



**UNIVERSIDADE FEDERAL DO CEARÁ**  
**CAMPUS DE SOBRAL**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E DE**  
**COMPUTAÇÃO**

**ACÉLIO LUNA MESQUITA**

**PREVISÃO E DETECÇÃO DE FALHAS EM CAPACITORES**  
**ELETROLÍTICOS**

**SOBRAL**

**2021**

ACÉLIO LUNA MESQUITA

**PREVISÃO E DETECÇÃO DE FALHAS EM CAPACITORES  
ELETROLÍTICOS**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e da Computação da Universidade Federal do Ceará, como requisito à obtenção do título de mestre em Engenharia Elétrica e da Computação. Área de concentração: Sistemas de Energia Elétrica e subárea: Eletrônica de Potência.

Orientador: Prof. Dr. Vandilberto Pereira Pinto.

SOBRAL

2021

Dados Internacionais de Catalogação na Publicação  
Universidade Federal do Ceará  
Biblioteca Universitária

Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

---

M543p Mesquita, Acêlio Luna.  
PREVISÃO E DETECÇÃO DE FALHAS EM CAPACITORES ELETROLÍTICOS / Acêlio Luna  
Mesquita. – 2021.  
100 f. : il. color.

Dissertação (mestrado) – Universidade Federal do Ceará, Campus de Sobral, Programa de Pós-Graduação  
em Engenharia Elétrica e de Computação, Sobral, 2021.  
Orientação: Prof. Dr. Vandilberto Pereira Pinto .

1. Capacitor. 2. Redes neurais artificiais . 3. Regressão por processo gaussiano. 4. Prognóstico e  
Monitoramento da Saúde. 5. Vida útil remanescente. I. Título.

CDD 621.3

---

ACÉLIO LUNA MESQUITA

**PREVISÃO E DETECÇÃO DE FALHAS EM CAPACITORES  
ELETROLÍTICOS UTILIZANDO REDES NEURAIIS E TÉCNICAS  
ESTASTÍSTICAS**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e da Computação da Universidade Federal do Ceará, como requisito à obtenção do título de mestre em Engenharia Elétrica e da Computação. Área de concentração: Sistemas de Energia Elétrica e subárea: Eletrônica de Potência.

Aprovada em: \_\_\_/\_\_\_/\_\_\_\_\_.

**BANCA EXAMINADORA**

---

Dr. Vandilberto Pereira Pinto (Orientador)  
Programa de Pós-Graduação em Engenharia Elétrica e de Computação (PPGEEC),  
Universidade Federal do Ceará (UFC)

---

Dr. Márcio André Baima Amora  
Programa de Pós-Graduação em Engenharia Elétrica e de Computação (PPGEEC),  
Universidade Federal do Ceará (UFC)

---

Dr. Leonardo Ramos Rodrigues (Externo a Instituição)  
Departamento de Ciência e Tecnologia Aeroespacial (DCTA), Instituto de Aeronáutica e  
Espaço (IAE)

A Deus.

A minha família.

E a todos que se fizeram presentes nessa caminhada.

## **AGRADECIMENTOS**

A Deus, por estar sempre presente em todos os momentos de minha vida, me auxiliando e me dando forças para superar todos os desafios que passaram e que estão por vir. Sem Ele, nada disto seria possível.

A toda a minha família por todo o suporte, carinho e atenção em todos os momentos da minha vida. Especialmente aos meus pais que sempre prezaram pela minha educação.

Aos amigos que obtive nesse período de mestrado, Lucivando Araújo, Miguel Eneas, Larissa Frota, Noeme Madeira e Emanuel Gomes pelos momentos de descontração, auxílio e reflexão.

Aos docentes e funcionários do Programa de Pós-Graduação em Engenharia Elétrica e de Computação.

Ao Prof. Dr. Vandilberto pela excelente orientação e grandes ensinamentos desde a época de graduação.

Aos membros da banca examinadora pelo tempo, pelas valiosas colaborações e sugestões.

“Nada é mais certo neste mundo do que a morte e os impostos.” De Benjamin Franklin

## RESUMO

Capacitores são componentes eletrônicos que apresentam grande variação de características ao longo de sua vida útil. Após serem submetidos a vários ciclos de carga e descarga, os capacitores apresentam perda na capacitância e com isso passam a operar fora de suas características nominais. Técnicas de Prognóstico e Monitoramento da Saúde (*Prognostics and Health Monitoring - PHM*) podem ser usadas para monitorar a evolução da degradação dos capacitores e estimar sua vida útil remanescente (*Remaining Useful Life - RUL*). O presente trabalho tem por objetivo monitorar a degradação e prever a vida útil remanescente de capacitores por meio da utilização de redes neurais artificiais e de regressão por processo gaussiano (*Gaussian Process Regression - GPR*) utilizando a base de dados do repositório da NASA. Diferentes arquiteturas de redes são avaliadas para a estimativa da vida útil remanescente: MLP (*Multilayer Perceptron*), RBF (*Radial Basis Function*) e ELM (*Extreme Learning Machine*). O coeficiente de determinação ( $R^2$ ) e o erro médio quadrático (*Mean Squared Error - MSE*), são usados como indicadores de desempenho para comparar as diferentes arquiteturas de redes e do GPR. A precisão das estimativas de RUL são comparadas em termos da precisão relativa (*Relative Accuracy - RA*) e do desempenho  $\alpha - \lambda$ , que são indicadores propostos na literatura para algoritmos de PHM.

**Palavras-chave:** Capacitor; Redes neurais artificiais; Regressão por processo gaussiano; Prognóstico e Monitoramento da Saúde; Vida útil remanescente.



## ABSTRACT

Capacitors are electronic components that vary widely in characteristics over their useful life. After being subjected to several charging and discharging cycles, the capacitors show a loss in their capacitance and with that they start operating outside nominal characteristics. Prognosis and Health Monitoring Techniques (PHM) can be used to monitor the evolution of capacitor degradation and estimate their remaining useful life (RUL). The present work aims to monitor the degradation and predict the remaining useful life of capacitors through the use of artificial neural networks and Gaussian process regression (GPR) using the NASA repository database. Different network architectures are evaluated to estimate the remaining useful life: MLP (Multilayer Perceptron), RBF (Radial Basis Function) and ELM (Extreme Learning Machine). The coefficient of determination ( $R^2$ ) and the mean square error (MSE) are used as performance indicators to compare GPR and the different network architectures. The accuracy of the RUL estimates are compared in terms of the relative accuracy (RA) and the  $\alpha - \lambda$  performance, which are indicators proposed in the literature for PHM algorithms.

**Keywords:** Capacitor; Artificial neural networks; Gaussian process regression; Prognosis and Health Monitoring; Remaining useful life.

## LISTA DE FIGURAS

Figura 1 – Hierarquia das abordagens de prognóstico de Falhas. ....	19
Figura 2– Degradação de um elemento mecânico de manufatura. ....	19
Figura 17 - Exemplo de prognóstico de falha com séries temporais. ....	22
Figura 3 - Estrutura física do capacitor. ....	25
Figura 4– Modelo físico do capacitor eletrolítico. ....	26
Figura 5- Secção transversal da estrutura do capacitor eletrolítico de alumínio. ....	27
Figura 6– Diagrama de espinha de peixe para falha no capacitor eletrolítico. ....	28
Figura 7 – Diagrama de blocos da configuração experimental. ....	30
Figura 8 – Experimento de envelhecimento por estresse de tensão. ....	31
Figura 9 – Gráfico da degradação dos capacitores pelo tempo. ....	31
Figura 10- Estrutura da rede ELM. ....	32
Figura 11 - Esquema de uma rede MLP. ....	34
Figura 12 - Estrutura de uma rede RBF. ....	35
Figura 13 - Exemplos de funções de base radial utilizadas. ....	36
Figura 14 - Comparação entre o mapeamento das redes RBF e MLP. ....	37
Figura 15 – Trajetórias de Processos Gaussianos. ....	39
Figura 16 – Amostras da distribuição de um Processo gaussiano. ....	39
Figura 18 - Esquema representando a precisão de $\alpha$ - $\lambda$ . ....	43
Figura 19 – Previsão de falha do capacitor 5 utilizando a rede ELM. a) previsão no tempo de 116h, b) previsão no tempo de 139h, c) previsão no tempo de 149h, d) previsão no tempo de 161h, e) previsão no tempo de 171h. ....	46
Figura 20 – Desempenho $\alpha - \lambda$ da previsão do RUL através da rede ELM do capacitor 2. ....	48
Figura 21 – Previsão de falha do capacitor 2 utilizando a rede MLP. ....	50
Figura 22– Desempenho $\alpha - \lambda$ da previsão do RUL através da rede MLP do capacitor 2. ....	51
Figura 23 – Previsão de falha do capacitor 2 utilizando a rede RBF. ....	53
Figura 24 - desempenho $\alpha - \lambda$ do da previsão do capacitor 2 utilizando a rede RBF. ....	54
Figura 25 - Previsão de falha do capacitor 6 utilizando GPR1 entre o tempo de a) 0h, b) 24h, c) 47 e d) 71h. ....	56
Figura 26 – Previsão de falha do capacitor 6 utilizando GRP1 entre o tempo de a) 94h, b) 116h, c) 139h e d) 149h. ....	57
Figura 27 – Previsão da falha do capacitor 6 utilizando GRP1 entre o tempo de a) 161, b) 171h e c)194h. ....	58

Figura 28– Desempenho $\alpha - \lambda$ do capacitor 6. ....	59
Figura 29 – Previsão de falha do capacitor 6 utilizando GPR2 entre o tempo de a) 0h, b) 24h, c) 47 e d) 71h. ....	61
Figura 30 – Previsão de falha do capacitor 6 utilizando GPR2 entre o tempo de a) 94h, b) 116h, c) 139h e d) 149h. ....	62
Figura 31 – Previsão de falha do capacitor 6 utilizando GPR2 entre o tempo de a) 161, b) 171h e c)194h. ....	62
Figura 32 – Desempenho $\alpha - \lambda$ do capacitor 2. ....	64
Figura 33 – Desempenho $\alpha - \lambda$ do capacitor 6. ....	64
Figura 34 – Comparativo do desempenho $\alpha - \lambda$ das técnicas utilizadas. ....	67

## LISTA DE TABELAS

Tabela 1 – Indicadores de desempenho para a rede ELM.....	47
Tabela 2 – Estimativas de RUL dos capacitores da rede ELM.....	47
Tabela 3 – Indicadores de desempenho da rede MLP.....	49
Tabela 4 – Estimativa do RUL dos capacitores da rede MLP. ....	51
Tabela 5 – Indicadores de desempenho da rede RBF. ....	52
Tabela 6 – Estimativa do RUL dos capacitores da rede RBF. ....	54
Tabela 7 – Indicadores de desempenho da rede GPR1 para cada previsão. ....	55
Tabela 8 – Estimativa do RUL dos capacitores da técnica GPR1. ....	59
Tabela 9 – Indicadores de desempenho da rede GPR2 para cada previsão. ....	60
Tabela 10 – Estimativa do RUL dos capacitores da técnica GPR2. ....	63
Tabela 11 – Comparativo entre os resultados de predição do capacitor 2.....	65
Tabela 12 – Comparativo entre os resultados do RUL do capacitor 2.....	66
Tabela 13 – Comparativo entre os resultados do RA do capacitor 2.....	67

## LISTA DE ABREVIATURAS E SIGLAS

CBM	<i>Condition Based Maintenance</i>
EIS	<i>Electrochemical-impedance spectroscopy</i>
ELM	Máquina de Aprendizagem Extrema ( <i>Extreme Learning Machine</i> )
EOF	<i>End of life</i>
ESR	<i>Equivalent series resistance</i>
PG	<i>Processo gaussiano</i>
GPR	Regressão por processo gaussiano ( <i>Gaussian process regression</i> )
MLP	<i>Multi Layer Perceptron</i>
NASA	<i>National Aeronautics and Space Administration</i>
OSA-CBM	<i>Open System Architecture for Condition Based Maintenance</i>
PHM	<i>Prognostics and Health Management</i>
R <sup>2</sup>	Coefficiente de Correlação Múltipla
RA	Precisão relativa ( <i>Relative Accuracy - RA</i> )
RBF	Função de base radial ( <i>Radial Basis Function</i> )
RCM	<i>Reability Centered Maintenance</i>
RNAs	Redes Neurais Artificiais
RUL	<i>Remaining Useful Life</i>

## LISTA DE SÍMBOLOS

$\varphi(\cdot)$	Função de ativação
$b$	Bias
C	Capacitância
t	Tempo
$\mathbf{K}_{XX}$	Função covariância
$w$	Pesos sinápticos da RNA
m()	Média
$f_i$	Variável aleatória
$y_i$	Dados observados
$\bar{y}$	Média dos dados observados
$\hat{y}_i$	Dados estimados pelo modelo
$t_{EOL}$	Instante previsto de falha
$t_p$	Instante atual da previsão
$\alpha$	Modificador de precisão
$\lambda$	Janela de tempo de modificação
RUL*	RUL real
RUL'	RUL predito
F	Farad

## SUMÁRIO

<b>1 INTRODUÇÃO .....</b>	<b>16</b>
<b>1.1 Prognóstico e Gestão de Saúde (<i>Prognostics and Health Monitoring - PHM</i>) .....</b>	<b>16</b>
<b>1.2 Vida Útil Remanescente (<i>Remaining Usefull Life - RUL</i>) .....</b>	<b>20</b>
<b>1.3 Justificativa .....</b>	<b>22</b>
<b>1.4 Objetivos.....</b>	<b>23</b>
<b>1.4.1 Objetivo Geral.....</b>	<b>23</b>
<b>1.4.2 Objetivos Específicos .....</b>	<b>23</b>
<b>1.5 Produções Científicas .....</b>	<b>23</b>
<b>1.6 Organização do Trabalho.....</b>	<b>23</b>
<b>2 CAPACITOR ELETROLÍTICO .....</b>	<b>25</b>
<b>2.1 Estrutura do capacitor eletrolítico de alumínio .....</b>	<b>25</b>
<b>2.2 Modos de falha .....</b>	<b>27</b>
<b>2.3 Critérios de falha para capacitores eletrolíticos .....</b>	<b>29</b>
<b>2.4 Base de Dados da NASA .....</b>	<b>29</b>
<b>3 MÉTODOS E TÉCNICAS.....</b>	<b>32</b>
<b>3.1 Extreme Learning Machine .....</b>	<b>32</b>
<b>3.2 Multilayer perceptron (MLP).....</b>	<b>33</b>
<b>3.3 <i>Radial Basis Funtion (RBF)</i> .....</b>	<b>35</b>
<b>3.4 Regressão por processo gaussiano.....</b>	<b>37</b>
<b>4 INDICADORES DE DESEMPENHO .....</b>	<b>41</b>
<b>4.1 Coeficiente de determinação.....</b>	<b>41</b>
<b>4.2 Erro quadrático médio .....</b>	<b>42</b>
<b>4.3 Precisão relativa.....</b>	<b>42</b>
<b>4.4 Desempenho <math>\alpha - \lambda</math> .....</b>	<b>42</b>
<b>5 RESULTADOS E DISCUSSÕES .....</b>	<b>44</b>
<b>5.1 Resultados da RNA ELM.....</b>	<b>44</b>

<b>5.2 Resultados da RNA MLP .....</b>	<b>48</b>
<b>5.3 Resultados da RNA RBF .....</b>	<b>52</b>
<b>5.4 Resultados da GPR.....</b>	<b>55</b>
<b>5.5 – Análise geral dos resultados.....</b>	<b>65</b>
<b>5 CONSIDERAÇÕES FINAIS.....</b>	<b>68</b>
<b>5.1 Propostas para Trabalhos Futuros.....</b>	<b>69</b>
<b>REFERÊNCIAS .....</b>	<b>70</b>
<b>ANEXO A – RESULTADO DAS DEMAIS PREVISÕES DA RNA ELM .....</b>	<b>75</b>
<b>ANEXO B – RESULTADO DAS DEMAIS PREVISÕES DA RNA MLP .....</b>	<b>79</b>
<b>ANEXO C – IMAGEM DOS RESULTADOS DAS DEMAIS PREVISÕES DA RNA RBF .....</b>	<b>87</b>
<b>ANEXO D – IMAGEM DOS RESULTADOS DAS DEMAIS PREVISÕES DA GPR....</b>	<b>92</b>



## 1 INTRODUÇÃO

### 1.1 Prognóstico e Gestão de Saúde (*Prognostics and Health Monitoring - PHM*)

Em virtude da revolução industrial ocorreu o aumento de produção em larga escala, gerando uma necessidade de evolução da indústria como um todo. Com essa evolução, a necessidade de cuidados específicos para cada equipamento aumentou de forma exponencial devido à complexidade do mesmo.

O único sistema de gestão, utilizado inicialmente, para os equipamentos era o de manutenção corretiva, que era a manutenção do equipamento após o mesmo apresentar um defeito. Este tipo de manutenção se torna quase inviável por ter um custo elevado, pois o equipamento fica indisponível, que gera um impacto diretamente na produção, na vida útil e na segurança. Com o tempo surgiu a manutenção preventiva, porém a mesma demanda de um custo elevado devido a realização de manutenções periódicas, custo de mão de obra e material. Já na manutenção preditiva ocorre a utilização de equipamentos para a coleta de dados e análise para uma melhor compreensão do estado atual da máquina, possibilitando diagnosticar se a mesma necessita da troca de componentes que já estão próximos do fim da vida útil antes da falha (TORRES; MACHADO; SOUZA, 2005).

Uma das principais técnicas de estudos para prognóstico e gestão de saúde (*Prognostics and Health Monitoring – PHM*) se baseia na estimação do cálculo da vida útil remanescente (*Remaining Useful Life – RUL*) do equipamento. Sendo esse um conceito da chamada Manutenção Baseada em Condição (*Condition Based Maintenance – CBM*), que tem como objetivo uma manutenção centrada em confiabilidade (*Reability Centered Maintenance – RCM*) (SOUALHI *et al.*, 2018).

Com a filosofia de aquisição de dados para análise das condições da saúde do equipamento pode-se observar os seus modos de falha com o objetivo de detectar a necessidade de uma manutenção anterior a falha funcional (BIZARRIA, 2009). Reduzindo o numero de manutenções preventivas exigidas pelo conceito de RCM, assim como falhas ocorridas em manutenções mal executadas (LEÃO, 2011).

No início da década de 70 o ministério de defesa dos Estados Unidos iniciou os estudos de PHM monitorando a vibração de rotores de helicópteros militares, visando a redução de custos com a manutenção e a segurança em aeronaves civis e militares (PENNA, 2011).

O PHM mescla a gestão de ciclo de vida com o estudo de mecanismos e modos de falhas. O estudo de prognóstico de falhas estrutura-se em quatro fundamentos (UCKUN; GOEBEL; LUCAS, 2008):

- As condições ambientais, o tempo e o uso levam ao desgaste natural de sistemas eletromecânicos;
- O envelhecimento é um processo monotônico que leva à degradação física e/ou química;
- É possível detectar sinais de envelhecimento antes da falha funcional;
- Há uma correlação entre o envelhecimento de um componente e um modelo de degradação.

O uso de módulos eletrônicos para a execução de diversas funcionalidades em sistemas tem apresentado um crescimento contínuo (SILTALA e TUOKKO, 2009). Módulos eletrônicos também têm sido usados para implementar funções críticas em sistemas (LAUER *et al.*, 2013). Em função disso, surge a necessidade de monitorar o nível de degradação de componentes eletrônicos, além de estimar o instante provável de falha desses componentes (VICHARE e PECHT, 2006). As falhas em componentes eletrônicos podem ser provocadas por uma série de fatores como variações de temperatura, vibração, umidade, picos de corrente, surtos de tensão, entre outros (FIDES GROUP, 2004).

Uma forma de monitorar a degradação de componentes eletrônicos é através do uso de técnicas de prognóstico e monitoramento da saúde de sistemas. As técnicas de PHM permitem avaliar o índice de RUL de componentes eletrônicos a partir de dados estatísticos, informações da física dos modos de falha do sistema, e leituras de sensores (ROEMER *et al.*, 2005).

Segundo Bizarria (2009), sistemas que não utilizam o conceito de PHM tendem a gerar um desperdício da vida útil dos equipamentos. O uso adequado de técnicas de PHM possui as seguintes vantagens: Redução dos custos de manutenção, logística, estoque e operação;

- Redução do número de paradas não-programadas (manutenção corretiva);
- Aumento da confiabilidade do sistema;
- Maximização da vida útil dos equipamentos que compõem o sistema e possuem período fixo de troca.

Os sistemas eletrônicos possuem inúmeros componentes que são de vital importância para seu funcionamento adequado. Dentre eles destacam-se os capacitores, que podem apresentar variação da sua capacitância com o tempo e com os ciclos de carga e descarga. Segundo a norma MIL-C-62F (2008), a falha de um capacitor é declarada quando a sua resistência interna apresenta um aumento entre 280 a 300% do valor inicial, ou quando o valor da capacitância apresenta redução de 20% do seu valor nominal. Com esses valores, pode-se definir o valor limiar do desgaste do capacitor para assim realizar sua troca.

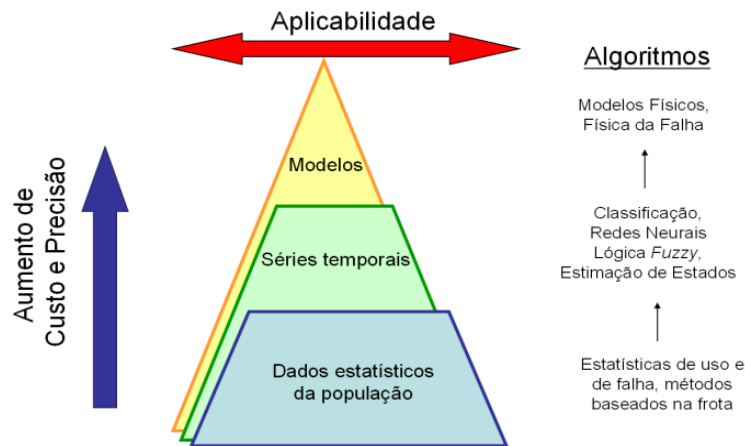
Técnicas de PHM vêm sendo utilizadas na área de sistemas de potência, como no estudo proposto por Kulkarni *et al.* (2009), que aborda a degradação de capacitores em conversores DC-DC. Em outro estudo, Marcos *et al.* (2014) utilizam técnicas de monitoramento para diagnóstico de falhas em unidades geradoras hidráulicas com o auxílio de lógica difusa. Em Soualhi *et al.* (2018), os autores utilizam diferentes técnicas de processamento de sinais para utilização de estratégias de PHM aplicadas ao monitoramento de rolamentos e caixas de engrenagens em componentes industriais. No estudo proposto por Alozie *et al.* (2019), é utilizada uma estrutura de prognóstico baseada em modelos para utilização em turbinas a gás de aeronaves.

Böhm (2017) utilizou classificação por meio de redes neurais artificiais e máquinas de vetores de suporte (*Support Vector Machines - SVM*) para previsão da vida útil remanescente para aplicação na indústria ferroviária. Corroborando com o estudo anterior, Costa (2019) afirma que as redes neurais conseguem obter resultados satisfatórios no monitoramento da saúde de sistemas.

O uso de técnicas de prognóstico e monitoramento da saúde de sistemas é de vital importância para sistemas eletrônicos e, através dessas técnicas, pode-se monitorar a degradação do componente para prever sua vida útil remanescente. Assim, o presente trabalho tem como objetivo aplicar diferentes arquiteturas de redes neurais artificiais e da técnica estatística de regressão por processo gaussiano (*Gaussian Process Regression - GPR*) para prever o comportamento da degradação de capacitores até o limiar de falha, além de fazer uma comparação do desempenho obtido por cada uma das diferentes arquiteturas consideradas.

As metodologias utilizadas para o prognóstico de falhas pode ser classificadas em três tipos. Sendo elas as baseadas em dados estatísticos, baseadas em séries temporais e baseadas em modelos analíticos. Dentre as metodologias, pode-se classificar o nível de hierarquia com base na complexidade e na aplicabilidade. Como mostra a Figura 1 (ALOZIE *et al.*, 2019).

Figura 1 – Hierarquia das abordagens de prognóstico de Falhas.

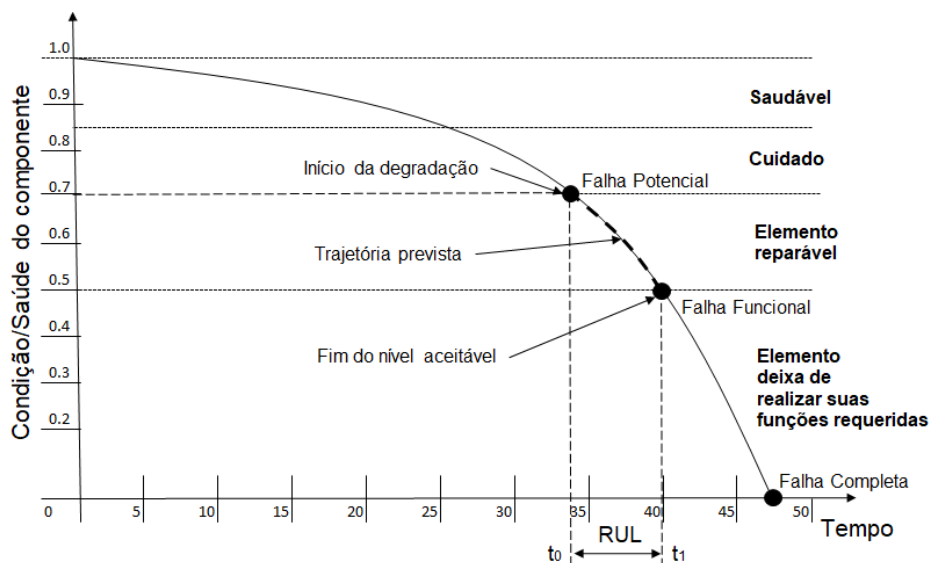


Fonte: Bizarria (2009).

Segundo Costa (2019), na base da pirâmide se encontra a metodologia mais abrangente, da qual utiliza dados históricos de falhas para modelos estatísticos, podendo assim ajustar a curvas de distribuição de probabilidade para calcular as probabilidades de falha de um componente e assim prever a vida remanescente do mesmo.

No meio da pirâmide estão os métodos de análise de tendências que necessitam de sensores no qual são encarregados das leituras dos parâmetros do componente. A partir dos dados coletados podem-se utilizar técnicas de classificação, inteligência computacional ou de estimação de estados para determinar o nível de degradação do equipamento estudado e calcular a vida útil remanescente (RUL) do mesmo. Conforme o exemplo Figura 2.

Figura 2– Degradação de um elemento mecânico de manufatura.



Fonte: Nuñez, 2017.

Onde são definidos os principais termos:

- Saúde/Condição do componente: Momento para o monitoramento do estado do equipamento para aquisição e processamento das informações/ dados determinando a manutenção do equipamento (ISO 13379-1,2012).
- Falha potencial: O momento no tempo em que o equipamento começa a apresentar deterioração e pode começar a apresentar falhas (VAN HORENBEEK *et al.*, 2013).
- Falha funcional: O momento no tempo em que o componente sofre uma falha crítica. Caracteriza como o fim da vida útil do componente (NUÑEZ, 2017).
- Falha completa: No ponto de falha completa, assim como o próprio nome diz, o equipamento deixa de funcionar completamente (IEC 60050-192,2015).

Segundo Alves (2010), para a definição da estrutura de um sistema de PHM é utilizado um padrão de seis camadas de OSA-CBM (*Open System Architecture for Condition Based Maintenance*). Onde as camadas são definidas pela linguagem ULM (*Unified Modeling Language*) de acordo com tendências técnicas, industriais, militares e comerciais. As seis camadas podem ser descritas como:

- Aquisição de Dados: através de transdutores que adquirirem a leitura dos parâmetros analógicos para a conversão do sinal digital e armazenamento do mesmo;
- Manipulação de Dados: processamento digital dos sinais adquiridos na etapa anterior;
- Detecção de Estado: comparação entre os sinais dos dados obtidos pelo processamento digital e características pré-definidas;
- Avaliação de Saúde: nessa fase ocorre a análise dos dados históricos e dos dados adquiridos na etapa anterior para determinar as condições atuais da saúde do sistema;
- Avaliação Prognostica: ocorre a previsão do estado de saúde futuro, com uma incerteza associada, com base no estado de saúde atual definido na etapa anterior;
- Geração de Alertas: interface com o objetivo de elucidar o usuário final com o estado de saúde do sistema, como alertas de quando este estado não é satisfatório.

## 1.2 Vida Útil Remanescente (*Remaining Usefull Life - RUL*)

Segundo a norma IEC 60050-192 (2015), a degradação é o estado na qual a

capacidade de desempenho de um equipamento é reduzida para executar uma função requerida, mas continua com um desempenho aceitável.

No PHM, a estimativa do RUL é adquirida através da análise do histórico das falhas existentes ou potenciais, assim, torna-se possível determinar o intervalo de tempo entre a presença das falhas potenciais e o início de uma falha funcional. Podendo determinar o tempo para a falha crítica e aumentar a vida útil do equipamento (ELMARAGHY, HODA et al., 2014).

Para o cálculo do RUL é necessário a identificação do fim da vida (*End of Life - EOL*) do equipamento que é baseado pelo limiar de falha definido pela equação 18 (SAXENA et al., 2010).

$$RUL(t_p) = t_{EOL} - t_p. \quad (1)$$

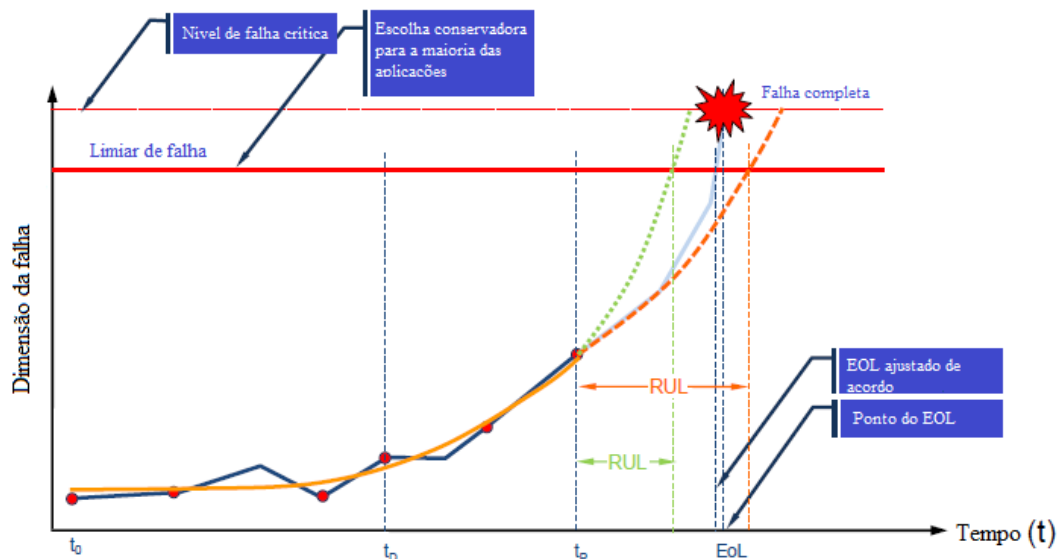
Onde:

- $t_{EOL}$ : é o instante previsto de falha;
- $t_p$ : é o instante atual da previsão.

Como o tempo é uma variável contínua, uma interpolação linear é feita para a identificação do  $t_{EOL}$ , sendo ele definido pelo instante em que o índice de degradação atinge o limiar de falha.

Para um melhor entendimento do RUL será utilizado a Figura 17 que ilustra o prognóstico de falha com séries temporais.

Figura 3 - Exemplo de prognóstico de falha com séries temporais.



Fonte: Adaptado de Saxena (2010).

Pode-se observar, pela Figura 17, que o fim da vida útil se encontra no ponto destacado como falha funcional, o RUL se encontra no intervalo entre falha potencial e a falha funcional. A partir do momento que o equipamento passa do ponto de falha funcional o mesmo para de realizar as funções da qual foi designada em projeto.

### 1.3 Justificativa

Com a constante evolução da manutenção e com o foco em reduzir os custos com a mesma, gera a necessidade de uma manutenção preditiva de confiança. Utilizando as técnicas de monitoramento e identificação do RUL, justifica-se o estudo feito para que ocorra a diminuição de manutenções preventivas, sem necessidades, e diminuir a quantidade de manutenções corretiva, que gera uma redução significativa de gastos com manutenção. Observando os dados e analisando os conceitos de CBM para uma maximização da confiança da manutenção.

Também, como justificativa para o trabalho, os dados dos capacitores foram utilizados com diferentes técnicas preditivas. Possibilitando assim uma análise por diferentes perspectivas.

## 1.4 Objetivos

### 1.4.1 Objetivo Geral

O presente trabalho tem por objetivo monitorar a degradação e prever a vida útil remanescente de capacitores eletrolíticos.

Proporcionar o gerenciamento de capacitores eletrolíticos de alumínio em equipamentos eletrônicos e filtros. A partir do monitoramento da degradação do capacitor e da queda da capacitância.

### 1.4.2 Objetivos Específicos

- Implementar técnicas para estimação da degradação do capacitor;
- Prever a deterioração e a RUL dos capacitores eletrolíticos através de técnicas de redes neurais e técnicas estatísticas.
- Realizar uma análise comparativa entre as técnicas implementadas.

## 1.5 Produções Científicas

No decorrer da pesquisa foi desenvolvido o seguinte artigo científico:

- MESQUITA, A. L.; PINTO, V. P.; RODRIGUES, L. R.; **Detection and Fault Prediction in Electrolytic Capacitors Using Artificial Neural Networks**. 2nd International Conference on Applied Technologies, 2020.

## 1.6 Organização do Trabalho

O Capítulo 1 apresentou uma revisão sobre prognóstico e gestão da vida útil de equipamentos e componentes. A partir de uma pesquisa bibliográfica, é apresentado o histórico dos trabalhos mais significativos, encontrados na literatura científica, e por fim, a justificativa e os objetivos do presente trabalho.

O Capítulo 2 será abordado a estrutura física do capacitor de alumínio e seus modos de falhas. Será explanada de forma breve a base de dados de degradação dos capacitores de alumínio da NASA, utilizada nas simulações.



O Capítulo 3 apresentará as discussões dos métodos de classificações *Extreme Learning Machine*, *Multilayer perceptron*, *Função de Base Radial* e *Regressão por Processo Gaussiano*, utilizados para predição da degradação dos capacitores de alumínio.

No Capítulo 4 serão apresentadas as métricas para avaliação dos resultados das predições como o coeficiente de correlação múltipla ( $R^2$ ), o erro quadrático médio (*Mean square error* - MSE), a precisão relativa (*Relative Accuracy* - RA), a vida útil remanescente (RUL) e o desempenho  $\alpha - \lambda$ .

No Capítulo 5 são mostrados e discutidos os resultados das predições e avaliados pelas métricas do coeficiente de correlação múltipla ( $R^2$ ), o erro quadrático médio (MSE), a precisão relativa (RA), a vida útil remanescente (RUL) e o desempenho  $\alpha - \lambda$ .

No Capítulo 6 serão comentadas as considerações finais do trabalho e sugeridas propostas para estudos futuros.

## 2 CAPACITOR ELETROLÍTICO


Neste capítulo será abordado a estrutura física do capacitor de alumínio, seus modos de falhas e a base de dados utilizada.

### 2.1 Estrutura do capacitor eletrolítico de alumínio

A configuração física de um capacitor eletrolítico de alumínio é ilustrada pela Figura 3. Os componentes primários de um capacitor eletrolítico são:

- Cátodo de folha de alumínio;
- Papel eletrolítico;
- Eletrólito;
- Uma camada de óxido de alumínio na superfície da folha de ânodo.

Figura 4 - Estrutura física do capacitor.




Fonte: Mundo da elétrica (2021).

Para a criação de uma camada de isolamento uma tira de papel impregnada com eletrólito líquido entra em contato com a camada de oxido de alumínio (GASPERI, 1996). Para fornecer altos valores de capacitância em um pequeno volume é usada uma folha de alumínio gravada de alta pureza com óxido de alumínio. Visto que a camada de óxido tem propriedades retificadoras, um capacitor tem polaridade. Se as folhas de ânodo e do cátodo forem revestidas com uma camada de óxido, os capacitores serão bipolares (CHEN, 2004).

A Figura 4 elucida como os componentes internos do capacitor são envolvidos em

forma de camadas cilíndricas.


Figura 5– Modelo físico do capacitor eletrolítico.



Fonte: Adaptado de Kulkarni (2013).

A Figura 5 apresenta uma visão detalhada da seção transversal da estrutura do capacitor eletrolítico de alumínio. Onde, as folhas de cátodo e ânodo sofrem o processo de anodização através do revestimento, fino, de óxido de alumínio na superfície da folha. Então, a camada de óxido de alumínio atua como dielétrico (isolante) e tem a função de bloquear o fluxo de corrente contínua entre o ânodo e a folha de superfície catódica. Quando uma tensão contínua é aplicada em um capacitor descarregado, inicialmente ocorre um pico de corrente por causa do acúmulo de carga no ânodo e nas folhas do cátodo.

Figura 6- Secção transversal da estrutura do capacitor eletrolítico de alumínio.



Fonte: Adaptado de Kulkarni (2013).

## 2.2 Modos de falha

Segundo Bhargava (2014), vários fatores influenciam na vida útil do capacitor. Está diretamente ligada a degradação do capacitor os parâmetros de variáveis elétricas e variáveis ambientais. Podem-se citar exemplos de variáveis elétricas tais como variações de corrente, tensão operacional e etc. Para as variáveis de ambiente pode-se destacar a temperatura, vibração, humidade e etc.

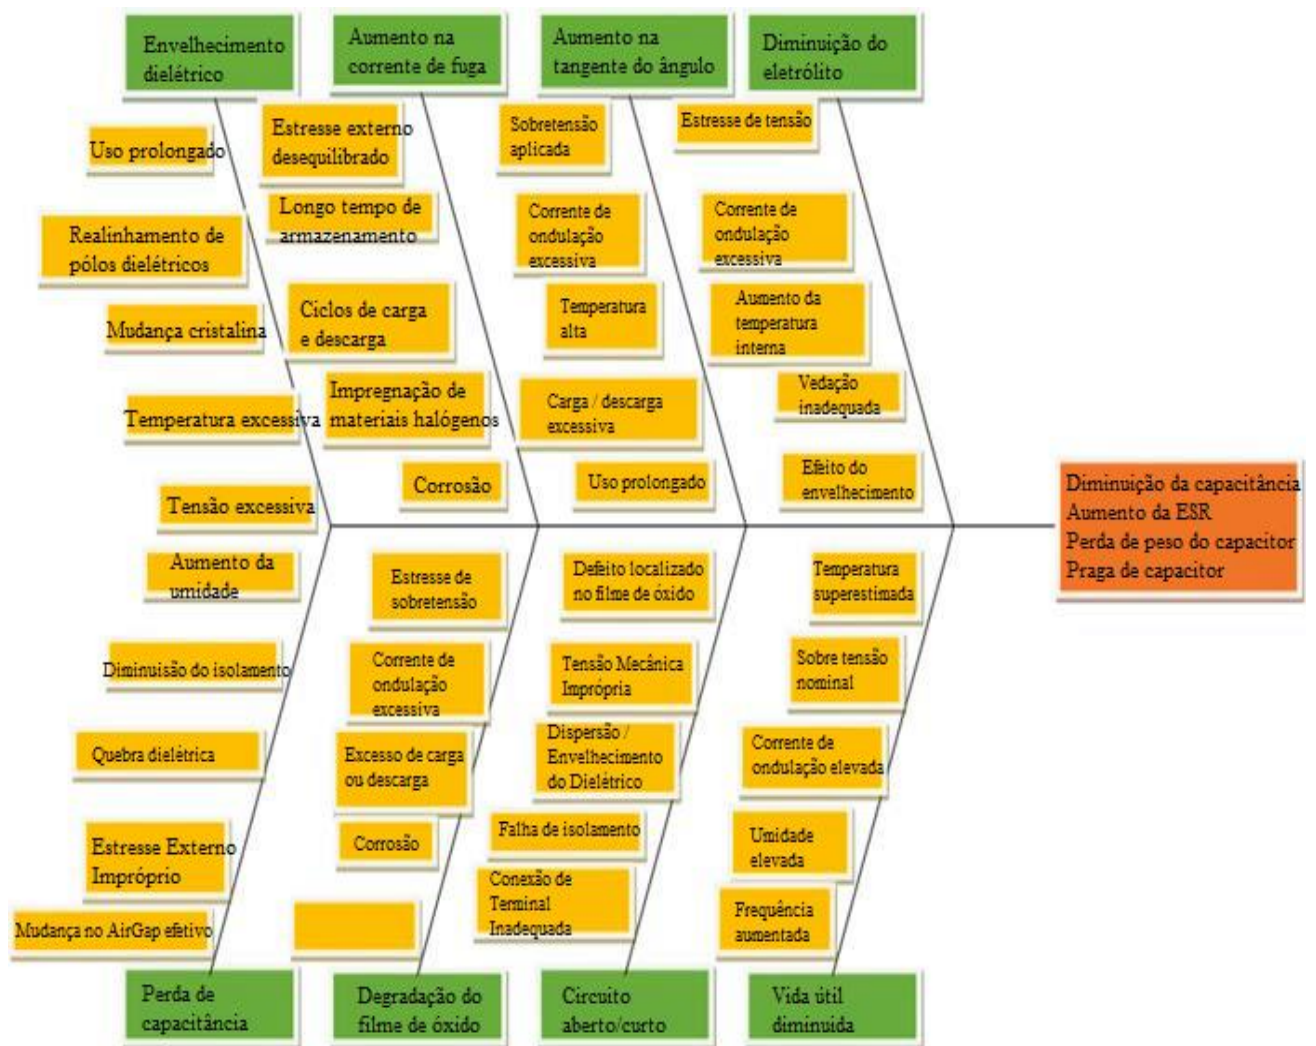
Durante a operação nominal do capacitor têm-se como principais causas de degradação os processos térmicos e elétricos. Durante o aumento da temperatura interna, devido o fluxo de corrente entre os ciclos de carga e descarga do capacitor, o calor gerado é transferido do núcleo até a superfície do corpo do capacitor, porém nem todo o calor consegue ser eliminado. O excesso de calor faz com que o aumento na temperatura interna do capacitor acelere a taxa de evaporação do eletrólito. Da mesma forma, o armazenamento ou operação do capacitor em ambientes com uma temperatura elevada faz com que o calor do corpo do capacitor fique elevado e o calor viaja do corpo ao núcleo do capacitor, por sua vez, aumentando assim a temperatura interna e consequentemente acelerando a taxa de evaporação

do eletrólito (CELAYA, 2012).

O diagrama de espinha de peixe (também chamado de diagrama de Ishikawa) para a causa e efeito da falha do capacitor, ilustrado pela Figura 6, resume as várias falhas em capacitores eletrolíticos, junto com suas causas primárias.

Vários métodos são propostos para a medição da degradação do capacitor eletrolítico de alumínio. A degradação do capacitor pode ser mesurada pela a perda da capacitância, aumento da resistência interna (*Equivalent series resistance* - ESR) e redução do peso do capacitor. Quando a capacitância diminui abaixo de um certo valor, o capacitor para de armazenar energia ou perde a função de filtro. Os elementos principais para a degradação do capacitor são o ambiente, o estresse de tensão e estresse mecânico (SANKARAN *et al.*, 1997).

Figura 7– Diagrama de espinha de peixe para falha no capacitor eletrolítico.



Fonte: Adaptado de Bhargava *et al.* (2017).

Segundo os padrões de fábrica (IEC-60068-1 e MIL-C-62F) para um capacitor ser classificado como sem saúde, em operações de estresse de tensão, a capacitância deve cair 20% e a sua resistência interna deve subir mais de 280% dos valores nominais. Essas taxas mudam se o estresse for causado por um estresse de temperatura. No estresse causado por temperatura o capacitor é considerado sem saúde se a capacitância cair 10% e a resistência interna aumentar 250% dos valores de fábrica.

As taxas de degradação, entre estresse de tensão e de temperatura, se diferenciam devido ao fato que em estresse de temperatura o capacitor se encontra estocado, diferente do estresse de tensão que se encontra em operação.

### **2.3 Critérios de falha para capacitores eletrolíticos**

Segundo Bhargava *et al.* (2017), para um capacitor eletrolítico de alumínio ser considerado defeituoso ele tem que seguir os seguintes critérios:

1. A capacitância for reduzida em 20 por cento de seu valor nominal;
2. O peso do capacitor cair por, pelo menos, 50% do valor nominal; e
3. O valor de ESR aumentar em 100% do valor nominal.

Assim que o aquecimento for acelerado, o eletrólito começará a evaporar e, conseqüentemente, diminuirá o valor da capacitância e aumentará o valor do ESR.

### **2.4 Base de Dados da NASA**


A base de dados utilizada foi coletada no experimento de (CELAYA, KULKARNI, BISWAS, GOEBEL, 2012) disponibilizada através do site do repositório da NASA (<https://ti.arc.nasa.gov/tech/dash/groups/pcoe/prognostic-data-repository/>). A mesma contém os dados de capacitância de seis capacitores. Que foram submetidos a um estresse de tensão, para identificar o comportamento da degradação e criar um modelo de degradação dependente do tempo.

No experimento foram utilizados capacitores eletrolíticos de 2200 $\mu$ F de capacitância, com uma tensão nominal máxima de 10V, corrente nominal de 1A e temperatura operacional máxima de 105°C. Os capacitores do experimento passaram pela medição de

Espectroscopia de impedância eletroquímica (*Electrochemical-impedance spectroscopy* (EIS)) antes do experimento e em diferentes estágios da execução do experimento.

No início do envelhecimento acelerado, os capacitores carregam e descarregam simultaneamente. À medida que o tempo avança e os capacitores se degradam a taxas diferentes, os tempos de carga e descarga variam para cada capacitor. Mesmo que todos os capacitores em teste estejam sujeitos às mesmas condições de carga e operação, seus valores de ESR e capacitância mudam de maneira diferente. Portanto, houve o monitoramento do carregamento e o descarregamento de cada capacitor em teste e a medição das tensões de entrada e saída do capacitor, bem como a corrente de carga. A Figura 7 ilustra o circuito elétrico do experimento de sobrecarga elétrica. Um gerador de função é usado para gerar uma forma de onda quadrada, que é amplificado até a amplitude desejada a ser aplicada ao capacitor. Uma carga resistiva foi usada em série com o capacitor para emular o lado de carga de um filtro passivo de primeira ordem.

Figura 8 – Diagrama de blocos da configuração experimental.




Fonte: Adaptado de CELAYA, KULKARNI, BISWAS, GOEBEL(2012).

As medidas do EIS foram registradas a cada 8 a 10 horas do total de mais de 180 horas de envelhecimento acelerado, a fim de capturar o fenômeno de degradação nos valores de resistência interna e capacitância. Durante cada medição, a fonte de tensão foi desligada, os capacitores foram descarregados completamente e, em seguida, o procedimento de caracterização do EIS foi realizado. Isso foi feito para todos os seis capacitores em teste. A bancada de teste com o experimento é apresentada na Figura 8.

Após o período de 196h foi coletada as informações da degradação de cada capacitor gerando o gráfico da porcentagem de perda de capacitância no tempo decorrido. Como mostra a Figura 9.

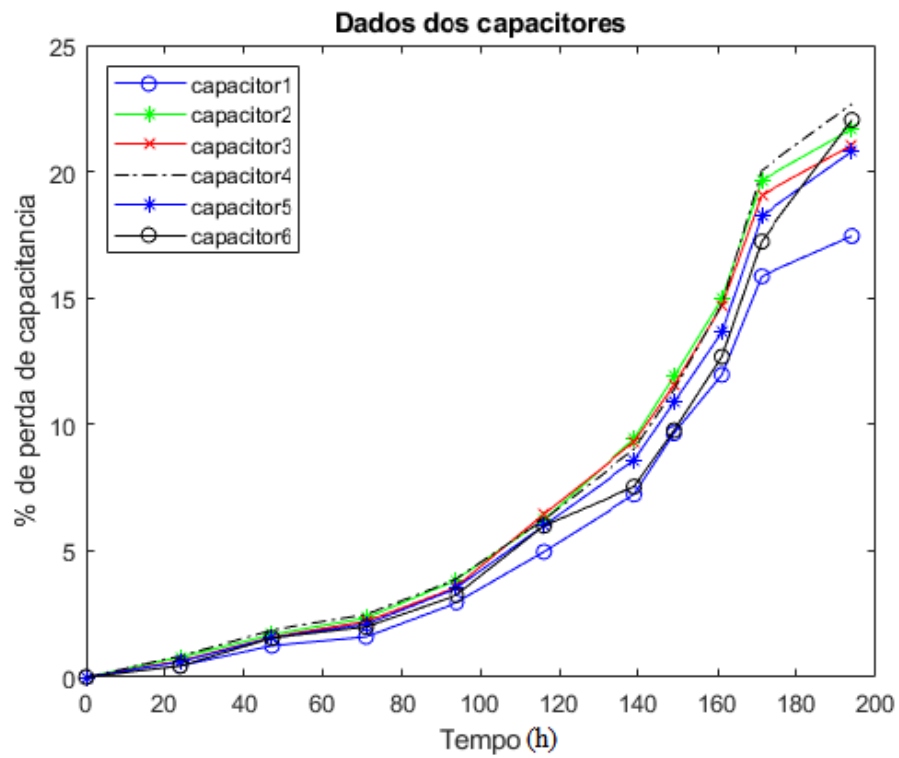


Figura 9 – Experimento de envelhecimento por estresse de tensão.



Fonte: Celaya, Kulkarni, Biswas e Goebel (2012).

Figura 10 – Gráfico da degradação dos capacitores pelo tempo.



Fonte: O Autor.




### 3 MÉTODOS E TÉCNICAS

Nesse capítulo será explanada as técnicas que serão utilizadas para as previsões do momento das falhas dos capacitores, que serão apresentadas no capítulo 5.

#### 3.1 Extreme Learning Machine

A ELM (*Extreme Learning Machine*) pode ser considerada uma rede neural do tipo *feedforward*, sem realimentação, com apenas uma camada de neurônios ocultos (HUANG *et al.*, 2006). A ELM, assim como a RBF (*Radial Basis Function*), tem semelhança com a MLP (*Multilayer Perceptron*). Porém, a ELM apresenta uma fase de aprendizado bem mais rápida que as redes anteriores (MESQUITA *et al.*, 2015). A ELM também consiste de uma camada de entrada, uma camada oculta, e uma camada de saída. A Figura 10 ilustra a estrutura de uma ELM.

Figura 11- Estrutura da rede ELM.



Fonte: Adaptado de Yang *et al.* (2018).

Apesar de que no exemplo utilizado a rede apresenta apenas uma saída, a mesma pode ser configurada com várias saídas.

A ELM é uma rede neural com pesos  $w$  e bias  $b$  aleatórios na camada oculta, sendo  $l$  a quantidade de neurônios utilizados.

Inicialmente a rede pesos de entrada randômicos para os pesos  $w$  e para bias  $b$ .

Em seguida determine a fórmula e a função de ativação. De acordo com a fórmula de cálculo da rede neural, a relação entre sua entrada e saída é a demonstrada pela equação 2.

$$\sum_{i=1}^L \beta_i \varphi(w_i, b_i, x_j) = t_j \quad (2)$$

Onde  $\varphi(\cdot)$  é a função de ativação.

A equação (2) pode ser representada de forma matricial, conforme apresentado em (3) (Yang *et al.* 2018).

$$H\varphi = T \quad (3)$$

Onde:

$$H = \begin{pmatrix} G(w_1, b_1, x_1) & \cdots & G(w_L, b_L, x_1) \\ \vdots & \ddots & \vdots \\ G(w_1, b_1, x_n) & \cdots & G(w_L, b_L, x_n) \end{pmatrix}_{N \times L} \quad (4)$$

Então é calculado o peso de saída. O valor da matriz inversa generalizada  $\beta$  é calculado pela Eq. (3)

$$\beta = H^+ T \quad (5)$$

Onde  $H^+$  é a Moore-Penrose generalizada inversa de H.

Com isso, pode-se observar que comparado com as redes tradicionais a ELM não contém passos de interação, o que reduz consideravelmente a complexidade computacional do processo de treinamento (Yang *et al.*, 2018).

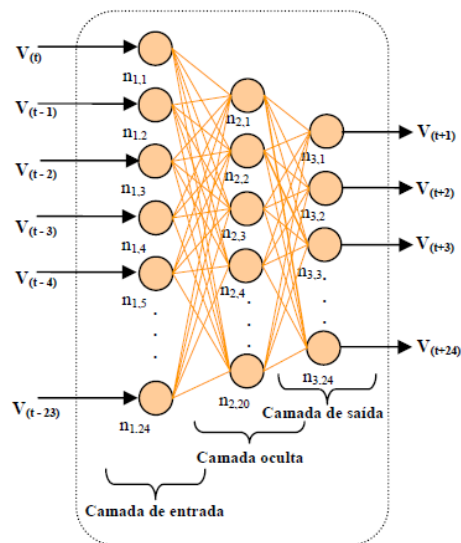
### 3.2 Multilayer perceptron (MLP)

Quando uma RNA é composta por várias camadas de neurônios artificiais, é atribuída a denominação de *Multilayer Perceptron* (MLP).

Uma arquitetura de rede neural é a MLP, que comumente utiliza a técnica de treinamento supervisionado de retropropagação do erro (*Error back-propagation*). O *backpropagation* pode ser dividido em duas etapas distintas e complementares. A primeira etapa é a de propagação do sinal. Onde o sinal de entrada é apresentado aos neurônios e é propagado camada por camada até que sejam encontradas as saídas da rede. Nesta etapa não ocorre o ajuste dos pesos sinápticos, os mesmos serão ajustados na etapa seguinte. Na

segunda etapa, onde ocorre a retropropagação, as saídas encontradas na etapa anterior são comparadas com as saídas desejadas (os *targets*) e o sinal do erro é propagado no sentido contrário ao realizado na primeira etapa. Então os pesos sinápticos podem ser ajustados com o intuito de tornar a saída encontrada mais próxima da saída real da rede. A Figura 11 ilustra de forma esquemática uma rede neural MLP.

Figura 12 - Esquema de uma rede MLP.



Fonte: Oliveira (2008).

Através da Figura 11, pode-se observar a estrutura básica de uma rede MLP, com a camada entrada, a camada oculta, e a camada de saída.

Os neurônios da rede neural comunicam-se entre si através conexões semelhantes às sinapses biológicas. Eles são capazes de analisar e aprender relações não lineares que existem entre uma entrada e uma saída.

O *back-propagation* é um algoritmo supervisionado no qual utiliza pares de entrada e saída desejada, para que por meio de um mecanismo de correção de erro possa ajustar os pesos da rede.

O treinamento ocorre em duas etapas, em que cada uma percorre um sentido da rede. Essas etapas são definidas como *forward* e *backward*.

Na etapa *forward* é utilizada para definir a saída da rede para um dado padrão de entrada, onde o vetor de entrada é apresentado aos neurônios da rede e propaga seu efeito camada por camada, nessa etapa os pesos da rede são fixos.

Na etapa *backward* é utilizada a saída desejada e a saída fornecida pela rede para atualizar os pesos de suas conexões, onde a resposta real da rede é subtraída da resposta

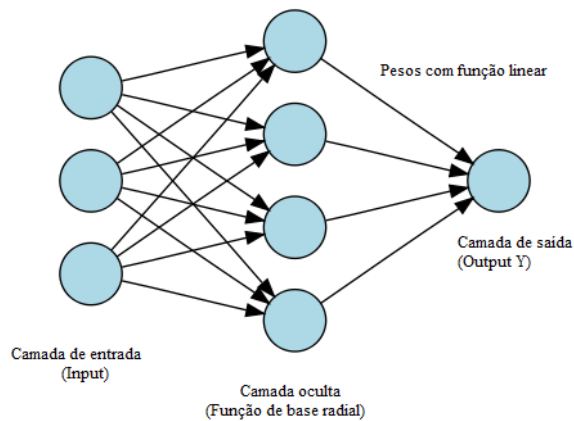
desejada para produzir o sinal de erro. Então esse sinal é retro propagado através da rede ajustando os pesos sinápticos com o objetivo que a resposta da rede se aproxime da resposta desejada (Santos, 2008).

### 3.3 Radial Basis Function (RBF)

Assim como na MLP, a rede RBF também utiliza técnicas de aprendizado de retropropagação do erro, nas interligações da camada intermediária com a camada de saída que ocorre após a etapa que definição dos centros e espalhamento dos centros gaussianos. Porém, a rede RBF consiste de uma única camada oculta e uma camada de saída, diferente da MLP que pode conter várias camadas ocultas (MOTA *et al.*, 2011).

A Figura 12 mostra um esquema que representa uma rede RBF. É possível observar a semelhança da rede RBF com a rede MLP. No entanto, a rede RBF possui uma função de base radial como função de ativação da camada oculta, e na camada de saída utiliza funções de ativação linear (MOTA *et al.*, 2011).

Figura 13 - Estrutura de uma rede RBF.





Fonte: O autor.



A função de base radial tem uma importância vital para o aprendizado da rede RBF. Tendo como característica a resposta diminuir (ou aumentar) com a distância de um ponto central. Algumas funções de base radial estão ilustradas pela Figura 13.

Figura 14 - Exemplos de funções de base radial utilizadas.


(a) Função gaussiana em duas dimensões. (b) Função gaussiana em três dimensões.




(c) Função sombrero mexicano em duas dimensões. (d) Função sombrero em três dimensões.



(e) Função thin-plate spline em duas dimensões.



(f) Função thin-plate spline em três dimensões.




Fonte: Vieira (2017).

Assim como na rede MLP, o treinamento da RBF ocorre de forma supervisionada. Então o treinamento visa reduzir o erro entre os padrões apresentado à rede e os valores de saída obtidos. A redução da distância entre os dados ocorre pelos ajustes nos parâmetros livres na rede RBF. Os principais parâmetros a serem ajustados são: o desvio padrão, os centros das regiões e os pesos da rede.

Podem-se notar similaridades e diferenças entre as redes MLP e RBF. Como similaridade, ambas apresentam camadas com saídas não lineares. Contudo, na RBF a camada escondida é não linear enquanto a camada de saída é linear. Na MLP as camadas escondidas e de saídas são, na maioria das vezes, do tipo não linear. Nas MLP o argumento da função de ativação é a soma dos produtos de cada uma das entradas pelos pesos sinápticos do neurônio. Com isso o mapeamento das regiões de classificação é realizado de maneira distinta por cada uma destas redes. Uma rede RBF constrói aproximações locais para o mapeamento entrada-saída, diferente de uma rede MLP que atinge aproximações globais para encontrar as regiões de classificação. A Figura 14 ilustra um exemplo da diferença entre as classificações (VIEIRA, 2017).

Figura 15 - Comparação entre o mapeamento das redes RBF e MLP.

(a) Mapeamento global de uma rede MLP. (b) Mapeamento local de uma rede RBF.



Fonte: Vieira (2017).

### 3.4 Regressão por processo gaussiano

Os modelos de regressão de processo gaussiano (ou, do inglês, *Gaussian Process Regression* - GPR) são modelos probabilísticos não paramétricos baseados em cernes (*kernel*).

O processo gaussiano (PG) é definido pela coleção de variáveis aleatórias que possui uma distribuição gaussiana conjunta (RASMUSSEN e WILLIAMS, 2006).

Assim como uma gaussiana, um Processo Gaussiano é definido por uma função de média  $m_X$  que é usualmente assumida como zero. Além disso, um PG também é definido por uma função covariância  $K_{XX}$ , que é conhecida como *kernel* (CAIXETA, 2016)

Um processo gaussiano (PG) define uma distribuição de probabilidade sobre funções e é denotado pela equação 7, como em Lima (2019):

$$f(X) \sim GP(m(X), K(X, X')) \quad (6)$$

Em que  $m(X)$  é da mesma dimensão de  $X$ , e  $K$  tem dimensões  $XX^T$ . E são denotadas pelas equações 8 e 9:  $\mathbb{E}$

$$m(X) = \mathbb{E}[f(X)] \quad (7)$$

$$K(X, X') = \mathbb{E}[(f(X) - m(X))(f(X') - m(X'))^T] \quad (8)$$

Para qualquer coleção finita de pontos de entrada, digamos  $X = X_1, \dots, X_n$ , este processo define uma distribuição de probabilidade  $p(f(X_1), \dots, f(X_n))$  que é conjuntamente gaussiana, com alguma média  $m(X)$  e covariância  $K(X)$ , dado que  $K_{ij} = K(X_i, X_j)$ .

A equação padrão para utilização do *kernel* é a exponencial quadrada decrescente, ou curva de Gauss. A função de covariância especifica a covariância entre pares de variáveis aleatórias. Como demonstrado pela equação 10 abaixo.


$$k(x, x') = \sigma^2 \exp\left(-\frac{\|x - x'\|^2}{2l^2}\right) \quad (9)$$

Os termos  $\sigma$  e  $l$  são os controladores das escalas de  $y$  e  $x$ , respectivamente.

Assumindo que uma função  $f$  é descrita por um PG, tem por especificação que as funções de média e covariância observadas implicam em uma distribuição sobre  $f$ .

Como exemplo, pode-se considerar uma variável aleatória  $f_i$  como descrita para o valor de uma função de  $x_i$  e tiram-se amostras destas distribuições. Pode-se gerar várias amostras de trajetórias possíveis deste processo estocástico. A Figura 15 demonstra cinco trajetórias, que mostram curvas suaves devido ao *kernel* exponencial quadrático decrescente. Na Figura 15 não há a dados a serem observados, cada trajetória é de forma arbitrária e corresponde a um vetor  $y$  de tamanho 100 e valores de  $x$  uniformemente espaçados.

Figura 16 – Trajetórias de Processos Gaussianos.




Fonte: Caixeta, 2016.

Quando existem dados a serem observados, podem-se gerar trajetórias usando distribuições condicionadas a essas amostras. As trajetórias são obtidas de maneira semelhante à distribuição a priori, contudo ocorre a alteração da média e diminuída a variância perto dos pontos observados, como demonstra a Figura 16.

É fácil ver que a função de covariância influencia no ajuste da interpolação da média e da variância. Ajustando a função de covariância e com a introdução de parâmetros pode-se obter os valores mais adequados possíveis aos dados. Dessa forma pode-se justificar a entrada dos parâmetros  $\sigma$  e  $l$  na equação 10 do *kernel*.

Figura 17 – Amostras da distribuição de um Processo gaussiano.



Fonte: Caixeta, 2016.



Considerando o modelo da equação 11 abaixo.

$$h(x)^T \beta + f(x) \quad (10)$$

Onde  $f(x) \sim \text{GP}(0, K(X, X'))$ , na qual  $f(x)$  é um GP com média zero e função de covariância  $K(X, X')$ . E  $h(x)$  é um conjunto de funções básicas que transformam o vetor de características original  $X$  em  $\mathbb{R}^d$  em um novo vetor de características  $h(x)$  em  $\mathbb{R}^p$ .  $\beta$  é um vetor p-por-1 dos coeficientes da função de base. Este modelo representa um modelo GPR. Um exemplo de como uma resposta  $y$  pode ser modelada é demonstrada pela equação 12

$$P(y_i | f(x_i), x_i) \sim N(y_i | h(x_i)^T \beta + f(x_i), \sigma^2) \quad (11)$$

Portanto, um modelo GPR é um modelo probabilístico. Existe uma variável latente  $f(x_i)$  introduzida para cada observação  $x_i$ , o que torna o modelo GPR não paramétrico. Na forma vetorial, este modelo é equivalente a equação 13.

$$P(y | f, X) \sim N(y | H\beta + f, \sigma^2 I) \quad (12)$$

Onde:

$$X = \begin{pmatrix} x_1^T \\ x_2^T \\ \dots \\ x_n^T \end{pmatrix}, \quad y = \begin{pmatrix} y_1 \\ y_2 \\ \dots \\ y_n \end{pmatrix}, \quad H = \begin{pmatrix} h(x_1^T) \\ h(x_2^T) \\ \dots \\ h(x_n^T) \end{pmatrix}, \quad f = \begin{pmatrix} f(x_1) \\ f(x_2) \\ \dots \\ f(x_n) \end{pmatrix}.$$

## 4 INDICADORES DE DESEMPENHO

Vários indicadores são utilizados para avaliar o desempenho de previsões, apesar de nenhum ser considerado o método padrão. Nesse capítulo serão explanados os indicadores de desempenho utilizados na pesquisa realizada.

### 4.1 Coeficiente de determinação

O coeficiente de determinação, mais conhecido como  $R^2$ , indicado pela equação 14, consegue julgar a adequação do quanto a previsão foi capaz de se aproximar dos dados do experimento (CASELLA e BERGER, 2002).

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2} \quad (15)$$

Onde:

$y_i$ : dados observados;

$\bar{y}$ : é a média dos dados observados;

$\hat{y}_i$ : dados estimados pelo modelo.

Note que:

$$0 \leq R^2 \leq 1 \quad (16)$$

No qual  $R^2 = 1$  simboliza um resultado perfeito.

Essa métrica deve ser usada com cautela, já que a mesma é dependente da quantidade de observações ( $i$ ) que gera um crescimento de  $R^2$  com a diminuição de ' $i$ '. Sempre que  $i = 2$ , o valor de  $R^2$  será sempre igual a 1.

Embora com a adição de termos ao modelo gere um aumento nos valores de  $R^2$  não significa que o novo modelo é superior ao anterior, devido a perda de 1 grau de liberdade. Na realidade o novo modelo pode ser pior que o anterior.

## 4.2 Erro quadrático médio

O erro quadrático médio (no inglês, *Mean Square Error* - MSE), indicado pela equação 16, tem por definição a média da diferença entre os valores do estimador e do modelo ao quadrado (CASELLA e BERGER, 2002).

$$MSE(i) = \frac{1}{L} \sum_{l=1}^L (\hat{y}_i - y_i)^2 \quad (17)$$

Onde  $L$  é o número de pontos observados.

Quando o valor de  $MSE = 0$  simboliza um resultado perfeito.

Essa métrica é muito útil para gerar comparações entre estimadores. Se os estimadores não forem viciados o mais eficaz será o que obteve melhores valores para o MSE.

Como o MSE é uma função do parâmetro, não deve ser utilizado como o único parâmetro de comparação. Porém o mesmo serve como um guia para a escolha dos estimadores.

## 4.3 Precisão relativa

Para avaliar o desempenho das diferentes estimadores na previsão do RUL, é utilizada a métrica da precisão relativa (*Relative Accuracy* - RA), definido em 17 (SAXENA *et al.*, 2010).

$$RA = 100 \left( 1 - \frac{|RUL^* - RUL'|}{RUL^*} \right) \quad (18)$$

A métrica RA permite uma avaliação da precisão percentual em relação ao valor do RUL verdadeiro ( $RUL^*$ ) e do RUL estimado ( $RUL'$ ). Valores de RA de 100 representam uma precisão perfeita.

## 4.4 Desempenho $\alpha - \lambda$

Essa métrica tem por objetivo quantificar a qualidade da predição do RUL dentro de uma faixa de desempenho de níveis aceitáveis em momentos determinados. Esses

pontos podem ser especificados como porcentagem da vida útil restante total partindo do primeiro ponto de predição ou em um determinado intervalo de tempo antes que o EOL seja atingido (SAXENA *et al.*, 2010).

O nível de precisão a ser analisada por ser definido pelo coeficiente  $\alpha$ . Por exemplo, essa métrica pode determinar se a previsão está em uma faixa de precisão de 20%.

Para a criação do gráfico de desempenho da Figura 18 é utilizada a equação 19.

$$[1-\alpha] \cdot RUL^*(t) \leq RUL'(t_\lambda) \leq [1+\alpha] \cdot RUL^* \quad (19)$$

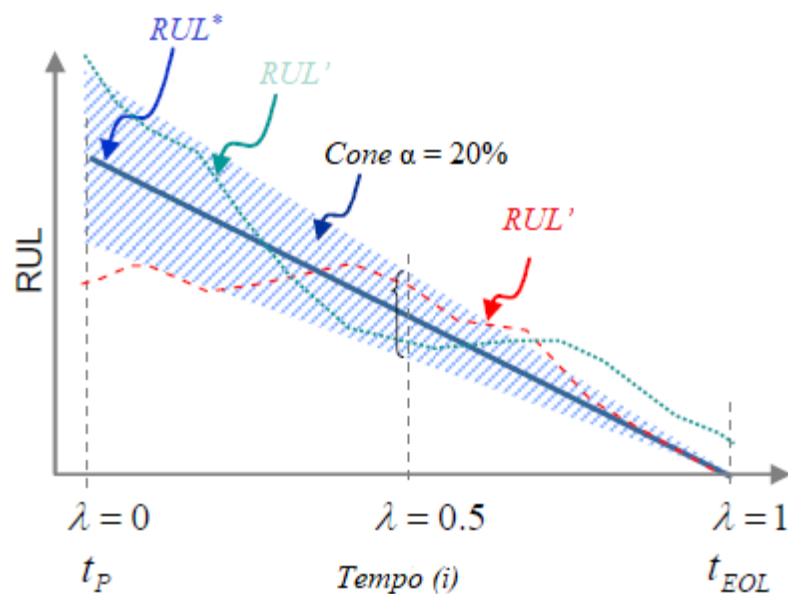
Onde:

$\alpha$  : modificador de precisão;

$\lambda$  : janela de tempo de modificação;

$t_\lambda$  :  $P + \alpha(EOL - P)$ .

Figura 18 - Esquema representando a precisão de  $\alpha$ - $\lambda$ .



Fonte: Modificado de (SAXENA *et al.*, 2009)

## 5 RESULTADOS E DISCUSSÕES

Para a predição da degradação e saúde dos capacitores foram utilizadas quatro técnicas preditivas: RNA ELM, RNA MLP, RNA RBF e GPR. Conforme foram apresentados nos capítulos anteriores. Neste capítulo são explanados os resultados das previsões dos seis capacitores.

### 5.1 Resultados da RNA ELM

As RNA são indispensáveis para o critério de comparação de previsões. Foi utilizado na RNA ELM. Após vários treinamentos utilizando diferentes parâmetros para a rede, das quais se iniciaram com 60 neurônios e passo de aprendizagem de 0,5, os melhores resultados foram obtidos com as seguintes configurações:

- Neurônios na camada escondida: 9;
- Passo de aprendizagem: 0,1;
- Função de ativação: sigmoidal.

E para cada entrada de dados, que se iniciou pela entrada a 116h da base de dados, foi definido os pesos  $W$  fixos de cada simulação adquiridos da camada oculta de cada entrada de dado, que são:

$$W = \begin{bmatrix} 0.0110 & 0.0469 & -0.2882 & 0.0450 & 0.0795 & 0.0454 & -0.0575 \\ -0.1161 & -0.0657 & -0.0047 & -0.0273 & 0.1037 & -0.0042 & 0.1442 \\ -0.0398 & -0.1717 & -0.0462 & -0.0101 & 0.2360 & 0.0458 & 0.0236 \\ 0.0254 & 0.1471 & -0.0577 & -0.1429 & 0.1175 & -0.0264 & 0.1021 \\ 0.1208 & 0.0694 & -0.0846 & -0.0764 & 0.0398 & -0.0292 & -0.0140 \\ -0.1034 & -0.0511 & -0.1817 & 0.0410 & 0.1951 & -0.0387 & -0.0082 \\ 0.1295 & 0.0113 & -0.0522 & -0.0790 & -0.0905 & -0.0554 & 0.1258 \\ 0.2768 & -0.0230 & 0.0161 & 0.0162 & -0.0682 & -0.0944 & 0.1469 \\ -0.0495 & -0.1462 & -0.1062 & 0.1978 & 0.2018 & -0.0060 & 0.0033 \end{bmatrix}$$

$$W_2 = \begin{bmatrix} 0.0199 & 0.0799 & -0.0308 & -0.0617 & 0.0867 & -0.1167 & 0.0751 & 0.2227 \\ -0.1521 & 0.0120 & -0.0132 & 0.0275 & -0.0080 & -0.1854 & 0.1778 & -0.0069 \\ -0.0724 & 0.0571 & 0.0595 & 0.0601 & 0.0898 & -0.1141 & 0.1223 & -0.0507 \\ -0.0593 & 0.0413 & 0.1047 & 0.0092 & 0.0184 & -0.1093 & -0.1283 & 0.0236 \\ 0.0401 & -0.0987 & -0.0198 & 0.1730 & 0.0291 & -0.0434 & -0.2329 & 0.0246 \\ 0.0942 & 0.0760 & 0.0328 & -0.0609 & 0.0113 & -0.0168 & 0.0902 & 0.0070 \\ 0.0300 & -0.0657 & -0.0238 & -0.0737 & 0.0440 & -0.0219 & -0.1836 & -0.0609 \\ -0.0373 & -0.0604 & 0.0230 & -0.1750 & 0.0102 & 0.0541 & 0.0067 & -0.1223 \\ 0.0815 & 0.0177 & 0.0440 & 0.0910 & 0.2787 & 0.0389 & 0.0035 & 0.0317 \end{bmatrix}$$

$$W_3 = \begin{bmatrix} 0.1236 & 0.1357 & 0.1542 & -0.0481 & -0.1223 & -0.0365 & -0.1486 & -0.1104 & -0.0720 \\ 0.0083 & -0.1197 & -0.0413 & 0.0804 & -0.0570 & 0.1827 & 0.0352 & 0.0741 & 0.1777 \\ -0.0030 & 0.1757 & -0.0451 & -0.0004 & -0.0505 & 0.0873 & 0.1036 & -0.1682 & -0.0868 \\ -0.0661 & -0.0985 & -0.1313 & -0.0443 & -0.0441 & 0.1220 & 0.1356 & -0.0295 & 0.0171 \\ -0.0557 & 0.2571 & -0.1174 & 0.0503 & -0.0469 & -0.0980 & -0.0918 & 0.0140 & 0.2042 \\ -0.0101 & 0.0199 & -0.0579 & 0.0505 & -0.0510 & -0.1828 & 0.0605 & 0.1093 & 0.1054 \\ 0.0128 & -0.0439 & 0.0360 & 0.2025 & -0.0237 & 0.0327 & 0.0614 & -0.0359 & -0.0017 \\ 0.0389 & -0.2021 & -0.2062 & -0.1301 & 0.0428 & 0.0344 & -0.0032 & -0.1392 & 0.0479 \\ 0.1635 & -0.0398 & 0.0667 & -0.0702 & 0.1114 & -0.1700 & -0.1052 & 0.0348 & 0.2403 \end{bmatrix}$$

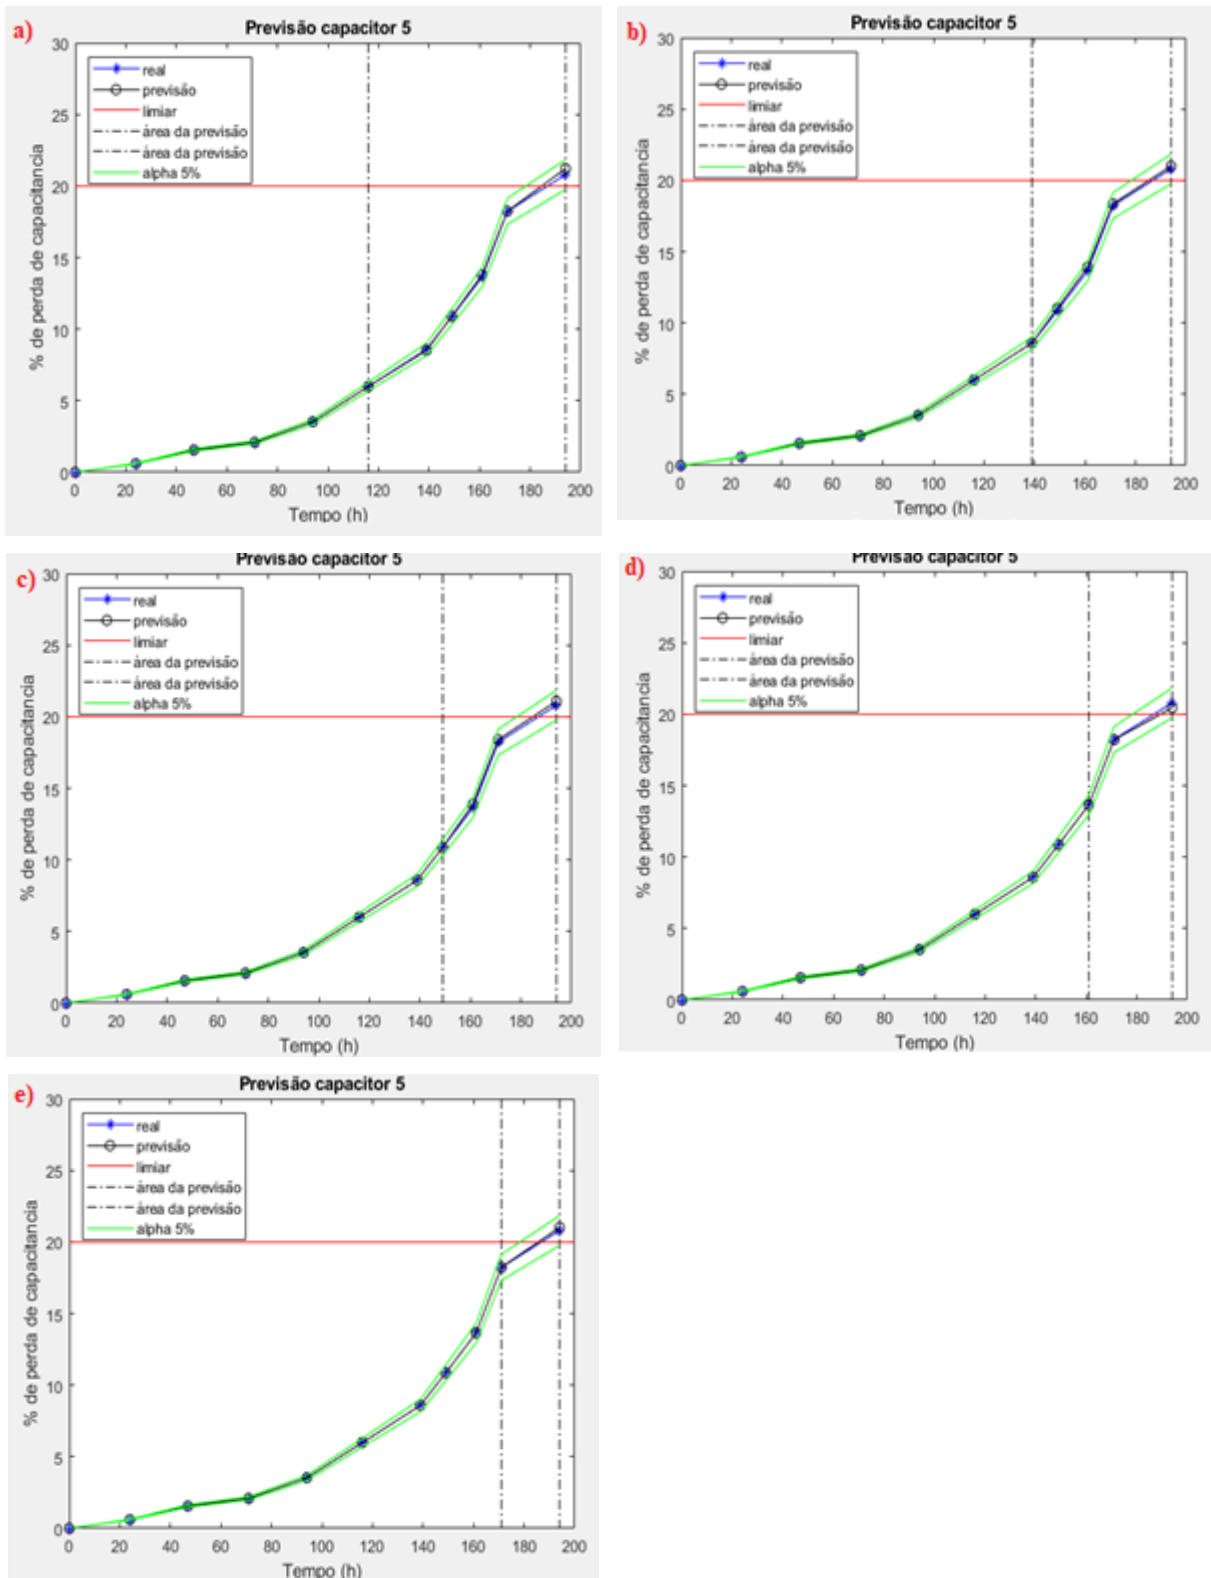
$$W_4 = \begin{bmatrix} -0.0239 & 0.0946 & -0.0212 & -0.3079 & -0.1186 & 0.0618 & -0.1190 & -0.2073 & -0.0088 & -0.1228 \\ -0.0843 & -0.0107 & -0.1566 & -0.0923 & 0.0429 & 0.0339 & 0.0128 & -0.1266 & 0.1372 & 0.1048 \\ -0.0413 & 0.0056 & -0.0538 & -0.1455 & -0.0586 & 0.0384 & -0.1166 & -0.0702 & -0.1830 & 0.0342 \\ 0.1183 & 0.1013 & 0.2910 & -0.0213 & 0.1417 & -0.0327 & 0.1363 & -0.0328 & -0.0961 & 0.0570 \\ 0.0782 & -0.0273 & 0.0493 & 0.1074 & -0.0117 & -0.0128 & 0.0821 & -0.1312 & -0.0471 & -0.0015 \\ 0.1172 & 0.0431 & 0.0215 & 0.0516 & -0.1519 & -0.0134 & -0.0539 & 0.0655 & 0.0555 & -0.0997 \\ -0.0214 & -0.0718 & -0.0409 & -0.0444 & 0.0079 & -0.0128 & 0.2065 & -0.0523 & -0.1023 & -0.1600 \\ 0.0151 & -0.0532 & -0.1819 & -0.1627 & 0.0717 & -0.1456 & 0.1139 & -0.0165 & -0.0525 & 0.0153 \\ -0.1814 & 0.0542 & 0.0136 & -0.0533 & -0.0496 & -0.0018 & 0.0853 & -0.0549 & 0.0703 & 0.0716 \end{bmatrix}$$

$$W_5 = \begin{bmatrix} -0.2525 & -0.0080 & 0.0917 & 0.0184 & 0.0699 & 0.0297 & 0.0439 & -0.0600 & 0.0230 & -0.0477 & 0.0667 \\ -0.1006 & 0.0334 & -0.0409 & 0.0325 & -0.0026 & 0.0159 & 0.1458 & 0.0096 & 0.0270 & 0.0312 & -0.0654 \\ -0.0424 & 0.0346 & 0.0401 & -0.0362 & 0.0328 & 0.0046 & -0.0287 & 0.1121 & 0.1327 & -0.0216 & -0.1527 \\ -0.0661 & -0.0119 & 0.0635 & -0.0045 & -0.0701 & -0.0111 & -0.0291 & 0.0562 & 0.1556 & -0.1352 & -0.1532 \\ 0.0728 & 0.0716 & 0.3331 & -0.0102 & -0.2166 & 0.1945 & -0.1456 & -0.0082 & -0.1863 & -0.0348 & 0.0807 \\ 0.0457 & 0.0228 & -0.0718 & -0.0302 & 0.0050 & -0.1158 & 0.0303 & -0.0844 & 0.1094 & -0.1907 & -0.0120 \\ -0.0506 & 0.0047 & -0.0204 & -0.0854 & 0.0626 & 0.0201 & 0.1037 & 0.0061 & -0.0649 & 0.1582 & 0.1063 \\ -0.1185 & -0.1065 & -0.0430 & -0.0719 & 0.1144 & 0.0442 & -0.1257 & 0.0539 & -0.1312 & -0.0644 & -0.0468 \\ 0.0782 & 0.0040 & -0.1533 & -0.0917 & -0.1822 & -0.1977 & -0.1351 & -0.0722 & -0.0606 & 0.0695 & -0.2927 \end{bmatrix}$$

Com o mesmo resultado dos pesos foi simulado a previsão de todos os capacitores. Para a predição foi definido um limiar de falhar de 20% para a perda de capacitância, também se avaliou a qualidade da previsão utilizando as métricas de correlação múltipla ( $R^2$ ) e erro médio quadrático (MSE).

O resultado da melhor previsão da falha do capacitor pode ser observado pela Figura 19. Onde a linha azul com estrelas representa os valores reais do capacitor, a linha preta com bolas representa os valores da previsão, a linha vermelha representa o limiar de falha (*threshold*) fixado em 20%, a linha pontilhada representa a área da previsão, que está entre 116 e 194h, e a linha verde representa o intervalo de confiança de 95%.

Figura 19 – Previsão de falha do capacitor 5 utilizando a rede ELM. a) previsão no tempo de 116h, b) previsão no tempo de 139h, c) previsão no tempo de 149h, d) previsão no tempo de 161h, e) previsão no tempo de 171h.



Fonte: O Autor.

As Figuras contendo as demais previsões, dos outros capacitores, se encontram nos Anexos da dissertação. Através da Figura 19, acima, pode-se observar o momento que a previsão obtém o valor de *threshold*, definido em 20%, está contido no intervalo de confiança de 95%.

Todos os valores das métricas  $R^2$  e MSE para os resultados de cada capacitor foram organizados e podem ser observados pela Tabela 1.

Tabela 1. Indicadores de desempenho para a rede ELM.

Tempo (h)	Capacitor 1		Capacitor 2		Capacitor 3		Capacitor 4		Capacitor 5		Capacitor 6	
	$R^2$	MSE	$R^2$	MSE	$R^2$	MSE	$R^2$	MSE	$R^2$	MSE	$R^2$	MSE
116	0,850	2,15	0,996	0,089	0,976	0,469	0,961	1,025	0,998	0,039	0,990	0,272
139	0,835	1,569	0,994	0,097	0,956	0,606	0,965	0,677	0,997	0,039	0,977	0,496
149	0,859	0,748	0,975	0,198	0,988	0,088	0,969	0,339	0,993	0,058	0,933	0,976
161	-2,61	2,304	0,684	0,32	-0,11	1,101	0,365	1,103	0,963	0,061	0,727	1,578
171		0,231		0,211		1,641		3,781		0,048		1,094

Fonte: O Autor.

Pode-se observar que, conforme a Tabela 1, com exceção do capacitor 1 que tem um resultado discrepante (*outlier*) as outras previsões apresentam um bom resultado com todas as previsões de  $R^2$  acima de 0.9 e resultados de MSE abaixo de 1.

Os valores do RUL da previsão para cada capacitor estão apresentados pela Tabela 2. São apresentados os valores dos capacitores 2 a 6 devido ao resultado discrepante (*outlier*) do capacitor 1, que não chega a ultrapassar o limiar de falha.

Tabela 2. Estimativas de RUL dos capacitores da rede ELM.

Tempo (h)	Capacitor 2		Capacitor 3		Capacitor 4		Capacitor 5		Capacitor 6	
	RUL*	RUL'	RUL*	RUL'	RUL*	RUL'	RUL*	RUL'	RUL*	RUL'
116	59,04	60,89	65,92	62,70	54,92	55,02	70,86	69,34	68,24	72,18
139	36,04	38,51	42,92	47,29	31,92	31,38	47,86	46,34	45,24	48,59
149	26,04	30,01	32,92	31,75	21,92	22,86	37,86	35,75	35,24	41,62

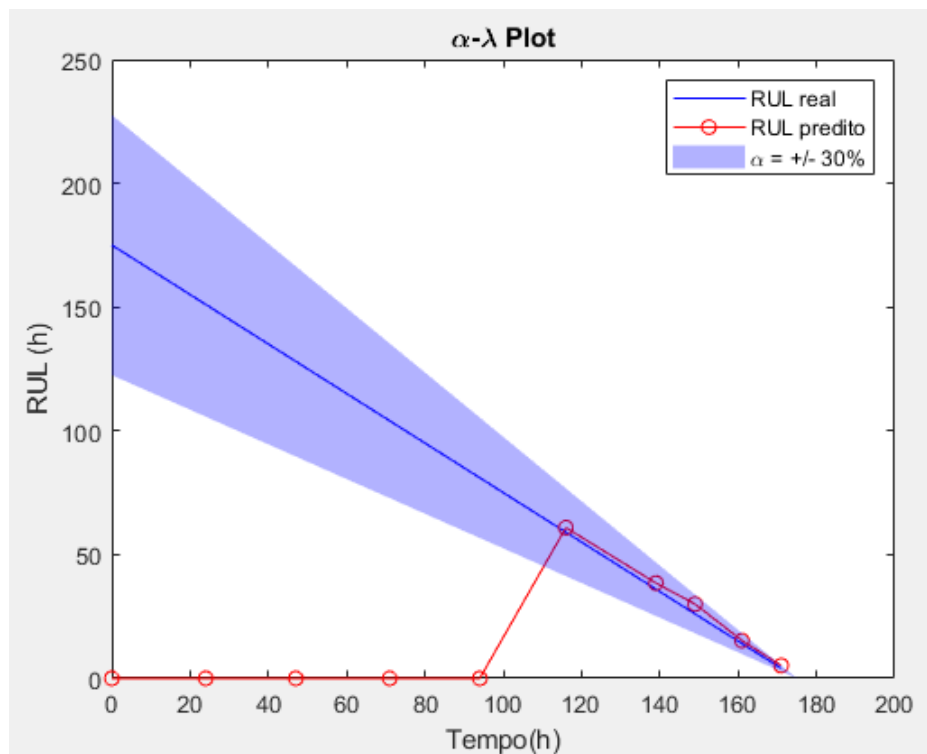


<b>161</b>	14,04	15,26	20,92	16,69	9,92	10,65	25,86	28,39	23,24	30,76
<b>171</b>	4,04	5,21	10,92	6,65	-0,08	-0,076	15,86	14,61	13,24	16,92

Fonte: O Autor.

Para uma melhor interpretação dos resultados do RUL será utilizada a Figura 20 que utiliza a métrica de desempenho  $\alpha - \lambda$  para a simulação da previsão do capacitor 2. Pode-se observar que todos os resultados da previsão estão contidos no intervalo de confiança de  $\alpha = 30\%$ .

Figura 20 – Desempenho  $\alpha - \lambda$  da previsão do RUL através da rede ELM do capacitor 2.



Fonte: O Autor.

A métrica RA, que utilizará os resultados do RUL obtidos nessa sessão, será utilizada em um tópico futuro como uma comparação entre os resultados de cada método preditivo.

## 5.2 Resultados da RNA MLP

O funcionamento da MLP foi explanado no capítulo 3. A mesma foi configurada da seguinte forma:

- Neurônios na camada escondida: 9;
- Epocas: 1500;

- Número máximo de falhas: 1000;
- Função de ativação: sigmoidal;
- Função na camada de saída: linear.

A quantidade de épocas e de falhas foi definida acima do padrão para que a RNA seja forçada a um treinamento mais eficiente.

Como a MLP possui pesos aleatórios a mesma foi treinada 10 vezes para cada simulação, gerando os resultados da Tabela 3 que contém os indicadores das métricas  $R^2$  e MSE dos melhores resultados. Os resultados completos das simulações se encontram nos anexos.

Tabela 3. Indicadores de desempenho da rede MLP.

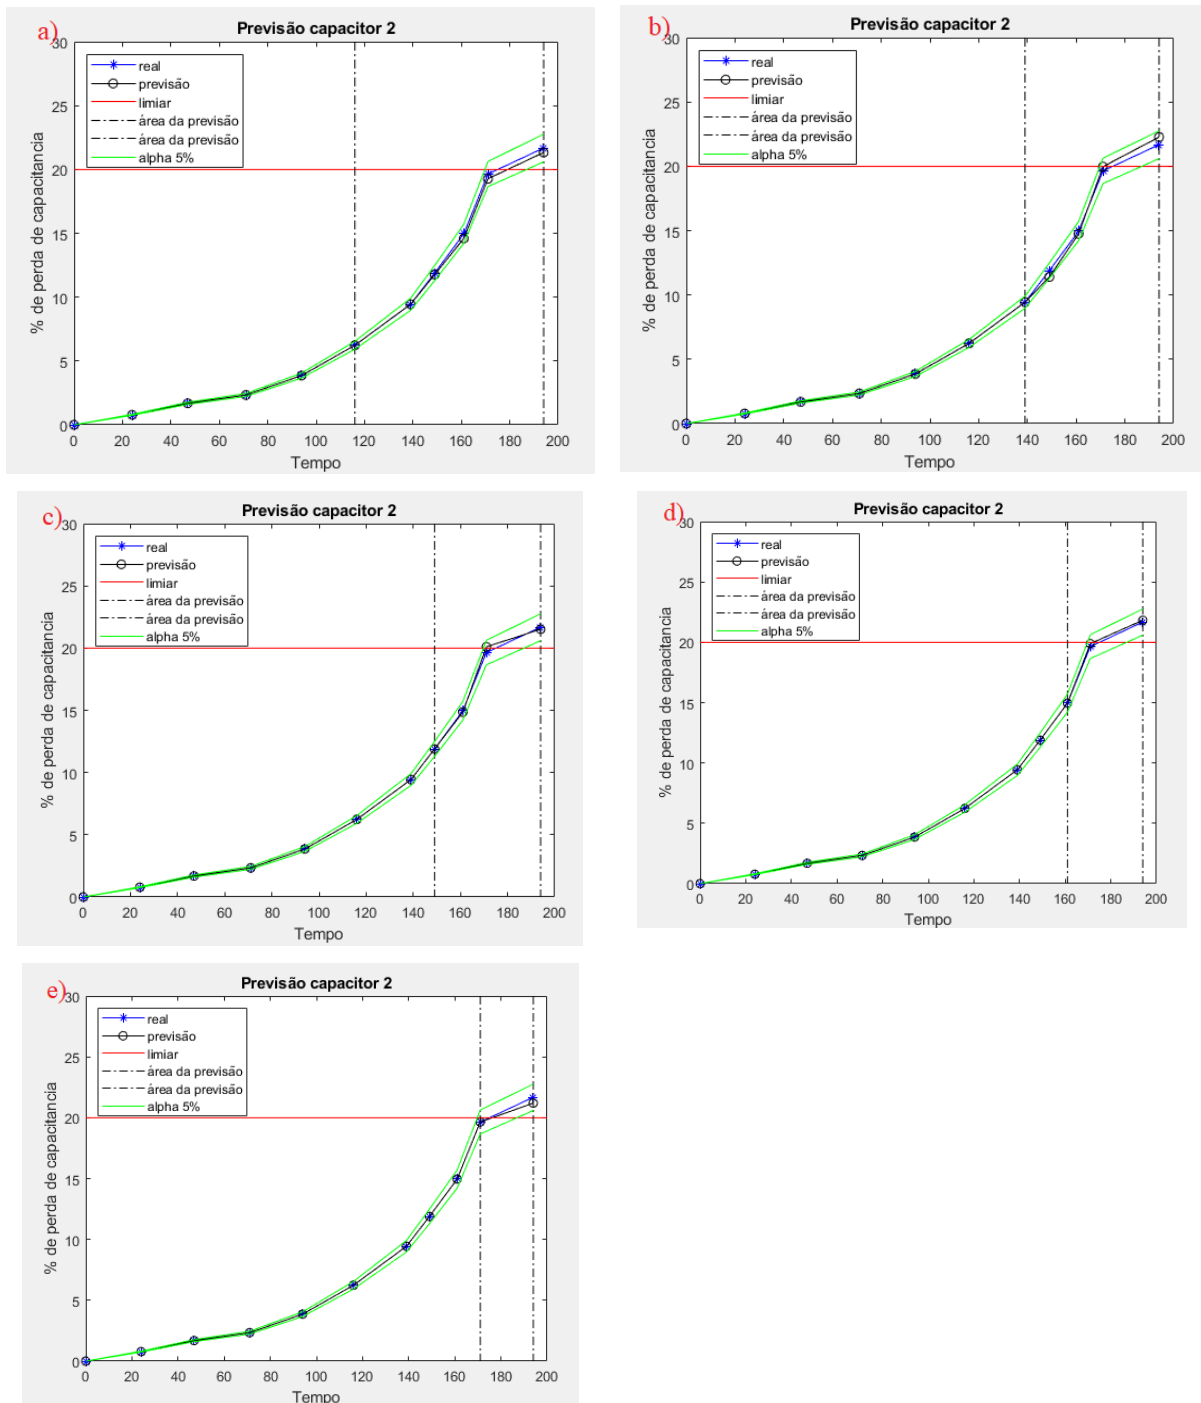
Tempo (h)	Capacitor 1		Capacitor 2		Capacitor 3		Capacitor 4		Capacitor 5		Capacitor 6	
	$R^2$	MSE	$R^2$	MSE	$R^2$	MSE	$R^2$	MSE	$R^2$	MSE	$R^2$	MSE
<b>116</b>	0,838	2,328	0,996	0,081	0,998	0,458	0,992	0,205	0,995	0,106	0,958	1,140
<b>139</b>	0,735	2,668	0,998	0,002	0,996	0,110	0,996	0,080	0,984	0,235	0,965	0,776
<b>149</b>	0,412	3,124	0,989	0,084	0,992	0,052	0,986	0,150	0,984	0,143	0,961	0,572
<b>161</b>	-8,26	5,899	0,960	0,041	0,986	0,014	0,905	0,166	0,918	0,134	0,831	0,978
<b>171</b>		6,546		0,231		0,004		0,029		0,011		0,034

Fonte: O Autor.

O resultado da melhor previsão da falha do capacitor pode ser observado pela Figura 21. Onde a linha azul com uma estrela representa os valores reais do capacitor, a linha preta com uma bola representa os valores da previsão, a linha vermelha representa o limiar de falha (*threshold*) fixado em 20% e a linha verde representa o intervalo de confiança de 95%.

As Figuras contendo as demais previsões se encontram nos Anexos da dissertação. Através da Figura 21, acima, pode-se observar o momento que a previsão toca o *threshold* está contido no intervalo de confiança de 95%.

Figura 21 – Previsão de falha do capacitor 2 utilizando a rede MLP.



Fonte: O Autor.

Assim como na RNA anterior, os valores do RUL da MLP foram organizados na Tabela 4 para uma melhor visualização.


Tabela 4. Estimativa do RUL dos capacitores da rede MLP.

Tempo (h)	Capacitor 2		Capacitor 3		Capacitor 4		Capacitor 5		Capacitor 6	
	RUL*	RUL'	RUL*	RUL'	RUL*	RUL'	RUL*	RUL'	RUL*	RUL'
<b>116</b>	59,04	59,70	65,92	67,53	54,92	54,39	70,86	68,43	68,24	71,58
<b>139</b>	36,04	32,27	42,92	44,19	31,92	34,08	47,86	44,69	45,24	51,99
<b>149</b>	26,04	21,80	32,92	32,5	21,92	21,21	37,86	37,12	35,24	39,99
<b>161</b>	14,04	13,59	20,92	22,29	9,92	9,72	25,86	22,65	23,24	28,85
<b>171</b>	4,04	5,28	10,92	11,27	-0,08	-0,076	15,86	15,23	13,24	13,77

Fonte: O Autor.

Para uma melhor visualização do resultado do melhor resultado de predição do RUL será utilizada a Figura 22 que contém a métrica de desempenho  $\alpha - \lambda$  para a simulação da predição do capacitor 2.

Figura 22– Desempenho  $\alpha - \lambda$  da previsão do RUL através da rede MLP do capacitor 2.



Fonte: O Autor.

Através da Figura 22 podemos observar que todos os resultados da previsão da rede MLP estão contidos no intervalo de confiança de  $\alpha = 30\%$ .

### 5.3 Resultados da RNA RBF

O funcionamento da RBF foi demonstrado no tópico 3.3 do capítulo 3. A configuração da RNA se deu da seguinte forma:

- Número máximo de neurônios: 9;
- Goal: 0;
- Spread: 1.

Essa é a configuração base da rede RBF. A mesma utilizou a técnica de validação *leave one out*, onde se utilizou os dados dos outros capacitores para o treino e o teste ocorreu com os dados do capacitor que não foi utilizado no treino.

Diferente das redes MLP e ELM a RBF não possui pesos randômicos o que exclui a necessidade de vários treinamentos.

Tabela 5. Indicadores de desempenho da rede RBF.

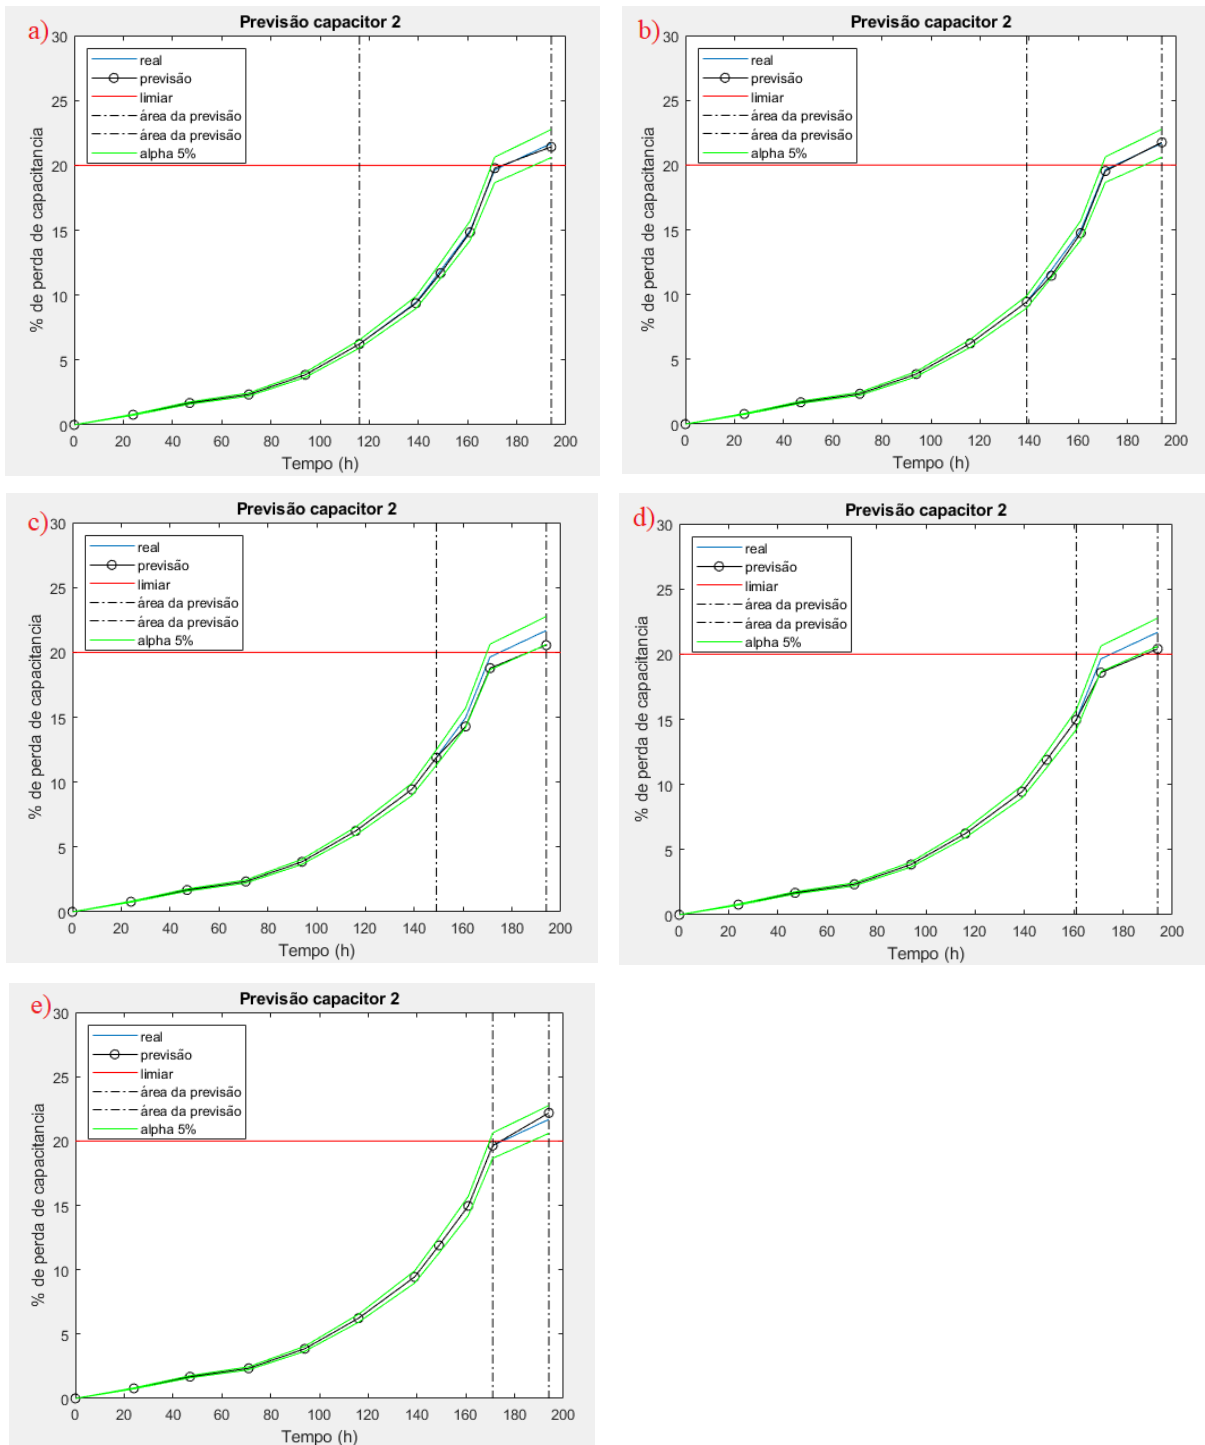
Tempo(h)	Capacitor 1		Capacitor 2		Capacitor 3		Capacitor 4		Capacitor 5		Capacitor 6	
	R <sup>2</sup>	MSE	R <sup>2</sup>	MSE	R <sup>2</sup>	MSE	R <sup>2</sup>	MSE	R <sup>2</sup>	MSE	R <sup>2</sup>	MSE
116	-3,480	64,387	0,999	0,029	0,955	0,880	0,996	0,107	0,996	0,077	0,992	0,210
139	0,591	3,90	0,996	0,064	0,997	0,045	0,9575	0,829	0,968	0,489	0,6	8,76
149	-0,768	9,40	0,8959	0,8238	0,984	0,110	0,872	1,391	0,945	0,479	0,841	2,325
161	-17,91	12,04	-0,331	1,382	0,724	0,274	-0,620	2,812	-2,711	6,112	0,586	2,40
171		46,107		0,252		0,621		7,2568		9,310		2,995

Fonte: O Autor.

Pode-se observar que a rede não consegue obter um bom resultado para o capacitor 1 que tem um resultado discrepante (*outlier*). Porém, ela obtém ótimos resultados para os demais capacitores.

O resultado da melhor previsão da falha do capacitor, na rede RBF, pode ser observado pela Figura 23 na qual ilustra o resultado do capacitor 2. Onde a linha azul com uma estrela representa os valores reais do capacitor, a linha preta com uma bola representa os valores da previsão, a linha vermelha representa o limiar de falha (*threshold*) fixado em 20% e a linha verde representa o intervalo de confiança de 95%.

Figura 23 – Previsão de falha do capacitor 2 utilizando a rede RBF.



Fonte: O Autor.

As Figuras contendo as demais previsões se encontram nos Anexos da dissertação. Assim como na RNA anterior, os valores do RUL da RBF foram organizados na Tabela 6, para uma melhor visualização.


Tabela 6. Estimativa do RUL dos capacitores da rede RBF.

Tempo (h)	Capacitor 2		Capacitor 3		Capacitor 4		Capacitor 5		Capacitor 6	
	RUL*	RUL'	RUL*	RUL'	RUL*	RUL'	RUL*	RUL'	RUL*	RUL'
<b>116</b>	59,04	58,10	65,92	62,23	54,92	56,79	70,86	69,09	68,24	69,89
<b>139</b>	36,04	36,80	42,92	45,72	31,92	41,77	47,86	40,83	45,24	Erro
<b>149</b>	26,04	37,80	32,92	28,59	21,92	33,89	37,86	Erro	35,24	Erro
<b>161</b>	14,04	27,94	20,92	15,61	9,92	24,88	25,86	Erro	23,24	26,76
<b>171</b>	4,04	3,24	10,92	18,08	-0,08	-0,07	15,86	7,24	13,24	9,74

Fonte: O Autor.

Para uma melhor ilustração dos resultados do RUL, será utilizada a Figura 24, que contém o desempenho  $\alpha - \lambda$  do resultado das previsões do capacitor 2.

Figura 24 - desempenho  $\alpha - \lambda$  da da previsão do capacitor 2 utilizando a rede RBF.



Fonte: O Autor.

Foi utilizado um  $\alpha$  no valor de 30%, mas apesar de as previsões começarem com bons resultados em alguns instantes da previsão a mesma perde a referência.

## 5.4 Resultados da GPR

O funcionamento da GPR foi demonstrado no tópico 3.4 do capítulo 3.

Foram feitas duas simulações no estudo do GPR, na qual utilizaram diferentes funções de base. O primeiro modelo utiliza do modelo exponencial clássico do estudo de degradação que foi utilizado em Celaya (2012). O segundo foi desenvolvido pelo autor através de adequação matemática utilizando a média dos resultados para cada medição da base de dados da NASA.

Como primeiro modelo, utilizando a equação 12 para uma função de base H, definida abaixo:

$$e^{ax} + b$$

Onde:

$$a = 0,0169;$$

$$b = -1,0049.$$

Então teremos os valores para as métricas  $R^2$  e MSE apresentadas pela Tabela 7.

Tabela 7. Indicadores de desempenho da rede GPR 1 para cada previsão.

Tempo (h)	Capacitor 1		Capacitor 2		Capacitor 3		Capacitor 4		Capacitor 5		Capacitor 6	
	R <sup>2</sup>	MSE	R <sup>2</sup>	MSE	R <sup>2</sup>	MSE	R <sup>2</sup>	MSE	R <sup>2</sup>	MSE	R <sup>2</sup>	MSE
0	-1,24	80,17	13,08	124,78	-1,30	118,55	-1,27	128,03	-1,27	108,95	-1,16	104,41
24	0,892	3,74	0,044	54,70	0,615	19,16	-0,25	68,81	0,665	15,58	0,986	0,643
47	0,710	9,975	0,339	34,20	0,536	22,74	0,013	53,64	0,488	23,56	0,619	17,93
71	0,947	1,829	0,926	3,846	0,918	4,052	0,848	8,443	0,933	3,112	0,974	1,255
94	0,941	2,124	0,934	3,607	0,941	3,055	0,946	3,119	0,955	2,159	0,980	1,011
116	0,939	2,418	0,929	4,242	0,917	4,700	0,947	3,417	0,939	3,250	0,974	1,467
139	0,939	2,858	0,935	4,602	0,927	4,897	0,951	3,726	0,953	2,991	0,976	1,624
149	0,936	3,784	0,929	6,339	0,924	6,352	0,953	4,451	0,951	3,896	0,977	1,922
161	0,928	5,433	0,92	9,209	0,915	9,200	0,952	5,942	0,947	5,449	0,981	2,020
171	0,886	11,36	0,876	18,69	0,871	18,236	0,919	13,49	0,916	11,60	0,984	2,395
194	0,946	6,256	0,941	10,32	0,937	10,32	0,967	6,650	0,962	6,293	0,996	0,726

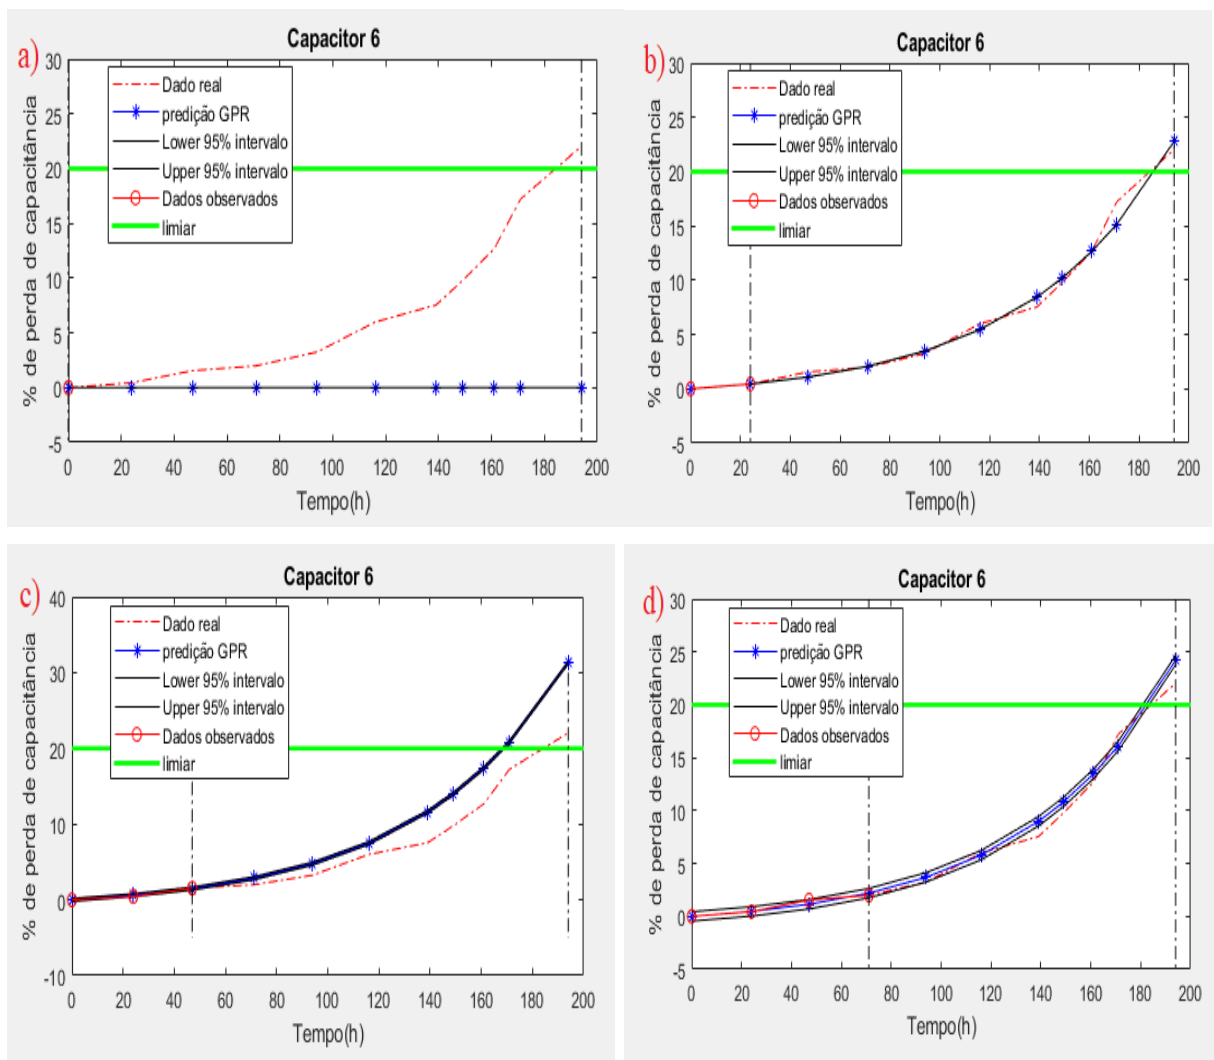
Fonte: O Autor.

As Figuras 25 a 27, abaixo, ilustra os resultados das previsões do capacitor 6 que



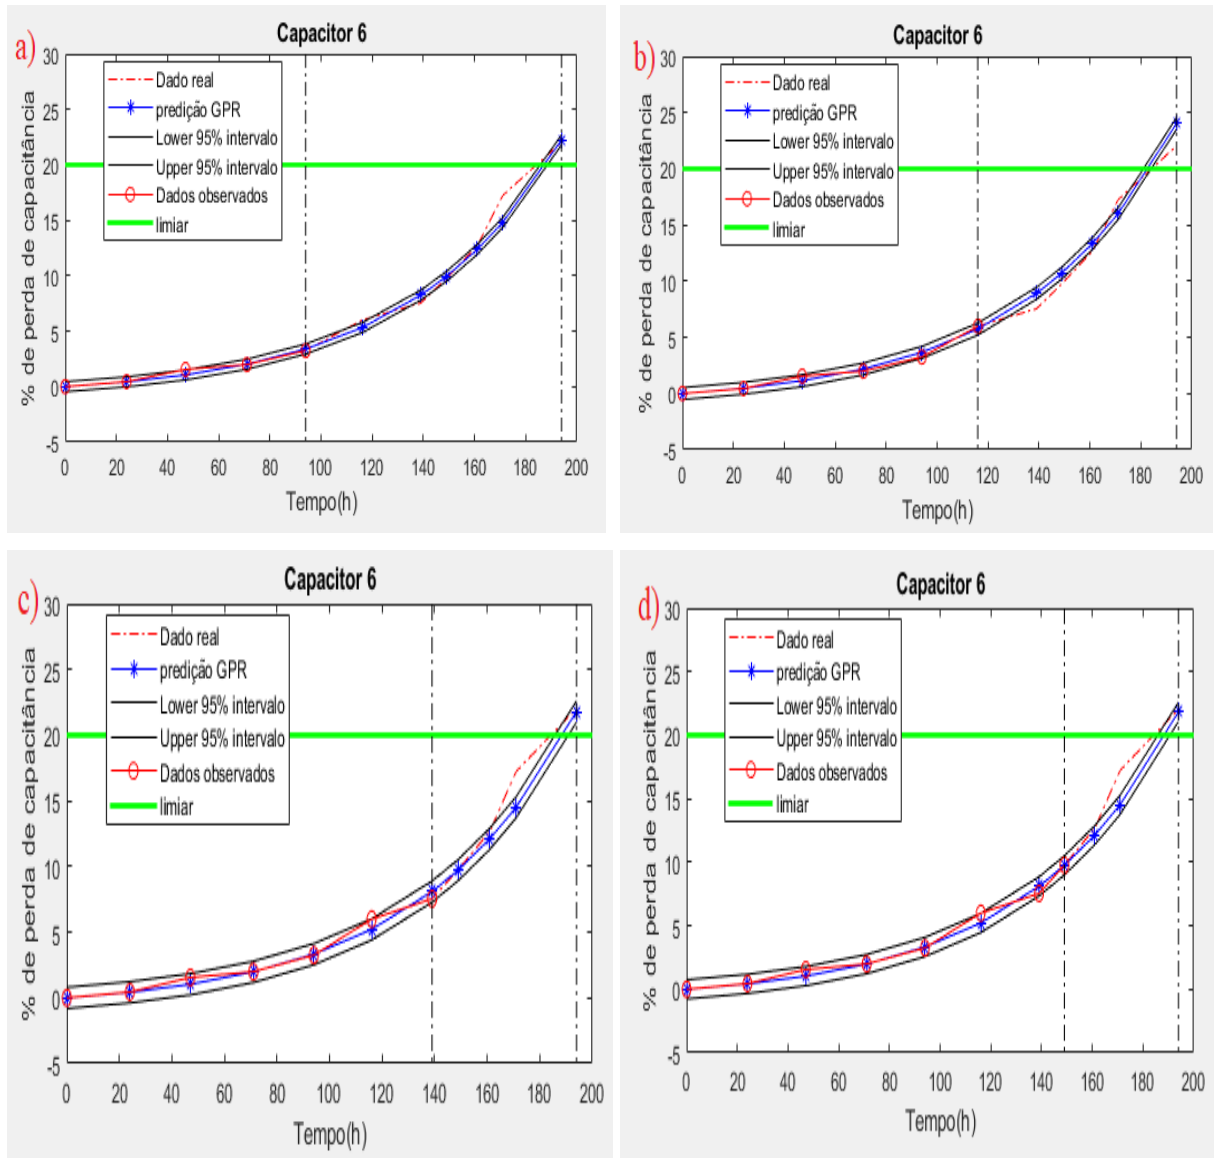
obteve os melhores resultados para a métrica  $R^2$ . Onde a linha pontilhada vermelha representa os valores reais do capacitor, a linha azul com estrelas representa os valores da previsão, a linha verde representa o limiar de falha (*threshold*) fixado em 20%, as linhas pretas pontilhadas representam a área da previsão e as linhas pretas representam o intervalo de confiança de 95%.

Figura 25 - Previsão de falha do capacitor 6 utilizando GPR1 entre o tempo de a) 0h, b) 24h, c) 47 e d) 71h.



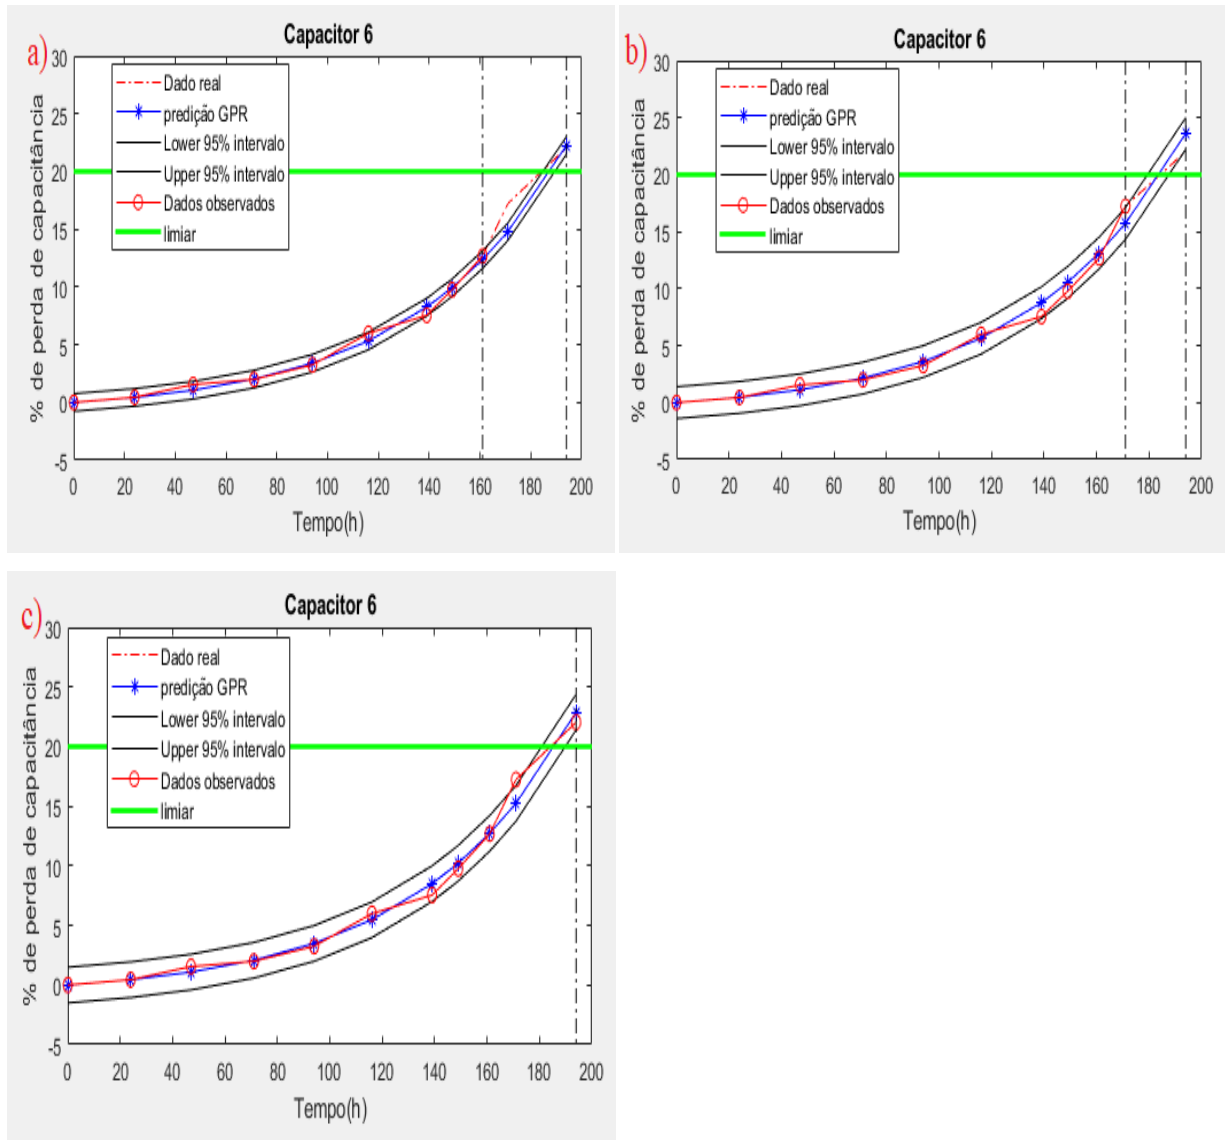
Fonte: O Autor.

Figura 26 – Previsão de falha do capacitor 6 utilizando GRP1 entre o tempo de a) 94h, b) 116h, c) 139h e d) 149h.



Fonte: O Autor.

Figura 27 – Previsão da falha do capacitor 6 utilizando GRP1 entre o tempo de a) 161, b) 171h e c) 194h.



Fonte: O Autor.

As Figuras contendo as demais previsões dos outros capacitores encontra-se nos Anexos da dissertação.

Como esperado as primeiras simulações não consegue obter um resultado satisfatório já que a entrada de dados ainda é baixa, com a entrada de mais dados a qualidade da previsão aumenta e a mesma consegue obter melhores resultados, como 0,9966 para  $R^2$  e 0,7263 para MSE.

Assim como nas técnicas anteriores os valores para o RUL foram organizados na Tabela 8.

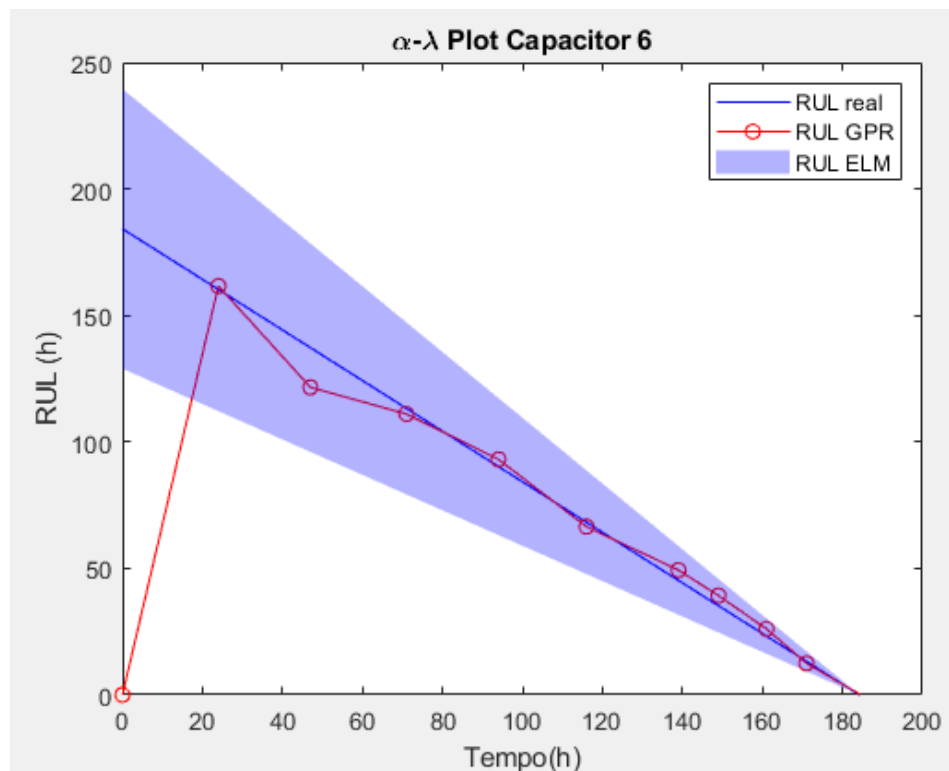
Tabela 8. Estimativa do RUL dos capacitores da técnica GPR 1.

Tempo (h)	Capacitor 2		Capacitor 3		Capacitor 4		Capacitor 5		Capacitor 6	
	RUL*	RUL'	RUL*	RUL'	RUL*	RUL'	RUL*	RUL'	RUL*	RUL'
0	175,04	0	181,92	0	170,92	0	186,86	0	184,24	0
24	151,04	130,32	157,92	141,44	146,92	127,31	162,86	144,51	160,24	161,61
47	128,04	113,41	134,92	117,89	123,92	108,09	139,86	118,90	137,24	121,55
71	104,04	105,35	110,92	106,14	99,92	100,07	115,86	108,25	113,24	111,04
94	81,04	83,87	87,92	88,07	76,92	82,96	92,86	89,08	90,24	93,08
116	59,04	61,79	65,92	62,05	54,92	61,44	70,86	64,70	68,24	66,50
139	36,04	40,28	42,92	40,20	31,92	42,43	47,86	44,13	45,24	49,33
149	25,04	28,80	32,92	29,85	21,92	30,91	37,86	33,48	35,24	39,25
161	14,04	15,88	20,92	17,17	9,92	16,31	25,86	20,96	23,24	26,07
171	4,04	3,81	10,92	5,22	-0,08	3,20	15,86	8,32	13,24	12,48

Fonte: O Autor.

Diferente do modelo anterior, o capacitor 6 obteve melhor resultado em todas as métricas. Pode-se observar esses resultados mais facilmente utilizando a métrica de desempenho  $\alpha - \lambda$  ilustrada pela Figura 28.

Figura 28– Desempenho  $\alpha - \lambda$  do capacitor 6.



Fonte: O Autor.

Pode-se observar que todos os resultados estão no intervalo de segurança de 30%,

quase que seguindo a linha do RUL real.

Como segundo modelo, utilizando a equação 12 para uma função de base H, definida abaixo:

$$ae^{bx} + ce^{dx}$$

Onde:

$$a = 0,4885;$$

$$b = 0,02149;$$

$$c = -3,951e-16;$$

$$d = 0,1926.$$

Com o auxílio do modelo matemático pode-se obter previsões adequadas sem a necessidade de um treinamento longo. O modelo foi obtido após analisar a média entre dos dados dos capacitores com o intuito de maximizar os resultados de  $R^2$  do MSE.

Com os vários resultados de previsão a utilização da métrica de desempenho  $\alpha - \lambda$  pode ser utilizada. E para a medição dos resultados das previsões foi utilizada a métrica do  $R^2$  e do MSE que para uma melhor comparação foi organizada pela Tabela 9.

Tabela 9. Indicadores de desempenho da rede GPR2 para cada previsão.

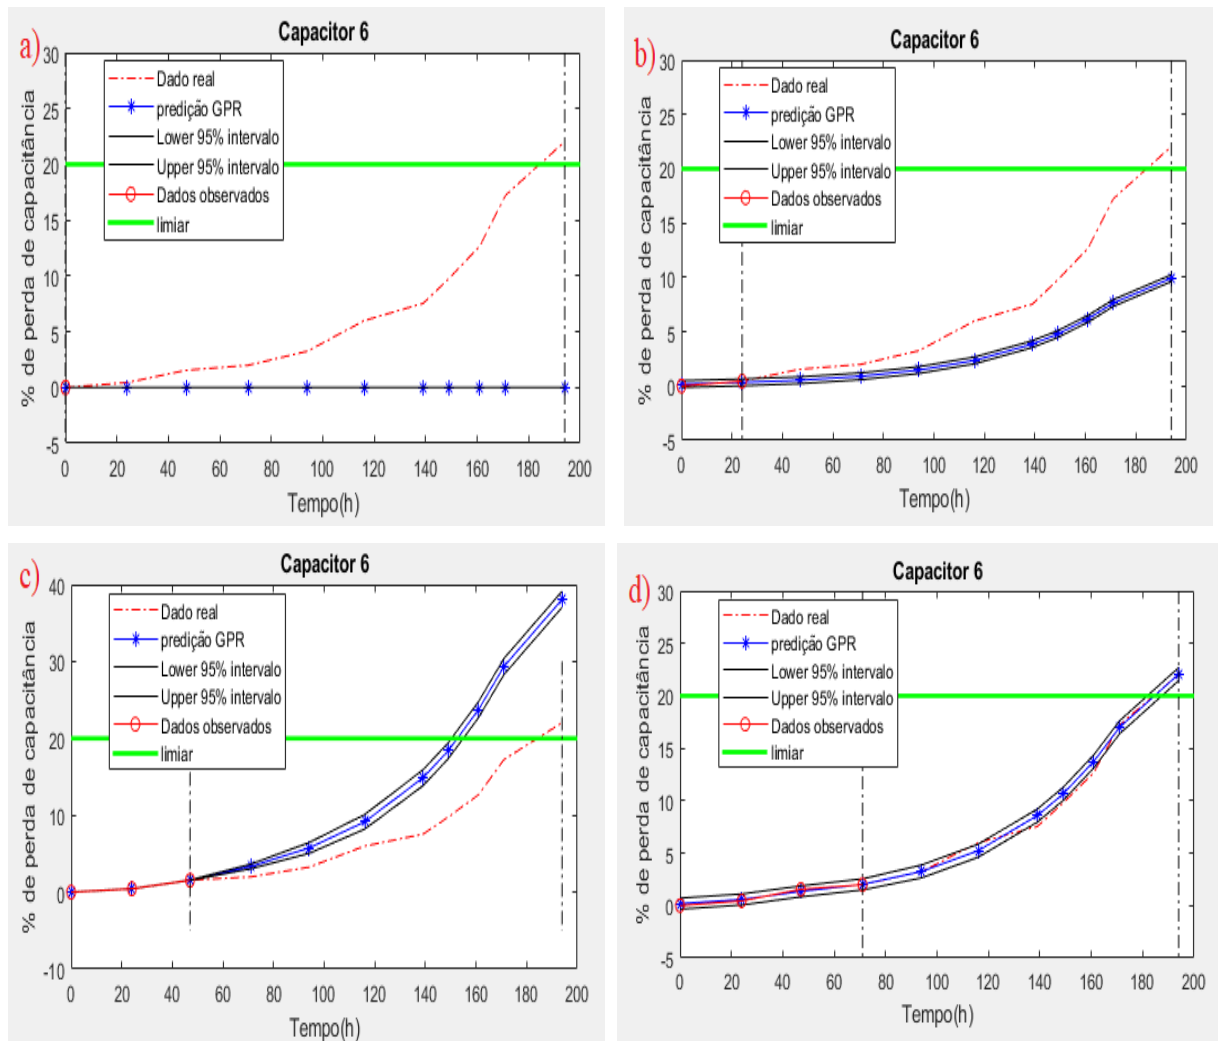
Tempo (h)	Capacitor 1		Capacitor 2		Capacitor 3		Capacitor 4		Capacitor 5		Capacitor 6	
	$R^2$	MSE	$R^2$	MSE	$R^2$	MSE	$R^2$	MSE	$R^2$	MSE	$R^2$	MSE
0	-1,24	80,17	-1,30	124,78	-1,30	118,55	-1,274	128,03	-1,27	108,96	-1,16	104,41
24	0,44	19,47	0,818	9,492	0,624	18,75	0,866	7,344	0,619	17,74	0,287	33,79
47	-1,16	74,17	0,796	10,581	-1,66	130,77	0,381	33,666	-1,95	136,00	-0,58	74,73
71	0,968	1,114	0,983	0,886	0,982	0,903	0,962	2,111	0,989	0,529	0,991	0,454
94	0,981	0,677	0,93	3,838	0,966	1,759	0,934	3,852	0,965	1,704	0,990	0,513
116	0,922	3,149	0,937	3,785	0,909	5,137	0,951	3,166	0,921	4,249	0,948	2,957
139	0,981	0,899	0,979	1,489	0,957	2,935	0,981	1,489	0,981	1,231	0,992	0,519
149	0,977	1,349	0,967	2,930	0,966	2,851	0,988	1,123	0,982	1,406	0,989	0,882
161	0,979	1,580	0,978	2,505	0,972	3,082	0,988	1,475	0,988	1,179	0,987	1,414
171	0,969	3,147	0,965	5,270	0,962	5,387	0,984	2,634	0,982	2,424	0,996	0,630
194	0,982	2,113	0,9794	3,620	0,977	3,746	0,993	1,512	0,991	1,585	0,999	0,197

Fonte: O Autor.

As Figuras 29 a 31, abaixo, ilustra os resultados das previsões do capacitor 6 que obteve os melhores resultados para a métrica  $R^2$ . Onde a linha pontilhada vermelha representa os valores reais do capacitor, a linha azul com estrelas representa os valores da previsão, a

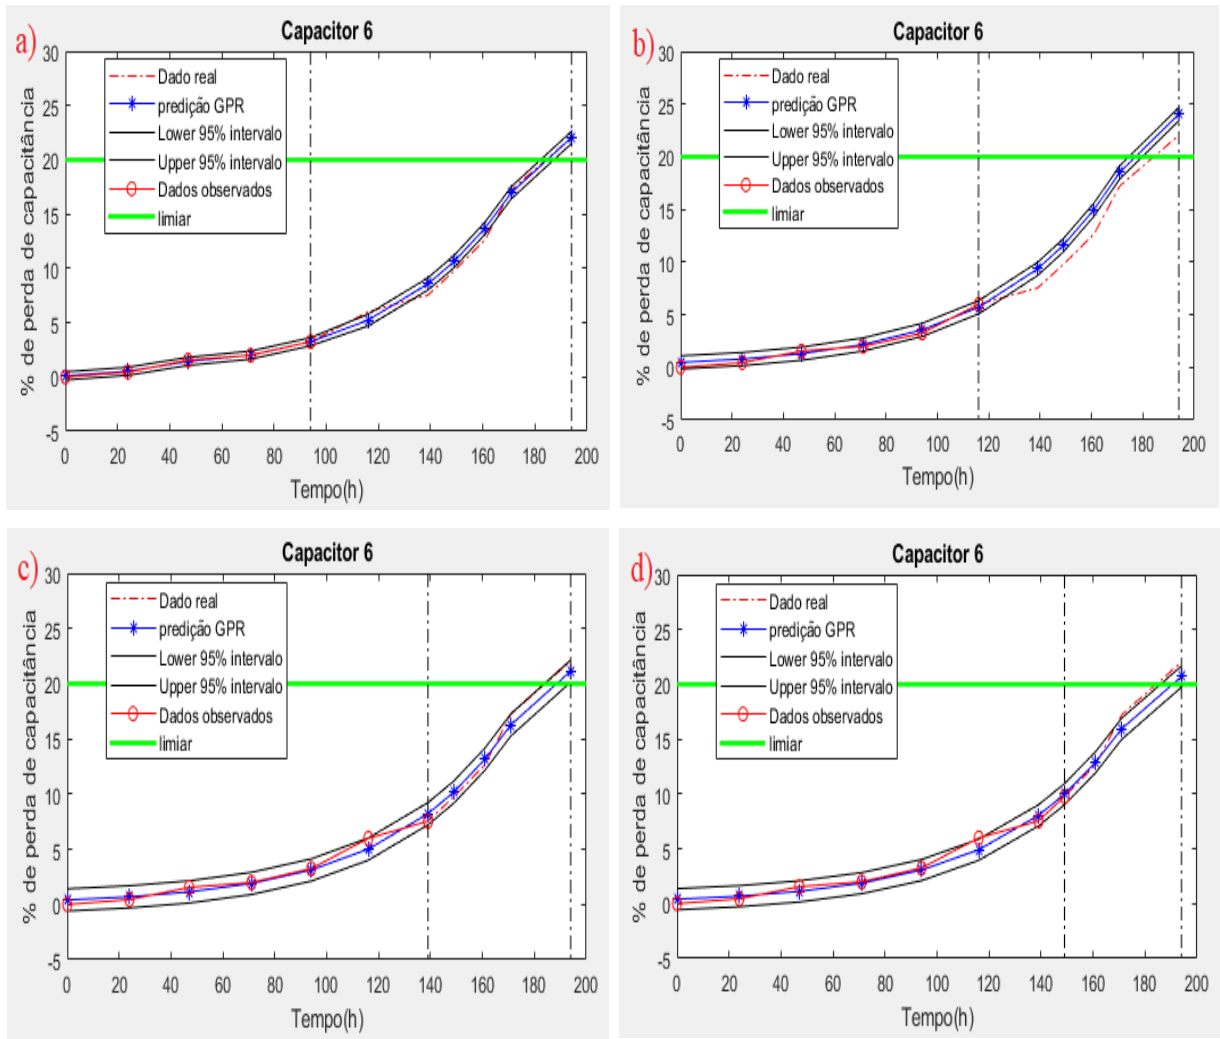
linha verde representa o limiar de falha (*threshold*) fixado em 20%, as linhas pretas pontilhadas representam a área da previsão e as linhas pretas representam o intervalo de confiança de 95%.

Figura 29 – Previsão de falha do capacitor 6 utilizando GPR2 entre o tempo de a) 0h, b) 24h, c) 47 e d) 71h.



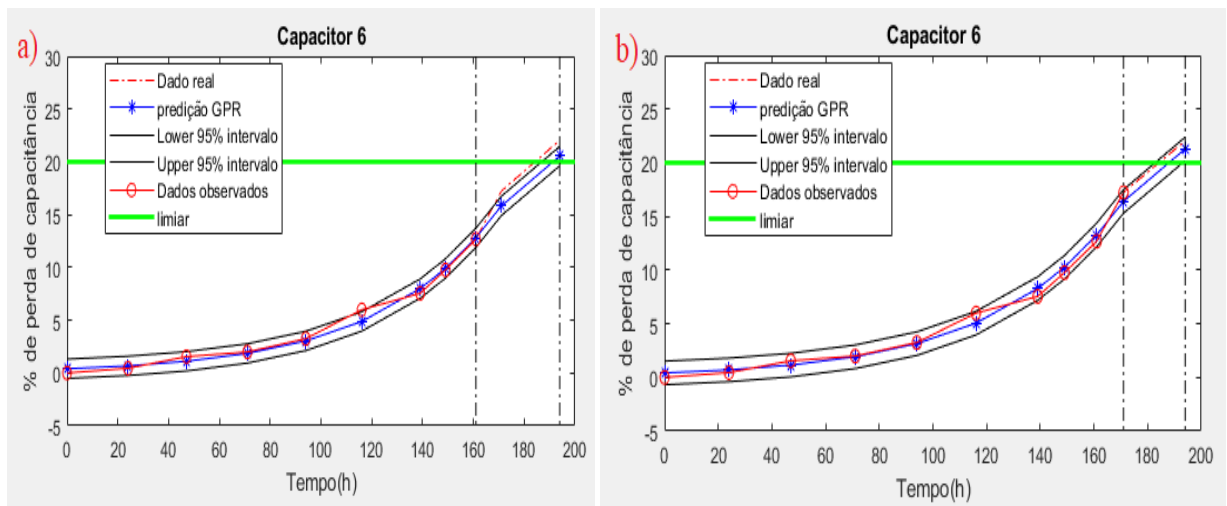
Fonte: O Autor.


Figura 30 – Previsão de falha do capacitor 6 utilizando GPR2 entre o tempo de a) 94h, b) 116h, c) 139h e d) 149h.



Fonte: O Autor.

Figura 31 – Previsão de falha do capacitor 6 utilizando GPR2 entre o tempo de a) 161, b) 171h e c) 194h.





Fonte: O Autor.

As Figuras contendo as demais previsões dos outros capacitores encontra-se nos Anexos da dissertação.

Como esperado as primeiras simulações não consegue obter um resultado satisfatório já que a entrada de dados ainda é baixa, com a entrada de mais dados a qualidade da previsão aumenta e a mesma consegue obter melhores resultados, como 0,9959 para  $R^2$  e 0,6301 para MSE.

Assim como nas técnicas anteriores os valores para o RUL foram organizados na Tabela 8.

Tabela 10. Estimativa do RUL dos capacitores da técnica GPR2.


Tempo (h)	Capacitor 2		Capacitor 3		Capacitor 4		Capacitor 5		Capacitor 6	
	RUL*	RUL'	RUL*	RUL'	RUL*	RUL'	RUL*	RUL'	RUL*	RUL'
0	175,04	0,00	181,92	0,00	170,92	0,00	186,86	0,00	184,24	0,00
24	151,04	-24,00	157,92	-24,00	146,92	-24,00	162,86	-24,00	160,24	-24,00
47	128,04	117,62	134,92	98,88	123,92	109,65	139,86	99,36	137,24	105,61
71	104,04	106,86	110,92	109,71	99,92	99,72	115,86	112,24	113,24	113,61
94	81,04	76,09	87,92	81,85	76,92	75,20	92,86	83,80	90,24	90,68
116	59,04	54,70	65,92	54,76	54,92	54,33	70,86	57,96	68,24	61,15
139	36,04	38,39	42,92	35,74	31,92	42,62	47,86	41,67	45,24	49,60
149	26,04	24,86	32,92	27,08	21,92	27,29	37,86	31,90	35,24	41,59
161	14,04	15,70	20,92	17,04	9,92	16,74	25,86	22,92	23,24	30,35
171	4,04	3,35	10,92	5,26	-0,08	3,81	15,86	10,26	13,24	16,94

Fonte: O Autor.




Embora o capacitor 6 apresente melhores resultados para as métricas  $R^2$  e MSE, os melhores resultados para o cálculo do RUL são apresentados pelo capacitor 2. Pode-se observar esses resultados mais facilmente utilizando da métrica de desempenho  $\alpha - \lambda$  ilustrada pelas Figuras 28 e 29 abaixo.

Figura 32 – Desempenho  $\alpha - \lambda$  do capacitor 2.



Fonte: O Autor.

Figura 33 – Desempenho  $\alpha - \lambda$  do capacitor 6.



Fonte: O Autor.

### 5.5 – Análise geral dos resultados.

Observando os resultados apresentados fica evidente que os valores de predição para o capacitor 1 ficou bem abaixo do esperando devido a discrepância dos dados *outlier*.

Com os resultados apresentados pelos tópicos anteriores, será apresentada a Tabela comparativa com os valores de cada técnica, para o capacitor 2, que apresentou os melhores resultados. Os demais resultados estão nos anexos do trabalho.

Como mostrado pelas Tabelas 1, 3, 5 e 7. As redes neurais conseguem obter resultados melhores a partir das previsões em 116h, porém, as mesmas não conseguem obter resultados antes de 116h devido os dados necessários para o treinamento.

A partir da Tabela 11 pode-se observar os resultados que a previsão do capacitor 2 obteve pelas métricas do coeficiente de relatividade e do erro médio quadrático. Como a rede neural necessita de dados anteriores para o treinamento, não foram computados (NC) os valores de previsão para os tempos de 24, 47 e 71 e 94h.

Tabela 11. Comparativo entre os resultados de predição do capacitor 2.

Tempo (h)	ELM		MLP		RBF		GPR1		GPR2	
	R <sup>2</sup>	MSE	R <sup>2</sup>	MSE	R <sup>2</sup>	MSE	R <sup>2</sup>	MSE	R <sup>2</sup>	MSE
24	NC	NC	NC	NC	NC	NC	-0,04	54,788	<b>0,819</b>	<b>9,491</b>
47	NC	NC	NC	NC	NC	NC	0,339	34,21	<b>0,796</b>	<b>10,581</b>
71	NC	NC	NC	NC	NC	NC	0,927	3,61	<b>0,983</b>	<b>0,885</b>
94	NC	NC	NC	NC	NC	NC	0,934	4,243	<b>0,930</b>	<b>3,838</b>
116	0,996	0,089	0,996	0,081	<b>0,999</b>	<b>0,029</b>	0,930	4,60	0,937	3,785
139	0,994	0,097	<b>0,998</b>	<b>0,002</b>	0,996	0,064	0,936	6,339	0,979	1,489
149	0,975	0,198	<b>0,989</b>	<b>0,084</b>	0,8959	0,823	0,929	9,210	0,967	2,930
161	0,684	0,320	0,960	0,041	-0,331	1,38	0,876	18,695	<b>0,978</b>	<b>2,505</b>
171		0,211		0,231		0,252	0,941	10,324	<b>0,965</b>	<b>5,270</b>

Fonte: O Autor.

Observando a Tabela 11, pode-se chegar a conclusão de que entre as redes neurais a rede MLP obteve o melhor resultado. Contudo, a mesma foi treinada várias vezes para cada capacitor e observado apenas os melhores resultados, diferente das redes ELM e RBF que

contém os pesos fixos.

Por sua vez a Tabela 12 contém os valores do RUL da previsão do capacitor 2 de cada rede neural e do GPR.

Tabela 12. Comparativo entre os resultados do RUL do capacitor 2.

		<b>ELM</b>	<b>MLP</b>	<b>RBF</b>	<b>GPR1</b>	<b>GPR2</b>
<b>Tempo (h)</b>	RUL*	RUL'	RUL'	RUL'	RUL'	RUL'
<b>24</b>	151,04	NC	NC	NC	0	-24,00
<b>47</b>	128,04	NC	NC	NC	130,32	117,62
<b>71</b>	104,04	NC	NC	NC	113,41	106,86
<b>94</b>	81,04	NC	NC	NC	83,47	76,09
<b>116</b>	59,04	60,89	59,70	58,10	61,79	54,70
<b>139</b>	36,04	38,51	32,57	36,80	40,28	38,39
<b>149</b>	26,04	30,01	28,42	37,80	28,80	24,86
<b>161</b>	14,04	15,26	13,59	27,94	15,88	15,70
<b>171</b>	4,04	5,21	7,62	3,24	3,81	3,35

Fonte: O Autor.


Como a Tabela 13 contém os valores dos RUL\* e os valores do RUL' de cada modelo pode-se fazer a comparação de o quão próximo os valores das previsões estão do valor real. Para uma melhor observação dos resultados do RUL foi utilizada a métrica da precisão relativa, explanado no tópico 3 do capítulo 4, e feita a comparação dos resultados através da Tabela 13.

A partir dos resultados apresentados nos tópicos anteriores podemos chegar a algumas conclusões através da comparação de cada técnica. Fica obvio a superioridade do GPR já que a mesma utiliza de um modelo matemático para iniciar as previsões, no entanto, as redes neurais apresentam resultados melhores para as previsões pós-treinamento. A Figura 34 faz a comparação dos resultados do RUL utilizando os dados da Tabela 13.

Tabela 13. Comparativo entre os resultados do RA do capacitor 2.

	ELM	MLP	RBF	GPR1	GPR2
<b>Tempo (h)</b>	RA	RA	RA	RA	RA
<b>24</b>	NC	NC	NC	<b>86,28</b>	-15,89
<b>47</b>	NC	NC	NC	88,57	<b>91,86</b>
<b>71</b>	NC	NC	NC	<b>98,73</b>	97,29
<b>94</b>	NC	NC	NC	<b>96,51</b>	93,89
<b>116</b>	96,85	97,56	<b>98,41</b>	95,34	92,65
<b>139</b>	93,14	89,54	<b>97,90</b>	88,23	93,48
<b>149</b>	84,77	90,84	54,72	89,41	<b>95,46</b>
<b>161</b>	91,33	96,81	<b>99,14</b>	86,92	88,16
<b>171</b>	70,90	69,16	80,26	<b>94,39</b>	82,93

Fonte: O Autor.

Figura 34 – Comparativo do desempenho  $\alpha - \lambda$  das técnicas utilizadas.

Fonte: O Autor.

Observando a Figura 34, pode-se perceber que a única técnica que perde a referência de  $\alpha=30\%$  é a técnica do RBF. O modelo indicado pelo autor do GPR2, apesar de ter valores de RUL com menor desempenho em comparação com o clássico modelo (GPR1), se manteve com excelentes resultados sem perder a referência  $\alpha$ . Assim, mantendo válida a utilização da mesma para estudos do comportamento do capacitor como para os estudos de vida útil remanescente do mesmo.

## 5 CONSIDERAÇÕES FINAIS

Com as reformulações dos conceitos básicos de manutenção utilizados nas técnicas de PHM, que visam à confiabilidade, redução de custos e maior disponibilidade dos equipamentos. Assim, os estudos de manutenção preditiva de falhas e da vida útil dos equipamentos vão ganhando espaço.

No trabalho foi apresentada uma revisão sobre os conceitos de prognósticos e gestão de saúde dos equipamentos, sobre um componente eletrônico, o capacitor eletrolítico, que é utilizado em módulos eletrônicos, filtros, conversores, entre outros. Foi apresentado o comparativo entre as técnicas de predição para o estudo do modelo de degradação como do cálculo do RUL. O trabalho utilizou-se de 4 métodos para a predição, foram elas: rede neural ELM, rede neural RBF, rede neural MLP e regressão por processo gaussiano.

Os métodos foram utilizados com a finalidade da predição da degradação da capacitância de seis capacitores eletrolíticos do repositório da NASA. Em todos os métodos foram utilizados como critérios de avaliação o  $R^2$ , MSE e pelo tamanho de intervalos de confiança do momento da falha, na qual foi definido um limiar de falha de 20% de degradação da capacitância e utilizou-se de um intervalo de confiança de 95% para a medição da confiança da predição. Já o cálculo do RUL utilizou-se das métricas RA e do desempenho  $\alpha - \lambda$ . Onde alfa foi definido por um fator de 30%.

Os métodos apresentaram resultados satisfatórios na predição e no cálculo do RUL. Apenas as predições do capacitor 1 que tem um comportamento discrepante e não obteve bons resultados, utilizando as redes neurais. Já a técnica da regressão por processo gaussiano apresenta resultados satisfatórios para todas as simulações dos modelos de degradação, pecando apenas em pequenos momentos para o cálculo do desempenho  $\alpha - \lambda$ .

Entre as redes neurais, mesmo que as redes MLP e RBF tenham superado a ELM em alguns resultados, a ELM contém os pesos fixos para a entrada de qualquer capacitor e obtêm resultados mais rápidos. Com resultados muito próximos entre elas a ELM se torna a mais interessante para o estudo do RUL do capacitor.

O modelo matemático desenvolvido pelo autor apresenta resultados satisfatórios em todas as métricas utilizados no trabalho. Gerando mais um modelo a ser levado em conta para estudos, principalmente para as métricas do comportamento do capacitor.

Observou-se que, na maioria das simulações o capacitor 2 possui um padrão de degradação mais regular se comparado com os demais. Mesmo com um banco de dados

pequeno as redes neurais ainda apresentaram resultados, muitas vezes, superiores em algumas previsões justificando a utilização das mesmas.

### **5.1 Propostas para Trabalhos Futuros**

No presente trabalho ocorreu o estudo de prognóstico de degradação dos capacitores eletrolíticos. Em trabalhos futuros podem-se aplicar novas técnicas comparativas ou outros componentes eletrônicos.

No estudo os capacitores sofreram a degradação por estresse elétrico para monitorar a queda da capacitância. Para trabalhos futuros os prognósticos que pode ser estudado é o de estresse por temperatura, na qual o capacitor é submetido a temperaturas acima das estabelecidas para o seu funcionamento normal.

No que diz os algoritmos, é possível e justificável buscar um algoritmo híbrido entre as redes neurais e métodos matemáticos. Complementando as falhas que cada um apresentou.

Outra forma de complementar as redes neurais seria o aumento do banco de dados, já que o mesmo ainda é considerado relativamente pequeno.

## REFERÊNCIAS

Alozie, O., Li, Y.-G., Wu, X., Shong, X., and Ren, W. **An adaptive model-based framework for prognosis of gas path faults in aircraft gas turbine engines.** *International Journal of Prognostics and Health Management*, vol. 10(2), pp. 1-12, 2019.

Bhargava, C., Banga, V. K. and Singh, Y. **Condition monitoring of aluminium electrolytic capacitors using accelerated life testing: A comparison.** *International Journal of Quality and Reliability Management*, 35(8), pp. 1671–1682. doi: 10.1108/IJQRM-06-2017-0115, 2018.

Bitencourt, D.B. **Estratégias de previsão de geração de energia eólica utilizando redes neurais artificiais.** *Dissertação de Mestrado em Engenharia Elétrica*, Universidade Federal de Sergipe, São Cristóvão, 86 f, 2015.

Bizzarria, C.O. **Prognóstico de falhas no atuador do leme da aeronave EMBRAER-190.** *Dissertação de Mestrado em Engenharia Aeronáutica*, Instituto Tecnológico de Aeronáutica, São José dos Campos, 98f, 2009.

Böhm, T. **Remaining useful life prediction for railway switch engines using classification techniques.** *International Journal of Prognostics and Health Management*, vol. 8(Sp7), pp. 1-15, 2017.

CASELLA, George; BERGER, L. Roger. **Statistical Interference.** Second edition. Duxbury, Pacific Grove, CA, USA, 2002.

Caixeta, R. G. **Uma abordagem computacional para predição de mortalidade em UTIs baseada em agrupamento de Processos Gaussianos.** *Dissertação de mestrado em Ciencia da Computação*, UNIVERSIDADE FEDERAL DE GOIÁS, 62f, 2016.

Celaya, J., Kulkarni, C., Biswas, G., and Goebel, K. **Towards a model-based prognostics methodology for electrolytic capacitors: a case study based on electrical overtree accelerated aging.** *International Journal of Prognostics and Health Management*, vol. 3(2), pp. 1-19, 2012.

Costa, E. F. **Predição da descarga e capacidade de baterias li-íon utilizadas em vants.** *Dissertação de Mestrado em Engenharia Elétrica e da Computação*, Universidade Federal do Ceará, Sobral, 95f, 2019

Cunha, J.P.Z. **Um estudo comparativo das técnicas de validação cruzada aplicadas a modelos mistos.** *Dissertação de Mestrado em Engenharia Estatística*, Universidade de São Paulo, 59 f, 2019.

Duong, P. L. T. and Raghavan, N. **A metaheuristic approach to remaining useful life estimation of systems subject to multiple degradation mechanisms.** *2017 IEEE International Conference on Prognostics and Health Management, ICPHM 2017*, pp. 227–233. doi: 10.1109/ICPHM.2017.7998333, 2017.

ELMARAGHY, Hoda et al. Product Services Systems and Value Creation. Proceedings of the 6th CIRP Conference on Industrial Product-Service Systems Overview of Remaining Useful Life Prediction Techniques in Through-life Engineering Services. **Procedia CIRP**, v. 16, p. 158-163, 2014.

FIDES Group. **A Reliability Methodology for Electronic Systems.** *FIDES Guide Issue A*, 2004.

Huang, G.-B., Zhu, Q.-Y., and Siew, C.-K. **Extreme learning machine: Theory and applications.** *Neurocomputing*, vol. 70(1–3), pp. 489-501, doi: 10.1016/j.neucom.2005.12.126, 2006.



INTERNATIONAL ELECTROTECHNICAL COMMISSION. **IEC 60050-192**: International Electrotechnical Vocabulary -Part 192: Dependability, 2015.

INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. **ISO 13379-1**: Condition monitoring and diagnostics of machines — Data interpretation and diagnostics techniques - Part 1: General guidelines, 2012.

Kulkarni, C.S., Biswas, G., and Koutsoukos, X. **A prognosis case study for electrolytic capacitor degradation in DC-DC converters**. *Annual Conference of the Prognostics and Health Management Society*, San Diego, pp. 1-10, 2009.

Lauer, M., Mullins, J., and Yeddes, M. **Cost optimization strategy for iterative integration of multi-critical functions in IMA and TTEthernet architecture**. *2013 IEEE 37th Annual Computer Software and Applications Conference Workshops*, Japan, pp. 139-144, doi: 10.1109/COMPSACW.2013.16, 2013.

Lima, E. G. **Metamodelagem kriging dinâmica aplicada em trocadores de calor**. *Dissertação de Mestrado em Engenharia Química*, Universidade Federal de Campina Grande, 94f, 2019.

Marcos, I.P.M., Álvares, A.J., and Abadia, M.R.U. **Metodologia para diagnóstico de falhas em unidades geradoras hidráulicas usando conceitos de lógica difusa**. *Congresso Nacional de Engenharia Mecânica (CONEM)*, Uberlândia, pp. 1-10, 2014.

Mesquita, D.P.P., Gomes, J.P.P., Rodrigues, L.R., and Galvão, R.K.H. **Pruning extreme learning machines using the successive projections algorithm**. *IEEE Latin America Transactions*, vol. 13(12), pp. 3974-3979, doi: 10.1109/TLA.2015.7404935, 2015.

MIL-C-62F. **General specification for capacitors, fixed, electrolytic (dc. aluminum, dry electrolyte, polarized)**. *Military Specification*. Department of Defense, 2008.

Mota, J.F., Siqueira, P.H., Souza, L.V., and Vitor, A. **Uma rede neural de base radial baseada em computação evolucionária.** XXXIII Congresso Íbero Latino Americano de Métodos Computacionais em Engenharia (CILAMCE), Ouro Preto, pp. 1-15, 2015.

MATTEDE, Henrique . **Mundo da elétrica,** c2021. Disponível em: < <https://www.mundodaeletrica.com.br/como-funcionam-os-capacitores/> >. Acesso em: 15 de mar de 2021.

RASMUSSEN, C.E., WILLIAMS, C.K.I, **Gaussian Process for Machine Learning.** the MIT Press, 2006. ISBN 02621853x. © 2006; Massachusetts Institute Technology.

Rodrigues, L. R., Coelho, D. B. P. and Gomes, J. P. P. **A Hybrid TLBO-Particle Filter Algorithm Applied to Remaining Useful Life Prediction in the Presence of Multiple Degradation Factors.** *IEEE Congress on Evolutionary Computation, CEC 2020 - Conference Proceedings.* doi: 10.1109/CEC48606.2020.9185898.

Roemer, M.J., Byington, C.S., Kacprzyński, G.J., and Vachtsevanos, G. **An overview of selected prognostic technologies with reference to an integrated PHM architecture.** *Proceedings of the First International Forum on Integrated System Health Engineering and Management in Aerospace,* Big Sky, pp. 3941-3947, 2005.

Santos, G. S. M. **Aplicação de redes neurais para diagnóstico de poluição em isoladores de alta tensão.** *Dissertação de Mestrado em Engenharia Elétrica,* Universidade Federal de Pernambuco, Recife, 126f, 2008.

Saxena, A., Celaya, J., Saha, B., Saha, S., and Goebel, K. **Metrics for offline evaluation of prognostic performance.** *International Journal of Prognostics and Health Management,* vol. 1(1), pp. 1-20, 2010.

Siltala, N., and Tuokko, R. **Use of electronic module descriptions for modular and reconfigurable assembly systems.** *Proceedings of the 2009 IEEE International Symposium*

*on Assembly and Manufacturing*, Suwon, pp. 214-219, doi: 10.1109/ISAM.2009.5376903, 2009.






Soualhi, A., Hawwari, Y., Medjaher, K., Clerc, G., Hubert, R., and Guillet, F. **PHM survey: implementation of signal processing methods for monitoring bearings and gearboxes.** *International Journal of Prognostics and Health Management*, vol. 9(2), pp. 1-14, 2018






VAN HORENBEEK, Adriaan et al. Quantifying the added value of an imperfectly performing condition monitoring system—Application to a wind turbine gearbox. **Reliability Engineering & System Safety**, v. 111, p. 45-57, 2013.


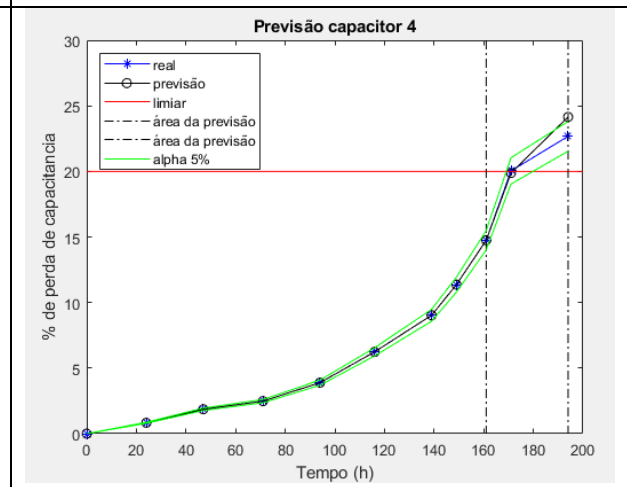
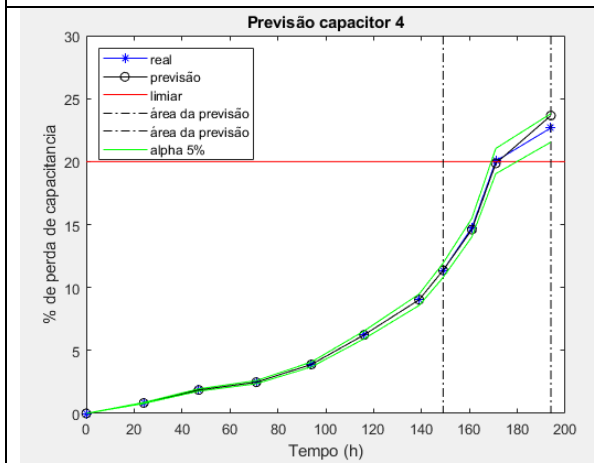


Vichare, N.M., and Pecht, M.G. **Prognostics and health management of electronics.** *IEEE Transactions on Components and Packaging Technologies*, vol. 29(1), pp. 222-229, doi: 10.1109/TCAPT.2006.870387, 2006.






Yang, J., Peng, Z., Wang, H., Yuan, H., and Wu, L. **The remaining useful life estimation of lithium-ion battery based on improved extreme learning machine algorithm.** *International Journal of Electrochemical Science*, vol. 13(5), pp. 4991-5004, 2018.

## ANEXO A – RESULTADO DAS DEMAIS PREVISÕES DA RNA ELM









## ANEXO B – RESULTADO DAS DEMAIS PREVISÕES DA RNA MLP

Treinamento de todos os capacitores para o tempo de 116h											
Capacitor 1		Capacitor 2		Capacitor 3		Capacitor 4		Capacitor 5		Capacitor 6	
R <sup>2</sup>	MSE	R <sup>2</sup>	MSE	R <sup>2</sup>	MSE	R <sup>2</sup>	MSE	R <sup>2</sup>	MSE	R <sup>2</sup>	MSE
0,564	6,263	0,994	0,132	0,951	0,947	0,978	0,583	0,977	0,473	0,929	1,939
0,613	5,569	0,993	0,153	0,991	0,170	0,985	0,392	0,987	0,267	0,957	1,167
0,664	4,834	0,985	0,313	0,990	0,194	0,987	0,357	0,998	0,046	0,950	1,378
0,461	7,752	0,632	7,753	0,996	0,078	0,985	0,387	0,978	0,443	0,984	0,444
0,838	2,328	0,978	0,463	0,390	11,869	0,971	0,771	0,990	0,211	0,970	0,814
0,744	3,680	0,989	0,229	0,975	0,480	0,985	0,397	0,966	0,700	0,932	1,859
0,825	2,511	0,989	0,223	0,947	1,029	0,992	0,205	0,998	0,050	0,946	1,484
0,339	9,503	0,934	1,388	0,989	0,225	0,991	0,248	0,958	0,861	0,928	1,977
0,607	5,643	0,996	0,081	0,998	0,458	0,959	1,092	0,992	0,169	0,840	4,355
0,749	3,603	0,986	0,294	0,991	0,182	0,933	1,775	0,995	0,106	0,958	1,140

Treinamento capacitor 3(139h)			
RA	R	mse	RUL_predito
<b>91,16</b>	0,9813	0,2565	50,18
<b>76,60</b>	0,9376	0,8582	44,2
<b>96,29</b>	0,9741	0,3557	42,07
<b>98,11</b>	0,9542	0,6292	37,84
<b>98,00</b>	0,864	18,701	38,42
<b>83,11</b>	0,9816	0,2538	46,52
<b>97,03</b>	0,9964	0,0491	52,96
<b>98,02</b>	0,992	0,1101	44,51
<b>88,17</b>	0,9808	0,2637	42,11
<b>89,52</b>	0,9601	0,5484	42,06



<b>Treinamento capacitor 3(149h)</b>			
<b>RA</b>	<b>R</b>	<b>mse</b>	<b>RUL_predito</b>
<b>87,42</b>	0,777	15.688	28,78
<b>-45,26</b>	0,8751	0,8785	-149
<b>96,62</b>	0,6703	23.195	34,03
<b>88,26</b>	0,9727	0,1917	36,78
<b>74,22</b>	0,7434	18.047	24,43
<b>96,87</b>	0,9747	0,1782	31,88
<b>98,71</b>	0,9926	0,0524	32,49
<b>96,04</b>	0,9891	0,0765	34,22
<b>86,91</b>	0,9187	0,5722	37,22
<b>85,43</b>	0,9531	0,3302	37,75

<b>Treinamento capacitor 3(161h)</b>			
<b>RA</b>	<b>R</b>	<b>mse</b>	<b>RUL_predito</b>
<b>93</b>	0,9858	0,014	22,29
<b>98</b>	0,874	0,1249	21,43
<b>83</b>	0,6697	0,3273	24,45
<b>-77</b>	-0,3468	13.347	-161,00
<b>81</b>	0,803	0,1953	16,86
<b>67</b>	0,5369	0,4589	14,11
<b>50</b>	-100.166	109.177	31,39
<b>82</b>	0,8936	0,1055	24,78
<b>97</b>	-0,9685	19.508	20,30
<b>97</b>	0,8302	0,1683	30,37

---

**Treinamento capacitor 3(171h)**

RA	mse	RUL_predito
<b>84,1</b>	0,1438	9,17
<b>91,6</b>	0,0335	10
<b>50,4</b>	0,4346	16,33
<b>91,9</b>	0,0312	10,03
<b>53,9</b>	29.118	5,88
<b>84,3</b>	0,1378	0,21
<b>-15.659</b>	27.933	-171
<b>-15.659</b>	28.671	-171
<b>68,2</b>	0,867	7,44
<b>96,8</b>	0,0036	11,26

---

**Previsão capacitor 4 (139h)**

RA	R	mse	RUL_predito
<b>95,64</b>	0,9694	0,5966	30,53
<b>99,90</b>	0,984	0,3127	31,89
<b>89,50</b>	0,9617	0,7477	35,27
<b>76,57</b>	0,9681	0,6235	39,39
<b>73,55</b>	0,9684	0,6164	40,36
<b>93,23</b>	0,9959	0,0802	34,08
<b>53,48</b>	0,8648	26.386	46,76
<b>70,28</b>	0,9227	15.090	41,4
<b>90,67</b>	0,9849	0,2947	24,89
<b>82,80</b>	0,9749	0,4904	37,41

---

---

**Previsão capacitor 4 (149h)**

RA	R	mse	RUL_predito
<b>62,49</b>	0,9457	0,5898	30,14
<b>78,24</b>	0,9615	0,4179	26,69
<b>99,86</b>	0,9725	0,2982	21,95
<b>-47,52</b>	0,0221	106.188	44,88
<b>59,43</b>	0,9074	10.051	30,81
<b>81,77</b>	0,9495	0,5488	25,91
<b>85,55</b>	0,9553	0	25,09
<b>96,76</b>	0,9862	0	21,21
<b>15,77</b>	0,511	53.098	43,49
<b>68,55</b>	0,9473	0,5719	28,81

---

**Previsão capacitor 4 (161h)**

RA	R	mse	RUL_predito
<b>81,32</b>	0,3593	11.121	8,06
<b>38,52</b>	0,5755	0,7368	16,02
<b>31,97</b>	0,5659	0,7536	16,67
<b>-34,22</b>	-0,3797	23.948	23,23
<b>-30,72</b>	-0,6685	28.962	22,89
<b>95,49</b>	0,5787	0,7313	9,47
<b>97,99</b>	0,9045	0	9,72
<b>36,20</b>	0,0592	16.331	16,25
<b>37,46</b>	0,718	0,4895	16,12
<b>34,50</b>	0,5876	0,7159	16,41

---

**Previsão capacitor 5 Tempo (139)**


---

RA	R	MSE	RUL predito
<b>90,79</b>	0,98	0,25	43,46
<b>83,30</b>	0,97	0,44	39,86
<b>89,09</b>	0,94	0,95	42,63
<b>93,38</b>	0,99	0,16	44,69
<b>-29,04</b>	0,70	44.387,00	-139,00
<b>92,99</b>	0,98	0,23	44,50
<b>90,54</b>	0,98	0,30	43,33
<b>89,85</b>	0,97	0,38	52,72
<b>-29,04</b>	0,42	86.259,00	-139,00
<b>75,06</b>	0,93	10.061,00	35,92

---



---

**Previsão capacitor 5 Tempo (149)**


---

RA	R	MSE	RUL predito
<b>93,96</b>	0,97	0,23	25,57
<b>-39,36</b>	0,78	18.901,00	-149,00
<b>96,63</b>	0,79	18.188,00	36,58
<b>88,25</b>	0,98	0,18	33,41
<b>92,55</b>	0,98	0,15	35,04
<b>99,44</b>	0,99	0,05	38,07
<b>81,72</b>	0,94	0,53	30,93
<b>72,14</b>	0,91	0,78	27,41
<b>-39,36</b>	0,92	0,70	-149,00
<b>98,04</b>	0,98	0,14	37,12

---

---

**Previsão capacitor 5 Tempo (161)**

RA	R	MSE	RUL predito
<b>81,83</b>	0,64	0,59	21,16
<b>82,79</b>	0,78	0,36	21,41
<b>81,26</b>	0,81	0,32	21,01
<b>90,31</b>	0,88	0,19	28,36
<b>-62,26</b>	0,32	11.269,00	-161,00
<b>95,36</b>	0,99	0,02	24,66
<b>73,26</b>	0,31	11.362,00	18,94
<b>87,59</b>	0,92	0,13	22,94
<b>82,11</b>	0,83	0,29	21,23
<b>84,73</b>	0,87	0,22	21,91

---

**Previsão capacitor 5 Tempo (171)**

RA	MSE	RUL predito
<b>6,23</b>	24.145,00	9,88
<b>-10,78</b>	0,82	-171,00
<b>63,70</b>	21.427,00	10,10
<b>81,60</b>	0,34	12,94
<b>65,60</b>	18.109,00	10,40
<b>87,50</b>	0,08	17,82
<b>86,30</b>	0,17	13,68
<b>75,40</b>	0,70	11,96
<b>66,30</b>	17.036,00	10,51
<b>96,00</b>	0,01	15,22

---

**Previsão capacitor 6 Tempo (139)**


---

RA	R	MSE	RUL predito
<b>85,07</b>	0,96	0,77	51,99
<b>-30,73</b>	0,87	2,81	-139,00
<b>92,06</b>	0,89	2,37	48,83
<b>-30,73</b>	0,84	3,41	-139,00
<b>-30,73</b>	0,90	2,17	-139,00
<b>80,02</b>	0,95	1,07	54,27
<b>-30,73</b>	0,94	1,38	-139,00
<b>-30,73</b>	0,94	1,27	-139,00
<b>-30,73</b>	0,83	3,76	-139,00
<b>97,64</b>	0,92	1,74	46,31

---



---

**Previsão capacitor 6 Tempo (149)**


---

RA	R	MSE	RUL predito
<b>-42,28</b>	0,35	9,43	-149,00
<b>-42,28</b>	0,58	6,17	-149,00
<b>-42,28</b>	0,88	1,73	-149,00
<b>72,33</b>	0,90	1,41	44,99
<b>-42,28</b>	0,87	1,95	-149,00
<b>-42,28</b>	0,54	6,77	-149,00
<b>86,52</b>	0,96	0,57	39,99
<b>-42,28</b>	0,32	9,98	-149,00
<b>-42,28</b>	0,76	3,47	-149,00
<b>-42,28</b>	0,81	2,82	-149,00

---

---

**Previsão capacitor 6 Tempo (161)**






RA	R	MSE	RUL predito
<b>-69,28</b>	-0,38	8,00	-161,00
<b>-69,28</b>	-0,12	6,46	-161,00
<b>-69,28</b>	-0,74	10,05	-161,00
<b>-69,28</b>	-0,75	10,10	-161,00
<b>83,01</b>	0,81	11,16	27,19
<b>-69,28</b>	-0,15	66,64	-161,00
<b>75,84</b>	0,83	0,98	28,86
<b>-69,28</b>	-0,64	9,46	-161,00
<b>-69,28</b>	-0,33	7,68	-161,00
<b>65,34</b>	0,22	4,50	15,18

---






**Previsão capacitor 6 Tempo (171)**






RA	MSE	RUL predito
<b>-12,92</b>	5,52	-171,00
<b>96,00</b>	0,03	13,77
<b>-12,92</b>	10,86	-171,00
<b>-12,92</b>	19,20	-171,00
<b>-12,92</b>	6,34	-171,00
<b>80,60</b>	0,61	15,81
<b>-12,92</b>	9,18	-171,00
<b>-12,92</b>	18,41	-171,00
<b>-12,92</b>	4,38	-171,00
<b>-12,92</b>	11,88	-171,00






**ANEXO C – IMAGEM DOS RESULTADOS DAS DEMAIS PREVISÕES DA RNA RBF**


















**ANEXO D – IMAGEM DOS RESULTADOS DAS DEMAIS PREVISÕES DA GPR**

