que a diferença entre estes dois critérios é a penalidade (WU, 2019). EMILIANO (2009) aborda de forma mais profunda os critérios AIC e BIC.

A precisão dos ajustes utilizando tanto os modelos SES, SED e SET como os modelos ARIMA e SARIMA, é determinada utilizando a REMQ, enquanto que os critérios AIC e BIC tem a finalidade apenas de determinar a ordem dos modelos ARIMA e SARIMA.

Capítulo 5 – Estudo de Caso

Este capítulo apresenta o Estudo de Caso utilizando neste trabalho. Este estudo versa sobre uma unidade TSA de desidratação em uma plataforma off-shore na produção de Gás Natural (GN) e o objetivo é avaliar a forma operacional e determinar o Número de Ciclos Remanescentes que a unidade poderá operar de modo a maximizar a produção e garantir a segurança operacional.

Em um primeiro momento é definido o conceito de Processo TSA apontando as suas vantagens e desvantagens e o seu mecanismo. A seguir, é introduzida a unidade TSA de desidratação para produção do gás natural, apresentando a sua estrutura e a sua importância. Por fim, são listadas as medições disponíveis da unidade para determinação da vida útil remanescente e a forma de operação da planta.

5.1 Processo TSA

O processo *Temperature Swing Adsorption* (TSA) é largamente utilizado para separação de misturas por adsorção. Nele, a etapa de adsorção ocorre a temperatura ambiente e após, o adsorvente é regenerado através do processo de dessorção, também chamado de regeneração, a altas temperaturas (FONSECA, 2011). A Figura 5.1 apresenta um exemplo de perfil de temperatura em um processo TSA em que é possível perceber a temperatura ambiente constante na etapa de adsorção e após, o aumento da temperatura para o início da etapa de dessorção. É importante salientar que o próximo ciclo de adsorção só começará após o leito resfriar para a temperatura ambiente.

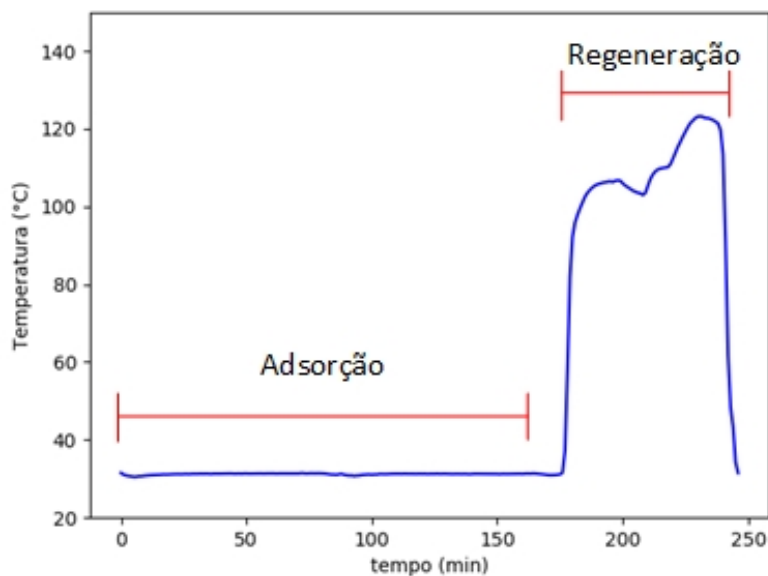


Figura 5.1: Exemplo de perfil de temperatura em um processo TSA.

Como no processo TSA, o leito precisa aquecer para a etapa de regeneração, e esfriar para a etapa de adsorção, o tempo de operação de um ciclo adsorção-regeneração em um processo TSA costuma ser maior que em um processo PSA, porque neste último a adsorção ocorre apenas através da mudança de pressão, sendo altas pressões referentes a etapa de adsorção e baixas pressões a etapa de dessorção não necessitando do tempo de resfriamento do leito para iniciar a etapa de adsorção. O método TSA é utilizado quando os componentes de uma mistura são fortemente adsorvidos enquanto que o PSA para casos em que os componentes da mistura são adsorvidos fracamente e o produto necessita de um elevado grau de pureza (FONSECA, 2011; SANTOS et al., 2017).

A configuração utilizada em um processo TSA se constitui de no mínimo dois leitos fixos em paralelo, operando em ciclos e, enquanto uma coluna adsorve à temperatura ambiente a outra dessorve a altas temperaturas (NASTAJ; AMBROZEK, 2015; SANTOS et al., 2017). Como o tempo de vida de um leito fixo utilizado para remover a espécie indesejada da mistura é expressado em ciclos, determinar o tempo ótimo das etapas de adsorção e regeneração em um ciclo de adsorção-regeneração é importante para prolongar a vida útil dos leitos em um processo TSA. O término das etapas de adsorção e regeneração de maneira precipitada ou atrasada provoca uma diminuição na vida útil do leito fixo utilizado. Como exemplo, em ciclos rápidos o método TSA não é indicado, pois não será utilizada a capacidade máxima do adsorvente (ALEGHAFOURI; DAVOUDI, 2018; FONSECA, 2011).

5.2 Unidade TSA para Desidratação

Na produção do GN, um dos componentes indesejáveis na composição do GN é a água, pois, além causar corrosão, provoca a formação de hidratos que causam o entupimento da tubulação do poço. Dentre os métodos utilizados para remoção de água do GN, está a desidratação por adsorção com peneiras moleculares, pela necessidade de remoção de água à concentração máxima de aproximadamente 1 ppm, utilizando o método TSA (NASTAJ; AMBROZEK, 2015; SANTOS et al., 2017). A unidade TSA utilizada para desidratação do GN estudada neste trabalho é composta por 3 leitos fixos, cada um consiste de 3 etapas: adsorção, regeneração e resfriamento do leito. Sendo que o tempo

de resfriamento do leito é considerado como tempo de regeneração. A Figura 5.2 apresenta a unidade TSA para desidratação do GN com 3 colunas de desidratação utilizando peneiras moleculares como adsorventes.

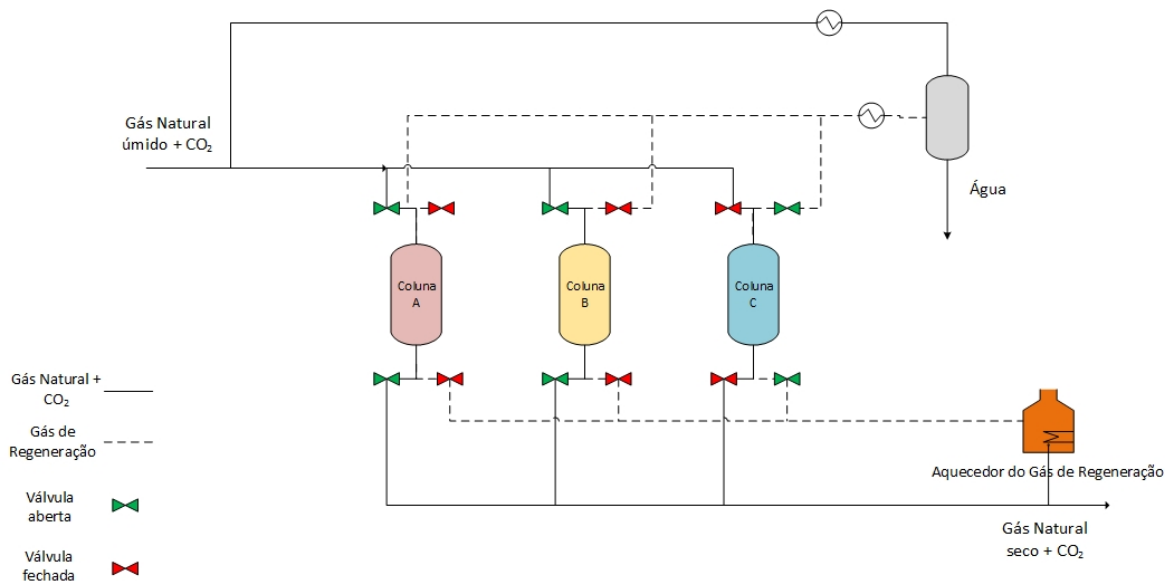


Figura 5.2: Unidade TSA para desidratação do GN com 3 colunas utilizando peneiras moleculares como adsorventes.

A Figura 5.2 apresenta o fluxograma da unidade TSA que será utilizada neste trabalho.

O GN+CO₂ úmido entra em duas colunas para realizar a adsorção da água pelas peneiras moleculares do leito, tendo como o produto de fundo o GN+CO₂ seco e uma parte deste produto é utilizada como gás de regeneração. Este gás de regeneração entra na coluna em que a etapa de dessorção está acontecendo para regenerar o adsorvente saindo no topo do leito, após passa por um aquecedor para separar a água retirada do adsorvente e então passa por um trocador de calor para resfriar a temperatura da corrente de gás de regeneração à temperatura ambiente, voltando como reciclo na corrente de gás natural. Enquanto uma coluna está no início da etapa de adsorção, outra está na metade desta mesma etapa e a terceira está em regeneração. Após, esta coluna que estava em regeneração passa para o início da etapa de adsorção, em seguida a coluna que estava no início da etapa de adsorção passa agora a estar na metade desta etapa, e por fim, o leito que estava na metade da etapa de adsorção, agora se encontra na etapa de regeneração. Na Figura 5.2 a linha contínua indica o caminho do GN, enquanto a linha tracejada representa o caminho do gás de regeneração. Ainda na Figura 5.2, se percebe que as Colunas A e B estão na etapa de Adsorção, enquanto a Coluna C está na etapa de regeneração. Isto é indicado no processo através da medição de queda de pressão nos leitos: pressões mais altas apontam a etapa de adsorção e pressões baixas a de regeneração e isto se explica pela diferença de vazão entre as duas etapas, da medição de temperatura, temperatura ambiente representa a etapa de adsorção e altas temperaturas a de dessorção, e também, analisando as válvulas do fluxograma, neste caso as válvulas das Colunas A e B estão abertas para a passagem do gás natural e as válvulas da Coluna C para a passagem do gás de regeneração.

5.3 Medições Disponíveis

O Estudo de Caso do presente trabalho, apresentado no item 5.2, possui as seguintes medições disponíveis: vazão total de gás natural úmido (não há medida individual por leito), variação de pressão dos três leitos fixos, temperatura dos três leitos fixos. Neste trabalho se utilizará como variável crítica para avaliação da vida útil de cada coluna de desidratação o fator de resistência ao escoamento para cada coluna, definida por:

$$R_i = \frac{\sqrt{\Delta P_i}}{F_i} \quad (5.1)$$

onde R_i , ΔP_i e F_i são o fator de resistência ao escoamento considerando um escoamento turbulento, a variação de pressão e a vazão de gás (GN+CO₂), respectivamente, da coluna i da unidade TSA em estudo, em que $1 \leq i \leq 3$, ρ é a massa específica do gás natural. A escolha do fator de resistência ao escoamento como variável crítica na determinação da vida útil de cada coluna se dá partindo do princípio de que o aumento da queda de pressão ao longo dos ciclos é determinante na degradação do leito fixo.

Como no presente Estudo de Caso não foi possível obter os dados de vazão individual de gás natural para cada coluna, ou as informações de aberturas de válvulas para converter a vazão total de gás em vazão individual para cada leito, na definição de fator de resistência ao escoamento foi considerada, por uma questão de simplificação, a vazão total de gás, F assim como a massa específica do gás foi desconsiderada, como apresentado a seguir:

$$R_i = \frac{\sqrt{\Delta P_i}}{F} \quad (5.2)$$

5.4 Forma de Operação

A Unidade TSA estudada está presente numa plataforma *off-shore* e tem como principal função separar o óleo do gás e da água durante o processo de operação. A plataforma tem capacidade para processar cerca de 150 mil barris de óleo por dia e 6 milhões de metros cúbicos de gás natural por dia. Justamente para manter a alta produção, com segurança operacional, se justifica o estudo da VUR (SIKORSKA; HODKIEWICZ; MA, 2011).

O processo de desidratação por adsorção utilizando peneiras moleculares opera com tempos fixos para as etapas de adsorção e regeneração, o que ocasiona uma degradação dos leitos de forma mais rápida, conforme visto no item 5.1 e por esta forma de operação os leitos possuem vida útil reduzida.

Este trabalho não tem o objetivo de otimizar o tempo de cada etapa, mas sim analisar o processo e determinar o NCR das colunas de desidratação. Esta determinação possibilita a tomada de decisões futuras, sendo uma delas, a otimização do processo.

Capítulo 6 – Resultados e Discussões

Neste Capítulo são apresentados os Resultados do Estudo de Caso de uma Unidade TSA de desidratação para produção de gás natural. Em um primeiro momento, são simuladas curvas de degradação para introduzir o mecanismo da metodologia Bayesiana na previsão da VUR utilizando o modelo de degradação baseado no Processo de Wiener, conforme a Equação (2.1). Estes dados são simulados em função do tempo com o objetivo de mostrar que para processos cíclicos e processos temporais, o procedimento na abordagem Bayesiana é o mesmo. Em seguida os resultados preliminares do Estudo de Caso são apresentados, seguidos da metodologia Bayesiana e suas discussões e por fim as Séries Temporais.

6.1 Dados Simulados

Como a metodologia Bayesiana proposta por WANG; HU; FAN (2018) é recente, foram simuladas cinco curvas de degradação utilizando a Equação (2.1) de forma não linear para ilustrar o método de predição da VUR, sendo que para estas simulações a parcela responsável pela não-linearidade do modelo foi definida como, $\mu(\tau;\beta) = \beta e^{\beta\tau}$. Esta função exponencial foi utilizada devido à sua ampla aplicação na teoria e na prática (SI et al., 2012; WANG; HU; FAN, 2018). As curvas de números 1, 2, 3 e 4 foram utilizadas para a determinação dos parâmetros determinísticos e hiperparâmetros de α , sendo a informação *a priori*, e a curva restante, no caso, a curva de número 5, foi utilizada para análise da metodologia. Cada conjunto de dados possui o mesmo passo de discretização, $dt = 0,1$, e valor inicial nulo, isto é $X(0) = 0$. A Figura 6.1 apresenta todas as curvas simuladas e estas simulações podem representar a medição da vibração de um rolamento ou a temperatura da parede de um forno, em que se for muito alta, pode indicar erosão do ferro fundido na parede, ou também, para o Estudo de Caso proposto, pode representar o aumento do fator de Resistência ao escoamento ao longo do tempo, em outras palavras, estas curvas simuladas representam uma variável importante para o desempenho do equipamento e o limite em que essa variável pode alcançar está ilustrado em preto na Figura 6.1.




Figura 6.1: Curvas de degradação simuladas.

A Figura 6.1 apresenta 5 sistemas idênticos operando com uma variável crítica que possui um limite aceitável de $X_f = 3,7778$. Para a curva utilizada como teste, este limite foi alcançado em $t_k = 10$, então o tempo de vida T para este sistema genérico é igual a 10.

Para o ajuste aos dados simulados, foi considerado $\mu(\tau; \beta) = \beta\tau^{\beta-1}$, por poder representar casos lineares, porque $\int \beta\tau^{\beta-1} d\tau = \tau^\beta$, ou seja, para $\beta = 1$, o modelo se ajusta a curva de degradação linear (WANG; HU; FAN, 2018). Como as curvas são simuladas, não há necessidade de remover *outliers* e como o exemplo simulado não é de um processo cíclico não há necessidade de realizar empacotamento dos ciclos. Após, foi utilizado o método da EMV para estimar os parâmetros, baseados nas informações *a priori*. O otimizador utilizado foi o algoritmo em *Python*, *Differential Evolution* do pacote *SciPy*. Este algoritmo é um otimizador estocástico que utiliza limites inferiores e superiores dos parâmetros a serem estimados. Os parâmetros foram obtidos após aproximadamente 1332 iterações e estão representados na Tabela 6.1.

Tabela 6.1: Parâmetros estimados pelo método da EMV

$\mu_{\alpha,0}$	$\sigma_{\alpha,0}^2$	β	σ_β^2
0,1679	0,000125	1,3935	0,1200

Importante salientar, na Tabela 6.1, que o valor de $\beta = 1,3935$ é coerente com os dados, devido ao comportamento não linear das curvas de degradação simuladas. Foi realizado o monitoramento do sistema a partir de $t_k = 1$ para avaliar a precisão da metodologia. Os dados de MC foram colhidos a cada 0,5 unidades de tempo, começando em $t_k = 1$ até $t_k = 9,5$. A Figura 6.2 apresenta as FDP para ponto t_k avaliado.




Figura 6.2: FDPs previstas para VUR da curva simulada de número 5.

Na Figura 6.2, o eixo “ t_k ” representa em que instante de tempo está sendo coletado o dado de MC, o eixo “VUR” apresenta os instantes de tempo em que as FDPs serão calculadas para definir a Vida Útil Remanescente do sistema que está sendo analisado, e por fim, o eixo “FDP” é calculado através da Equação (2.8). Observando a Figura 6.2, percebe-se que as FDPs calculadas para a VUR em cada ponto de MC analisado conseguem se aproximar da realidade, visto que à medida que o eixo “ t_k ” se aproxima de 10, o eixo “VUR” se aproxima de 0. Isto é evidenciado, calculando o valor esperado das FDPs, VUR média, em cada ponto de MC analisado utilizando a Equação (2.9). A Figura 6.3 apresenta o valor médio da VUR para os tempos t_k analisados.




Figura 6.3: Valores previstos de VUR em cada ponto de MC analisado.

A Figura 6.3 ilustra que a metodologia Bayesiana desenvolvida por WANG; HU; FAN (2018) é um método promissor, pois os valores previstos e o valor real da VUR são próximos, tendo, principalmente após $t_k = 5$, uma previsão semelhante ao valor real. Para

verificar a confiabilidade do método Bayesiano, foram calculados a REMQ, definido na Equação (4.1), e o Erro Médio Absoluto (EMA), definido na equação abaixo:

$$EMA = \sum_{i=1}^N \left| \frac{x_{pi} - x_{oi}}{N} \right| \quad (6.1)$$

Onde N é o tamanho da amostra, x_p é o valor previsto e x_o é o valor observado. Os valores de REMQ e EMA para a previsão da VUR utilizando a metodologia Bayesiana para estes dados simulados são apresentados na Tabela 6.2

Tabela 6.2: Valores de REMQ e EMA para a previsão da VUR dos dados simulados

REMQ	EMA
0,6433	0,5107

6.2 Previsão do NCR da Unidade TSA de Desidratação

Como dito no item 5.3, uma variável crítica a ser considerada na Unidade TSA de Desidratação para prever o NCR é o fator de resistência ao escoamento. Como no presente Estudo de Caso não se pode utilizar a vazão individual de gás natural em cada leito, uma vez que se dispunha apenas da vazão total, o que foi responsável pelo surgimento de *outliers*, decorrentes da etapa de chaveamento de leitos, pois quando uma coluna sai da etapa de dessorção, a tendência é que inicialmente boa parte da vazão total de gás natural vá para esta coluna para dar início à etapa de adsorção. Para resolver esse problema seria necessário que se fizesse a utilização de um modelo dinâmico, o qual estimaria a distribuição das vazões nos leitos ao longo da operação e principalmente na etapa inicial. Nesse caso se utilizaria o modelo de base fenomenológica e um estimador de estados (p.ex., Filtro de Kalman Estendido). Essa abordagem, embora promissora, está fora do escopo do presente trabalho, ficando como sugestão para trabalhos futuros.

Para o cálculo do fator de resistência foi utilizada a Equação (5.2) e para a previsão da VUR foi analisada a etapa de adsorção da Unidade TSA que ocorre a temperatura ambiente constante, então a massa específica do gás natural foi desprezada. As Figuras 6.4, 6.5 e 6.6 apresentam o fator de resistência ao escoamento das Colunas A, B e C ao longo do tempo. Os dados de ΔP de cada coluna estão em Pascal (Pa) e a vazão total de gás natural, F , em m^3/h , além disto, o fator de Resistência ao Escoamento foi multiplicado por 10^7 para facilitar a aplicação das metodologias.




Figura 6.4: Fator de Resistência ao Escoamento da Coluna A.




Figura 6.5: Fator de Resistência ao Escoamento da Coluna B.




Figura 6.6: Fator de Resistência ao Escoamento da Coluna C.

Observando as Figuras 6.4, 6.5 e 6.6 se nota a dificuldade que seria analisar a degradação do processo em função do tempo. A Figura 6.7 apresenta o padrão cíclico do fator de resistência ao escoamento, sendo este em função da vazão total de gás natural.

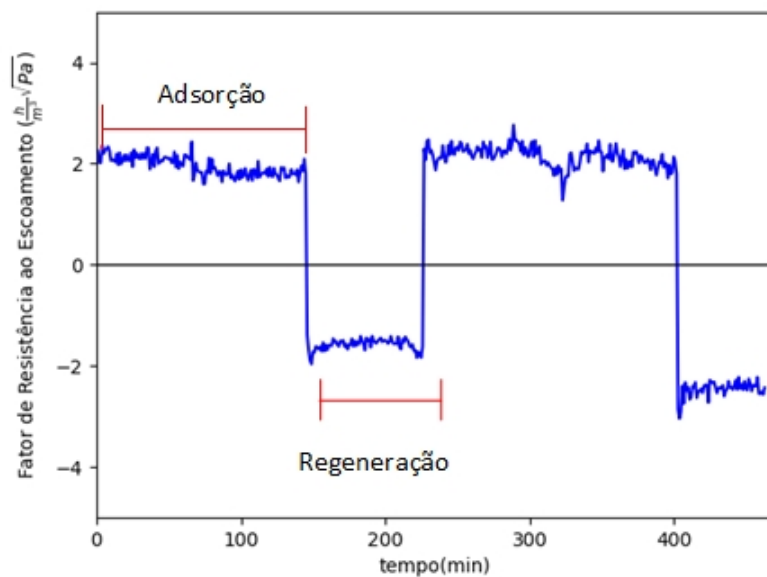


Figura 6.7: Padrão cíclico do fator de resistência ao escoamento.

Para separar os ciclos de adsorção-regeneração, ou apenas as etapas de adsorção e regeneração poderia ser utilizada a informação de válvula aberta e fechada, conforme ilustrado na Figura 5.2 em que seria possível saber se está entrando na coluna a corrente de gás natural ou de gás de regeneração. Porém neste Estudo de Caso não se conseguiu os dados de abertura de válvulas, então uma boa opção para separar os ciclos foi se utilizar uma função do ΔP do leito, mais precisamente a derivada do fator de resistência. Quando o sinal da derivada for positivo, indica o início da etapa de adsorção e quando for negativo, o início da etapa de regeneração, o ciclo completo de adsorção-regeneração é identificado no intervalo entre duas derivadas positivas. A Figura 6.8 representa o método de separação de ciclos utilizando a derivada.




Figura 6.8: Separação dos ciclos utilizando a derivada do fator de resistência.

Tendo o início de cada ciclo sido identificado, é possível realizar o empacotamento dos ciclos de operação do processo trazendo todos os ciclos para o mesmo tempo inicial, facilitando a análise para determinar o NCR. As Figuras 6.9, 6.10 e 6.11 apresentam o fator de resistência ao escoamento das 3 colunas de desidratação da unidade TSA em função do ciclo e do tempo de duração de cada ciclo.




Figura 6.9: Ciclos de adsorção-regeneração da Coluna A.




Figura 6.10: Ciclos de adsorção-regeneração da Coluna B.




Figura 6.11: Ciclos de adsorção-regeneração da Coluna C.

A partir deste empacotamento dos ciclos, se pode determinar o NCR utilizando a metodologia Bayesiana e as Séries Temporais e apenas a etapa de adsorção foi analisada. O limite aceitável que este fator de Resistência ao Escoamento pode chegar na etapa de adsorção foi definido como sendo $X_f = 8 \text{ h/m}^3\text{Pa}^{1/2}$ e este valor foi arbitrado, uma vez que o valor industrial não foi informado. A Figura 6.12 apresenta os ciclos e o tempo de duração de cada um deles para as 3 colunas de desidratação. Fica evidente nesta Figura que a operação se dá por um tempo fixo dos ciclos de adsorção-regeneração, aproximadamente 250 minutos, isto quer dizer que não necessariamente há um aproveitamento completo das peneiras moleculares e, conforme dito no item 5.1, isto influencia na vida útil dos leitos.

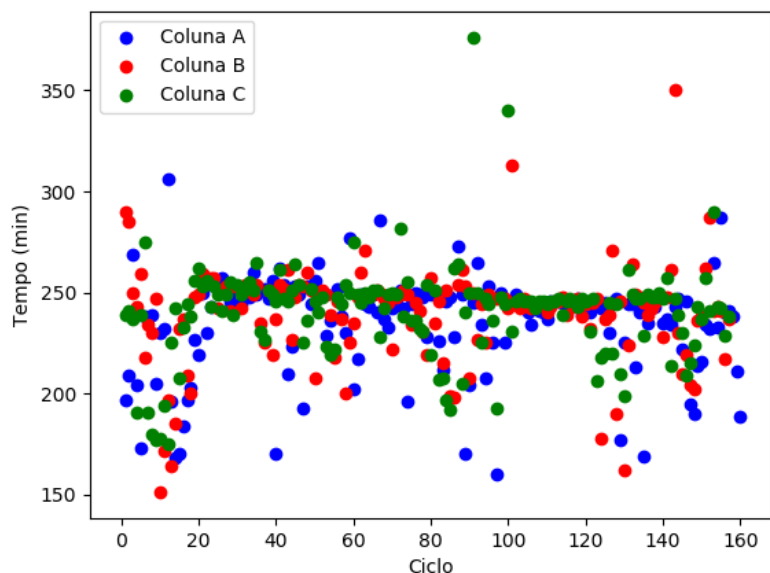


Figura 6.12: Tempo de duração dos ciclos de adsorção-regeneração para as 3 colunas da unidade TSA de desidratação.

Para as 3 colunas foram avaliados 3 instantes de tempo de cada ciclo de adsorção, considerando a porcentagem do ciclo. Estes instantes foram de 30%, 50% e 75% do ciclo de adsorção, sendo que como os dados do fator de resistência oscilam, por ele ser em função da vazão total e do diferencial de pressão, para cada instante analisado foi considerado o valor médio entre um limite inferior, isto é, a porcentagem de ciclo menos 5% e um limite superior, porcentagem de ciclo mais 5%. Por exemplo, para a análise em 30% do ciclo de adsorção, foi calculado o valor médio entre 25% e 35% de cada ciclo de adsorção para as 3 colunas da unidade TSA de desidratação. As Figuras 6.13, 6.14 e 6.15 apresentam o fator de resistência ao escoamento em função dos ciclos de operação dos leitos.




Figura 6.13: Fator de resistência ao escoamento em função do ciclo em 30% da etapa de adsorção.




Figura 6.14: Fator de resistência ao escoamento em função do ciclo em 50% da etapa de adsorção.




Figura 6.15: Fator de resistência ao escoamento em função do ciclo em 75% da etapa de adsorção.

A base de dados das 3 colunas possui em média 160 ciclos, isto equivale a 26 dias de operação da Unidade TSA. Neste período a Coluna A apresentou um comportamento diferente das outras duas colunas, por isto ela será selecionada para avaliar os métodos propostos para a estimativa do NCR.

6.2.1 Metodologia Bayesiana

A informação *a priori* da degradação da Coluna A foi definido como sendo o fator de Resistência das Colunas B e C em 30% da etapa de adsorção, não sendo necessário encontrar parâmetros ótimos para cada instante do ciclo, pois a informação *a priori* tem o objetivo de fornecer uma estimativa inicial de como um leito para processos cíclicos similares se comporta, enquanto que a Inferência Bayesiana tem a finalidade de particularizar cada caso de degradação atualizando o efeito estocástico no processo. Assim como nos dados simulados, a parcela responsável pela não-linearidade da

degradação foi escolhida como sendo $\int \beta t^{\beta-1} dt = t^\beta$, pelos mesmos motivos citados anteriormente. A Tabela 6.3 mostra os parâmetros otimizados com método da EMV utilizando o algoritmo *Differential Evolution* com aproximadamente 1005 iterações.

Tabela 6.3: Parâmetros estimados para informação *a priori* da degradação da Coluna A

$\mu_{\alpha,0}$	$\sigma_{\alpha,0}^2$	β	σ_β^2
0,1533	0,0001	0,8055	0,030

O valor de β apresentado na Tabela 6.3 é coerente, pois como a função utilizada na modelagem da característica não-linear da degradação é uma função exponencial, o valor de β deve ser pequeno para que seja possível um leito ter uma longa vida útil.

O monitoramento do processo foi realizado a partir do ciclo de número 100, sendo colhidos os dados e calculados as FDPs para todos os ciclos a partir deste ciclo inicial. As Figuras 6.16, 6.17 e 6.18 apresentam as FDPs para os instantes de tempo de 30%, 50% e 75% da etapa de adsorção de cada ciclo da Coluna A.




Figura 6.16: FDPs previstas para o NCR da Coluna A em 30% da etapa de adsorção.




Figura 6.17: FDPs previstas para o NCR da Coluna A em 50% da etapa de adsorção.




Figura 6.18: FDPs previstas para o NCR da Coluna A em 75% da etapa de adsorção.

Se percebe através das Figuras 6.16, 6.17 e 6.18 que as FDPs previstas para cada caso são próximas, isto se deve ao comportamento praticamente constante do fator de resistência ao longo do ciclo de adsorção e, o baixo valor das FDPs calculadas em cada ciclo indica que o equipamento está distante do fim da sua vida útil. O NCR médio para os casos estudados é apresentado a seguir nas Figuras 6.19, 6.20 e 6.21, e assim como as Figuras acima, possuem um comportamento semelhante, indicando quantos ciclos a Coluna A poderia operar até atingir o limite X_f suposto.




Figura 6.19: Valores previstos de NCR em cada ciclo de MC analisado em 30% da etapa de adsorção.




Figura 6.20: Valores previstos de NCR em cada ciclo de MC analisado em 50% da etapa de adsorção.

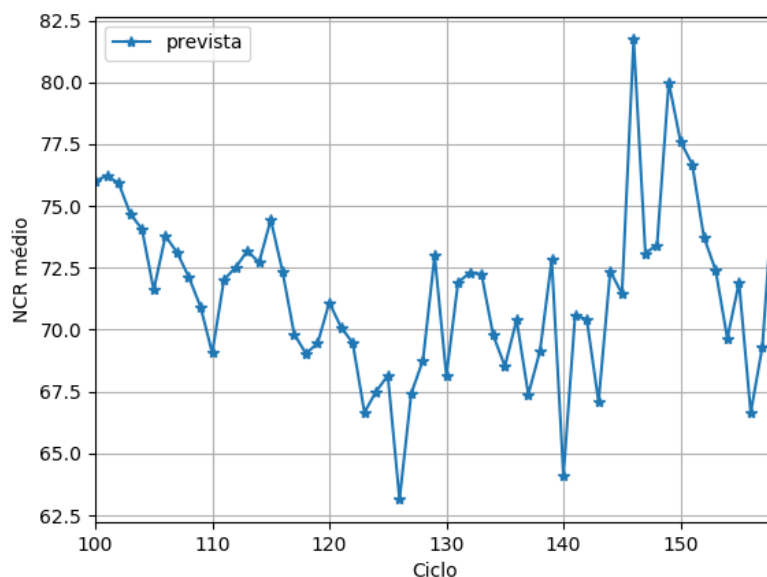


Figura 6.21: Valores previstos de NCR em cada ciclo de MC analisado em 75% da etapa de adsorção.

Os valores de NCR previstos apresentados nas Figuras acima são semelhantes em cada caso estudado, porém possuem oscilações na previsão, principalmente a partir do ciclo de número 140, isto se deve a possivelmente alguma alteração na operação da unidade TSA e, portanto, indica que a abordagem Bayesiana necessitaria de uma base de dados maior para estimar os dados *a priori*, não sendo suficiente os 26 dias de operação em que os dados foram coletados.

6.2.2 Séries Temporais

A abordagem por Séries Temporais na determinação do NCR é um pouco diferente da metodologia Bayesiana. Enquanto esta última retorna quantos ciclos de operação faltam para a degradação alcançar o limite aceitável X_i , as Séries Temporais tentam ajustar um modelo que se aproxime da degradação ao longo dos ciclos, desta forma ajudando na tomada de decisões.

Nos casos abordados, que são: 30%, 50% e 75% da Etapa de Adsorção, o componente interno da série presente é apenas a tendência. A separação entre conjunto de Treino e conjunto de Teste para estes casos é retratada nas Figuras 6.22, 6.23 e 6.24. Foram considerados 100 ciclos da Coluna A para conjunto de Treino, em que o modelo de Série Temporal se baseará para ser ajustado, e os ciclos restantes da mesma coluna foram utilizados para Teste para avaliar o modelo de Série Temporal obtido.




Figura 6.22: Separação do conjunto de Treino e Teste da Coluna A para 30% da etapa de adsorção.




Figura 6.23: Separação do conjunto de Treino e Teste da Coluna A para 50% da etapa de adsorção.




Figura 6.24: Separação do conjunto de Treino e Teste da Coluna A para 75% da etapa de adsorção.

As Figuras 6.25, 6.26 e 6.27 representam a autocorrelação (ACF) e autocorrelação parcial (PACF) entre as porcentagens de tempo estudadas. Analisando estas Figuras, se conclui que os dados são fortemente autocorrelacionados até o *lag* 12 e parcialmente autocorrelacionados até o *lag* 4. Ainda, a autocorrelação não indicou a presença de sazonalidade.

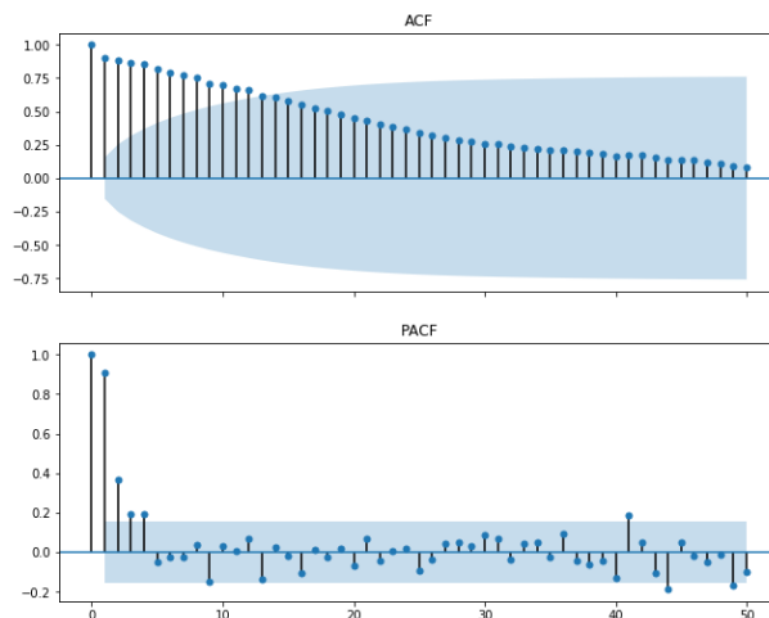


Figura 6.25: ACF e PACF para 30% da etapa de adsorção.




Figura 6.26: ACF e PACF para 50% da etapa de adsorção.




Figura 6.27: ACF e PACF para 75% da etapa de adsorção.

A Tabela 6.4 mostra os valores do Teste ADF para as três porcentagens de tempo avaliadas, juntamente com os valores críticos de significância, com o objetivo de determinar a estacionariedade da série. Quanto mais negativo for o valor do Teste ADF, maior a possibilidade de se rejeitar a hipótese nula do teste, então a série é dita estacionária (BROWNLEE, 2016).

Tabela 6.4: Teste ADF para os três casos estudados.

	30%	50%	75%
ADF	-2,403	-2,471	-2,077
1%	-3,501	-3,501	-3,501
5%	-2,892	-2,892	-2,892
10%	-2,583	-2,583	-2,583

Os valores do Teste ADF para os três casos são negativos, indicando que os dados de fator de resistência são estacionários, porém analisando a Tabela 6.4, se percebe que estes valores são maiores que os valores de 10% de significância, por isto, neste trabalho são considerados modelos estacionários de Séries Temporais (Suavização Exponencial Simples) e modelos não estacionários (Suavização Exponencial Dupla e ARIMA). Ainda, modelos com a componente interna de sazonalidade (Suavização Exponencial Tripla e SARIMA) também são utilizados, para verificar se é possível utilizar a sazonalidade para ajustar as oscilações no fator de resistência em determinada porcentagem de tempo dos ciclos.

6.2.2.1 Suavização Exponencial Simples

A constante de suavização a_s foi determinada variando este parâmetro de 0 a 1, utilizando a busca exaustiva, e calculando a REMQ do modelo ajustado com o conjunto de Teste através do algoritmo em *Python*, *SimpleExpSmoothing*, da biblioteca *statsmodels*. O modelo que possuir a menor REMQ possuirá a constante de suavização ótima. A Tabela 6.5 apresenta o parâmetro a_s para os casos estudados e a REMQ.

Tabela 6.5: Valores da constante de suavização e da REMQ para os casos estudados.

	30%	50%	75%
a_s	0,1	0,1	0,11
REMQ	0,3654	0,3929	0,3695

Os valores do parâmetro a_s que obtiveram o menor valor de REMQ são próximos para os três casos e, segundo o modelo de Suavização Exponencial, quanto mais próximo de zero o valor da constante de suavização, maior peso é dado aos valores antigos da série. As Figuras 6.28, 6.29 e 6.30 representam os conjuntos de Teste e Treino, os modelos ajustados para 30%, 50% e 75% da etapa de adsorção e o limite aceitável do fator de resistência ao escoamento que foi definido como sendo $X_f = 8 \text{ h/m}^3\text{Pa}^{1/2}$.




Figura 6.28: Conjuntos de Treino, Teste e modelo SES ajustado para 30% da etapa de adsorção.




Figura 6.29: Conjuntos de Treino, Teste e modelo SES ajustado para 50% da etapa de adsorção.




Figura 6.30: Conjuntos de Treino, Teste e modelo SES ajustado para 75% da etapa de adsorção.

Observando as Figuras acima, se percebe que mesmo os modelos ajustados possuindo um valor de REMQ baixo, o modelo SES não é adequado para determinar o NCR da Coluna A da Unidade TSA de desidratação, pois segundo o modelo, o fator de resistência permanecerá constante ao longo dos ciclos. Isto se dá pelo fato do SES considerar apenas um parâmetro de nível no ajuste, sendo então adequado para séries que são estacionárias. As Figuras 6.31, 6.32 e 6.33 mostram os resíduos, e sua distribuição, entre o modelo ajustado e o conjunto de Teste em nota-se que os resíduos estão distribuídos um pouco acima de zero e, como é de esperar que o valor do fator de resistência ao escoamento aumente com o passar dos ciclos, os resíduos também aumentarão.




Figura 6.31: a) Resíduos entre o modelo SES ajustado e o conjunto de Teste em 30% da etapa de adsorção; b) Distribuição dos Resíduos.




Figura 6.32: a) Resíduos entre o modelo SES ajustado e o conjunto de Teste em 50% da etapa de adsorção; b) Distribuição dos Resíduos.




Figura 6.33: a) Resíduos entre o modelo SES ajustado e o conjunto de Teste em 50% da etapa de adsorção; b) Distribuição dos Resíduos.

6.2.2.2 Suavização Exponencial Dupla

A constante de suavização de nível a_s , e a constante de tendência b_s foram determinadas da mesma forma que no método SES, através da busca exaustiva, desta vez utilizando o algoritmo em *Python*, *Holt*, também pertencente à biblioteca *statsmodels*. O modelo que possuir a menor REMQ possuirá as constantes de suavização ótimas. A Tabela 6.6 apresenta os parâmetros a_s e b_s para os casos estudados e o REMQ obtido.

Tabela 6.6: Valores das constantes de suavização e da REMQ para os casos estudados.

	30%	50%	75%
a_s	0,05	0,08	0,09
b_s	0,27	0,07	0,08
REMQ	0,1694	0,1713	0,1523

Os valores das constantes de suavização são próximos nos três, com exceção do parâmetro $b_s = 0,27$ em 30% da etapa de adsorção. Porém, todos os valores estão mais próximos de zero, o que quer dizer que os valores antigos são mais importantes no ajuste

do modelo. As Figuras 6.34, 6.35 e 6.36 apresentam os conjuntos de Teste e Treino, os modelos ajustados para 30%, 50% e 75% da etapa de adsorção e o limite aceitável do fator de resistência ao escoamento.




Figura 6.34: Conjuntos de Treino, Teste e modelo SED ajustado para 30% da etapa de adsorção.




Figura 6.35: Conjuntos de Treino, Teste e modelo SED ajustado para 50% da etapa de adsorção.




Figura 6.36: Conjuntos de Treino, Teste e modelo SED ajustado para 75% da etapa de adsorção.

As Figuras acima comprovam que os modelos SED se ajustaram bem para os casos estudados, produzindo um valor de REMQ baixo. Se a inclinação da tendência do fator de resistência permanecer constante, este modelo SED é uma boa opção para prever o NCR da Unidade TSA, porém se houver uma mudança abrupta na dinâmica do processo, possivelmente estes modelos não sejam adequados, pois consideram um aumento de tendência linear, enquanto a degradação em alguns processos costuma ser não-linear. As Figuras 6.37, 6.38 e 6.39 ilustram os resíduos e sua distribuição. Estas Figuras comprovam a eficácia do modelo, visto que a distribuição dos resíduos se dá em torno de zero.




Figura 6.37: a) Resíduos entre o modelo SED ajustado e o conjunto de Teste em 30% da etapa de adsorção; b) Distribuição dos Resíduos.




Figura 6.38: a) Resíduos entre o modelo SED ajustado e o conjunto de Teste em 50% da etapa de adsorção; b) Distribuição dos Resíduos.




Figura 6.39: a) Resíduos entre o modelo SED ajustado e o conjunto de Teste em 75% da etapa de adsorção; b) Distribuição dos Resíduos.

6.2.2.3 Modelo ARIMA

Na escolha da ordem dos modelos ARIMA a serem utilizados, recorreu-se aos critérios AIC e BIC. Para o instante de 30% da etapa de adsorção, os critérios AIC e BIC convergiram para a mesma ordem de modelo ARIMA, porém em 50% e 75% de adsorção não houve convergência, cada critério definiu uma ordem diferente, sendo escolhido o modelo ARIMA que melhor se ajustasse. Os modelos ARIMA para 50% e 75% de adsorção com menor qualidade na previsão são apresentados no Apêndice E. As Tabelas 6.7, 6.8 e 6.9 a seguir, mostram a ordem dos modelos ARIMA, os coeficientes do modelo, juntamente com os valores AIC, BIC e a REMQ.

Tabela 6.7: Modelo ARIMA (1, 0, 1) ajustado para 30% da etapa de adsorção.

Ordem	δ	ϕ_1	θ_1	AIC	BIC	REMQ
(1, 0, 1)	3,4183	0,9914	-0,2463	119,80	130,23	0,7275


Tabela 6.8: Modelo ARIMA (5, 0, 0) ajustado para 50% da etapa de adsorção.

Ordem	δ	ϕ_1	ϕ_2	ϕ_3	ϕ_4	ϕ_5	AIC	BIC	REMQ
(5, 0, 0)	3,3266	0,3763	0,1259	0,1478	-0,0108	0,3416	108,85	127,09	0,6843

Tabela 6.9: Modelo ARIMA (1, 0, 4) ajustado para 50% da etapa de adsorção.

Ordem	δ	ϕ_1	θ_1	θ_2	θ_3	θ_4	AIC	BIC	REMQ
(1, 0, 4)	3,3117	0,9866	-0,2988	0,0554	-0,3368	0,2135	37,92	56,15	0,7970

As Tabelas acima mostram que para cada instante de ciclo analisado, um modelo ARIMA diferente foi ajustado. Além disso, evidencia que para nenhum caso foi necessária a componente de integração do ARIMA, isso pode estar relacionado ao fato do Teste ADF ter indicado que o fator de resistência ao longo dos ciclos tem característica estacionária. As Figuras 6.40, 6.41 e 6.42 apresentam os conjuntos de Teste e Treino, os modelos ARIMA ajustados para os instantes de ciclo estudados e o limite aceitável do fator de resistência ao escoamento.

**Figura 6.40:** Conjuntos de Treino, Teste e modelo ARIMA ajustado para 30% da etapa de adsorção.




Figura 6.41: Conjuntos de Treino, Teste e modelo ARIMA ajustado para 50% da etapa de adsorção.




Figura 6.42: Conjuntos de Treino, Teste e modelo ARIMA ajustado para 75% da etapa de adsorção.

Observando as Figuras 6.40, 6.41 e 6.42, se conclui que o modelo ARIMA em nenhum caso se ajustou bem à degradação observada na Coluna A, não sendo recomendada a utilização dele na previsão do NCR. As Figuras 6.43, 6.44 e 6.45 que apresentam os resíduos e sua distribuição evidenciam esta conclusão, pois a distribuição destes resíduos se encontra distante de zero.




Figura 6.43: a) Resíduos entre o modelo ARIMA ajustado e o conjunto de Teste em 30% da etapa de adsorção; b) Distribuição dos Resíduos.




Figura 6.44: a) Resíduos entre o modelo ARIMA ajustado e o conjunto de Teste em 50% da etapa de adsorção; b) Distribuição dos Resíduos.




Figura 6.45: a) Resíduos entre o modelo ARIMA ajustado e o conjunto de Teste em 75% da etapa de adsorção; b) Distribuição dos Resíduos.

6.2.2.4 Suavização Exponencial Tripla

Diferente dos modelos SES e SED, as constantes de suavização de nível a_s , de tendência b_s e de sazonalidade γ_s foram determinadas automaticamente pelo algoritmo em *Python* da biblioteca *statsmodels*, *ExponentialSmoothing*. O tamanho do período m foi definido como sendo de 12 ciclos com o objetivo de verificar se a componente de sazonalidade consegue se ajustar às oscilações no fator de resistência e apenas o modelo sazonal aditivo foi considerado. A Tabela 6.10 apresenta a REMQ dos modelos SET e as

Figuras 6.46, 6.47 e 6.48 mostram os conjuntos de Teste e Treino, os modelos SET para os três casos abordados e o limite aceitável do fator de resistência.

Tabela 6.10: REMQ para os modelos SET

	30%	50%	75%
REMQ	0,5791	0,5617	0,4863




Figura 6.46: Conjuntos de Treino, Teste e modelo SET ajustado para 30% da etapa de adsorção.




Figura 6.47: Conjuntos de Treino, Teste e modelo SET ajustado para 50% da etapa de adsorção.




Figura 6.48: Conjuntos de Treino, Teste e modelo SET ajustado para 75% da etapa de adsorção.

Fica evidente ao analisar as Figuras acima, que os ajustes feitos pela SET não são adequados em determinar o NCR. A constante de sazonalidade adicionou uma oscilação sazonal no modelo, porém a componente de tendência não condiz com o que está sendo observado. Segundo os modelos SET, o fator de resistência alcançaria o limite X_f antes do que realmente está sendo observado. Esta falha na estimativa do NCR fica evidente ao analisar os resíduos e sua distribuição, presentes nas Figuras 6.49, 6.50 e 6.51, em que com o passar dos ciclos, o valor do resíduo aumenta, o que implica na distribuição residual longe de zero.




Figura 6.49: a) Resíduos entre o modelo SET ajustado e o conjunto de Teste em 30% da etapa de adsorção; b) Distribuição dos Resíduos.




Figura 6.50: a) Resíduos entre o modelo SET ajustado e o conjunto de Teste em 50% da etapa de adsorção; b) Distribuição dos Resíduos.




Figura 6.51: a) Resíduos entre o modelo SET ajustado e o conjunto de Teste em 75% da etapa de adsorção; b) Distribuição dos Resíduos.

6.2.2.5 Modelo SARIMA

Assim como no modelo ARIMA, para escolher a ordem dos SARIMA que serão aplicados, se utilizou os critérios AIC e BIC e conforme citado em 6.2.2.4, o tamanho do período m foi definido como sendo 12 ciclos. No instante de 30% da etapa de adsorção, estes critérios não convergiram sendo escolhido a ordem de modelo que melhor se ajustasse ao conjunto de Teste. Em 50% da etapa de adsorção os critérios AIC e BIC também não convergiram e em 75% de adsorção houve convergência, porém, a ordem dos modelos SARIMA que estes critérios indicaram para estes dois casos não se ajustou corretamente ao conjunto de Teste, por este motivo a mesma ordem do modelo SARIMA utilizado para ajustar o conjunto de Teste em 30% da etapa de adsorção será utilizado nas outras duas porcentagens de ciclos analisadas neste trabalho. Os modelos SARIMA com menor qualidade no ajuste estão apresentados no Apêndice F. As Tabelas 6.11, 6.12 e 6.13 apresentam os coeficientes dos modelos, assim como os valores AIC, BIC e o valor da REMQ.

Tabela 6.11: Modelo SARIMA $(0, 1, 1)(1,0,1)_{12}$ ajustado para 30% da etapa de adsorção.

Ordem	δ	θ_1	$\hat{\phi}_{12}$	$\hat{\theta}_{12}$	AIC	BIC	REMQ
$(0,1,1)(1,0,1)_{12}$	0,1481	-0,6472	0,9988	-0,9780	110,32	120,70	0,3047


Tabela 6.12: Modelo SARIMA (0, 1, 1)(1,0,1)₁₂ ajustado para 50% da etapa de adsorção.

Ordem	δ	θ_1	$\hat{\phi}_{12}$	$\hat{\theta}_{12}$	AIC	BIC	REMQ
(0,1,1)(1,0,1) ₁₂	0,1364	-0,6286	0,9990	-0,9812	101,40	111,78	0,2788

Tabela 6.13: Modelo SARIMA (0, 1, 1)(1,0,1)₁₂ ajustado para 75% da etapa de adsorção.

Ordem	δ	θ_1	$\hat{\phi}_{12}$	$\hat{\theta}_{12}$	AIC	BIC	REMQ
(0,1,1)(1,0,1) ₁₂	0,0798	-0,3307	0,3373	-0,4303	38,98	49,36	0,3936

Os coeficientes dos modelos apresentados nas Tabelas acima, indicam que os ajustes para 30% e 50% da etapa de adsorção são parecidos, visto que os coeficientes possuem valores próximos, enquanto que em 75% do ciclo de adsorção os coeficientes diferem das duas porcentagens de tempo anteriores. Os conjuntos de Teste e Treino, os modelos SARIMA ajustados para os instantes de ciclos estudados e o limite aceitável do fator de resistência ao escoamento são apresentados nas Figuras 6.52, 6.53 e 6.54.

**Figura 6.52:** Conjuntos de Treino, Teste e modelo SARIMA ajustado para 30% da etapa de adsorção.




Figura 6.53: Conjuntos de Treino, Teste e modelo SARIMA ajustado para 50% da etapa de adsorção.




Figura 6.54: Conjuntos de Treino, Teste e modelo SARIMA ajustado para 75% da etapa de adsorção.

Pelas Figuras acima se nota que em 30% e 50% do ciclo de adsorção, o modelo SARIMA teve uma estimativa razoável, em comparação com a SET, teve um desempenho melhor, porém o fator de resistência teria que manter a tendência de crescimento linear para que a estimativa do NCR utilizando o SARIMA seja precisa. No instante de 75% o modelo SARIMA não conseguiu ser adequado na previsão do NCR, porque, segundo o SARIMA ajustado para este caso, o fator de resistência ao escoamento permaneceria constante ao longo dos ciclos. Os resíduos e sua distribuição são mostrados nas Figuras 6.55, 6.56 e 6.57 onde também se tem esta conclusão.




Figura 6.55: a) Resíduos entre o modelo SARIMA ajustado e o conjunto de Teste em 30% da etapa de adsorção; b) Distribuição dos Resíduos.




Figura 6.56: a) Resíduos entre o modelo SARIMA ajustado e o conjunto de Teste em 50% da etapa de adsorção; b) Distribuição dos Resíduos.




Figura 6.57: a) Resíduos entre o modelo SARIMA ajustado e o conjunto de Teste em 75% da etapa de adsorção; b) Distribuição dos Resíduos.

6.3 Metodologia Bayesiana vs Séries Temporais

Os subitens anteriores sintetizaram como prever o NCR utilizando a metodologia Bayesiana e Séries Temporais. Em Séries Temporais, o método SED foi o que melhor se ajustou ao conjunto de Teste, porém, para este método manter a qualidade, é necessário garantir que a variável analisada para a degradação, neste caso o fator de resistência ao escoamento, mantenha um comportamento padrão ao que o modelo foi ajustado. Esta é grande desvantagem das Séries Temporais, por outro lado, a abordagem Bayesiana consegue se adequar e particularizar a cada caso analisado, pois os parâmetros obtidos

pela informação *a priori*, podem ser tratado como um conjunto de Treino da metodologia, porém ao utilizar a Inferência Bayesiana torna-se a estimativa mais confiável, conforme mostrado no item 6.1 em que a partir da informação de 4 curvas de degradação simuladas foi possível estimar a VUR de uma outra curva simulada com um comportamento diferente das outras. Outra vantagem da abordagem Bayesiana é que ela retorna a FDP, o que auxilia na tomada de decisões.

A desvantagem da metodologia Bayesiana é que ela calcula a distância de um ponto, x_k , até um outro ponto, X_f , não sendo possível simular um comportamento cíclico caso haja necessidade de entender a dinâmica do ciclo de adsorção-regeneração. Isto pode ser ajustado utilizando Séries Temporais, como por exemplo, a Figura 6.58 apresenta os ciclos de Teste e os ciclos ajustados utilizando um modelo SARIMA, porque entre ele e o modelo SET, o SARIMA obteve maior representatividade, para o fator de resistência ao escoamento.




Figura 6.58: Previsão do padrão cíclico utilizando o modelo SARIMA

A Figura 6.58 mostra que o modelo SARIMA consegue prever o padrão cíclico no comportamento do fator de resistência. Neste caso, devido à um problema no algoritmo em *Python* da biblioteca *statsmodels*, foi necessário reduzir o tamanho do ciclo, o algoritmo falha para períodos sazonais maiores que 100. Então foi utilizada a média entre 10 pontos para reduzir o tamanho do ciclo para 25 minutos, enquanto na realidade o tempo de duração é de 250 minutos, sendo usados 2500 dados iniciais de conjunto de Treino e o restante de conjunto de Teste. A defasagem entre o ciclo real e o ciclo previsto se dá pelo fato de nem todos os ciclos possuírem o tempo de duração de 250 minutos, conforme citado anteriormente na Figura 6.12. Pode-se concluir então que caso o tempo de duração dos ciclos seja padronizado, o modelo SARIMA pode prever a dinâmica de forma aceitável.

Por fim, salienta-se que uma metodologia não exclui a outra, sendo possível utilizar as Séries Temporais para compreender o comportamento de um ciclo de adsorção-regeneração e usar a metodologia Bayesiana para ter maior confiança na estimativa do NCR em processos cíclicos ou VUR em processos temporais.

Capítulo 7 – Conclusões e Trabalhos Futuros

Este trabalho apresentou duas abordagens distintas que podem ser utilizados na determinação do Número de Ciclos Remanescente em um processo cíclico. Para maximizar a produção garantindo a segurança operacional, é necessário que fim da vida útil seja estimado com um bom grau de confiança, por este motivo se comparou uma abordagem que combinava o comportamento determinístico de um sistema com o comportamento estocástico utilizando a Inferência Bayesiana e outra que se valia de um comportamento puramente determinístico (Séries Temporais). O objetivo em se considerar o efeito estocástico é de obter a estimativa do NCR mais precisa, pois não há garantia de que todos os M sistemas similares tenham o mesmo comportamento ao longo da vida útil e isto se explica pela natureza probabilística de um processo.

Se estes M sistemas similares possuem um comportamento semelhante ao longo dos ciclos, se justifica a utilização das Séries Temporais. Como esta metodologia se baseia em um ajuste de um modelo a partir de um conjunto de dados de Treino, é necessário que os dados do conjunto de validação e ao longo dos ciclos mantenham o padrão do conjunto de Treino, se este padrão mudar com o passar dos ciclos, é provável que esta metodologia de Séries Temporais não seja adequada para a previsão do NCR.

O Estudo de Caso da Unidade TSA de desidratação corroborou com essas expectativas. Entre os modelos de Séries Temporais utilizados para avaliar a vida útil da Coluna A desta unidade, apenas o modelo de Suavização Exponencial Dupla conseguiu obter resultados satisfatórios, porém para esta estimativa estar precisa, o fator de resistência ao escoamento teria que manter a tendência de crescimento. Caso esta tendência aumentasse de forma inesperada, o término da vida útil do leite ocorreria antes do previsto ocasionando riscos à operação, enquanto que se a degradação estagnasse, o método SED levaria a crer que a unidade deveria ser parada antes do necessário, o que geraria perda de produção.

Estas considerações fazem com que o uso da metodologia Bayesiana desenvolvida por WANG; HU; FAN (2018) se justifique. Embora no Estudo de Caso não tenha ficado claro as vantagens desta metodologia devido à baixa quantidade de dias de operação da unidade, o fato de atualizar o comportamento e monitorar a cada novo dado de degradação obtido torna a previsão mais confiável, conforme mostrado nos dados de degradação que foram

simulados. Além do mais, a obtenção da FDP do NCR no tempo t_k avaliado, englobando a natureza probabilística, auxilia na tomada de decisões.

A abordagem de empacotamento dos ciclos torna menos complexa a análise do processo, porque ela fornece o ciclo atual de operação e o tempo de duração do mesmo, podendo ser comparado com o tempo de duração de ciclos anteriores. Na estimativa da Vida Útil Remanescente este empacotamento se torna interessante pelo fato de possibilitar que a análise da série temporal seja feita no ciclo, enquanto que a determinação da VUR em função do tempo total do processo é difícil em comparação à determinação do NCR, pois cada ciclo possui um tempo grande de duração.

Por fim, o uso de uma metodologia não elimina a outra. A abordagem Bayesiana pode ser utilizada na determinação dos ciclos remanescentes do processo, enquanto que uma série temporal seja usada para modelar um ciclo na tentativa de entender a dinâmica do processo cíclico. Ficam as seguintes sugestões para trabalhos futuros:

- Desenvolver uma metodologia Bayesiana para degradação não-linear em que não seja necessário conhecer a informação *a priori* do sistema, para que seja possível utilizar esta abordagem em equipamentos que sejam únicos, ou novos, em uma indústria;
- Obter os dados do tempo total de vida de leitos de desidratação para que seja possível obter resultados mais confiáveis;
- Considerar a vazão individual de gás natural e de gás de regeneração em um Estudo de Caso de leitos de desidratação;
- Suavizar o fator de resistência ao escoamento em função do ciclo de operação com o objetivo de reduzir as oscilações nas medições e obter uma qualidade maior na precisão do NCR;
- Avaliar o coeficiente de inclinação do fator de resistência ao escoamento e estimar a VUR a partir da variação da inclinação ao longo dos ciclos;
- Comparar a abordagem Bayesiana com métodos que se baseiam na dinâmica da falha de um componente para evidenciar as vantagens em utilizar um modelo de degradação baseado na coleta de dados;
- Avaliar uma degradação multivariável, isto é, quando mais de uma variável seja crítica para o comportamento do sistema;
- Padronizar o período dos ciclos de adsorção e dessorção com o objetivo de obter maior precisão na previsão dos ciclos utilizando Séries Temporais.

Referências

ALEGHAFOURI, Abbas; DAVOUDI, Mehdi. Modeling and simulation of a pressure–temperature swing adsorption process for dehydration of natural gas. **Adsorption**, [s. l.], v. 24, n. 1, p. 121–133, 2018. Disponível em: <<http://dx.doi.org/10.1007/s10450-017-9924-z>>

BOX, George E. P.; JENKINS, Gwilym M.; REINSEL, Gregory C. **Time Series Analysis: Forecasting and Control**. 4. ed. [s.l.] : Wiley, 2008.

BROWNLEE, Jason. **How to Check if Time Series Data is Stationary with Python**. 2016. Disponível em: <<https://machinelearningmastery.com/time-series-data-stationary-python/>>. Acesso em: 10 jan. 2019.

CENTER, The Methodology. **AIC vs BIC**. [s.d.]. Disponível em: <<https://www.methodology.psu.edu/AIC-vs-BIC>>. Acesso em: 8 fev. 2019.

COLAÇO, Marcelo J. et al. Application of Two Bayesian Filters to Estimate Unknown Heat Fluxes in a Natural Convection Problem. **Journal of Heat Transfer**, [s. l.], v. 134, n. 9, p. 092501, 2012.

CORTADI, Alberto Jimenez et al. Time Series Forecasting in Turning Processes Using ARIMA Model. [s. l.], v. 798, p. 157–166, 2018. Disponível em: <<http://link.springer.com/10.1007/978-3-319-99626-4>>

DAIGLE, Matthew J.; GOEBEL, Kai. A Model-Based Prognostics Approach Applied to Pneumatic Valves. **Int. J. Prognostics and Health Management (IJPHM)**, [s. l.], v. 2, p. 1–16, 2011.

DURRETT, Rick. Probability: Theory and Examples. [s. l.], p. 438, 2010.

EMILIANO, Paulo César. Fundamentos e aplicações dos critérios de Informação : Akaike e Bayesiano. **Ufla**, [s. l.], p. 105, 2009.

- FOGLIATTO, Flávio S.; RIBEIRO, Jose Luis Duarte. **Confiabilidade e Manutenção Industrial**. [s.l.: s.n.].
- FONSECA, Natalie Alexandra Amézquita. Simulação do processo de adsorção PSA para separação da mistura etanol-água. [s. l.], p. 141, 2011. Disponível em: <<http://www.bibliotecadigital.unicamp.br/document/?code=000807033&fd=y>>
- GEBRAEEL, Nagi Z. et al. Residual-life distributions from component degradation signals: A Bayesian approach. **IIE Transactions (Institute of Industrial Engineers)**, [s. l.], v. 37, n. 6, p. 543–557, 2005.
- HENRIQUE, Bruno Miranda; SOBREIRO, Vinicius Amorim; KIMURA, Herbert. Literature review: Machine learning techniques applied to financial market prediction. **Expert Systems with Applications**, [s. l.], v. 124, p. 226–251, 2019. Disponível em: <<https://doi.org/10.1016/j.eswa.2019.01.012>>
- HU, Changhua et al. A new remaining useful life estimation method for equipment subjected to intervention of imperfect maintenance activities. **Chinese Journal of Aeronautics**, [s. l.], v. 31, n. 3, p. 514–528, 2018.
- HYNDMAN, Rob J.; ATHANASOPOULOS, George. **Forecasting: Principles and Practice**. 2018.
- LEE, Mei-Ling Ting; WHITMORE, G. A. Threshold Regression for Survival Analysis: Modeling Event Times by a Stochastic Process Reaching a Boundary. **Statistical Science**, [s. l.], v. 21, n. 4, p. 501–513, 2006.
- LEE, Mei Ling Ting et al. A case-control study relating railroad worker mortality to diesel exhaust exposure using a threshold regression model. **Journal of Statistical Planning and Inference**, [s. l.], v. 139, n. 5, p. 1633–1642, 2009.
- LIMA, Marcos Bruno Santos Pereira et al. Aplicação Do Modelo De Previsão De Demanda Holt- Winters Em Uma Regional De Corte E Dobra De Aço. In: 2015, **Anais...** [s.l.: s.n.]
- LIU, Jie et al. An Adaptive Recurrent Neural Network for Remaining Useful Life Prediction of Lithium-ion Batteries. **National Aeronautics and Space Administration Moffett Field Ca Ames Research Center**, [s. l.], p. 1–9, 2010.
- MORETTIN, Pedro A.; TOLOI, Clelia M. C. **Análise de Séries Temporais**. 2. ed. [s.l.: s.n.].
- NASA. **Prognostic Data Repository**. 2019. Disponível em: <<https://ti.arc.nasa.gov/tech/dash/groups/pcoe/prognostic-data-repository/>>. Acesso em: 26 fev. 2019.
- NASTAJ, J.; AMBROZEK, B. Analysis of gas dehydration in TSA system with multi-layered bed of solid adsorbents. **Chemical Engineering and Processing: Process Intensification**, [s. l.], v. 96, p. 44–53, 2015.
- NIKULIN, M. S. et al. **Advances in Degradation Modeling**. [s.l.] : Springer Science & Business Media, 2010.
- ORDÓÑEZ, Celestino et al. A hybrid ARIMA–SVM model for the study of the remaining

useful life of aircraft engines. **Journal of Computational and Applied Mathematics**, [s. l.], v. 346, p. 184–191, 2019. Disponível em: <<https://doi.org/10.1016/j.cam.2018.07.008>>

PAL, Avishek; PRAKASH, PKS. **Practical Time Series Analysis**. [s.l.: s.n.]. Disponível em: <<https://www.packtpub.com/big-data-and-business-intelligence/practical-time-series-analysis>>

PARMEZAN, Antonio Rafael Sabino; SOUZA, Vinicius M. A.; BATISTA, Gustavo E. A. P. A. Evaluation of statistical and machine learning models for time series prediction: Identifying the state-of-the-art and the best conditions for the use of each model. **Information Sciences**, [s. l.], v. 484, p. 302–337, 2019. Disponível em: <<https://doi.org/10.1016/j.ins.2019.01.076>>

SANTOS, Myrlla G. R. S. et al. Natural gas dehydration by molecular sieve in offshore plants: Impact of increasing carbon dioxide content. **Energy Conversion and Management**, [s. l.], v. 149, p. 760–773, 2017.

SI, Xiao-Sheng et al. Remaining Useful Life Estimation Based on a Nonlinear Diffusion Degradation Process. **Reliability, IEEE Transactions on**, [s. l.], v. 61, n. 1, p. 50–67, 2012.

SI, Xiao Sheng et al. Remaining useful life estimation - A review on the statistical data driven approaches. **European Journal of Operational Research**, [s. l.], v. 213, n. 1, p. 1–14, 2011.

SI, Xiao Sheng et al. A degradation path-dependent approach for remaining useful life estimation with an exact and closed-form solution. **European Journal of Operational Research**, [s. l.], v. 226, n. 1, p. 53–66, 2013.

SI, Xiao Sheng. An adaptive prognostic approach via nonlinear degradation modeling: Application to battery data. **IEEE Transactions on Industrial Electronics**, [s. l.], v. 62, n. 8, p. 5082–5096, 2015.

SIKORSKA, J. Z.; HODKIEWICZ, M.; MA, L. Prognostic modelling options for remaining useful life estimation by industry. **Mechanical Systems and Signal Processing**, [s. l.], v. 25, n. 5, p. 1803–1836, 2011.

SINGH DOORGA, Jay Rovisham et al. Forecasting mesoscale distribution of surface solar irradiation using a proposed hybrid approach combining satellite remote sensing and time series models. **Renewable and Sustainable Energy Reviews**, [s. l.], v. 104, n. September 2018, p. 69–85, 2019. Disponível em: <<https://doi.org/10.1016/j.rser.2018.12.055>>

SINGH, Gurchetan. **7 methods to perform Time Series forecasting (with Python codes)**. 2018. Disponível em: <<https://www.analyticsvidhya.com/blog/2018/02/time->>. Acesso em: 20 fev. 2019.

TAY, Dennis. Time series analysis of discourse: A case study of metaphor in psychotherapy sessions. **Discourse Studies**, [s. l.], v. 19, n. 6, p. 694–710, 2017. Disponível em: <<https://doi.org/10.1177/1461445617727187>>

WANG, Xue et al. Remaining Useful Life Prediction of Lithium-Ion Batteries Based on the Wiener Process with Measurement Error. **Energies**, [s. l.], v. 7, n. 2, p. 520–547, 2014.

WANG, Zhao Qiang; HU, Chang Hua; FAN, Hong Dong. Real-Time Remaining Useful Life Prediction for a Nonlinear Degrading System in Service: Application to Bearing Data. **IEEE/ASME Transactions on Mechatronics**, [s. l.], v. 23, n. 1, p. 211–222, 2018.

WU, Shaomin. A failure process model with the exponential smoothing of intensity functions. **European Journal of Operational Research**, [s. l.], v. 275, n. 2, p. 502–513, 2019. Disponível em: <<https://doi.org/10.1016/j.ejor.2018.11.045>>

Apêndice A – FDP condicional ao tempo de vida

Segundo SI et al. (2012) o termo variável no tempo $S_B(t)$ definido como o limite de $W(t)$, deve ser derivado baseado na Equação (2.1) e é dado por:

$$S_B(t) = \frac{X_f - \alpha \int_0^t \mu(\tau; \beta) d\tau}{\sigma_B} \quad (\text{A.1})$$

Admitindo o efeito aleatório do parâmetro estocástico α , a FDP condicional ao tempo de vida T definido na Equação (2.2) é obtida utilizando o Teorema 1 proposto por SI et al. (2012):

$$f_{T|\alpha}(t|\alpha) \cong \frac{1}{\sqrt{2\pi t}} \exp \left\{ -\frac{\left[X_f - \alpha \int_0^t \mu(\tau; \beta) d\tau \right]^2}{2\sigma_B^2 t} \right\} \left[\frac{S_B(t)}{t} - \frac{dS_B(t)}{dt} \right] \quad (\text{A.2})$$

Para chegar na Equação (2.3) basta substituir (A.1) em (A.2) e manipular algebricamente.

Apêndice B – FDP do tempo de vida remanescente

Relacionando o tempo de vida T com a VUR, definida como L_k , se pode definir que o processo de degradação definido pela Equação (2.1) se transforma no processo estocástico $Y(l_k)$, $l_k \geq 0$ dado pela Equação (2.5) e que estas duas equações são semelhantes. Assim, da mesma forma que a Equação (2.3), a FDP condicional à VUR L_k no tempo t_k é dada por:

$$f_{L_k|\alpha}(l_k|\alpha) \cong \frac{X_f - x_k - \alpha \int_{t_k}^{t_k+l_k} \mu(\tau;\beta) d\tau + \alpha \mu(t_k+l_k;\beta) l_k}{\sigma_B l_k \sqrt{2\pi l_k}} \exp \left\{ -\frac{[X_f - x_k - \alpha \int_{t_k}^{t_k+l_k} \mu(\tau;\beta) d\tau]^2}{2\sigma_B^2 l_k} \right\} \quad (\text{B.1})$$

Através da lei da probabilidade total, é obtida a FDP incondicional ao parâmetro estocástico α :

$$f_{L_k}(l_k) = \int_{\Omega} f_{L_k|\alpha}(l_k|\alpha) f(\alpha) d\alpha \quad (\text{B.2})$$

A partir de (B.1) e (B.2) se obtém a Equação (2.8). WANG; HU; FAN (2018) apresenta maiores detalhes.

Apêndice C – Código em Python da Metodologia Bayesiana

```
1 # Bibliotecas necessárias
2 #Importando bibliotecas
3 import math
4 from math import sqrt
5 from scipy.stats import norm
6 import numpy as np
7 import matplotlib.pyplot as plt
8 import numpy
9 from pylab import plot, show, grid, xlabel, ylabel
10 import pandas as pd
11 import numpy.linalg as la
12 from mpl_toolkits.mplot3d import axes3d
13 from scipy.integrate import quad
14 %matplotlib notebook
15
16 # Matriz dos tempos de covariância #----> Equação 2.14
17 matriz = np.zeros((len(Ni), len(Ni)))
18 for i in range(len(Ni)):
19     matriz[i,i] = Ni[i]
20     matriz[i:,i] = Ni[i]
21 Ki = matriz
22
23 # Otimização Estocástica
24 from scipy.optimize import differential_evolution #importando a biblioteca responsável pela otimização
25 # definindo os limites de cada parâmetro
26 bounds = [(0.1500,0.1700), (0.00100, 0.00500), (1.0000, 2.0000), (0.3500, 0.3700)]
27
28 #Função objetivo para a estimação dos parâmetros
29 def objective(fi):
30     mu_alfa0 = fi[0]
31     var_alfa0 = fi[1]
32     beta = fi[2]
33     var = fi[3]
34     # A função objetivo foi dividida em três partes para facilitar a escrita do código
35     test_part1 = -1/2*(numpy.reshape(Z_i, (1, len(Z_i)))-numpy.reshape(mu_alfa0*Ni**beta,
36 (1, len(Ni))) * np.linalg.inv(var_alfa0*Ni**beta*numpy.reshape(Ni**beta, (1, len(Ni)) + var*Ki)*(Z_i-mu_alfa0*Ni**beta)
37     test_part2 = -1/2*np.log(2*pi)*Ni
38     test_part3 = -1/2*np.log(var_alfa0*Ni**beta*numpy.reshape(Ni**beta, (1, len(Ni)) + var*Ki)
39     fi_max = -(test_part1 + test_part2 + test_part3) #-----> Equação 2.15
40     erro = la.norm(Z_quatro - fi_max, np.inf)
41     print('erro', erro)
42     return erro
43 result4 = differential_evolution(objective, bounds, strategy='randlexp')
```

```

44 # Função Densidade de Probabilidade
45 def pdf_vur(tk, lk, mu_alfa0, var_alfa0, beta, var, Xf, xk):
46     # tk - tempo em análise
47     # lk - vida útil remanescente no tempo em análise
48     # mu_alfa0 - média a priori (baseada em dados históricos e obtida através da otimização acima) do parâmetro
    estocástico
49     # var_alfa0 - variância a priori (baseada em dados históricos e obtida através da otimização acima) do parâmetro
    estocástico
50     # beta - parâmetro determinístico baseado em dados históricos e obtido através da otimização
51     # var - coeficiente de difusão do movimento Browniano baseado em dados históricos e obtido através da otimização
52     # Xf - limite aceitável da variável crítica
53     # xk - degradação da variável crítica do equipamento em análise no tempo t
54
55     t = np.linspace(0,tk,int(tk)+1) #vetor de tempo até tk
56     sum_a = 0.0
57     for i in range(1,len(str(tk))):
58         sum_a += ((t[i]**beta - t[i-1]**beta)**2)/(var*(t[i] - t[i-1])) #-----> Equação 2.20
59         A = sum_a
60     B = 1/var_alfa0 #-----> Equação 2.21
61     C = mu_alfa0/var_alfa0 #-----> Equação 2.22
62     sum_d = 0.0
63     for i in range(1,len(str(tk))):
64         sum_d += ((xk[i,] - xk[i-1,])**2*(t[i]**beta - t[i-1]**beta))/(var*(t[i] - t[i-1])) #----- Equação 2.23
65         D = sum_d
66     # Atualização das médias e variâncias do parâmetro estocástico a cada tk analisado.
67     mu_alfa_posteriori = (C+D)/(A+B) #-----> Equação 2.18
68     var_alfa_posteriori = 1/(A+B) #-----> Equação 2.19
69     # VIDA ÚTIL REMANESCENTE
70     # Cálculo da Vida Útil Remanescente.
71     xk = xk[int(tk),]
72     int_lk = (lk+tk)**beta-tk**beta
73
74     pdf_rul = 1/(np.sqrt(2*pi*lk**2*(var_alfa_posteriori*(int_lk**2)+(var)*lk)))*(Xf - xk - (int_lk - u_lk*lk)*
    (var_alfa_posteriori*(Xf-xk)*int_lk+mu_alfa_posteriori*(var)*lk)/(var_alfa_posteriori*(int_lk**2)+(var)*lk))*np.exp(-(Xf-
    xk-mu_alfa_posteriori*int_lk)**2/(2*(var_alfa_posteriori*(int_lk**2)+(var)*lk))) #-----> Equação 2.8
75
76     #Plot 3D
77     z = tk
78     z = numpy.array([z for i in range(len(lk))])
79     ax.plot(z,lk,pdf_rul,'blue',label='PDF VUR')
80     return pdf_rul
81
82 #Para Chamar a Função
83 %matplotlib notebook
84 fig = plt.figure()
85 ax = fig.add_subplot(111,projection='3d')
86
87 for i in range(len(t_k)):
88     pdf_vur(t_k[i],x, mu_alfa0, var_alfa0, beta, var, Xf, xk)
89
90 ax.set_xlabel('MC')
91 ax.set_ylabel('VUR')
92 ax.set_zlabel('PDF')
93 ax.set_xlim([t_k[0],10])
94 plt.show()

```

```

96 # Vida Útil Remanescente Média #----> Equação 2.9
97 def mttf_pdf_vur(lk, tk, mu_alfa0, var_alfa0, beta, var, Xf, xk):
98     # tk - tempo em análise
99     # lk - vida útil remanescente no tempo em análise
100    # mu_alfa0 - média a priori (baseada em dados históricos e obtida através da otimização acima) do parâmetro
    estocástico
101    # var_alfa0 - variância a priori (baseada em dados históricos e obtida através da otimização acima) do parâmetro
    estocástico
102    # beta - parâmetro determinístico baseado em dados históricos e obtido através da otimização
103    # var - coeficiente de difusão do movimento Browniano baseado em dados históricos e obtido através da otimização
104    # Xf - limite aceitável da variável crítica
105    # xk - degradação da variável crítica do equipamento em análise no tempo t
106
107    t = np.linspace(0,tk,int(tk)+1) #vetor de tempo até tk
108    sum_a = 0.0
109    for i in range(1,len(str(tk))):
110        sum_a += ((t[i]**beta - t[i-1]**beta)**2)/(var*(t[i,] - t[i-1,])) #----> Equação 2.20
111        A = sum_a
112        B = 1/var_alfa0 #----> Equação 2.21
113        C = mu_alfa0/var_alfa0 #----> Equação 2.22
114        sum_d = 0.0
115        for i in range(1,len(str(tk))):
116            sum_d += ((xk[i,] - xk[i-1,])*t[i]**beta - t[i-1]**beta)/(var*(t[i,] - t[i-1,])) #----> Equação 2.23
117            D = sum_d
118    # Atualização das médias e variâncias do parâmetro estocástico a cada tk analisado.
119    mu_alfa_posteriori = (C+D)/(A+B) #----> Equação 2.18
120    var_alfa_posteriori = 1/(A+B) #----> Equação 2.19
121    # VIDA UTIL REMANESCENTE
122    # Cálculo da Vida Útil Remanescente.
123    xk = xk[int(tk),]
124    int_lk = (lk+tk)**beta-tk**beta
125
126    pdf_rul = 1/(np.sqrt(2*pi*lk**2*(var_alfa_posteriori*(int_lk**2)+(var)*lk)))*(Xf - xk - (int_lk - u_lk*lk)*
    (var_alfa_posteriori*(Xf-xk)*int_lk+mu_alfa_posteriori*(var)*lk)/(var_alfa_posteriori*(int_lk**2)+(var)*lk))*np.exp(-(Xf-
    xk-mu_alfa_posteriori*int_lk)**2/(2*(var_alfa_posteriori*(int_lk**2)+(var)*lk))) #----> Equação 2.8
127    return lk*pdf_rul
128    # Para chamar a Função
129    mttf = []
130    for i in range(len(t_k)):
131        mttf_vur = quad(mttf_pdf_vur, 0, np.inf, args=(t_k[i],mu_alfa0, var_alfa0, beta, var, Xf, xk))
132        mttf.append(mttf_vur[0])
133    x_real = np.linspace(t_k[0],t_k[-1],len(x))
134    Rul_real = -x_real + 10
135    fig = plt.figure()
136    ax = fig.add_subplot(111)
137    plt.grid(True)
138    ax.plot(t_k,mttf,'- ',label='prevista')
139    ax.plot(x_real,Rul_real,label='real')
140    ax.set_xlabel('tempo')
141    ax.set_ylabel('Vida Útil Remanescente média')
142    ax.set_xlim([t_k[0],t_k[-1]])
143    ax.legend()
144    plt.show()
145

```

Apêndice D – Código em Python das Séries Temporais

Importando Bibliotecas:

```
#Bibliotecas necessárias
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
from statsmodels.graphics.tsaplots import plot_acf, plot_pacf
from sklearn.metrics import mean_squared_error
from math import sqrt
from statsmodels.tsa.api import ExponentialSmoothing, SimpleExpSmoothing, Holt
import statsmodels.api as sm
from statsmodels.tsa.arima_model import ARIMA
```

Suavização Exponencial Simples:

```
#Otimizando o valor de alfa
otm_SES = []
alfa = np.linspace(0,1,101)
for i in range(len(alfa)):
    y_hat_avg_20 = test_20.copy()
    fit2 = SimpleExpSmoothing(np.asarray(train_20['Resistencia'])).fit(smoothing_level=alfa[i], optimized=True)
    y_hat_avg_20['SES'] = fit2.forecast(len(test_20))
    rms_ses = sqrt(mean_squared_error(test_20.Resistencia, y_hat_avg_20.SES))
    otm_SES.append([alfa[i], rms_ses])

#Retornando o valor de alfa ótimo
rms_otm = []
for i in range(len(otm_SES)):
    min_otm = otm_SES[i][1]
    rms_otm.append(min_otm)
rms_minimo = min(rms_otm)
index = rms_otm.index(min(rms_otm))
alfa_otm = otm_SES[index][0]
print('rms = ', rms_minimo)
print('indice = ', index)
print('alfa = ', alfa_otm)

#Treinando o modelo e comparando com os dados de Teste
y_hat_avg_20 = test_20.copy()
fit_ses = SimpleExpSmoothing(np.asarray(train_20['Resistencia'])).fit(smoothing_level=alfa_otm, optimized=True)
y_hat_avg_20['SES'] = fit_ses.forecast(len(test_20))
plt.figure(figsize=(10.5,8.5))
plt.plot(train_20['Resistencia'], label='Treino')
plt.plot(test_20['Resistencia'], label='Teste')
plt.plot(data_20.index, y_lim, '--k', label='Limite')
plt.plot(y_hat_avg_20['SES'], label='SES')
plt.xlabel('Ciclo')
plt.ylabel('Resistência')
plt.legend(loc='best')
plt.show()
```

Suavização Exponencial Dupla

```
# Testando estacionaridade
result = sm.tsa.stattools.adfuller(train_30.Resistencia)
#result
print('Teste de Estacionariedade do fator de Resistência')
print('ADF Statistic: %f' % result[0])
print('p-value: %f' % result[1])
print('Critical Values:')
for key, value in result[4].items():
    print('\t%s: %.3f' % (key, value))

# Otimizando valor de alfa e beta
otm_hltm = []
alfa = np.linspace(0,1,101)
beta = np.linspace(0,1,101)
for i in range(len(alfa)):
    for j in range(len(beta)):
        y_hat_avg_30 = test_30.copy()
        fit1 = Holt(np.asarray(train_30['Resistencia'])).fit(smoothing_level = alfa[i],smoothing_slope = beta[j])
        y_hat_avg_30['Holt_linear'] = fit1.forecast(len(test_30))
        rms_hltm = sqrt(mean_squared_error(test_30.Resistencia, y_hat_avg_30.Holt_linear))
        otm_hltm.append([alfa[i], beta[j], rms_hltm])

#Retornando os valores de alfa e beta ótimos
rms_otm = []
for i in range(10201):
    min_otm = otm_hltm[i][2]
    rms_otm.append(min_otm)
rms_minimo = min(rms_otm)
index = rms_otm.index(min(rms_otm))
alfa_otm = otm_hltm[index][0]
beta_otm = otm_hltm[index][1]
print('rms =', rms_minimo)
print('indice = ', index)
print('alfa = ', alfa_otm)
print('beta = ', beta_otm)

#Treinando o modelo e comparando com os dados de Teste
fit_hltm = Holt(np.asarray(train_30['Resistencia'])).fit(smoothing_level = alfa_otm,smoothing_slope = beta_otm)
y_hat_avg_30['Holt_linear'] = fit_hltm.forecast(len(test_30))
plt.figure(figsize=(10.5,8.5))
plt.plot(train_30['Resistencia'], label='Treino')
plt.plot(test_30['Resistencia'], label='Teste')
plt.plot(y_hat_avg_30['Holt_linear'], label='SED')
plt.plot(data_30.index, y_lim, '--k', label='Limite')
plt.xlabel('Ciclo')
plt.ylabel(r'Fator de Resistência ao Escoamento ( $\frac{h}{m^3}\sqrt{Pa}$ )')
plt.legend(loc='best')
plt.show()
```

Suavização Exponencial Tripla:

```
#Treinando o modelo e comparando com os dados de Teste
#m = tamanho do período
fit_hwm = ExponentialSmoothing(np.asarray(train_30['Resistencia']),seasonal_periods=m,trend='add',seasonal='add',).fit()
y_hat_avg_30['Holt_Winter'] = fit_hwm.forecast(len(test_30))
plt.figure(figsize=(10.5,8.5))
plt.plot( train_30['Resistencia'], label='Treino')
plt.plot(test_30['Resistencia'], label='Teste')
plt.plot(y_hat_avg_30['Holt_Winter'], label='SET')
plt.plot(data_30.index, y_lim, '--k', label='Limite')
plt.xlabel('Ciclo')
plt.ylabel(r'Fator de Resistência ao Escoamento ( $\frac{h}{m^3}\sqrt{Pa}$ )')
plt.legend(loc='best')
plt.show()
```

ARIMA:

```
#Critério AIC para obtenção da ordem do Modelo ARIMA
aicVal=[]
for d in range(0,2):
    for ari in range(0, 20):
        for maj in range(0,10):
            try:
                arima_obj = ARIMA(train_30['Resistencia'].tolist(), order=(ari,d,maj))
                arima_obj_fit=arima_obj.fit()
                aicVal.append([ari, d, maj, arima_obj_fit.aic])
            except ValueError:
                pass

#Retornando ordem do modelo ARIMA através do critério AIC
aic_arima_otm = []
for i in range(len(aicVal)):
    min_arima_otm = aicVal[i][3]
    aic_arima_otm.append(min_arima_otm)
aic_minimo = min(aic_arima_otm)
index = aic_arima_otm.index(min(aic_arima_otm))
p_otm = aicVal[index][0]
d_otm = aicVal[index][1]
q_otm = aicVal[index][2]

print('AIC =', aic_minimo)
print('indice = ', index)
print('AR = ', p_otm)
print('d = ', d_otm)
print('MA = ', q_otm)

#Critério BIC para obtenção da ordem do Modelo ARIMA
bicVal=[]
for d in range(0,2):
    for ari in range(0, 20):
        for maj in range(0,10):
            try:
                arima_obj = ARIMA(train_30['Resistencia'].tolist(), order=(ari,d,maj))
                arima_obj_fit=arima_obj.fit()
                bicVal.append([ari, d, maj, arima_obj_fit.bic])
            except ValueError:
                pass

# Retornando ordem do modelo ARIMA através do critério BIC
bic_arima_otm = []
for i in range(len(bicVal)):
    min_arima_otm = bicVal[i][3]
    bic_arima_otm.append(min_arima_otm)
bic_minimo = min(bic_arima_otm)
index = bic_arima_otm.index(min(bic_arima_otm))
p_otm = bicVal[index][0]
d_otm = bicVal[index][1]
q_otm = bicVal[index][2]

print('BIC =', bic_minimo)
print('indice = ', index)
print('AR = ', p_otm)
print('d = ', d_otm)
print('MA = ', q_otm)

#Treinando o modelo ARIMA e comparando com os dados de Teste
fit_arima = ARIMA(train_30.Resistencia, order=(p_otm, d_otm, q_otm)).fit()
y_hat_avg_30['ARIMA'] = fit_arima.predict(start=100, end=163, dynamic=True)
plt.figure(figsize=(10.5,8.5))
plt.plot( train_30['Resistencia'], label='Treino')
plt.plot(test_30['Resistencia'], label='Teste')
plt.plot(y_hat_avg_30['ARIMA'], label='ARIMA (1,0,1)')
plt.plot(data_30.index, y_lim, '--k', label='Limite')
plt.xlabel('Ciclo')
plt.ylabel(r'Fator de Resistência ao Escoamento ( $\frac{h}{m^3} \sqrt{Pa}$ )')
plt.legend(loc='best')
plt.show()
```

SARIMA:

```
#Critério AIC para obtenção da ordem do Modelo SARIMA
aicVal=[]
for d in range(0,2):
    for ari in range(0, 5):
        for maj in range(0,5):
            for D in range(0,2):
                for ARI in range(0,5):
                    for MAJ in range(0,5):
                        try:
                            sarima_obj = sm.tsa.statespace.SARIMAX(train_30['Resistencia'].tolist(), order=
(ari,d,maj),seasonal_order=(ARI,D,MAJ,m))
                            sarima_obj_fit=sarima_obj.fit()
                            aicVal.append([ari, d, maj, ARI, D, MAJ, sarima_obj_fit.aic])
                        except ValueError:
                            pass

#Retornando ordem do modelo SARIMA através do critério AIC
aic_sarima_otm = []
for i in range(len(aicVal)):
    min_sarima_otm = aicVal[i][6]
    aic_sarima_otm.append(min_sarima_otm)
aic_minimo = min(aic_sarima_otm)
index = aic_sarima_otm.index(min(aic_sarima_otm))
p_otm = aicVal[index][0]
d_otm = aicVal[index][1]
q_otm = aicVal[index][2]
P_otm = aicVal[index][3]
D_otm = aicVal[index][4]
Q_otm = aicVal[index][5]

print('AIC =', aic_minimo)
print('indice = ', index)
print('AR = ', p_otm)
print('d = ', d_otm)
print('MA = ', q_otm)
print('P = ', P_otm)
print('D = ', D_otm)
print('Q = ', Q_otm)

#Critério BIC para obtenção da ordem do Modelo SARIMA
bicVal=[]
for d in range(0,2):
    for ari in range(0, 5):
        for maj in range(0,5):
            for D in range(0,2):
                for ARI in range(0,5):
                    for MAJ in range(0,5):
                        try:
                            sarima_obj = sm.tsa.statespace.SARIMAX(train_30['Resistencia'].tolist(), order=
(ari,d,maj),seasonal_order=(ARI,D,MAJ,m))
                            sarima_obj_fit=sarima_obj.fit()
                            bicVal.append([ari, d, maj, ARI, D, MAJ, sarima_obj_fit.bic])
                        except ValueError:
                            pass

# Retornando ordem do modelo SARIMA através do critério BIC
bic_sarima_otm = []
for i in range(len(bicVal)):
    min_sarima_otm = bicVal[i][6]
    bic_sarima_otm.append(min_sarima_otm)
bic_minimo = min(bic_sarima_otm)
index = bic_sarima_otm.index(min(bic_sarima_otm))
p_otm = bicVal[index][0]
d_otm = bicVal[index][1]
q_otm = bicVal[index][2]
P_otm = bicVal[index][3]
D_otm = bicVal[index][4]
Q_otm = bicVal[index][5]

print('BIC =', bic_minimo)
print('indice = ', index)
print('AR = ', p_otm)
print('d = ', d_otm)
print('MA = ', q_otm)
print('P = ', P_otm)
print('D = ', D_otm)
print('Q = ', Q_otm)
```



```

#Treinando o modelo ARIMA e comparando com os dados de Teste
# m = tamanho do periodo sazonal
fit_sarima_ml = sm.tsa.statespace.SARIMAX(train_30.Resistencia, order=(p_otm, d_otm, q_otm),seasonal_order=
(P_otm,D_otm,Q_otm,m)).fit()
y_hat_avg_30['SARIMA_M1'] = fit_sarima_ml.predict(start=100, end=163, dynamic=True)
plt.figure(figsize=(10.5,8.5))
plt.plot( train_30['Resistencia'], label='Treino')
plt.plot(test_30['Resistencia'], label='Teste')
plt.plot(y_hat_avg_30['SARIMA_M1'], label='SARIMA (0,1,1)(1,0,1,12)')
plt.plot(data_30.index, y_lim, '--k', label='Limite')
plt.xlabel('Ciclo')
plt.ylabel(r'Fator de Resistência ao Escoamento ( $\frac{h}{m^3}\sqrt{Pa}$ )')
plt.legend(loc='best')
plt.show()

```

Apêndice E – Modelos ARIMA

A ordem dos modelos ARIMA com menor qualidade no ajuste, determinados pelos critérios AIC e BIC para os instantes de 50% e 75% de adsorção é apresentada nas Tabelas E.1 e E.2:

Tabela E.1: Modelo ARIMA (1, 0, 1) ajustado para 50% da etapa de adsorção.

Ordem	δ	ϕ_1	θ_1	AIC	BIC	REMQ
(1, 0, 1)	3,3880	0,9910	-0,6257	109,54	119,96	0,7303

Tabela E.2: Modelo ARIMA (1, 0, 1) ajustado para 75% da etapa de adsorção.

Ordem	δ	ϕ_1	θ_1	AIC	BIC	REMQ
(1, 0, 1)	3,3223	0,9825	-0,3202	41,81	52,23	0,8690

As Figuras E.1 e E.2 apresentam os conjuntos de Teste e Treino, os modelos ARIMA acima definidos e o limite aceitável do fator de resistência ao escoamento.




Figura E.1: Conjuntos de Treino, Teste e modelo ARIMA ajustado para 50% da etapa de adsorção.




Figura E.2: Conjuntos de Treino, Teste e modelo ARIMA ajustado para 75% da etapa de adsorção.

Apêndice F – Modelos SARIMA

A ordem dos modelos SARIMA com menor qualidade no ajuste, determinados pelos critérios AIC e BIC, para os instantes de 30%, 50% e 75% de adsorção é apresentada nas Tabelas F.1, F.2, F.3 e F.4:

Tabela F.1: Modelo SARIMA $(0, 1, 1)(0,0,0)_{12}$ ajustado para 30% da etapa de adsorção.

Ordem	δ	θ_1	AIC	BIC	REMQR
$(0,1,1)(0,0,0)_{12}$	0,1751	-0,6495	113,01	118,20	0,4517

Tabela F.2: Modelo SARIMA $(0, 1, 1)(3,0,1)_{12}$ ajustado para 50% da etapa de adsorção.

Ordem	δ	θ_1	$\hat{\Phi}_{12}$	$\hat{\Phi}_{24}$	$\hat{\Phi}_{36}$	$\hat{\theta}_{12}$	AIC	BIC	REMQR
$(0,1,1)(1,0,1)_{12}$	0,1094	-0,6192	0,6414	-0,0307	0,3857	-0,9412	97,14	112,71	0,8273

Tabela F.3: Modelo SARIMA $(0, 1, 1)(0,0,0)_{12}$ ajustado para 50% da etapa de adsorção.

Ordem	δ	θ_1	AIC	BIC	REMQR
$(0,1,1)(0,0,0)_{12}$	0,1580	-0,6335	102,81	108,00	0,4487

Tabela F.4: Modelo SARIMA $(0, 1, 0)(0,0,0)_{12}$ ajustado para 75% da etapa de adsorção.

Ordem	δ	AIC	BIC	REMQR
$(0,1,0)(0,0,0)_{12}$	0,0881	42,48	45,07	0,4367

As Figuras F.1, F.2, F.3 e F.4 apresentam os conjuntos de Teste e Treino, os modelos SARIMA acima definidos e o limite aceitável do fator de resistência ao escoamento.




Figura F.1: Conjuntos de Treino, Teste e modelo SARIMA ajustado para 30% da etapa de adsorção.




Figura F.2: Conjuntos de Treino, Teste e modelo SARIMA ajustado para 50% da etapa de adsorção.




Figura F.3: Conjuntos de Treino, Teste e modelo SARIMA ajustado para 50% da etapa de adsorção.




Figura F.4: Conjuntos de Treino, Teste e modelo SARIMA ajustado para 75% da etapa de adsorção.