

**UNIVERSIDADE FEDERAL DE ITAJUBA**  
**PROGRAMA DE PÓS GRADUAÇÃO EM ENGENHARIA MECÂNICA**

**André Belluco Guerrini**

**Modelagem Computacional e Diagnóstico Termodinâmico de Turbina a  
Gás usando Redes Neurais**

**Novembro/2023**

**Itajubá – MG**

**UNIVERSIDADE FEDERAL DE ITAJUBA**

**PROGRAMA DE PÓS GRADUAÇÃO EM ENGENHARIA MECÂNICA**

**André Belluco Guerrini**

**Modelagem Computacional e Diagnóstico Termodinâmico de Turbina a Gás usando Redes Neurais**

Dissertação submetida ao programa de Pós Graduação em Engenharia Mecânica da Universidade Federal de Itajubá – UNIFEI como parte dos requisitos para a obtenção do título de Mestre em Ciências em Engenharia Mecânica

Área de Concentração: Térmica, Fluidos e Máquinas de Fluxo

Orientador: Prof. Dr. Osvaldo José Venturini

Co – orientador: Prof. Dr. Jose Carlos Escobar Palacio

**Novembro/2023**

**Itajubá – MG**



## **Agradecimentos**

Agradeço ao meu orientador Prof. Dr. Osvaldo José Venturini que dedicou seu tempo e compartilhou o conhecimento sempre de forma segura e paciente e me proporcionou realizar este trabalho. A você, professor, meu carinho e meu agradecimento.

Agradeço ao Mestre Eng. André Andrade, o Prof. Dr. Tiago Mendes e Prof. Dr. Euler Horta, excelentes profissionais, obrigado por toda a ajuda e atenção. Pessoas fundamentais para a conclusão deste trabalho.

Agradeço à Pró-Reitoria de Pesquisa e Pós-graduação PRPPG/IEM da UNIFEI por todo suporte nos períodos de dúvidas.

E à minha família por todo apoio e compreensão durante todo o tempo.

*Não devemos acreditar nos muitos que dizem que só as pessoas livres devem ser educadas, deveríamos antes acreditar nos filósofos que dizem que apenas as pessoas educadas são livres.*

Epicteto, filósofo romano e ex-escravo, *Discursos*

## Resumo

As turbinas a gás aeroderivativas são amplamente utilizadas em plataformas de produção de petróleo e gás do tipo FPSO, isto é, unidades de produção, armazenagem e transferência de petróleo (Floating Production Storage and Offloading), seja para a geração de energia elétrica, quando acopladas a um gerador elétrico, seja para o acionamento mecânico de bombas e compressores, quando acopladas a essas máquinas. A produção de óleo e gás é intermitente e exige das turbinas a gás disponibilidade e flexibilidade para uma operação segura e confiável. Para alcançar tais condições, o seu monitoramento é fator fundamental para garantir a segurança da operação. Outro fator é a realização do diagnóstico de falhas da turbina, ou seja, identificar de forma eficiente e confiável onde essas falhas estão ocorrendo, de forma que o planejamento da manutenção seja eficaz para manter a máquina disponível. Considerando esse cenário, este trabalho tem como objetivo principal a desenvolver um método para auxiliar na realização do diagnóstico de falhas que afetam o desempenho da turbina a gás. Para isso, um modelo de turbina a gás aeroderivativa composta por gerador de gás de dois *spools* turbina livre (PT) foi desenvolvido em MATLAB/Simulink com auxílio da biblioteca T-MATS. O modelo desenvolvido é capaz de representar o comportamento da turbina quando operando em regime permanente, uma vez que o objetivo é gerar dados para diferentes condições de operação e diferentes condições ambientes, para posterior utilização dos mesmos em um modelo de rede neural. O modelo da turbina a gás apresentou comportamento satisfatório, apresentando desvios não maiores que 1%, quando comparados com dados reais de operação. Em seguida, condições de falhas foram impostas ao modelo, o que possibilitou levantar informações sobre parâmetros operacionais do turbogerador operando sob degradação de alguns dos seus componentes. Os dados gerados pelo modelo da turbina a gás em MATLAB/Simulink foram utilizados para alimentar um modelo de *machine learning* para o diagnóstico das falhas. O modelo proposto é composto por duas redes neurais de propagação direta atuando em paralelo, sendo uma de regressão e outra de classificação. A rede de regressão tem o objetivo de atender os valores numéricos e o comportamento da turbina; a rede de classificação tem o objetivo de identificar e classificar as falhas. Ambas as redes apresentaram bons desempenhos para ambos os problemas de falhas isoladas e de falhas combinadas, não gerando erros quadráticos médios maiores que  $5 \times 10^{-6}$  para a rede de regressão e um erro percentual de 0.37% para a rede de classificação.

**Palavras-chave:** Turbinas a Gás, Diagnóstico de falhas, Machine Learning, Rede neural.

## Abstract

Aeroderivative gas turbines are widely used on Floating Production Storage and Offloading (FPSO) oil and gas production platforms. These units serve as production, storage, and oil transfer facilities. These turbines are employed either for generating electrical power when connected to an electrical generator or for mechanically driving pumps and compressors when connected to these machines. Oil and gas production is intermittent and demands gas turbines to be available and flexible for safe and reliable operation. To achieve such conditions, monitoring them is a crucial factor to ensure operational safety. Another factor is diagnosing turbine faults, efficiently and reliably identifying where these faults are occurring, so that maintenance planning is effective in keeping the machine operational. In this context, the primary objective of this work is to develop a method to assist in diagnosing faults that affect the performance of aeroderivative gas turbines. To achieve this, a model of an aeroderivative gas turbine, consisting of a two-spool gas generator and a power turbine (PT), was developed using MATLAB/Simulink with the assistance of the T-MATS library. The developed model can represent the behaviour of the gas turbine when operating in a steady-state since the goal is to generate data for different operating conditions and different environmental conditions for subsequent use in a neural network model. The gas turbine model exhibited satisfactory behaviour, with deviations not exceeding 1% when compared to actual operational data. Subsequently, fault conditions were imposed on the model, which provided information about operational parameters of the turbogenerator operating with degradation in some of its components. The data generated by the gas turbine model in MATLAB/Simulink were used to feed a machine learning model for fault diagnosis. The proposed model consists of two parallel feedforward neural networks, one for regression and one for classification. The regression network aims to handle numerical values and the turbine's behaviour, while the classification network aims to identify and classify faults. Both networks performed well for both single and combined fault problems, with mean squared errors not exceeding  $5 \times 10^{-6}$  for the regression network and a percentage error of 0.37% for the classification network.

**Key-words:** Gas Turbines, Fault Diagnosis, Machine Learning, Neural Network.

# Sumário

<b>INTRODUÇÃO</b> .....	16
<b>1.3 OBJETIVOS ESPECÍFICOS</b> .....	18
<b>REVISÃO BIBLIOGRÁFICA</b> .....	19
<b>2.1 TURBINAS A GÁS</b> .....	19
2.1.1 Compressor .....	20
2.1.2 Câmara de Combustão .....	24
2.1.3 Turbina .....	26
<b>2.2 CONFIGURAÇÕES DAS TURBINAS A GÁS</b> .....	29
<b>2.3 FALHAS EM TURBINAS A GÁS</b> .....	32
2.3.1 Depósito de Material nas Palhetas (Fouling) .....	33
2.3.2 Corrosão .....	33
2.3.3 Erosão .....	34
2.3.3 Folga no topo das palhetas do rotor ( <i>Tip Clearance</i> ) .....	34
2.3.4 Danos causados por objetos .....	35
<b>2.4 TÉCNICAS DE DIAGNÓSTICO</b> .....	35
2.4.1 Técnicas de diagnóstico com base em Machine Learning .....	37
2.4.1.1 Redes Neurais Artificiais de Propagação direta .....	37
2.4.1.2 Redes Neurais Recorrentes .....	40
2.4.1.2 Construção do modelo de rede neural .....	43
<b>MODELAGEM APLICADA DA TURBINA A GÁS</b> .....	48
3.1 Termodinâmica das turbinas a gás .....	48
3.2 Desempenho da Turbina a Gás .....	51
3.3 Desenvolvimento do modelo da turbina a gás .....	53
3.3.1 Descrição dos componentes .....	54
3.3.1.1 Compressores .....	56
3.3.1.2 Câmara de Combustão .....	62
3.3.1.3 Turbina .....	63
3.3.1.4 Componentes Auxiliares .....	67
3.3.1.4.1 Eixos Mecânicos .....	67
3.3.1.4.2 Redutor de Velocidades .....	68
3.3.1.4.3 Gerador elétrico .....	70
3.3.1.4.4 Solucionador Iterativo .....	70
<b>DIAGNÓSTICO TERMODINÂMICO DA TURBINA A GÁS</b> .....	76
4.1 Identificação do problema .....	76

<b>4.2 Coleta de dados .....</b>	<b>76</b>
<b>4.3 Pré-processamento dos dados .....</b>	<b>82</b>
<b>4.4 Construção do modelo e treinamento .....</b>	<b>86</b>
<b>4.5 Resultados e Avaliação do modelo de falhas isoladas.....</b>	<b>88</b>
<b>4.6 Aplicação do modelo para análise de falhas combinadas .....</b>	<b>91</b>
<b>4.7 Aplicação do diagnóstico termodinâmico .....</b>	<b>94</b>
<b>CONCLUSÕES.....</b>	<b>95</b>
<b>REFERÊNCIAS BIBLIOGRÁFICAS .....</b>	<b>99</b>
<b>APENDICE A. DADOS SIMULADOS .....</b>	<b>103</b>
<b>APÊNCIE B. REDE NEURAL PARA FALHAS ISOLADAS.....</b>	<b>105</b>
<b>APÊNCIE C. REDE NEURAL PARA FALHAS COMBINADAS .....</b>	<b>110</b>

## LISTA DE FIGURAS

Figura 2.1 Estrutura de uma turbina a gás simples.....	20
Figura 2.2. Esquema de um compressor axial .....	21
Figura 2.3. Compressor axial.....	22
Figura 2.4. Mapa típico de um compressor axial .....	23
Figura 2.5. Representação esquemática de uma câmara de combustão. ....	24
Figura 2.6. Câmara de combustão múltipla.....	25
Figura 2.7. Câmara de combustão tubo-anular.....	25
Figura 2.8. Câmara de combustão anular .....	26
Figura 2.9. Esquema de uma turbina axial .....	27
Figura 2.10. Mapa da Turbina .....	28
Figura 2.11. Mapa de eficiência da Turbina.....	28
Figura 2.12. Turbina a gás de eixo simples com Turbina Livre.....	29
Figura 2.13. Turbina a gás de eixo concêntrico.....	30
Figura 2.14. Turbina a gás de eixos concêntricos com PT.....	30
Figura 2.15. Potência e Heat Rate em função da Temperatura ambiente – GE-MS7001 FA..	31
Figura 2.16. Potência em Função da Altitude .....	32
Figura 2.17. Acúmulo de material nas palhetas da turbina .....	33
Figura 2.18. Corrosão de uma palheta.....	34
Figura 2.19. Nó de uma rede neural .....	38
Figura 2.20. Funções de transferência .....	39
Figura 2.21. Estrutura das camadas de uma rede neural .....	40
Figura 2.22. RNN simples .....	41
Figura 2.23. Estrutura da rede LSTM.....	42
Figura 2.24. Fluxograma para construção do modelo de Rede Neural .....	43
Figura 3.1. Ciclo Brayton. (a) Diagrama T-s. (b) Diagrama h-s .....	49
Figura 3.2. Mapa do compressor .....	52
Figura 3.3. Mapa da Turbina .....	53
Figura 3.4. Representação da Turbina a Gás simulada - SGT-A35(GT62) .....	55
Figura 3.5. Mapa do compressor de baixa pressão - LPC .....	57
Figura 3.6. Mapa do compressor de alta pressão - HPC .....	58
Figura 3.7. Bloco T-MATS para o compressor.....	59
Figura 3.8. Bloco T-MATS para a Câmara de Combustão .....	63
Figura 3.9. Mapa da Turbina livre.....	64
Figura 3.10. Bloco T-MATS para a Turbina.....	66
Figura 3.11. Bloco eixo mecânico .....	68
Figura 3.12. Bloco Caixa de engrenagem.....	69
Figura 3.13. Bloco Gerador elétrico .....	70
Figura 3.14. Bloco Solucionador Iterativo .....	72
Figura 3.15. Efeito da temperatura ambiente .....	74
Figura 3.16. Potência Elétrica x Heat Rate.....	74
Figura 3.17. Efeito da operação em carga parcial .....	75
Figura 4.1. Parâmetros de entrada da rede neural em condição nominal .....	78
Figura 4.2. Parâmetros de entrada da rede neural em condição de perda da eficiência da câmara de combustão .....	79
Figura 4.3. Parâmetros de entrada da rede neural em condição de fouling do LPC – severidade 1. ....	79

Figura 4.4. Parâmetros de entrada da rede neural em condição fouling do LPC – severidade 2 .....	80
Figura 4.5. Parâmetros de entrada da rede neural em condição fouling do HPC – severidade 1 .....	80
Figura 4.6. Parâmetros de entrada da rede neural em condição do fouling HPC – severidade 2 .....	81
Figura 4.7. Parâmetros de saída em condição nominal .....	82
Figura 4.9. Modelo proposto da rede neural para diagnostico .....	87
Figura 4.10. Erro Percentual para a rede neural de regressão .....	89
Figura 4.11. MSE para a rede neural de regressão .....	90
Figura 4.12. Erro percentual nulo para a rede neural de classificação .....	90
Figura 4.13. Modelo proposto da rede neural para diagnostico de falhas combinadas .....	92
Figura 4.14. Erro percentual para a rede de regressão – Falhas Combinadas .....	93
Figura 4.15. MSE rede neural de regressão – Falhas Combinadas .....	93
Figura 5.1. Fluxograma para um modelo de previsão de falhas .....	98

## LISTA DE TABELAS

Tabela 3.1. Dados de desempenho do turbogerador SGT-A35(GT62).....	55
Tabela 3.2. Parâmetros de entrada do compressor .....	60
Tabela 3.3. Parâmetros de saída do compressor.....	61
Tabela 3.4. Parâmetros de entrada da câmara de combustão .....	63
Tabela 3.5. Parâmetros de saída da câmara de combustão.....	63
Tabela 3.6. Parâmetros de entrada da turbina.....	66
Tabela 3.7. Parâmetros de saída da turbina .....	67
Tabela 3.8. Parâmetros de entrada do eixo.....	68
Tabela 3.9. Parâmetros de saída do eixo .....	68
Tabela 3.10. Parâmetros de entrada da caixa de engrenagem .....	69
Tabela 3.11. Parâmetros de saída da caixa de engrenagem.....	69
Tabela 3.12. Parâmetros de entrada do gerador elétrico.....	70
Tabela 3.13. Parâmetros de saída do gerador elétrico .....	70
Tabela 3.14. Parâmetros de entrada do Solucionador Iterativo.....	71
Tabela 3.15. Parâmetros de saída do Solucionador Iterativo .....	71
Tabela 3.16. Validação do Modelo para carga nominal .....	73
Tabela 4.1. Falhas Simuladas .....	77
Tabela 4.2. Organização dos dados de entrada e saída e rotulação das falhas .....	85
Tabela 4.3. Falhas Combinadas simuladas.....	91
Tabela 4.4. Rotulação das falhas combinadas simuladas .....	91
Tabela 4.5. Comparação dos resultados .....	94

## LISTA DE ABREVIATURAS

*DOD – Domestic Object Damage (Danos por Objetos Domésticos)*

*FNN – Feedforward Neural Network (Redes neurais de propagação direta)*

*FOD – Foreign Object Damage (Danos por Objetos Estranhos)*

*GG – Geradora de Gás*

*GHG – Green House Gases (Gases de efeito estufa)*

*HPC – High Pressure Compressor (Compressor de alta pressão)*

*HPT – High Pressure Turbine (Turbina de alta pressão)*

*HR – Heat Rate*

*IGV – Inlet Guide Vanes (Palhetas guia de entrada)*

*ISO – International Organization for Standardization*

*LHV – Low Heat Value (Poder Calorífico Inferior)*

*LPC – Low Pressure Compressor (Compressor de baixa de pressão)*

*LPT – Low Pressure Turbine (Turbina de baixa pressão)*

*LSTM – Long-Short Term Memory*

*NGV – Nozzle Guide Vanes (Palhetas Guia de Bocal)*

*PT – Power Turbine (Turbina Livre)*

*RNN – Recurrent Neural Network (Rede Neural Recorrente)*

*TMATS - Tool Box for the Modeling and Analysis of Thermodynamics Systems*

*VGW – Variable Guide Vanes (Palhetas de Direção Variável)*

## SIMBOLOGIA

### TERMODINAMICA

$\theta$  – *Parâmetro adimensional da temperatura [-]*

$\delta$  – *Parâmetro adimensional da pressão [-]*

$\eta_{Ci}$  – *Eficiência isentrópica do compressor [%]*

$\eta_{Ti}$  – *Eficiência isentrópica da turbina [%]*

$\eta_b$  – *Eficiência da combustão [%]*

$\eta_{th}$  – *Eficiência térmica da turbina a gás [%]*

$\eta_{LPC}$  – *Eficiência do compressor de baixa pressão [%]*

$\eta_{HPC}$  – *Eficiência do compressor de alta pressão [%]*

$\eta_{HPT}$  – *Eficiência da turbina de alta pressão [%]*

$\eta_{LPT}$  – *Eficiência da turbina de baixa pressão [%]*

$\eta_{PT}$  – *Eficiência da turbina de potência [%]*

$c_p$  – *Calor específico a pressão constante*

$k$  – *Razão entre calores específicos [-]*

$P_{rC}$  – *Razão de pressão do compressor [-]*

$P_{rT}$  – *Razão de expansão da turbina [-]*

$\dot{m}_f$  – *Vazão mássica de combustível [kg/s]*

$\dot{m}_a$  – *Vazão mássica de ar [kg/s]*

$\dot{m}_g$  – *Vazão mássica dos gases de saída da turbina a gás [kg/s]*

$W_{comp}$  – *Trabalho do compressor [kJ]*

$W_t$  – *Trabalho da turbina [kJ]*

$\dot{W}_{out}$  – *Potência produzida pela turbina a gás [kW]*

$\dot{Q}$  – *Calor fornecido pelo combustível [kW]*

## **MACHINE LEARNING**

$\mu$  – Média

$\sigma$  – *Desvio padrão*

$b$  – *Bias*

$f(A_i)$  – *Função de transferência*

purelin – *Função de transferência linear*

logsig – *Função de transferência log-sigmoid*

tansig – *Função de transferência tangente hiperbólica*

MAE – *Erro médio absoluto*

MSE – *Erro quadrático médio*

MAPE – *Erro médio percentual absoluto*

RMSE – *Erro médio quadrático da raiz*

$x$  – *vetor de entrada*

$w$  – *pesos sinápticos*

$Z$  – *Conjunto de dados normalizados*

# CAPÍTULO 1

## INTRODUÇÃO

Em plataformas marítimas de produção de petróleo, a geração de energia elétrica é efetuada fundamentalmente por turbinas a gás aeroderivativas, uma vez que as mesmas apresentam alta relação potência/peso, em uma configuração que normalmente adota quatro turbogeradores que alimentam dois barramentos elétricos principais. Essas turbinas são responsáveis por manter os equipamentos da planta operando e, também, fornecendo eletricidade para as atividades humanas básicas. Nessas unidades de produção de óleo, a rede elétrica é um sistema ilhado, ou seja, não possui suporte de um grande centro de geração para manter estáveis a frequência e a tensão. Dessa forma, essas turbinas precisam ser colocadas em operação rapidamente e, muitas vezes, fora da carga nominal (operação *off-design*), o que pode levar degradação prematura dos seus componentes.

A detecção dessas falhas é uma tarefa extremamente complexa e vai além de falhas mecânicas, como identificação de desbalanceamento e vibração, por exemplo. No entanto, as falhas não mecânicas, também conhecidas como falhas de desempenho, são de difícil determinação devido a altas temperaturas em que as turbinas a gás operam. Assim, para a determinação desse tipo de falha, a inteligência artificial vem ajudando em muito no diagnóstico termodinâmico das turbinas a gás [TSOUTSANIS, QURESHI, HESHAM, 2023].

Aumentar a confiabilidade, disponibilidade e segurança dos equipamentos, ao mesmo tempo em que reduz os custos operacionais e de manutenção, são fatores-chave para a lucratividade e competitividade. As práticas de monitoramento têm sido realizadas há muito tempo; no entanto, ao longo da última década, os algoritmos e sua implementação se tornaram mais sofisticados. Além disso, a tendência atual de aumentar o uso de sensores em equipamentos industriais, bem como o desenvolvimento de ferramentas inteligentes para avaliação de condição e falha, tem levado a estratégias de gerenciamento mais eficazes [PRAKASH *et al.*, 2021].

Com isso, a grande quantidade de dados coletados por sistemas industriais contém informações sobre os componentes, eventos e alarmes relacionados ao processo industrial. Esse conjunto de dados pode fornecer conhecimento e informação relevante sobre os processos e

suas dinâmicas, levando a um entendimento avançado do processo e, logo, a menores custos de manutenção e redução das falhas de máquinas e, assim, aumentando a produção e a segurança do operador [ALCALÁ *et al.*, 2019]. A análise de dados usando técnicas de *machine learning* é capaz de lidar com grandes quantidades de dados e adquirir informação em tempo real sobre o estado da máquina. Esses procedimentos são usados para obter informações de séries temporais multidimensionais, para identificar padrões ocultos e gerenciar resultados para uma tomada de decisões estratégicas [DING *et al.*, 2016].

Todo esse procedimento para a análise do estado da máquina ou de um processo industrial é obrigatório para lidar com os problemas industriais atualmente. Dessa forma, este trabalho visa aplicar esses procedimentos em turbinas a gás, uma máquina termodinâmica que usa ar e combustível para converter a potência química do combustível em potência mecânica [TALAAT *et al.*, 2018].

Mudanças nas condições ambientais e condições de controle operacionais levam a mudanças significantes no estado interno da turbina a gás. Uma turbina a gás industrial é um sistema termodinâmico não linear, o que traz grandes desafios para diagnosticar a degradação, envelhecimento, danos e falhas dos seus componentes [YING, LI, 2022].

A necessidade de uma rápida atuação na turbina a gás quando esta entra em falha, a fim de reduzir custos operacionais, reduzir consumo energético e emissões, este trabalho tem como objetivo aplicar um método de inteligência computacional em um modelo termodinâmico de uma turbina a gás, a fim de detectar falhas, realizando o diagnóstico termodinâmico de forma eficiente e rápida. O modelo termodinâmico será construído com base na turbina SGT-A35(GT62), da Siemens, e validado com dados reais do fabricante. Após a validação, o modelo será usado para simulação termodinâmica para diferentes condições, as quais as turbinas a gás reais estão sujeitas, assim como as condições de operação com falhas em seus componentes.

## **1.2 OBJETIVOS GERAIS**

Propor e avaliar um método de diagnóstico termodinâmico de turbinas a gás aeroderivativa, baseado em inteligência artificial, a fim de identificar anomalias nos componentes dessas unidades.

### 1.3 OBJETIVOS ESPECÍFICOS

- Modelar uma Turbina a Gás aeroderivativa em regime permanente e validar o modelo através da comparação com dados reais, a fim de utilizar o modelo para simulação termodinâmica
- Desenvolver de um modelo de rede neural artificial para identificação e classificação de falhas.

### 1.4 ESTRUTURA DA DISSERTAÇÃO

Esta dissertação, além deste capítulo, ao qual já foram apresentadas as motivações e justificativas, bem como os objetivos gerais e específicos, possui a seguinte estrutura.

**Capítulo 2: Revisão Bibliográfica.** Este capítulo apresenta as turbinas a gás de médio e grande porte do ponto de vista técnico, mostrando os principais componentes mecânicos e as principais configurações utilizadas na indústria. As principais falhas que afetam o desempenho das turbinas a gás. Neste capítulo, também, é apresentado a fundamentação teórica para as técnicas de *machine learning* e como implementa-las.

**Capítulo 3: Modelagem Aplicada da Turbina a Gás.** Neste capítulo é apresentado o equacionamento termodinâmico para uma turbina a gás simples, uma discussão sobre o desempenho dessas turbomaquinas e todo o processo de escalonamento e modelagem da turbina a gás, em MATLAB/Simulink, utilizada no estudo de caso. Os resultados e a validação do modelo são apresentados ao final do capítulo.

**Capítulo 4: Diagnóstico Termodinâmico da Turbina a Gás.** Neste capítulo é apresentado a metodologia proposta de identificação e classificação de falhas. Os dados gerados pelo modelo em MATLAB/Simulink são apresentados. O modelo de rede neural para diagnóstico é proposto e os resultados são apresentados.

**Capítulo 5: Conclusão.** Neste capítulo é feita uma discussão sobre os resultados obtidos e as conclusões finais sobre o estudo de caso e o problema proposto, bem como as sugestões para trabalhos futuros.

**Capítulo 6: Referências Bibliográficas.** O último capítulo deste trabalho apresenta as referências bibliográficas utilizadas.

# CAPÍTULO 2

## REVISÃO BIBLIOGRÁFICA

Esta revisão contém informações de base pertinentes ao trabalho, tais como o estudo de turbinas a gás e as configurações encontradas, o estudo das principais falhas encontradas nessas turbomáquinas, e os métodos de diagnóstico termodinâmico baseados em *machine learning*.

### 2.1 TURBINAS A GÁS

As turbinas a gás são turbomáquinas compostas essencialmente por um compressor uma câmara de combustão e um expensor (turbina). Atualmente, as turbinas a gás são abundantemente usadas em diversas indústrias a fim de acionar geradores visando a geração de eletricidade, e são empregadas também para acionamento de cargas como geradores, bombas, compressores ou propulsores. A turbina a gás inicialmente era um sistema relativamente simples e se desenvolveu em um sistema complexo, porém com confiabilidade e de altas eficiências. O desempenho e operação satisfatória das turbinas a gás são de suma importância para a rentabilidade das indústrias [RASAK, 2007].

Raak (2007) ainda explica que para uma turbina produzir potência, é necessário que a pressão de entrada da turbina (expansor) seja maior que a pressão de saída. Um compressor é usado para fornecer esse aumento de pressão na entrada do expensor (turbina). Se a vazão de descarga do compressor é expandida através da turbina, a potência produzida pela turbina será menor que a potência consumida pelo compressor, devido às perdas no compressor e na turbina. Nessas condições, o sistema como um todo não irá funcionar. Se energia for adicionada à vazão de descarga do compressor, de forma a suprir as perdas no compressor e na turbina, então o sistema irá rotacionar, mas não produzirá potência excedente. Para isso, energia adicional precisa ser fornecida na vazão de descarga do compressor. Essa energia adicional é fornecida através da queima de um combustível em uma câmara de combustão, que é instalada entre o compressor e a turbina, como mostra a Figura 2.1.

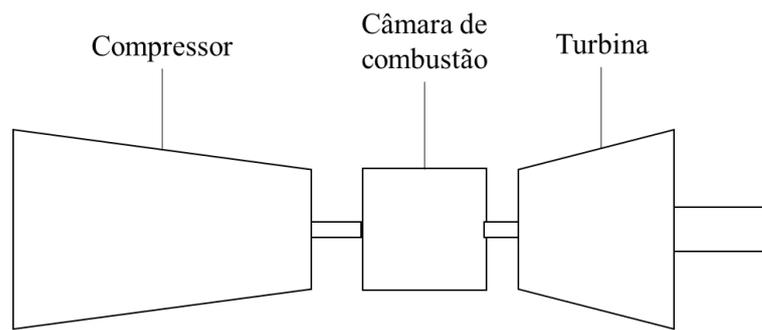


Figura 2.1 Estrutura de uma turbina a gás simples. (Fonte: Autor)

As turbinas a gás estão sujeitas a limites operacionais, os quais, se não forem respeitados, podem levar a instabilidades operacionais, comprometendo a eficiência do motor, ou até mesmo causando danos ao equipamento. Estas instabilidades podem ocorrer devido a mudanças de condições de operação (carga, climáticas etc.) ou transitórios operacionais, os quais são normalmente decorrentes de mudanças de carga, partida, parada ou condições anormais de operação [Kim et al., 2000; Wilson e Korakianitis, 2014].

A compreensão do comportamento das turbinas a gás quando operando nas suas condições de projeto (“*design point*”) e fora dele (“*off-design*”) é de fundamental importância, pois alterações climáticas, mudanças nas características do combustível ou de cargas podem levar a variações significativas do desempenho do acionador. Este comportamento deve ser conhecido para que seja possível projetar soluções para os eventuais problemas, mantendo o acionador, sempre que possível, com elevado desempenho e operando em condições seguras [ANDRADE, 2021].

### 2.1.1 Compressor

O propósito do compressor é aumentar a pressão total do ar para a pressão requerida pelo ciclo termodinâmico, o que deve ser feito preferencialmente com o menor consumo de potência de eixo possível. Dependendo da direção do escoamento, o compressor é classificado como centrífugo, quando o escoamento principal é radial ao eixo do rotor, ou axial, quando o escoamento principal é axial ao eixo do rotor, sendo o compressor axial mais utilizado em turbinas de médio e grande porte, como na turbina a gás utilizada neste trabalho. Logo, esta dissertação foca apenas no compressor axial.

Para conseguir elevar a pressão, o compressor axial possui vários estágios, os quais são compostos fundamentalmente de um rotor e um estator, como mostra Figura 2.2 [RAZAK,

2007]. O ar é inicialmente acelerado pelo rotor e, então, desacelerado pelo estator, esse processo transforma a energia cinética no rotor em pressão estática no estator, sendo o processo repetido quantas vezes for necessário para atingir a razão de pressão requerida pelo ciclo termodinâmico (SARAVANAMUTTOO et al., 2013).

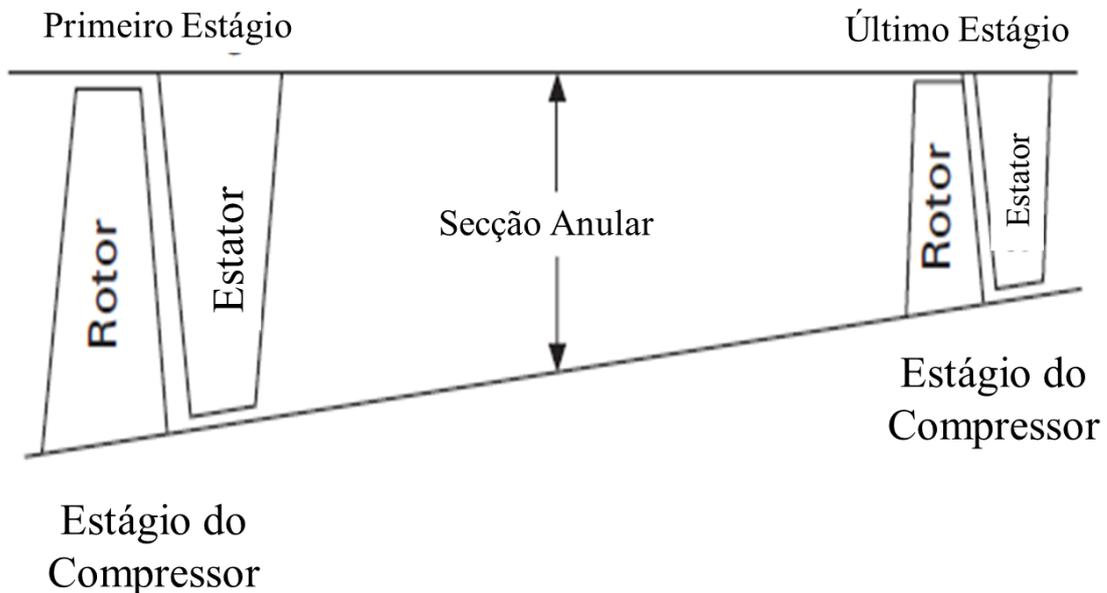


Figura 2.2. Esquema de um compressor axial (Fonte: Razak, 2007)

Alguns compressores axiais de turbinas a gás utilizam as *pás diretoras de entrada (IGVs – Inlet Guide Vanes)*, as quais guiam o fluxo de ar para o primeiro estágio. Muitas unidades industriais possuem IGVs móveis, permitindo que o ângulo de entrada no primeiro estágio varie com a velocidade rotacional, de forma a melhorar o desempenho em *off-design*.

A Figura 2.2 mostra que o compressor tem uma redução no tamanho das pás tanto do rotor quanto do estator, à medida que o fluxo avança. Isso é desejável para manter a velocidade axial aproximadamente constante em todo o compressor, e, para isso, é necessário diminuir a área de fluxo e, logo, a altura das palhetas [SARAVANAMUTTO, 2013].

SARAVANAMUTTO *et al.* 2013 ainda explica que devido ao gradiente de pressão adverso em compressores, as camadas limites ao longo da secção anular aumentam à medida que o fluxo avança, o principal efeito é reduzir a área disponível para o fluxo de ar abaixo da área geométrica da secção anular. Isso trará efeitos consideráveis na velocidade axial através do compressor e deve ser considerado no processo. O fluxo é extremamente complexo, com sucessíveis acelerações e desacelerações combinadas com mudanças na direção tangencial do

fluxo; os efeitos da folga da ponta também são significativos, tornando o cálculo do crescimento da camada limite extremamente difícil. Para ilustrar a complexidade dos compressores axiais, a Figura 2.3 mostra um compressor axial de dois eixos.

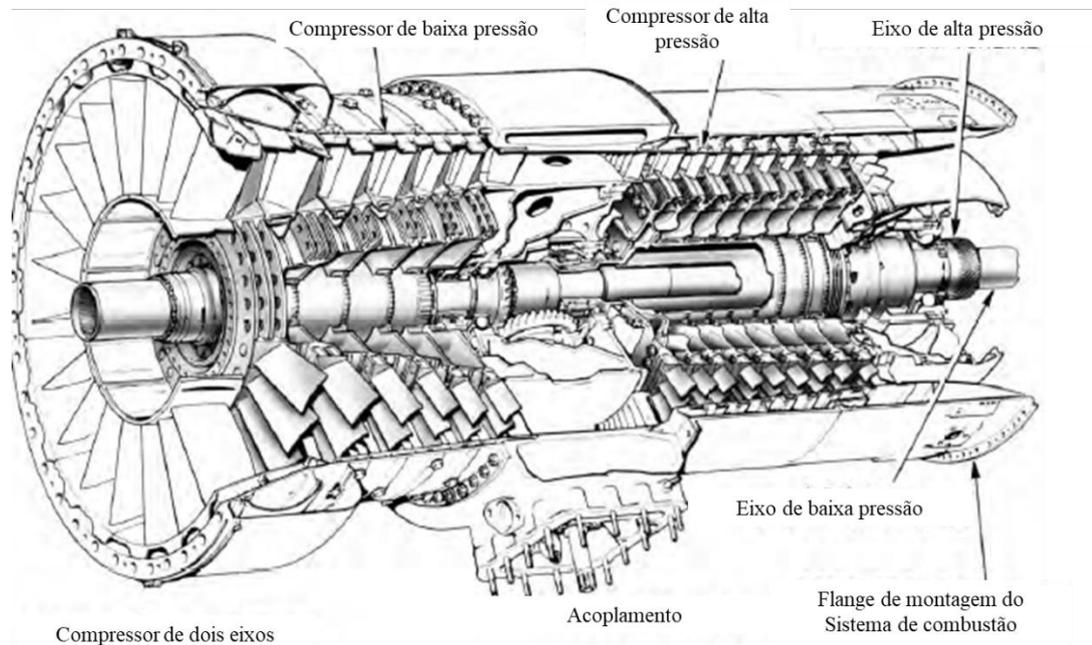


Figura 2.3. Compressor axial (Fonte: Roll Royce, 1986)

Quando o compressor opera a baixas velocidades, a velocidade axial nos estágios finais de compressão é muito menor que a velocidade de projeto, resultando em velocidades axiais incorretas, o que pode causar *stall* nas palhetas e o surge do compressor. Existem métodos para solucionar esse problema, tais como usar configurações de múltiplos eixos ou usar estatores móveis nos primeiros estágios do compressor.

Será exigido para todo e qualquer compressor operar em condições *off-design*, tais como partida, operação em carga parcial e/ou potência máxima e o compressor deve ser capaz de satisfazer a operação sob diversas velocidades rotacionais e diferentes condições do ar de entrada. Para isso, é preciso definir os estados estáveis de operação do compressor, ou seja, curvas contendo os parâmetros do compressor. O conjunto dessas curvas são conhecidas como mapa de desempenho do compressor e podem ser especificadas pela razão de pressão entregue em função da vazão mássica corrigida para vários valores fixos de velocidade rotacional. Essas características, no entanto, são dependentes de outras variáveis, tais como as condições de temperatura e pressão na entrada do compressor. A Figura 2.4 mostra um mapa típico de um compressor axial. Qualquer operação à esquerda/acima da linha de surge não é possível, uma vez que após o *surge*, o compressor perde a capacidade de compressão e entra em trip.

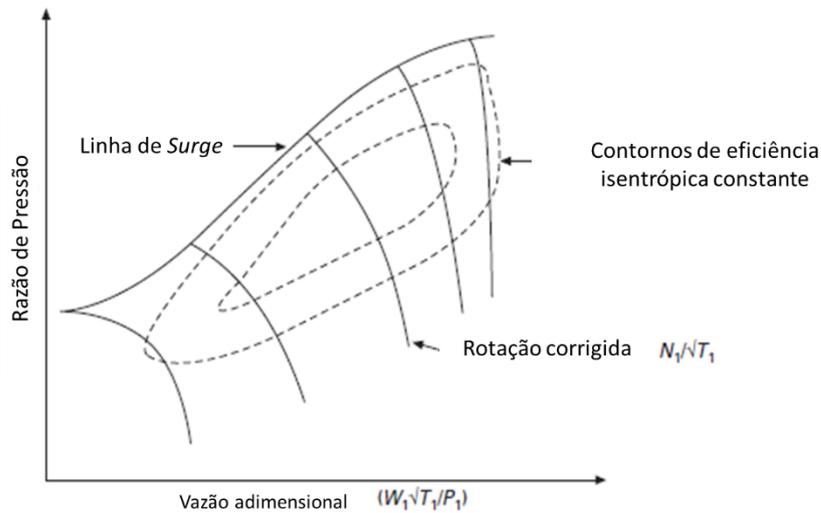


Figura 2.4. Estrutura de um Mapa típico de um compressor axial (Fonte: Razak, 2007)

Sob altas rotações, as curvas de rotação constantes tendem a ficar verticais devido à condição de “*chocking*”. O *chocking* ocorre quando o compressor atinge a vazão máxima para uma dada rotação. A partir desse ponto, não há mais aumento de vazão, mesmo havendo variação da razão de pressão. Este ponto de operação também é conhecido como “*stonewall*” e se diz que o compressor está ‘blocado’ ou ‘entupido’ [ANDRADE, 2021].

O surge é um fenômeno complexo que ocorre devido ao gradiente de pressão do fluxo de ar, ou seja, como a pressão de saída do compressor é maior que a pressão de entrada, fluxo reverso pode acontecer quando ocorre o *stall* (descolamento da camada limite na palheta) nas palhetas dos últimos estágios do compressor, causando altos índices de vibração e perda de eficiência.

Para obter o mapa de operação do compressor é necessário que a máquina seja conduzida por uma fonte externa de potência e essa fonte externa deve ser capaz de atender a operação a velocidade variável, com a velocidade sendo continuamente modificada e controlada de forma estreita. Outro método de se obter o mapa do compressor de forma preliminar é utilizando simulação computacional.

Além disso, a faixa de operação do compressor axial se torna muito restrita ao combinar o compressor junto à câmara de combustão e a turbina em uma turbina a gás como será visto no próximo capítulo desta dissertação.

## 2.1.2 Câmara de Combustão

O fornecimento de energia ao ciclo termodinâmico se dá na câmara de combustão, onde o combustível é misturado com ar a alta pressão e queimado. A câmara de combustão deve obviamente impor baixa perda de carga no escoamento e possuir elevada eficiência, de forma que possa queimar adequadamente todo o combustível injetado na mesma. A quantidade de combustível é limitada pela máxima temperatura suportada pelo material das palhetas da turbina, que pode chegar a temperaturas de 1550 °C [TYLISZCZAK et al., 2016; BOSE, 2016]. Cerca de 15-20% do ar é injetado ao redor do jato de combustível na zona primária para fornecer a alta temperatura necessária para uma combustão rápida. 30% do total de ar é introduzido através de orifícios na câmara de combustão na zona secundária para completar a combustão. Para obter alta eficiência de combustão, este ar deve ser injetado cuidadosamente nos pontos certos do processo, para evitar resfriar a chama localmente e reduzir drasticamente a taxa de reação. Por fim, na zona terciária, ou zona de diluição, o restante do ar é misturado com os produtos da combustão para resfriar o fluxo e atingir a temperatura necessária na entrada da turbina. Deve-se promover turbulência suficiente para que os fluxos quente e frio se misturem completamente e proporcionem a distribuição desejada de temperatura na saída, sem apresentar pontos quentes que possam danificar as pás da turbina (SARAVANAMUTTOO *et al.*, 2013). Figura 2.5 mostra um esquema desse processo.

O *design* da câmara de combustão e o método de injeção de combustível pode variar, mas a distribuição do fluxo de ar para efetuar e manter a combustão é sempre similar ao processo descrito no parágrafo anterior. (SOARES, 2014).

Existem três tipos principais de câmaras de combustão para turbinas a gás, os quais são múltiplas câmaras, câmaras tubo-anular e a anular.

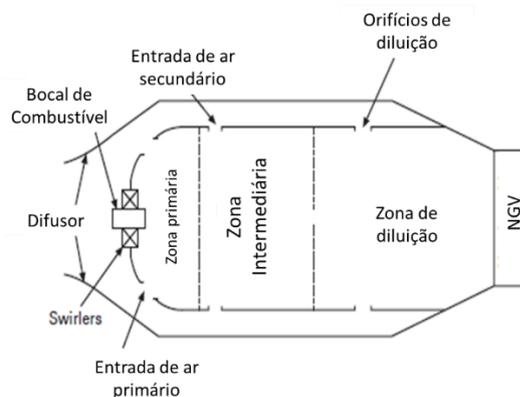


Figura 2.5. Representação esquemática de uma câmara de combustão. (Fonte: Razak, 2007)

A câmara de combustão múltipla é mais utilizada em turbinas a gás com compressores centrífugos e as primeiras turbinas a gás com compressor axial. As câmaras são dispostas ao redor do eixo e o ar proveniente do compressor é direcionado por dutos para atender cada câmara. Cada câmara possui um tubo de chama interno em torno do qual há um invólucro de ar. O ar passa pelo bico do tubo de combustão e também entre o tubo e o invólucro externo (*air casing*), como já descrito. Os tubos de combustão são todos interconectados, permitindo que cada tubo opere com a mesma pressão e também permite que a chama propague em torno dos tubos de combustão durante a partida da turbina a gás. A Figura 2.6 mostra a câmara de combustão múltipla.

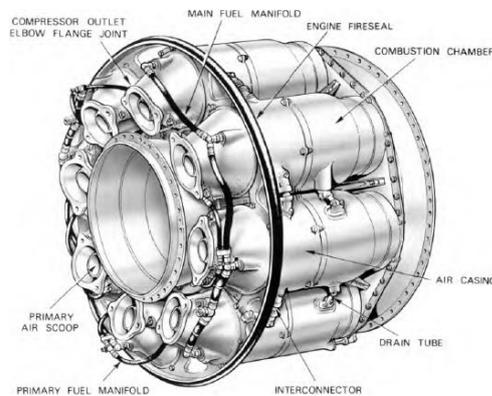


Figura 2.6. Câmara de combustão múltipla. (Fonte: Rolls Royce, 1986)

A configuração tubo-anular da câmara de combustão é a transição entre a câmara de combustão múltipla e anular. Um determinado número de tubos de combustão é alocado dentro um mesmo invólucro externo (*air casing*). Esta configuração combina a facilidade de revisão e teste do sistema múltiplo com a compacidade do sistema anular. A Figura 2.7 mostra essa configuração.

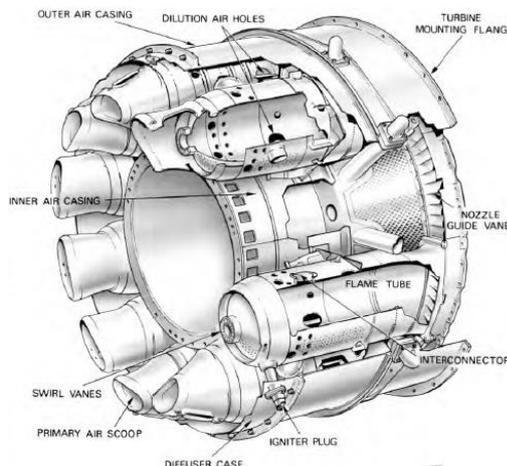


Figura 2.7. Câmara de combustão tubo-anular. (Fonte: Rolls Royce, 1986)

A câmara de combustão anular, Figura 2.8, consiste de um único tubo de combustão, na forma completamente anular contido em um invólucro interno e um invólucro externo. A principal vantagem deste tipo de câmara de combustão é que, para a mesma potência produzida, o tamanho da câmara é apenas 75% do tamanho do tubo-anular com o mesmo diâmetro, resultando em uma considerável economia de peso e custos com manufatura. Outra vantagem é a eliminação da propagação da combustão de câmara para câmara.

Comparada com a câmara de combustão tubo-anular, a área da parede de uma câmara anular comparável é muito menor; conseqüentemente, a quantidade de ar de resfriamento necessária para evitar a queima da parede do tubo de chama é menor, em cerca de 15%. Essa redução de ar de resfriamento aumenta a eficiência de combustão, eliminando praticamente o combustível não queimado e oxidando o monóxido de carbono em dióxido de carbono não tóxico, reduzindo assim a poluição do ar (SOARES, 2014).

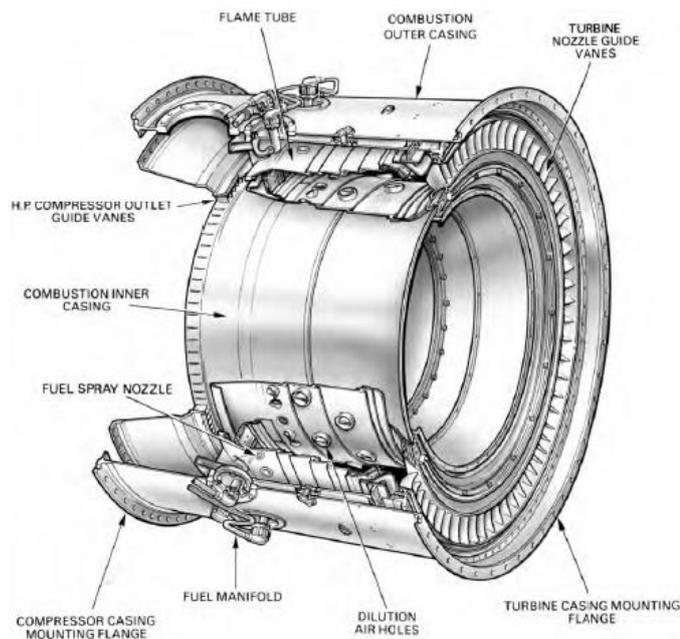


Figura 2.8. Câmara de combustão anular (Fonte: Rolls Royce, 1986)

### 2.1.3 Turbina

A turbina é responsável por fornecer potência para acionar o compressor e fornecer potência de eixo para uma carga. O fornecimento de potência ocorre através da extração da energia contida nos gases da combustão, expandindo para baixas temperaturas e pressões. O processo é complexo e envolve altos níveis de estresse, uma vez que as palhetas da turbina

giram a altas rotações e o gás que entra na turbina está à altas temperaturas, podendo chegar a 1.600°C [GÜLEN, 2019].

Para produzir a potência de eixo, a turbina possui uma série de estágios e cada estágio consiste de uma seção de bocais guia estacionários (*NGV – nozzle guide vanes*, também chamados de estatores) e uma seção de palhetas móveis, como mostra a Figura 2.9. O número de estágios depende da relação entre a potência requerida, a velocidade rotacional necessária para produzir essa potência, e diâmetro permitido (SOARES,2014).

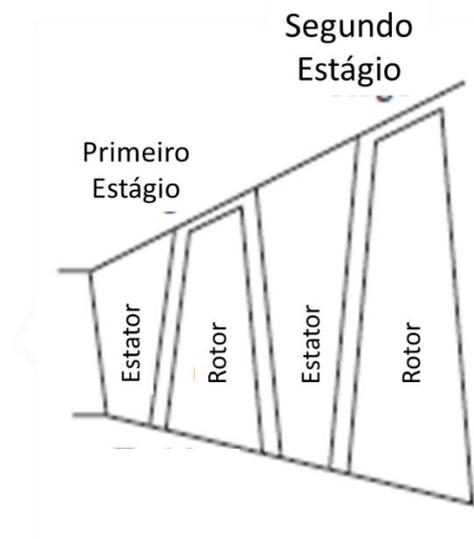


Figura 2.9. Esquema de uma turbina axial (Fonte: Razak, 2007)

Como a turbina trabalha com um gradiente de pressão favorável, ou seja, a pressão diminui ao longo dos estágios, esta não possui os problemas com *surge* e a quantidade de trabalho extraído por um estágio da turbina pode ser consideravelmente maior, se comparada com o trabalho absorvido por um estágio do compressor (RAZAK, 2007).

Assim como nos compressores, é conveniente representar a faixa operacional da turbina em um mapa, baseado em todos os estágios da turbina. O mapa é muito útil quando a turbina precisa operar em condições de *off-design*. Um mapa típico de uma turina é mostrado na Figura 2.10. A vazão mássica da turbina aumenta com o aumento da razão de pressão e a partir de uma dada razão de pressão, o número de Mach na palheta atinge a unidade, o que pode restringir a vazão mássica que passa pela turbina. Essas são as condições de *chocke* da turbina. A vazão mássica permanece constante devido ao *chocke* apenas se a NGV está em estrangulamento (em estado de *chocke*), como mostra a Figura 2.10.

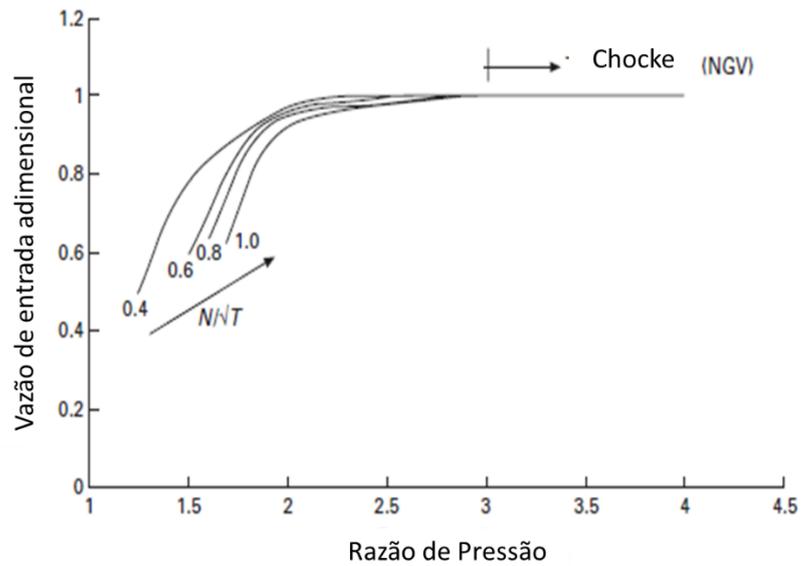


Figura 2.10. Mapa da Turbina (Razak, 2007)

A Figura 2.11. mostra um mapa típico de eficiência da turbina. A turbina apresenta uma perda na eficiência com o aumento da razão de pressão à baixas rotações, mas em operações nominais, a 80% ou mais da rotação, a eficiência permanece aproximadamente constante.

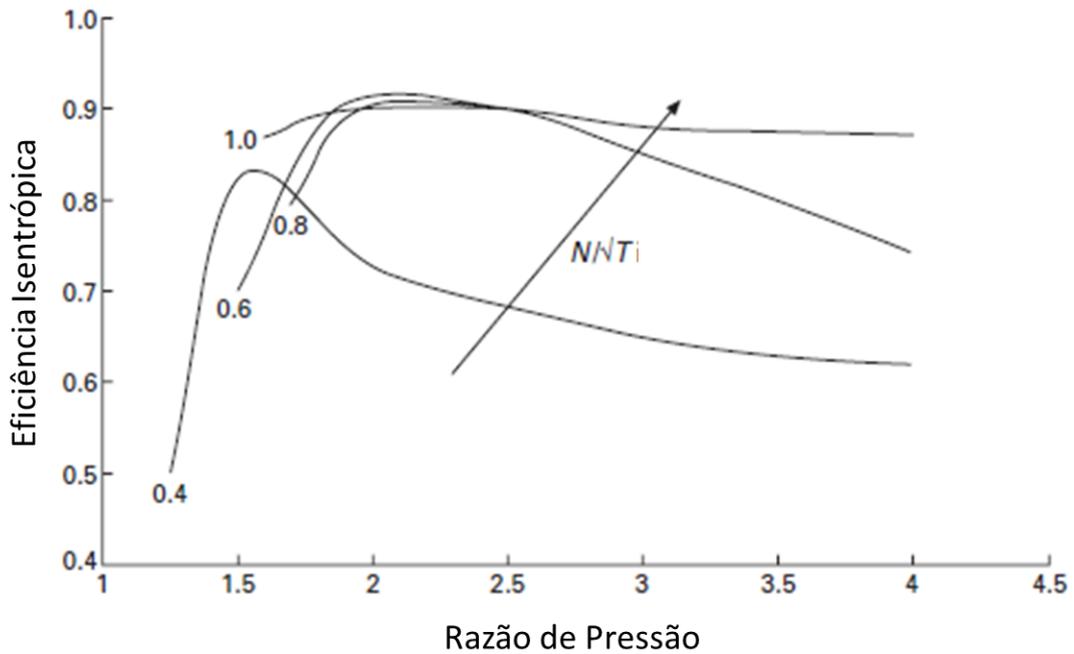


Figura 2.11. Mapa de eficiência da Turbina (Fonte: Razak, 2007)

## 2.2 CONFIGURAÇÕES DAS TURBINAS A GÁS

A configuração adotada para uma dada turbina a gás é uma característica na análise de desempenho. Apesar de a maioria das turbinas a gás trabalharem com ciclos semelhantes e a mesma estrutura básica, há consideráveis diferenças quando analisadas em detalhes. Para aumentar o desempenho, eficiência e potência produzida, diversas configurações podem ser utilizadas, tais como reaquecimento, inter-resfriamento e/ou regeneração. As turbinas a gás também podem ser classificadas baseadas no número de eixos, podendo ser de um eixo simples ou vários eixos – dois eixos ou três eixos (ASGARI, 2014).

Uma turbina a gás de eixo simples possui uma configuração básica em que o compressor e a turbina são acopladas por um eixo em comum, e que parte da potência produzida pela turbina é utilizada para acionar o compressor (GHOJEL, 2020), como mostrado na Figura 2.1. Esses equipamentos são tipicamente utilizados para acionamento de geradores, em que variações significantes de rotação não são necessárias (BROOKS, 2015).

Turbinas a gás de eixo simples com turbina de potência, Figura 2.12, são geralmente usadas na geração de eletricidade, indústria marinha, e plataformas de óleo e gás. Essas turbinas a gás são divididas em duas partes. A primeira, o conjunto composto por compressor, combustor e turbina, é conhecida como gerador de gás (GG), que aciona o compressor, enquanto a segunda parte, composta por uma turbina livre é conhecida como turbina de potência - PT (ou turbina livre), a qual aciona a carga externa. O gerador de gás fornece pressão e temperatura suficientes para a turbina de potência, e não há acoplamento mecânico entre as duas turbinas, a PT rotaciona apenas com a velocidade dos gases de exaustão do GG (GHOJEL, 2020). Ou seja, o acoplamento dessa turbina de baixa pressão é feita aerodinamicamente, um recurso que permite que a turbina de potência seja operada com uma gama de velocidades, fazendo as turbinas de dois eixos ideais para aplicações de rotação variável (BROOKS, 2015).

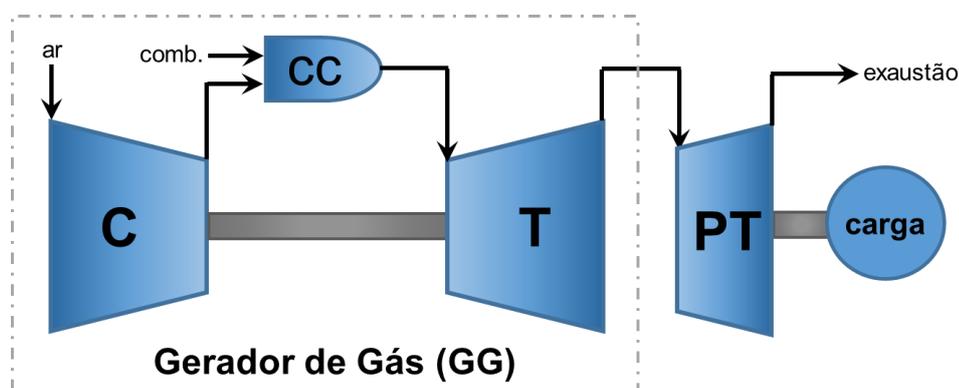


Figura 2.12. Esquema de uma Turbina a gás de eixo simples com Turbina Livre

A configuração de eixos concêntricos, Figura 2.13, é uma configuração mais complexa, sendo também considerada uma turbina a gás de dois eixos, mas o gerador de gás possui dois *spools* (eixos rotativos), um eixo de baixa pressão e um eixo de alta pressão. O compressor de baixa pressão (LPC – *low pressure compressor*) é acionado pela turbina de baixa pressão (LPT – *low pressure turbine*) e o compressor de alta pressão (HPC – *high pressure compressor*) é acionado pela turbina de alta pressão (HPT – *high pressure turbine*).

A configuração de eixos concêntricos com turbina de potência, Figura 2.14, é essencialmente uma turbina a gás projetada para propulsão aeronáutica. Uma turbina de potência é adicionada ao ciclo como geradora de potência/torque. Essa configuração é a configuração utilizada nesse trabalho.

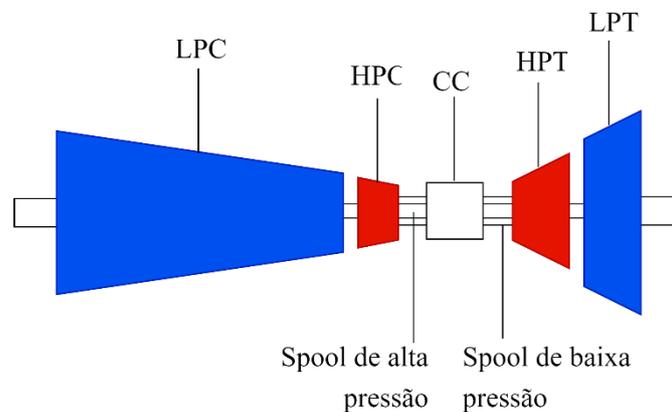


Figura 2.13. Esquema de uma Turbina a gás de eixo concêntrico. (Fonte: Autor)

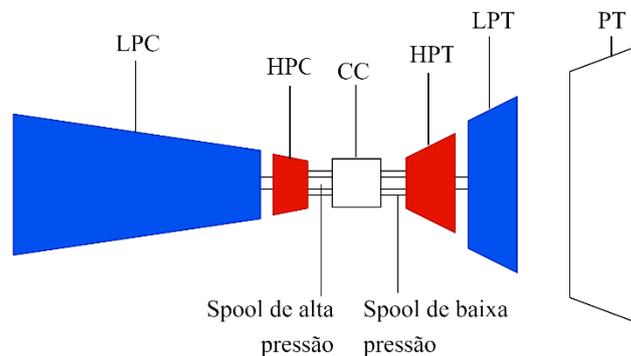


Figura 2.14. Esquema de uma Turbina a gás de eixos concêntricos com PT. (Fonte: Autor)

Com deslocamento volumétrico essencialmente constante, as turbinas a gás usam como fluido de trabalho o ar atmosférico, logo seu desempenho está intimamente relacionado às condições do ambiente em que está instalada. Seu desempenho será afetado quando a vazão mássica de ar que entra no compressor for diferente das condições de referência (ISO), isto é, das condições padrão usadas pelos fabricantes e entidades certificadoras, para estabelecer de maneira uniforme as suas características de trabalho e desempenho. As condições ISO de referência são: temperatura ambiente 15 °C, pressão atmosférica de 101,32 kPa e umidade relativa do ar de 60%.

A título de exemplo a Figura 2.15 mostra o comportamento típico da potência gerada e o consumo específico de calor (*Heat Rate*) em função da temperatura ambiente, usando o caso da turbina GE-MS7001 FA. Como pode ser observado, incrementos na temperatura ambiente de 5 °C, levam a redução de aproximadamente 6% na potência produzida e incrementos de 2,5% no “Heat Rate”. A Figura 2.16 mostra o efeito da altitude ou pressão barométrica na potência gerada pela turbina, em termos da fração do valor de projeto (condições ISO). Ar menos denso reduz a vazão em massa de ar e a potência de saída, praticamente de forma proporcional. O *heat rate* e outros parâmetros do ciclo não são afetados tão significativamente, quanto o são pela temperatura.

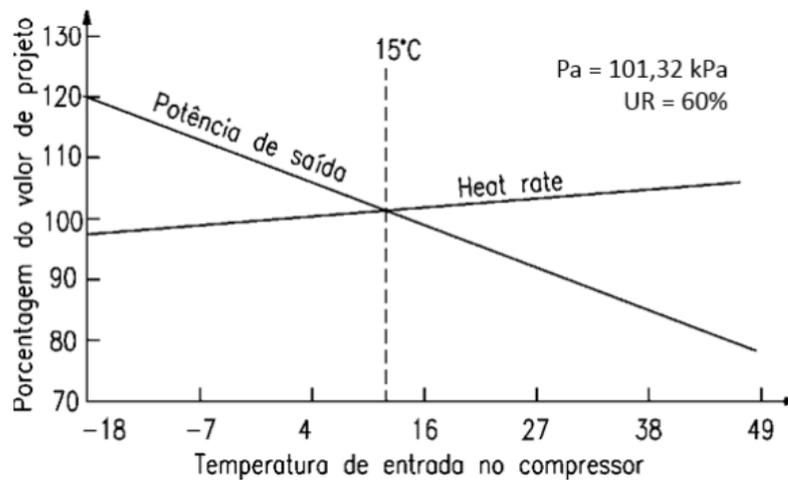


Figura 2.15. Potência e *Heat Rate* em função da Temperatura ambiente (GE-MS7001 FA)

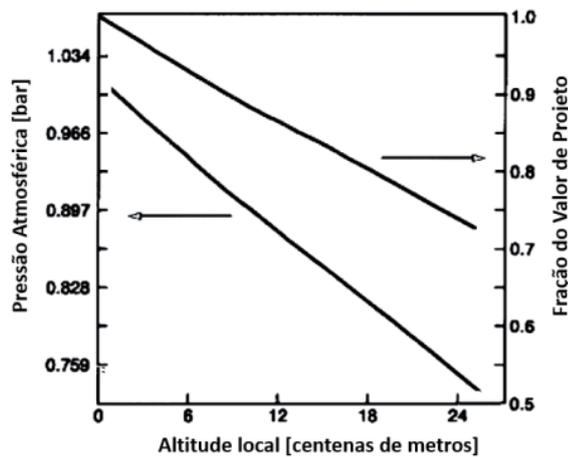


Figura 2.16. Potência em Função da Altitude (GE-MS7001 FA)

### 2.3 FALHAS EM TURBINAS A GÁS

São vários os tipos de parâmetros que podem ser acompanhados para se estabelecer a condição de uma máquina. O acompanhamento de vibração nos mancais de uma turbina a gás, por exemplo, pode detectar vários tipos de falha, inclusive nos próprios mancais. No entanto, a vibração, apenas, não diz muito sobre as falhas que afetam o desempenho da turbina a gás, tais como vazão mássica e eficiência dos componentes e, cujos efeitos, são observados nos parâmetros termodinâmicos (pressão, temperatura, potência, etc.) (MONTEIRO, 2010). Normalmente, qualquer falha em um único componente ou inconsistência no desempenho de um grupo de componentes pode aumentar a degradação da máquina [KURZ, BRUN, 2009].

Deposito de material (*fouling*), corrosão, erosão, danos causados por objetos, aumento da folga no topo das palhetas e vazamentos são as causas mais comuns de deterioramento da máquina [KURZ, WOLLIE, 2009]. Deve-se observar que falhas em turbinas a gás aeronáuticas são diferentes das turbinas a gás industriais [KURZ, BRUN, 2009]. Motores aeronáuticos operam sem um filtro de ar na entrada e, conseqüentemente, erosão é o principal fator de degradação, especialmente no compressor. Turbinas a gás industriais utilizam apropriados sistemas de filtragem e estão sujeitos ao *fouling*, causado por partículas pequenas. A exceção pode ser em motores sujeitos à injeção de água na entrada do compressor, onde um sistema com tamanho incorreto pode gerar gotículas de água que são suficientemente grandes para causar erosão nas pás [KURZ, SIMMONS, 2006]. No entanto, o efeito de uma determinada falha no desempenho da turbina a gás é semelhante, independentemente se o motor é utilizado em aeronaves ou em indústria [MUHAMMAD *et al*, 2017].

### 2.3.1 Depósito de Material nas Palhetas (Fouling)

O acúmulo de material nas superfícies das palhetas causa um aumento na rugosidade da superfície, muda a forma da palheta e/ou o ângulo de entrada e diminui a abertura da passagem. É uma das causas mais comuns de perda de desempenho e pode ser responsável por mais de 70% da perda de desempenho durante a operação (OGAJI et al., 2002a, 2002b). A Figura 2.17 mostra o acúmulo de material nas palhetas do bocal do 1º estágio de uma turbina.

O depósito leva às reduções da vazão mássica e da pressão na saída do compressor, a uma queda na eficiência do compressor e à diminuição da potência e ao aumento do *heat rate*. Existe, contudo, um limite para a quantidade de material que é depositado, determinado pelas forças aerodinâmicas que previnem depósitos adicionais nas palhetas.

A deterioração do desempenho devido ao depósito de material é, na sua maior parte, recuperada pela limpeza, e a recomendação é que seja realizada uma lavagem quando a vazão mássica cai aproximadamente 2,5% (OGAJI et al., 2002).

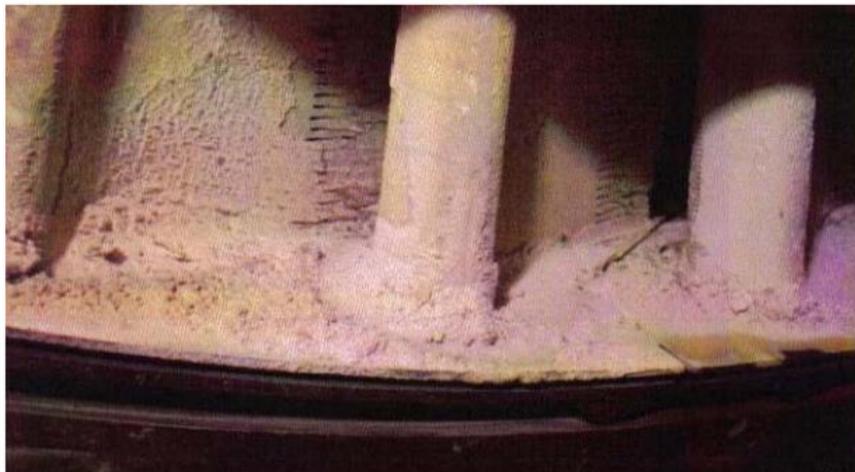


Figura 2.17. Acúmulo de material nas palhetas da turbina (Fonte: Monteiro, 2010)

### 2.3.2 Corrosão

Quando as perdas de material dos componentes da turbina a gás são causadas pelas reações químicas com os contaminantes que entram na turbina a gás junto com o ar, combustível, água ou vapor injetado, o processo é chamado de corrosão. As palhetas da turbina são mais susceptíveis à corrosão (OGAJI et al., 2002a) devido à presença, nos produtos da combustão, de elementos como o vanádio e o sódio, levando à redução da eficiência desses componentes.

O efeito da corrosão é similar ao da erosão, uma vez que há perda de parte do material das palhetas e aumento da rugosidade da superfície. Uma proteção efetiva contra o ataque corrosivo, tanto nas turbinas quanto nos compressores, (EFSTRATIOS, 2008) é obtida através do revestimento das superfícies expostas ao ataque. A Figura 2.18 mostra uma palheta do compressor corroída.



Figura 2.18. Corrosão de uma palheta (Fonte: Monteiro, 2010)

### 2.3.3 Erosão

A erosão é causada pela remoção abrasiva do material dos componentes da turbina a gás pelas partículas em suspensão no ar (EFSTRATIOS, 2008). As superfícies expostas aos impactos tornam-se rugosas, há uma mudança no perfil das palhetas, aumento das folgas, variação da distribuição de pressão na superfície da palheta e, portanto, decréscimo da eficiência e da vazão em massa do componente (OGAJI et al., 2002).

Outro efeito da erosão é fazer com que os estágios frontais dos compressores de baixa e alta pressão fiquem susceptíveis ao surge. Foi mostrado também (OGAJI, S.O.T., SINGH, R., 2003), que a erosão afeta mais os últimos estágios do compressor (devido à alta pressão nessa região) do que os estágios iniciais.

### 2.3.3 Folga no topo das palhetas do rotor (*Tip Clearance*)

Condição típica de máquinas de fluxo axial como turbinas e compressores axiais, que ocorre devido à diferença de pressão através das pás do compressor, o que leva a ocorrência de um escoamento da superfície de pressão para a superfície de sucção pela folga no topo das palhetas do rotor (*tip clearance*). O efeito desse escoamento causa uma elevação da pressão e na redução da eficiência e da estabilidade operacional que não podem ser negligenciadas [MUHAMMAD

*et al.*, 2017]. A instabilidade é provocada pela distribuição não uniforme da folga da selagem no topo das palhetas. Isso provoca um diferencial na força axial do fluido sobre o rotor, gerando a componente desestabilizadora conhecida como “força de Alford” (RESENDE, 1991). A falha influencia ambos a eficiência e a vazão: um aumento de 0,8% na folga, para um compressor axial, leva a uma redução de 3% na vazão e a uma redução de 2% na eficiência (OGAJI et al., 2002a). A eficiência é mais sensível ao *tip clearance* do que ao *fouling*.

### **2.3.4 Danos causados por objetos**

É o resultado de um corpo que colide com as superfícies dos componentes da turbina a gás. A origem desses objetos pode ser via seção de entrada, junto com o ar (danos causados por objetos estranhos – FOD, falha típica em turbinas a gás utilizadas na aviação civil / militar), ou parte dos próprios componentes que se quebram e são transportados ao longo da turbina a gás (danos causados por objetos domésticos – DOD). A assinatura dessa falha, com respeito ao seu efeito no desempenho, às vezes, é idêntica ao do *fouling* (OGAJI et al., 2002a).

## **2.4 TÉCNICAS DE DIAGNÓSTICO**

Toda turbomáquina perde eficiência com o tempo. A queda de desempenho da turbina a gás pode ser classificada em recuperável e não recuperável. Perdas recuperáveis são, geralmente, associadas com as falhas que podem ser retificadas através de lavagem com água ou por limpeza mecânica das palhetas e outros componentes ao abrir a unidade. Perdas não recuperáveis se atrelam a danos em superfícies e que não podem ser reestabelecidas por procedimentos operacionais, manutenção ou lavagens, mas apenas através de substituição das partes danificadas [BROOKS, 2015].

A “condição” da turbina a gás é caracterizada pelas seguintes informações [Gülen, 2019]:

- Desempenho Térmico (Potência, vazão de combustível, eficiência);
- Integridade Mecânica (Vibração do rotor e rolamentos, temperatura do óleo de lubrificação);
- Estatísticas Operacionais (Horas de operação, número de partidas, número de trips, etc.);
- Alarmes.

De acordo com o Instituto Nacional de Padrões Americanos – ANSI (*American National Standards Institute*), um alarme “é uma indicação sonora e/ou visível ao operador de uma

anomalia no equipamento, um desvio no processo ou uma condição anormal e necessita de uma resposta”. O alarme auxilia no monitoramento da turbina a gás, evitando que a mesma sofra consequências irremediáveis e alguns parâmetros devem ser monitorados de perto, com requisitos de manutenção programada no período de tempo adequado. Dados que devem ser monitorados durante a operação da turbina a gás [Gülen, 2019]:

- Perdas de pressão na entrada e na saída;
- Temperatura de entrada do compressor;
- Temperatura e pressão de descarga do compressor;
- Temperatura de exaustão;
- Potência gerada;
- Temperatura e vazão do combustível;
- Vibrações do rotor e rolamentos;
- Temperatura do óleo de lubrificação.

O monitoramento da condição da turbina a gás consiste em verificação periódica do estado (condição) do equipamento, enquanto é feito um registro das observações. O monitoramento pode ser desempenhado próximo à máquina ou de forma remota, dependendo da configuração. Dados são coletados através de diversos sensores alocados ao longo do equipamento, transmitidos para os escritórios, onde são processados e analisados para diagnosticar qualquer evento não previsto [DE CASTRO-CROS, ANGULO, 2021].

A avaliação da condição da turbina a gás consiste em uma inspeção sistemática, uma revisão e a informação sobre o estado do equipamento. Procedimentos de inspeção tem evoluído recentemente e técnicas mais efetivas tem sido desenvolvida com o aumento da disponibilidade de dados. Dessa forma, os métodos monitoramento podem ser classificados em três componentes principais: monitoramento da condição, diagnóstico e prognóstico [VOLPONI, 2014].

O diagnóstico processa a informação do estado do equipamento para determinar e identificar os riscos que impactam a degradação de desempenho e a integridade operacional. O principal objetivo desse processo é tornar a máquina mais confiável, disponível e segura, melhorando, assim, seu desempenho [DAILY, PETERSON, 2017]. O diagnóstico é complementar ao monitoramento da condição, de tal forma que um tem como objetivo capturar o desempenho do sistema, enquanto o outro tem como objetivo melhorá-lo. Portanto, ambos os métodos precisam funcionar adequadamente [DE CASTRO-CROS, ANGULO, 2021].

Prognóstico consiste em prever a condição futura de um componente e/ou sistema de componentes. O objetivo do prognóstico da condição futura geralmente é definido em termos de prevenção de falhas graves nos componentes ou redução da degradação de desempenho relacionada à operação do equipamento. O prognóstico de falha concentra-se em prever o estado de dano ou taxa de falha de um componente ou sistema de componentes em um equipamento, enquanto o prognóstico de degradação está associado à degradação mais lenta de desempenho ao longo de sua vida útil. Esse processo está um passo à frente do monitoramento e diagnóstico de condição, mas, ao mesmo tempo, há alguma dependência de como o diagnóstico é realizado [DE CASTRO-CROS, ANGULO, 2021].

#### **2.4.1 Técnicas de diagnóstico com base em Machine Learning**

*Machine Learning* é uma abordagem algorítmica computacional aplicada em uma ampla variedade de campos para a construção automatizada de modelos analíticos. Ela utiliza algoritmos que aprendem automaticamente e reconhecem padrões a partir de dados, aplicando esse aprendizado para tomar decisões cada vez melhores. Esses algoritmos de análise de dados são capazes de lidar com uma quantidade considerável de dados e fornecer informações detalhadas sobre o desempenho da máquina. Essas metodologias são principalmente usadas para extrair conhecimento de séries temporais multidimensionais a fim de identificar estruturas ocultas [QIU *et al.*, 2016]. Essas técnicas podem ser aplicadas em uma infinidade de áreas e para diversos propósitos.

##### **2.4.1.1 Redes Neurais Artificiais de Propagação direta**

As redes neurais são compostas de elementos simples operando em paralelo. Esses elementos são inspirados no sistema nervoso biológico humano. Ou seja, a rede neural imita o mecanismo do cérebro humano [BEALE, HAGAN, DEMUTH, 2016]. Assim como o cérebro, composto por inúmeras conexões entre neurônios, a rede neural é composta por conexões entre *nós*. Para construir um modelo de associação entre as conexões entre neurônios, a rede neural utiliza os *pesos* [Kim, 2017].

A construção da rede neural é baseada em certos princípios, por exemplo, o fato de que o processamento de informações ocorrer em nós, também referidos como neurônios, e que cada neurônio artificial é um processador computacional unitário com um operador somatório e uma função de transferência [SALMAN *et al.*, 2023]. A Figura 2.19 mostra a estrutura de um

neurônio artificial (nó), e os parâmetros dos pesos e *bias* da rede neural são usados para conectar as entradas, os neurônios e as saídas [KHAYET, COJOCARU, 2013].

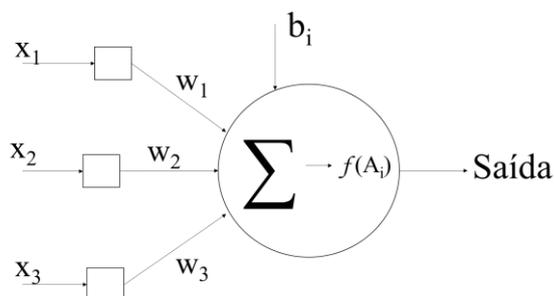


Figura 2.19. Nó de uma rede neural (Fonte: Autor)

A caracterização da rede neural depende de sua estrutura, a qual mostra as conexões dos nós, a função de ativação e o esquema de ponderação das conexões [LÓPEZ, LÓPEZ, CROSSA, 2022]. A topologia convencional de redes neurais consiste em um grande número de nós dispostos em um padrão predefinido. Além disso, a categorização de redes neurais artificiais, pode ser baseada na direção do fluxo de informações durante o processamento, onde os nós em uma rede de propagação direta (FNN – *Feedforward Neural Network*) são orientados da camada de entrada para a camada de saída [DOBAY *et al.*, 2020].

Na figura 2.19, os pesos e o *bias* são combinados em uma única entrada  $A_i$ , frequentemente referida como argumento, através do operador somatório de um único neurônio ( $i$ ).  $W_1$ ,  $W_2$  e  $W_3$  são os pesos da conexão,  $X_1$ ,  $X_2$  e  $X_3$  são as variáveis de entrada, e  $b_i$  denota o *bias* de um único neurônio artificial. O argumento líquido  $A_i$  é transformado na saída escalar pela função de transferência de um único neurônio ( $i$ ) [SALMAN *et al.*, 2023].

As Equações 2.1, 2.2 e 2.3 mostram a conexão explícita para o operador somatório e os tipos de funções de transferência frequentemente usados para problemas de regressão múltipla para um único neurônio artificial. As três funções de transferência mais comumente usadas para lidar com problemas de regressão múltipla são a função de transferência linear (purelin) – Equação 2.1, a função de transferência log-sigmoide (logsig) – Equação 2.2 e a função de transferência sigmoide tangente hiperbólica (tansig) – Equação 2.3 [SALMAN *et al.*, 2023]. A Figura 2.20 mostra os gráficos dessas funções.

$$f(Ai) = Ai \quad (2.1)$$

$$f(Ai) = \frac{1}{1 + e^{-Ai}} \quad (2.2)$$

$$f(Ai) = \frac{1 - e^{-Ai}}{1 + e^{-Ai}} \quad (2.3)$$

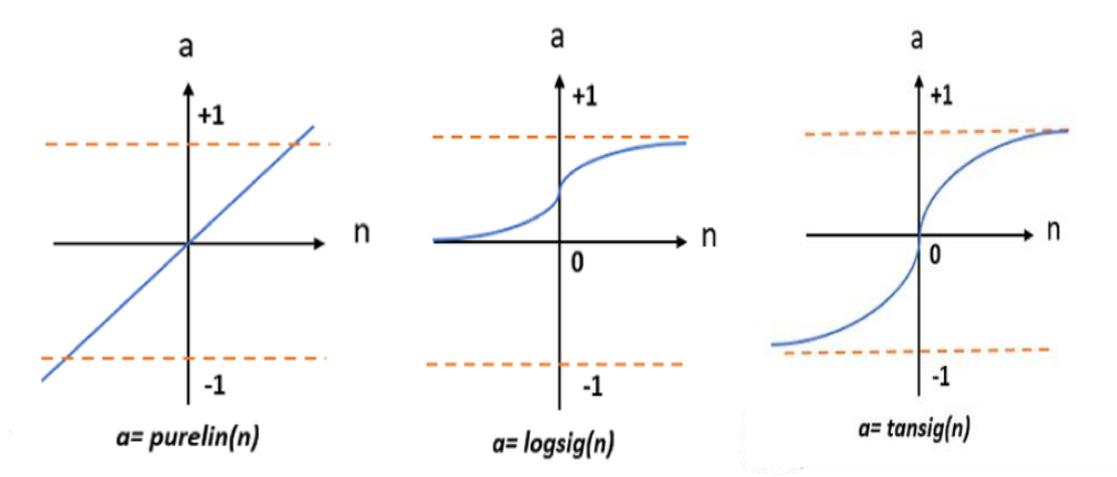


Figura 2.20. Funções de transferência (Fonte: SALMAN et al., 2023)

Assim como o cérebro é uma rede enorme de neurônios, a rede neural artificial é uma rede enorme de nós, como mostra a Figura 2.21 onde os nós, representados por quadrados, são chamados de camada de entrada, que atuam como transmissores dos sinais de entrada para os próximos nós. Portanto, a camada de entrada não calcula a soma dos pesos e a função de ativação. As camadas centrais são chamadas de camadas ocultas e recebem esse nome por não serem acessíveis pela rede neural. A camada de saída entrega o resultado final da rede neural. Atualmente, as redes neurais utilizadas possuem mais de uma camada escondida, sendo classificadas como “deep neural networks” [Kim, 2017].

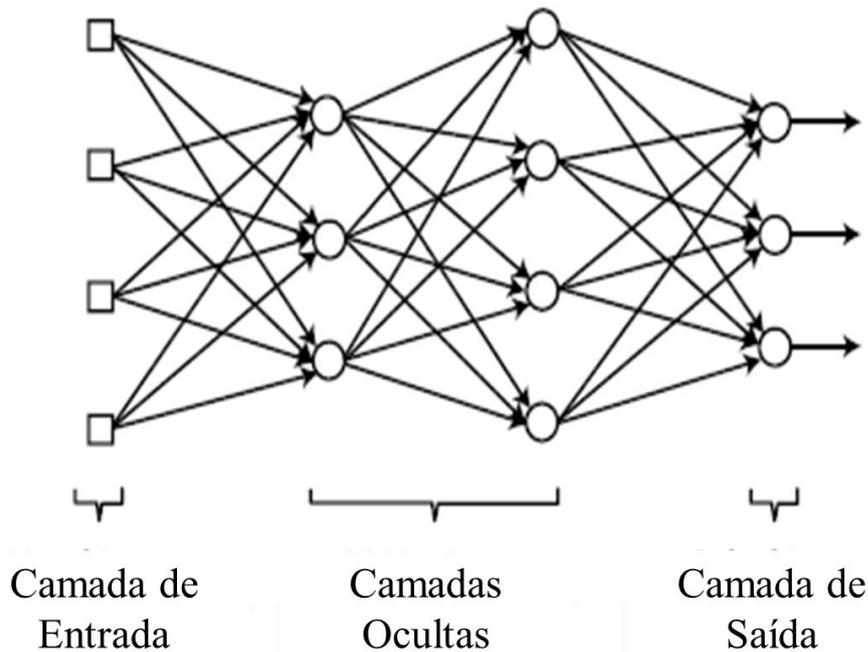


Figura 2.21. Estrutura das camadas de uma rede neural (Fonte: Kim, 2017)

O principal conceito por trás da rede neural pode ser resumido em duas partes: uma passagem para frente para prever a saída desejada e uma passagem para trás para atualizar os pesos e *bias*. Na passagem para a frente, as características de entrada são propagadas através da rede neural para gerar a saída prevista. Na passagem para trás, a saída prevista é comparada com a saída real, e o erro é retro propagado por todos os nós. Os pesos e *bias* de cada nó são atualizados em relação ao erro para melhorar a próxima previsão [CHRISTOFIDES *et al.*, 2022].

#### 2.4.1.2 Redes Neurais Recorrentes

A rede neural recorrente (em inglês Recurrent Neural Network – RNN) é um tipo de rede neural artificial capaz de detectar padrões temporais em dados sequenciais ou séries temporais. O algoritmo possui o conceito de “memória” que ajuda a armazenar informações das entradas anteriores e usa-las para prever a saída [DYER,2016, GREGOR, 2015].

No entanto, uma limitação das RNN simples é a curta memória, que restringe a habilidade de reter informações de grandes dados sequenciais [APAYDIN *et al.*, 2020]. Para superar esse problema, RNN avançadas têm sido desenvolvidas, incluindo LSTM (*Long Short-Term Memory*), GRU (*Gated Recurrent Unit*) e Bayesian RNN [SHIRI *et al.*, 2023].

A Figura 2.22 mostra uma RNN simples, onde a memória interna,  $h_t$ , é calculada pela Equação 2.4. Na equação,  $g(\cdot)$  representa a função de ativação,  $U$  e  $W$  são os pesos ajustáveis para a camada escondida ( $h$ ),  $b$  é o *bias*, e  $x$  indica o vetor de entrada.

$$h_t = g(Wx_t + Uh_t + b) \quad (2.4)$$

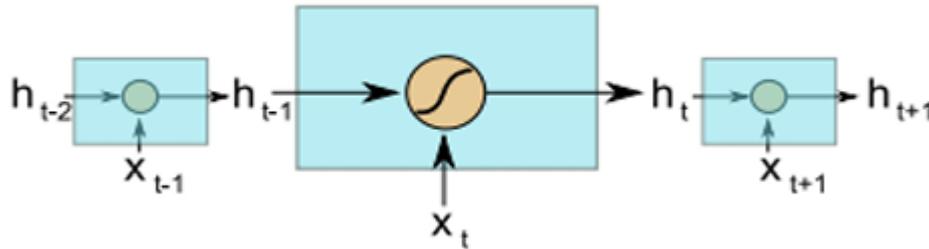


Figura 2.22. RNN simples (Fonte: Kratzert et al., 2018)

Em uma rede LSTM, a entrada atual em um determinado passo de tempo e a saída do passo de tempo anterior são inseridas na unidade LSTM, que então gera uma saída que passada para o próximo passo de tempo. A camada oculta final do último passo de tempo, às vezes juntamente com todas as camadas ocultas, é comumente utilizada para fins de classificação [MINAEE, AZIMI, ABDOLRASHIDI, 2019].

A rede LSTM possui três portões: portão de entrada, portão de esquecimento e portão de saída. Cada portão desempenha uma função específica no controle do fluxo de informações. O portão de entrada decide como atualizar o estado interno com base na entrada atual e no estado interno anterior. O portão de esquecimento determina quanto do estado interno anterior deve ser esquecido. Por fim, o portão de saída regula a influência do estado interno no sistema [FANG, CHEN, XUE, 2021]. A Figura 2.23 mostra o mecanismo de funcionamento da rede LSTM e as equações a seguir mostram o princípio matemático da rede [BAI *et al.*, 2021].

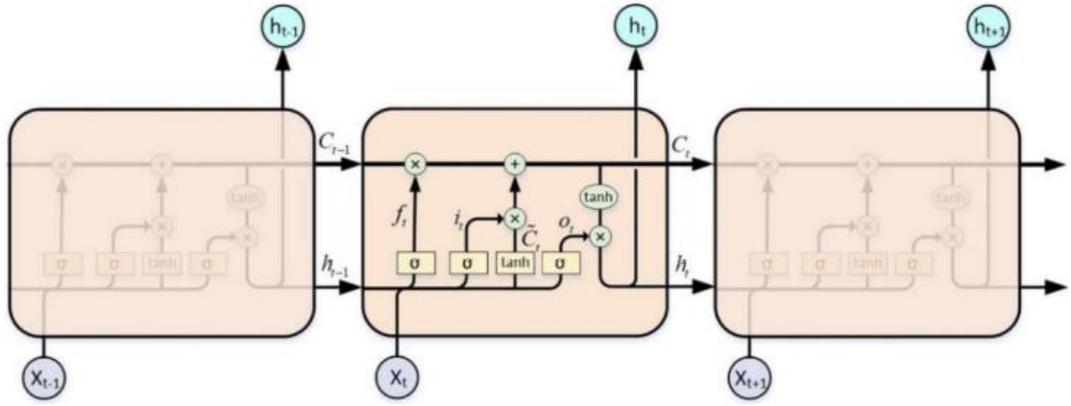


Figura 2.23. Estrutura da rede LSTM (Bai *et al.*, 2019)

O portão de esquecimento  $f_t$  representa a razão de informações históricas que devem permanecer, como mostra a Equação 2.5.

$$f_t = \sigma(W_f(x_t, h_{t-1}) + \delta_f) \quad (2.5)$$

O portão de entrada  $i_t$  representa a razão de informação atual que deve ser computada

$$i_t = \sigma(W_i(x_t, h_{t-1}) + \delta_i) \quad (2.6)$$

A célula  $C_t$  representa o estado oculto atual, a qual é obtido pela soma ponderada do valor candidato atual  $\hat{C}$  e do estado histórico da célula  $C_{t-1}$ , com o portão de esquecimento  $f_t$  e portão de entrada  $i_t$  sendo seus respectivos pesos.

$$\tilde{C}_t = \tanh(W_c(x_t, h_{t-1}) + \delta_c) \quad (2.7)$$

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \quad (2.8)$$

O portão de saída é a razão de informações a serem a atual saída da unidade LSTM. Através do portão de saída, o estado da célula atual  $C_t$  é convertido na saída atual.

$$o_t = \sigma(W_o(x_t, h_{t-1}) + \delta_o) \quad (2.9)$$

$$h_t = o_t \odot \tanh(C_t) \quad (2.10)$$

Nas equações,  $W_f$ ,  $W_i$ ,  $W_c$ ,  $W_o$  são as matrizes de pesos,  $b_f$ ,  $b_i$ ,  $b_c$ ,  $b_o$ , são os *bias*. A matriz de pesos e os *bias* da rede LSTM aprendem com os dados de treinamento através da estratégia de *backpropagation* pelo tempo. A operação  $\circ$  o produto ponto a ponto,  $x_t$  é a entrada atual e  $h_{t-1}$  é a saída da unidade LSTM do passo temporal anterior. A função  $\sigma(\cdot)$  e  $\tanh(\cdot)$  são funções de ativação definidas pelas Equações 2.11 e 2.12 [BAI *et al.*, 2021].

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (2.11)$$

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.12)$$

### 2.4.1.2 Construção do modelo de rede neural

Incorporar *machine learning* para resolver problemas realistas não é um processo direto. Frequentemente, é um processo cíclico que utiliza avaliação do modelo para iterar entre a melhoria dos dados e a melhoria do modelo. Esse ciclo é crucial no desenvolvimento de um modelo de *machine learning* bem-sucedido, pois avalia o *feedback* dos resultados anteriores e implementa mudanças para melhorar ainda mais as etapas anteriores [CHRISTOFIDES *et al.*, 2022]. A Figura 2.24 mostra o fluxograma dos passos necessários para se obter uma rede neural operando corretamente.

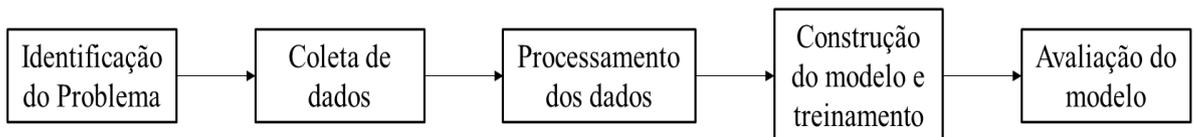


Figura 2.24. Fluxograma para construção do modelo de Rede Neural (Fonte: Adaptado - Christofides et al., 2022)

#### 1. Identificação do problema

O primeiro passo no desenvolvimento de um modelo de *machine learning* é identificar uma declaração geral do problema e transformá-la em uma tarefa específica. Mesmo com uma declaração de problema bem definida, ainda não há um problema de *machine learning* claramente definido. Nesta etapa, os detalhes da tarefa de machine learning, como classificação versus regressão, e supervisionado versus não supervisionado versus semi-supervisionado, devem ser formulados com base na descrição da tarefa e na disponibilidade de dados. No aprendizado supervisionado, algoritmos de *machine learning* são treinados para aprender a relação alvo dentro de conjuntos de dados que contêm tanto as entradas quanto as saídas

rotuladas. No aprendizado não supervisionado, nenhuma saída é fornecida, e os algoritmos de *machine learning* tentam encontrar possíveis relações entre as entradas sozinhas. Por fim, no aprendizado semi-supervisionado, técnicas de aprendizado não supervisionado são incorporadas a algoritmos de machine learning supervisionados para evitar a necessidade de rotular grandes quantidades de dados [CHRISTOFIDES et al., 2022].

## 2. Coleta de dados

Após a tarefa ser identificada e especificada, é importante entender a variedade existente das fontes de dados. A coleta de dados pode vir desde equipamentos físicos até informações de tráfego de rede [CHRISTOFIDES et al., 2022]. No caso das turbinas a gás, os dados de operação são coletados através de sensores físicos instalados ao longo da máquina para obter os valores de pressão, temperatura, rotação e vazão mássica.

No entanto, mesmo ao medir a mesma propriedade física, os dados podem se apresentar de forma estruturada ou não estruturada. Por exemplo, um sensor pode produzir dados de temperatura em série temporal na forma de uma lista numérica ou tabela, o que é considerado um dado estruturado. Por outro lado, câmeras infravermelhas podem gerar um mapa de calor, que pode ser mais relevante do que os dados em série temporal, porém em uma forma não estruturada. Além disso, a etapa de pré-processamento dos dados pode variar de acordo com o estado do processo – regime permanente ou transiente. No contexto da engenharia mecânica, dados em regime permanente podem ser considerados como estado estacionário, enquanto dados em regime transiente se referem a comportamentos transitórios. Para dados em regime transiente, a ordem pode ser importante para o processo, enquanto dados em regime permanente podem ser embaralhados. Sejam dados estruturados/não estruturados ou regime permanente/transiente, identificar o tipo e qualidade dos dados é de extrema importância para garantir o sucesso do modelo de inteligência computacional [CHRISTOFIDES et al., 2022].

Outra forma de obter dados é através de simulação e modelagem dos sistemas desejados, como realizado neste trabalho, em que a coleta de dados foi obtida através da simulação da turbina a gás SGT-A35(GT62), utilizando o *software* MATLAB/Simulink, como discutido no próximo capítulo desta dissertação.

## 3. Pré-processamento dos dados

O pré-processamento dos dados é um passo essencial para converter os dados brutos coletados dos sensores ou de simulações em um conjunto de dados limpo e utilizável. O

primeiro passo é remover observações duplicadas e irrelevantes, que são inevitáveis em grandes conjuntos de dados. Na indústria, diversos sensores são instalados, mas nem todos podem ser relevantes para o problema e a tarefa de inteligência computacional. O principal objetivo do pré-processamento dos dados é reduzir o tamanho do conjunto de dados, mantendo a informação relevante. O próximo passo é identificar erros estruturais, tais como dados corrompidos e recursos ausentes ou com rótulos incorretos. O processo de preenchimento dos dados ausentes é chamado de “imputação dos dados” [Zhang *et al.*, 2006], o que pode variar desde o uso simples da média, mediana ou moda até a implementação de técnicas simples de inteligência computacional. Métodos de interpolação também podem ser usados dependendo da natureza do conjunto de dados. Por fim, após o tratamento dos dados com relação a dados ausentes e informação irrelevante, a detecção de *outliers* (“pontos fora da curva”) pode ser implementada para aumentar o desempenho do modelo de *machine learning*. Os métodos mais comuns incluem *Z-score* (Normalização), modelos probabilísticos e métodos de agrupamento. Para conjunto de dados paramétricos, que são dados com distribuição conhecida, o método de normalização prova ser eficiente em eliminar os *outliers* e é descrito pela equação 2.13, onde  $x$  é o ponto de dado atual,  $\mu$  e  $\sigma$  são a média e o desvio padrão do conjunto de dados e  $Z$  é o dado normalizado para esse ponto de dado atual [CHRISTOFIDES *et al.*, 2022].

$$Z = \frac{x - \mu}{\sigma} \quad (2.13)$$

Para todo projeto de inteligência computacional, é importante ter pelo menos dois conjuntos de dados para fins de treinamento e teste. No caso de modelos de redes neurais, também é recomendado um terceiro conjunto de validação para ajuste do modelo. Uma razão de divisão típica é 80% para treinamento e 20% para teste ou 70/15/15 com o conjunto de validação, sendo que essas proporções devem ser ajustadas baseadas no problema e na disponibilidade de dados. O conjunto de treinamento é usado para ajustar os pesos e *biases* da rede neural, o conjunto de validação é usado para ajustar os hiper parâmetros (número de neurônios, número de camadas, etc.), e o conjunto de teste é usado para avaliar a *performance* da rede neural em um conjunto de dados desconhecido.

A divisão de dados é realizada antes de qualquer processamento adicional para evitar vazamento de dados. O vazamento de dados refere-se ao vazamento de informações, como a média ou desvio padrão dos dados de teste, para o conjunto de treinamento, o que pode afetar a precisão dos testes. O próximo passo no preparo dos dados é o processamento dos mesmos, que se refere à aplicação de diferentes transformações ao conjunto de dados para melhorar o

desempenho do treinamento. A escala de dados, que aplica algum tipo de escalonador para normalizar o conjunto de dados dentro de uma determinada faixa, pode ser aplicada tanto a dados estruturados quanto a dados não estruturados, sendo comumente a primeira transformação aplicada a um conjunto de dados. Isso evita grandes discrepâncias no gradiente entre diferentes características de entrada durante o treinamento do modelo, o que pode fazer com que os valores dos pesos mudem drasticamente, tornando o processo de treinamento instável. Os dois escalonadores mais comumente usados são o escalonador *Min-Max* e o escalonador *Z-score*. O método *Z-score*, já mostrado na Equação 2.13, dimensiona o conjunto de dados para uma distribuição com média zero e desvio padrão unitário. Após o dimensionamento dos dados, transformações mais específicas para a tarefa podem ser implementadas para gerar o tensor de entrada. Com base no tipo de biblioteca de inteligência computacional (*Tensorflow*, *Keras*, *Pytorch*, *MatLab*) e no tipo de rede neural escolhida (*MLP*, *RNN*), o formato de entrada dos dados de treinamento é processado de forma diferente. Funções auxiliares personalizadas podem ser implementadas para transformar o conjunto de dados original no formato de treinamento desejado [CHRISTOFIDES et al., 2022].

O escalonador *Min-Max* dimensiona os valores de todo o conjunto de dados entre um intervalo definido pelo usuário e é calculado pela equação 2.14.

$$x_{esc} = \frac{x - x_{min}}{x_{max} - x_{min}}(f_{max} - f_{min}) + f_{min} \quad (2.14)$$

Onde  $x$  é o ponto do dado atual,  $x_{max}$  e  $x_{min}$  são os valores máximo e mínimo dentro do conjunto de dados,  $f_{max}$  e  $f_{min}$  são os valores máximo e mínimo definidos pelo usuário e  $x_{esc}$  é o ponto escalonado entre o mínimo e máximo. Geralmente,  $f_{max}$  e  $f_{min}$  são 1 e 0, por padrão, resultando o  $x_{esc}$  dentro da faixa de 0 e 1.

#### 4. Construção do Modelo e treinamento

Dependendo da tarefa de inteligência computacional, existem diversos modelos que podem ser aplicados, como os já mencionados neste capítulo.

Após a escolha do modelo a ser usado, é necessário realizar o treinamento, sendo importante salvar o histórico de treinamento, uma vez que esse histórico pode indicar se o modelo apresenta tendências de superajuste (*overfitting*) ou subajuste (*underfitting*). O gráfico mais comum mostra a evolução da função de perda em relação às épocas (*epochs*) durante o treinamento e validação. Na maioria dos casos, treinamentos muito longos resultará em um ajuste excessivo

(*overfitting*) do modelo ao conjunto de dados e não irá generalizar adequadamente para os conjuntos de validação e teste. Em caso de *overfitting*, as perdas de treinamento continuam diminuindo enquanto as perdas de validação aumentam em vez de diminuírem à medida que mais épocas passam. Uma função de parada precoce pode ser implementada para evitar treinamento excessivo através do monitoramento da perda de validação. Por exemplo, um critério de parada precoce de um certo número de aumentos consecutivos na perda de validação pode ser definido, e o processo de treinamento será interrompido quando esse critério for atingido. Por outro lado, no caso de subajuste (*underfitting*), tanto a perda de treinamento quanto a perda de validação são muito altas e ainda estão diminuindo em uma taxa exponencial. Idealmente, um bom modelo deve ter uma perda de treinamento e de validação semelhante ao final do treinamento. [CHRISTOFIDES et al., 2022].

### 5. Avaliação do Modelo

Após a construção e treinamento do modelo, é necessário avaliar o modelo com métricas significativas. Anteriormente, os erros de treinamento e validação eram usados para verificar o processo de treinamento e ajustar os parâmetros do modelo. Na avaliação do modelo, o conjunto de dados de teste é usado para avaliar o desempenho do modelo finalizado em termos de precisão e generalização em um conjunto de dados não visto anteriormente. No contexto da modelagem de processos, o conjunto de dados de teste pode conter condições operacionais não vistas nas condições de treinamento. Para tarefas de previsão de séries temporais, métricas gerais de teste de regressão que podem ser usadas incluem MAE, MSE, erro médio percentual absoluto (MAPE) e raiz quadrada do erro médio quadrático (RMSE). Essas métricas de erro descrevem o quão próximos os estados previstos pelo modelo estão em relação aos estados reais do processo. Portanto, os erros são usados para verificar o processo de treinamento e ajustar os parâmetros do modelo [CHRISTOFIDES et al., 2022].

# CAPÍTULO 3

## MODELAGEM APLICADA DA TURBINA A GÁS

Neste capítulo será abordado o equacionamento termodinâmico para uma turbina a gás simples e uma breve discussão sobre o desempenho dessas turbomáquinas. Também será discutido a modelagem da turbina a gás em MATLAB/Simulink/T-MATS e será apresentado os resultados obtidos da simulação e a validação do modelo.

### 3.1 Termodinâmica das turbinas a gás

A turbina a gás utiliza ar como fluido de trabalho no compressor, que é responsável por comprimir o ar até a pressão requerida pelo ciclo. O ar pressurizado entra na câmara de combustão, onde se mistura com o combustível e a ignição dá início a combustão à pressão constante. Os gases da combustão alimentam o exaustor (turbina), produzindo potência de eixo. A turbina a gás obedece às leis de conservação de massa e energia. Portanto, geralmente existe uma relação de mapeamento intrínseca entre os parâmetros medidos das turbinas a gás operando em condições padrão (BAI et al., 2019).

Segundo os princípios básicos de operação das turbinas a gás, o ciclo termodinâmico da turbina a gás é o Ciclo Brayton, como mostram as Figuras 3.1. Analisando a Figura 3.1(a), o ar é comprimido pelo compressor do estado 1 para o estado 2, havendo um pequeno ganho de temperatura de  $T_1$  para  $T_2$ . O calor adicionado a pressão constante pela câmara de combustão é representado de 2 até 3. Então, os gases de alta temperatura sofrem a expansão, de 3 para 4. Analisando a Figura 3.1(b), em uma turbina de eixo simples, a expansão é direta dos estados 3 para 7. Enquanto que em uma turbina de dois eixos, o gás é expandido dos estados 3 para 5 na turbina de acionamento do compressor e, então, de 5 para 7 na turbina de potência. A diferença entre as linhas 1-2 e 3-7 é o trabalho produzido pela turbina, ou seja, a maior parte do trabalho gerado na expansão entre 3 e 7 é usado para acionamento do compressor. A linha 5-7 descreve o trabalho de saída da turbina de potência (KURZ, 2015).

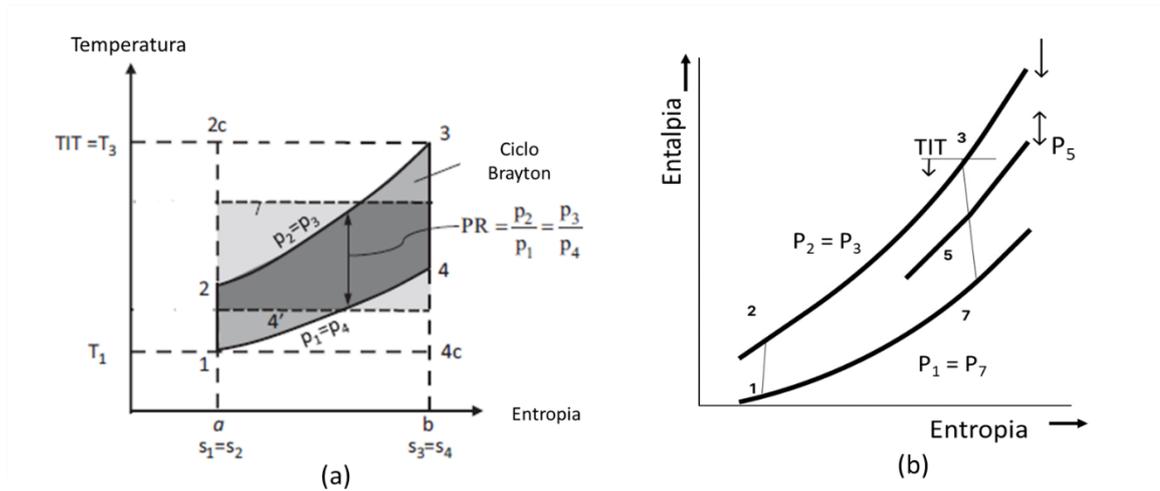


Figura 3.1. Ciclo Brayton. (a) (Gulen, 2020) Diagrama T-s. (b) Diagrama h-s (Kurz, 2005)

De acordo com a representação do ciclo Brayton da Figura 3.1a, para uma turbina de eixo simples, assumindo uma razão entre calores específicos constante  $k$ , então a temperatura do ar na saída do compressor é dada pela equação 3.1 (SIEGELMANN, HORNE, GILES, 1997).

$$T_2 = T_1 \left[ 1 + \frac{1}{\eta_{C_i}} * (Pr_C^{k-1/k} - 1) \right] \quad (3.1)$$

Onde  $\eta_{C_i}$  é a eficiência isentrópica do compressor,  $Pr_C$  é a razão de pressão do compressor,  $T_1$  e  $T_2$  são as temperaturas de entrada e saída do compressor, respectivamente. Normalmente,  $T_1$  se aproxima da temperatura ambiente (RAZAK, 2007).

Seguindo as leis de conservação de massa e energia, desprezando as perdas e assumindo o calor específico a pressão constante e o poder calorífico inferior como constantes, então a equação 3.2 descreve o processo que ocorre na câmara de combustão.

$$\dot{m}_f * \eta_b * LHV = (\dot{m}_f + \dot{m}_a) * c_p * (T_3 - T_2) \quad (3.2)$$

Onde  $T_3$ ,  $m_f$ ,  $\eta_b$  e LHV são a temperatura de saída da câmara de combustão, a vazão mássica de combustível, a eficiência da combustão e o poder calorífico inferior do combustível, respectivamente. Assim, juntando-se essas duas equações, tem-se a equação 3.3.

$$T_3 = \frac{\dot{m}_f * \eta_b * LHV}{(\dot{m}_f + \dot{m}_a) * c_p} + T_1 \left[ 1 + \frac{1}{\eta_C} * (Pr_T^{k-1/k} - 1) \right] \quad (3.3)$$

Seguindo o ciclo Brayton, a temperatura dos gases de exaustão na turbina é dada pela equação 3.4.

$$T_4 = T_3 [1 - \eta_{T_i} * (1 - Pr_T^{1-k/k})] \quad (3.4)$$

Onde  $\eta_{T_i}$  é a eficiência isentrópica da turbina e  $Pr_T$  é a razão de expansão da turbina (SIEGELMANN, HORNE, GILES, 1997).

A razão de expansão da turbina,  $Pr_T$ , se iguala à pressão de entrada na turbina,  $P_3$ , dividida pela pressão de saída da turbina,  $P_4$ . A razão de compressão do compressor,  $Pr_C$ , se iguala a pressão de saída do compressor,  $P_2$ , dividida pela pressão de entrada no compressor,  $P_1$ . Se a perda de pressão no processo de entrada e saída é negligenciada, então  $P_4$  e  $P_1$  se aproximam da pressão ambiente. Enquanto que, se a perda de carga na câmara de combustão também é negligenciada, então  $P_2$  se aproxima de  $P_3$ . Logo, tem-se a equação 3.5 (BAI et al., 2019)

$$Pr_T = \frac{P_3}{P_4} \approx Pr_C = \frac{P_2}{P_1} \quad (3.5)$$

A pressão ambiente praticamente não se altera na superfície. Então,  $Pr_T$  se aproxima de  $Pr_C$  e ambos são dependentes de  $P_2$ .

Usando as equações acima, é possível determinar os trabalhos do compressor e da turbina a gás ( $W_t$ ), como mostram as equações 3.6 e 3.7 (IBRAHIM, RAHMAN, ABDALLA, 2011)

$$W_{comp} = \frac{cp}{\dot{m}_a} * \eta_c * T_1 * [(Pr_C)^{k-1/k} - 1] \quad (3.6)$$

$$W_t = \frac{cp}{\dot{m}_g} * \eta_T * T_3 * [1 - (Pr_T)^{k-1/k}] \quad (3.7)$$

O calor fornecido pelo combustível ( $Q_f$ ) pode ser calculado pela equação 3.8 (IBRAHIM, RAHMAN, ABDALLA, 2011)

$$\dot{Q}_f = \dot{m}_f * LHV \quad (3.8)$$

A eficiência da turbina a gás é definida pela razão entre a potência líquida produzida pela turbina e a quantidade de energia fornecida pelo combustível. Logo, a eficiência térmica da turbina pode ser calculada pela equação 3.9 (KURZ, 2005).

$$\eta_{th} = \frac{\dot{W}_{out}}{\dot{Q}_f} \quad (3.9)$$

E o Heat Rate é definido pela equação 3.10

$$HR = \frac{1}{\eta_{th}} = \frac{\dot{Q}_f}{\dot{W}_{out}} \quad (3.10)$$

### 3.2 Desempenho da Turbina a Gás

A partir das equações termodinâmicas, é possível determinar a razão de pressão, de forma que, para uma dada temperatura máxima do ciclo termodinâmico, a maior eficiência geral e o fluxo mássico necessário para fornecer a potência desejada, poderão ser encontradas. Quando tais cálculos são feitos, os dados de projeto, adequados para uma aplicação particular, podem ser escolhidos. Então, é possível projetar os componentes mecânicos individuais da turbina a gás para que a unidade completa entregue o desempenho desejado quando operando no ponto de projeto. Ou seja, quando operando à determinada rotação, razão de pressão e vazão mássica para os quais os componentes foram projetados. O problema, no entanto, está em encontrar a variação de desempenho da turbina a gás em toda a faixa operacional de rotação e potência, comumente chamados de operação em *off-design* (SARAVANAMUTTOO, COHEN, ROGERS, 2013).

Saravanamuttoo, 2013 complementa que, quando os componentes estão conectados em um motor (turbina a gás), a faixa de operação de cada componente é consideravelmente reduzida. O problema é encontrar o ponto de operação correspondente às características de cada componente quando a turbina a gás está operando em equilíbrio. Os pontos de equilíbrio para uma série de rotações podem ser representados em um mapa do compressor e unidos para formar uma “zona de equilíbrio”, construindo, assim, as linhas de operação da turbina sobre o mapa do compressor. Após determinar as condições de operação, o problema se resume apenas em determinar as curvas de potência líquida e desempenho (consumo específico de combustível, *heat rate*, etc.).

O envelope de operação também mostra a proximidade da operação em relação aos limites de surge do compressor. Se um ponto de operação atingir os limites de surge, a turbina a gás não será capaz de operar na rotação nominal sem que seja tomada alguma ação corretiva. Em resumo, o mapa do compressor mostra se a turbina está operando em uma região estável e com

eficiência adequada. De maneira ideal, a linha de operação deve ficar próxima do ponto de máxima eficiência do compressor para uma dada rotação, conforme mostrado na Figura 3.2.

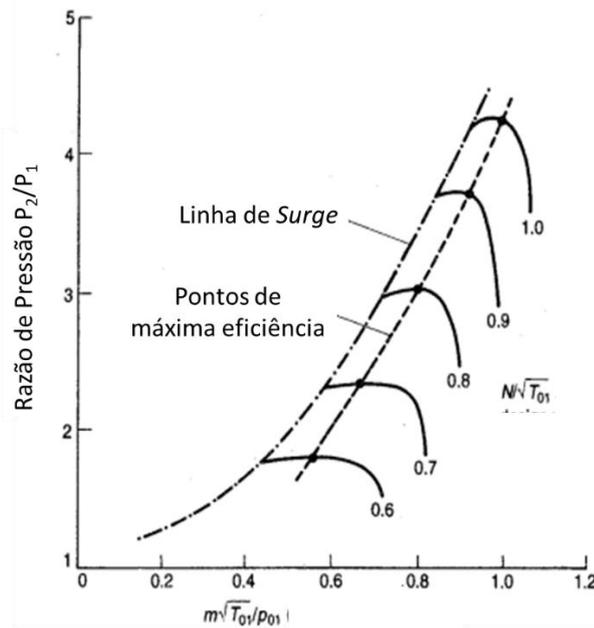


Figura 3.2. Mapa do compressor (Fonte: Saravanamuttoo, 2013)

O mapa de desempenho é normalmente representado através de parâmetros adimensionais, os quais são vazão adimensional ( $m\sqrt{T_{01}/p_{01}}$ ), rotação adimensional ( $N/\sqrt{T_{01}}$ ), razão de pressão ( $p_{02}/p_{01}$ ) e eficiência isentrópica ( $\eta_C$ ) (RAZAK, 2007).

Em compressores axiais, o mapa para os valores fixos de rotação adimensional abrange uma faixa mais estreita de vazão mássica do que em compressores centrífugos. À altas rotações, as linhas de rotação constante se tornam mais íngremes, podendo ser praticamente verticais. Conseqüentemente, a faixa de operação em equilíbrio de um compressor axial é estreita e o uso desse tipo de compressor nas turbinas a gás requer atenção especial na combinação dos componentes individuais se a instabilidade deve ser evitada em condições de operação em *off-design*.

Ao determinar o desempenho em *off-design* é importante prever não apenas o efeito do consumo específico de combustível em operação em carga parcial, mas também o efeito das condições ambientes, uma vez que a variação da temperatura ambiente afeta o desempenho da turbina a gás e deve ser considerada.

Todos os cálculos em *off-design* devem satisfazer as condições essenciais de compatibilidade de vazão mássica, potência e rotação entre os componentes. A variação de vazão, razão de pressão e eficiência com a rotação do compressor e da turbina são obtidos dos

mapas do compressor e da turbina. O mapa da turbina pode ser representado pela Figura 3.3. Na prática, no entanto, a turbina não mostra uma variação significativa na vazão adimensional com a rotação adimensional e, na maioria dos casos, a região de operação da turbina é restringida pelo componente a jusante.

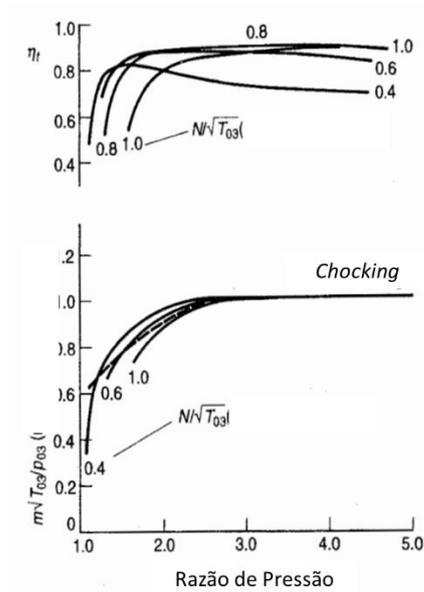


Figura 3.3. Mapa da Turbina (Fonte: Saravanamuttoo, 2013)

### 3.3 Desenvolvimento do modelo da turbina a gás

Para a geração de dados a serem utilizados em um modelo de inteligência artificial, foi, primeiro, criado um modelo de uma turbina a gás utilizando o *software* Matlab/simulink com a biblioteca T-MATS (*Tool box for the Modeling and Analysis of Thermodynamics Systems*), que permite a criação de modelos complexos que podem gerar resultados muito próximos dos reais de turbomáquinas aeronáuticas e aeroderivativas. O *software* possui uma biblioteca própria para o desenvolvimento dessas turbomáquinas e que, através da integração de componentes individuais, permite criar um modelo da turbina a gás desejada. Cada componente possui o equacionamento adequado de forma a respeitar os balanços de massa e energia, já demonstrados neste capítulo

Dessa maneira, foi elaborado um modelo de uma turbina a gás de dois eixos com turbina de potência, de forma a representar a turbina SGT-A35(GT62) da Siemens, turbina a gás utilizada pelas plataformas replicantes do tipo FPSO da Petrobrás. Para atingir o modelo de uma turbina a gás que represente a turbina SGT-A35(GT62) foi necessário a realização de um processo

iterativo de escalonamento dos mapas dos compressores e turbinas, até se atingir erros mínimos aceitáveis, de forma a se obter um modelo termodinâmico robusto e fiel ao real.

### 3.3.1 Descrição dos componentes

A turbina simulada é uma turbina de dois eixos com turbina de potência. Dessa forma, a turbina é constituída por um compressor de baixa pressão, um compressor de alta pressão, uma câmara de combustão, uma turbina de alta pressão, uma turbina de baixa pressão e a turbina de potência, como representado na Figura 3.4. Para a construção completa do modelo, também foram utilizados os blocos representativos para o meio ambiente, os eixos de baixa, de alta pressão e o eixo da turbina livre, assim como o gerador elétrico e outros componentes auxiliares, tais como as sangrias e resfriamentos da turbina.

A turbina a gás em questão produz 30.715 kW de potência nominal com um *Heat Rate* de 9.706 kW/kWh, em condições ISO. O gerador de gás conta com sistema diretor na entrada do compressor com posição variável (IGV) e dois *spools* dividem o equipamento em dois compressores axiais, um de baixa pressão (LP), com sete (7) estágios, e outro de alta pressão (HP), de seis (6) estágios, entregando uma relação de pressão total de 20:1, e duas turbinas axiais de um estágio cada. Os eixos LP e HP são mecanicamente independentes e cada um opera em sua própria velocidade de rotação ideal. A câmara de combustão do tipo anular conta com múltiplos bicos injetores de combustível que podem operar tanto a gás quanto a diesel. A variação nos ângulos das *IGVs* permite com que o gerador de gás opere em máxima eficiência sobre toda sua faixa operacional.

A Tabela 3.1 fornece os dados de desempenho do turbogerador SGT-A35(GT62), para diferentes condições de operação, as quais contemplam a condição de especificação do turbogerador para o local de trabalho (*on site – rated*), condições ISO, condição de máxima temperatura no local de trabalho (*on site – max. Temp.*) e condições de mínima temperatura no local de trabalho (*on site – min. Temp.*). Ressalta-se que estes dados foram obtidos do material fornecido pela Petrobrás, *data sheet – I-FD-3010.97-5147-330-rzc-001*.

Tabela 3.1. Dados de desempenho do turbogerador SGT-A35(GT62)

	On site Rated	ISO	On site Max. Temp	On site Min. Temp
Temp. ambiente [°C]	25	15	35	14
Umidade relativa [%]	82	60	82	82
Pressão Barométrica [kPa]	101,3	101,3	101,3	101,3
Potência gerada [kW]	27.972	30.715	26.704	30.038
Heat Rate [kJ/kWh]	9.905	9.706	10.090	9.755
Rotação PT [rpm]	4.800	4.800	4.800	4.800
Vazão de ar [kg/s]	90,1	95,6	85,6	94,7
Vazão de exaustão [kg/s]	91,2	96,8	87,5	95,9
Temp. Exaustão – GG [°C]	795	795	795	795
Temp. Exaustão – PT [°C]	505	497	513	497

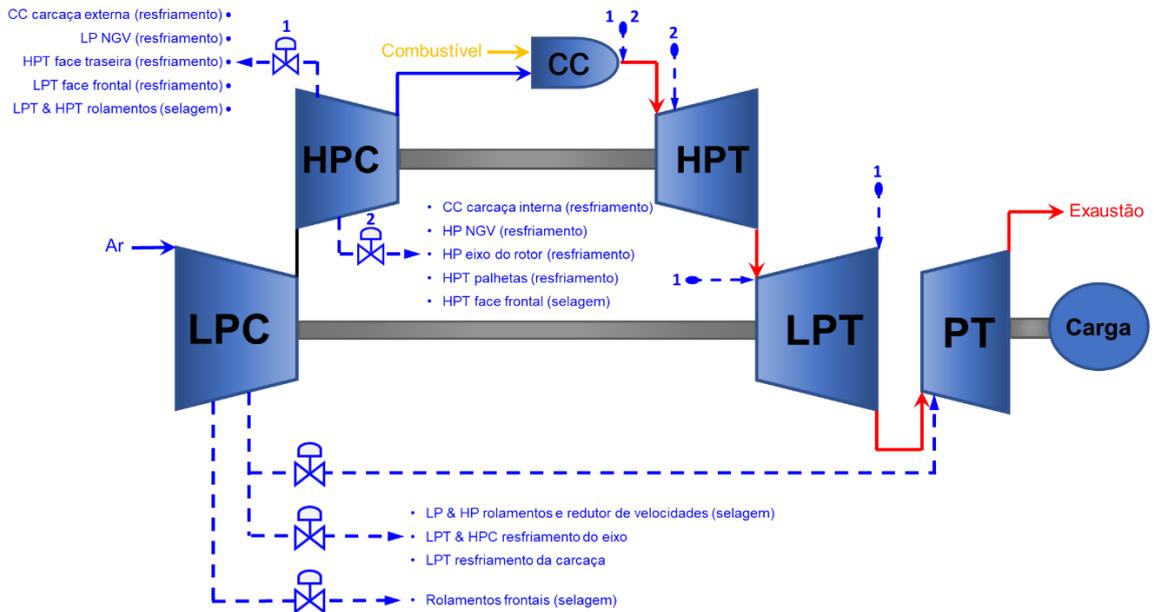


Figura 3.4. Representação da Turbina a Gás simulada - SGT-A35(GT62)

Os próximos subitens a seguir descrevem os blocos fornecidos pelo T-MATS e utilizados para configurar o modelo da turbina a gás SGT-A35(GT62).

### 3.3.1.1 Compressores

O bloco do compressor, utilizado para modelar os compressores de baixa e alta pressão, é utilizado para simular o desempenho do compressor usando o equacionamento básico e as propriedades termodinâmicas. As entalpia e entropia de entrada são computadas através do método de equacionamento polinomial, que usam coeficientes tabelados, usando os valores de temperatura, pressão e razão combustível/ar como referência.

Dois valores relacionados à vazão do fluido são calculados usando as equações 3.11 e 3.12. Esses parâmetros são definidos como parâmetros adimensionais da temperatura e pressão total.

$$\theta = \frac{Tt_{in}}{288.15} \quad (3.11)$$

$$\delta = \frac{Pt_{in}}{101.325} \quad (3.12)$$

Com isso, é possível determinar a vazão corrigida de entrada no compressor, usando a Eq. (3.13).

$$\dot{m}_c = \dot{m}_{in} \frac{\sqrt{\theta}}{\delta} \quad (3.13)$$

De forma semelhante, a rotação corrigida é determinada pela Eq. (3.14).

$$N_c = \frac{N_{mech}}{\sqrt{\theta}} \quad (3.14)$$

O desempenho geral do compressor é regido pelo seu mapa de desempenho, que relaciona a rotação corrigida e uma variável (*Rline*) definida para a vazão corrigida, razão de pressão e eficiência.

A rotação do mapa do compressor pode ser determinada através da rotação corrigida e uma constante escalar pré-definida (*S\_C\_Nc*), conforme a equação 3.15. Essa constante escalar é determinada de forma iterativa ao simular o compressor até que seja encontrada a convergência.

$$NcMap = \frac{N_c}{S\_C\_Nc} \quad (3.15)$$

De forma análoga, o bloco realiza os cálculos para os parâmetros de vazão total de entrada, razão de pressão e eficiência do compressor. Ou seja, os valores são interpolados do mapa e é utilizado um escalar pré-definido para o cálculo final do parâmetro. As Figuras 3.5 e 3.6 mostram os comportamentos dos compressores de baixa e alta pressão modelados para a turbina a gás em estudo, respectivamente. Em ambos os mapas, foi demarcado uma linha tracejada que indica os pontos de maior eficiência para cada rotação.

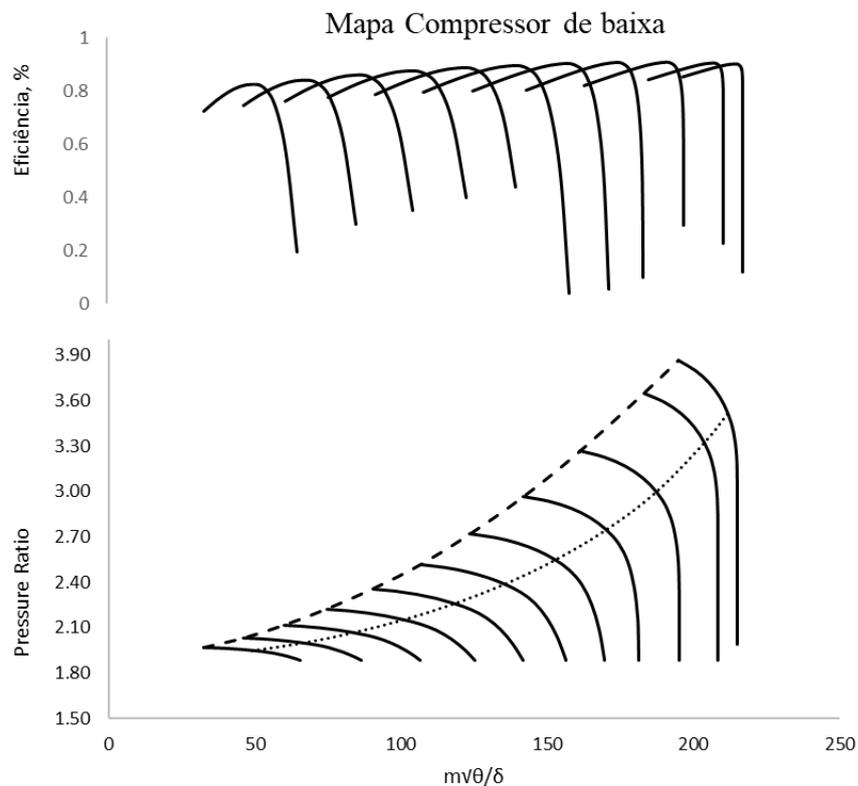


Figura 3.5. Mapa do compressor de baixa pressão – LPC (Fonte: Autor)

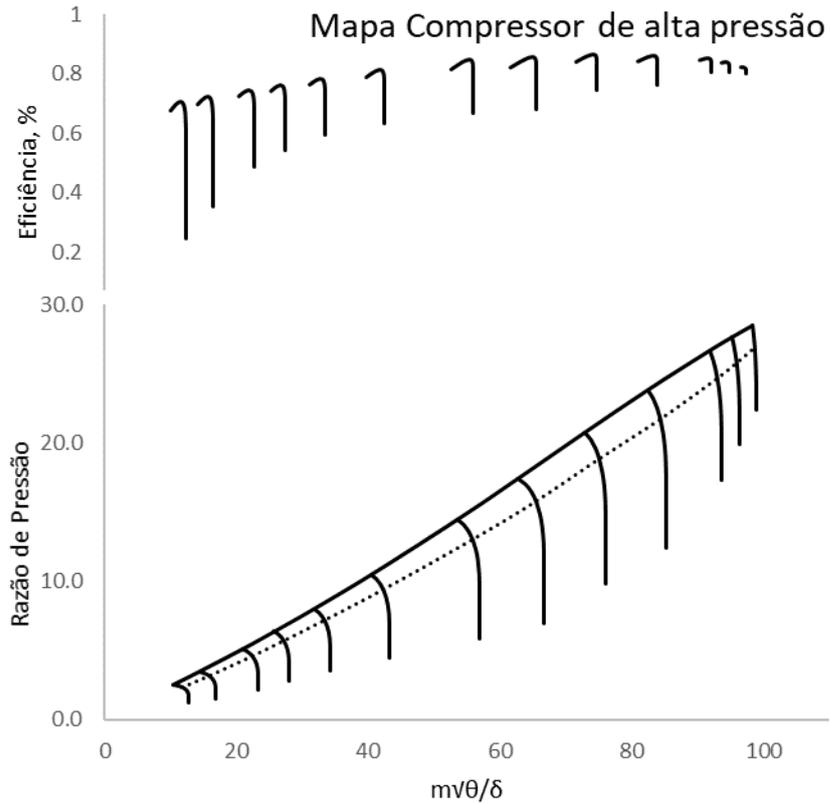


Figura 3.6. Mapa do compressor de alta pressão – HPC (Fonte: Autor)

Para o cálculo da entalpia total de saída, o bloco assume que o compressor é isentrópico, de forma que a entropia de entrada é igual à de saída. Isso permite o cálculo para os valores ideais de temperatura usando a entropia e pressão. Dessa forma, é encontrado o valor ideal da entalpia usando o valor da temperatura ideal. O valor da entalpia total de saída pode ser calculado pela equação 3.16.

$$ht_{out} = \frac{ht_{ideal\ out} - ht_{in}}{\eta_{th}} + ht_{in} \quad (3.16)$$

A temperatura de saída é determinada utilizando o valor da entalpia de saída.

A vazão de saída do compressor é calculada pela subtração da vazão de entrada pela vazão de sangria, utilizada para resfriamento da turbina, como mostra a Equação 3.17.

$$\dot{m}_{out} = \dot{m}_{in} - \dot{m}_{bleeds} \quad (3.17)$$

Semelhante ao cálculo da vazão, a potência do compressor pode ser calculada. A potência do compressor depende da potência de entrada, ou seja, potência fornecida pela turbina e do total de sangria, como mostra a equação 3.18.

$$\dot{W}_{comp-out} = \dot{W}_{in} - \dot{W}_{bleeds} \quad (3.18)$$

Sendo que a potência de entrada e de sangria são calculadas pelas equações 3.19 e 3.20:

$$\dot{W}_{in} = \dot{m}_{in} * (ht_{in} - ht_{out}) \quad (3.19)$$

$$\dot{W}_{bleeds} = \sum \dot{m}_{bleeds} * (ht_{bld_{out}} - ht_{out}) \quad (3.20)$$

Onde  $ht_{bld_{out}}$  é valor da entalpia do fluxo no momento da sangria.

O cálculo do torque é feito pela razão entre a potência e a rotação, conforme Equação 3.21.

$$\tau_{out} = \frac{\dot{W}_{out}}{N_{mech}} \quad (3.21)$$

Um resumo dos parâmetros de entrada e de saída do compressor é mostrado na Figura 3.7 e Tabelas 3.2 e 3.3. A Figura 3.7 mostra o bloco do compressor fornecido pelo T-MATS e utilizado no *simulink*. Analisando o bloco, é possível visualizar as entradas e as saídas, as quais são detalhadas nas Tabelas 3.2 e 3.3.

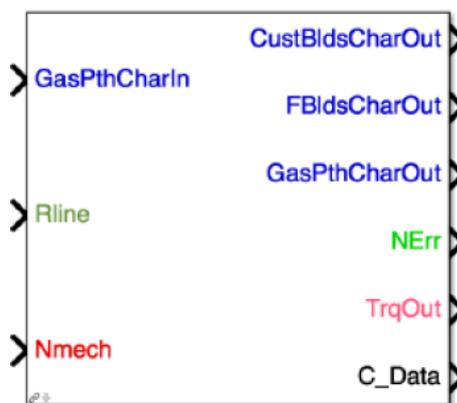


Figura 3.7. Bloco T-MATS para o compressor (Fonte: T-MATS)

Tabela 3.2. Parâmetros de entrada do compressor

<i>Entrada</i>	<i>Descrição</i>
<i>GasPthCharIn</i>	Características do fluido de entrada (vetor 5x1): <ul style="list-style-type: none"> <li>- Vazão [pps]</li> <li>- Entalpia [BTU/lbm]</li> <li>- Temperatura total [°R]</li> <li>- Pressão total [psia]</li> <li>- Razão combustível/ar</li> </ul>
<i>Rline</i>	Posição do mapa do compressor. Determina a razão de pressão, eficiência e vazão.
<i>Nmech</i>	Rotação do eixo [rpm]

Tabela 3.3. Parâmetros de saída do compressor

<i>Saída</i>	<i>Descrição</i>
<i>CustBldsCharOut</i>	Vazão de sangria (vetor 5x1)
<i>FBldsCharOut</i>	Vazão de sangria (porcentagem) (vetor 5x1)
<i>GasPthCharOut</i>	Características do fluido de saída (vetor 5x1)
<i>NErr</i>	Erro normalizado. Em um sistema típico, esse valor é aproximado de zero pelo solucionador iterativo
<i>TrqOut</i>	Torque de saída do compressor (lbf*ft). Para o compressor, é um valor negativo.
<i>C_Data</i>	<p>Dados de cálculo interno do compressor. Vetor 18x1:</p> <ul style="list-style-type: none"> <li>- SMavail: Margem disponível de stall [%]</li> <li>- s_C_Nc: Valor escalar do mapa de rotação</li> <li>- s_C_Wc: Valor escalar do mapa de vazão</li> <li>- s_C_PR: Valor escalar do mapa de razão pressão</li> <li>- s_C_Eff: Valor escalar do mapa de razão da eficiência</li> <li>- Wcin: Vazão corrigida de entrada [pps]</li> <li>- Nc: Rotação corrigida [rpm]</li> <li>- PR: Razão de pressão</li> <li>- NcMap: Rotação corrigida do mapa</li> <li>- WcMap: Vazão corrigida do mapa</li> <li>- PRMap: Razão de pressão do mapa</li> <li>- SurgePR: Razão de pressão para o surge na respectiva vazão corrigida</li> <li>- Wbleeds: Vazão de sangria [pps]</li> <li>- Pwrb4bleeds: Potência requerida se não houver sangria [hp]</li> <li>- PwrBld: Potência de sangria [hp]</li> <li>- Pwrout: Potência total de saída [hp]</li> <li>- SMMMap: Margem de stall baseado nos valores do mapa [%]</li> <li>- SPRMap: Razão de pressão do stall do mapa</li> <li>- Test: Dados de cálculo internos</li> <li>- Nmech: Rotação mecânica de entrada[rpm]</li> </ul>

### 3.3.1.2 Câmara de Combustão

Bloco utilizado para simular a câmara de combustão usando as propriedades e equações básicas da termodinâmica.

A vazão de saída é calculada usando a equação 3.22, que segue a conservação de massa. A vazão mássica de entrada deve ser igual à vazão de saída.

$$\dot{m}_{out} = \dot{m}_f + \dot{m}_{in} \quad (3.22)$$

A razão combustível/ar é calculada pela equação 3.23.

$$FAR_{out} = \frac{\dot{m}_{in} * FAR_{in} + \dot{m}_f}{\dot{m}_{in} * (1 - FAR_{in})} \quad (3.23)$$

A entalpia total de saída é calculada usando o valor do Poder Calorífico Inferior (LHV) do combustível, como mostra a Equação 3.24.

$$ht_{out} = \frac{\dot{m}_{in} * ht_{in} + \dot{m}_f * LHV * \eta_{cc}}{\dot{m}_{out}} \quad (3.24)$$

Dessa forma, a temperatura total de saída é determinada a partir da entalpia total como valor de referência. A perda de pressão total na câmara de combustão é calculada pela equação 3.25, onde dPcc é uma fração da pressão total de entrada.

$$Pt_{out} = Pt_{in} * (1 - dP_{cc}) \quad (3.25)$$

Um resumo dos parâmetros de entrada e de saída do bloco usado para representar a câmara de combustão é mostrado na Figura 3.8 e Tabelas 3.4 e 3.5. A Figura 3.8 mostra o bloco da câmara de combustão fornecido pelo T-MATS e utilizado no *simulink*. Analisando o bloco, é possível visualizar as entradas e as saídas, as quais são detalhadas nas Tabelas 3.4 e 3.5



Figura 3.8. Bloco T-MATS para a Câmara de Combustão (Fonte: T-MATS)

Tabela 3.4. Parâmetros de entrada da câmara de combustão

<i>Entrada</i>	<i>Descrição</i>
<i>FuelFlwIn</i>	Vazão de combustível [pps]
<i>GasPthCharIn</i>	Características do fluido de entrada (vetor 5x1): <ul style="list-style-type: none"> <li>- Vazão [pps]</li> <li>- Entalpia [BTU/lbm]</li> <li>- Temperatura total [°R]</li> <li>- Pressão total [psia]</li> <li>- Razão combustível/ar</li> </ul>

Tabela 3.5. Parâmetros de saída da câmara de combustão

<i>Saída</i>	<i>Descrição</i>
<i>GasPthCharOut</i>	Características do fluido de entrada (vetor 5x1): <ul style="list-style-type: none"> <li>- Vazão [pps]</li> <li>- Entalpia [BTU/lbm]</li> <li>- Temperatura total [°R]</li> <li>- Pressão total [psia]</li> <li>- Razão combustível/ar</li> </ul>
<i>B_Data</i>	Dados de cálculo interno da câmara de combustão

### 3.3.1.3 Turbina

Bloco utilizado para simular o desempenho da turbina usando as equações e propriedades termodinâmicas. O desempenho geral da turina, assim como do compressor, é regido pelo mapa de desempenho da mesma, que relaciona a rotação corrigida e a razão de pressão com a vazão corrigida e a eficiência. O mapa da PT modelada é mostrado na Figura 3.9.

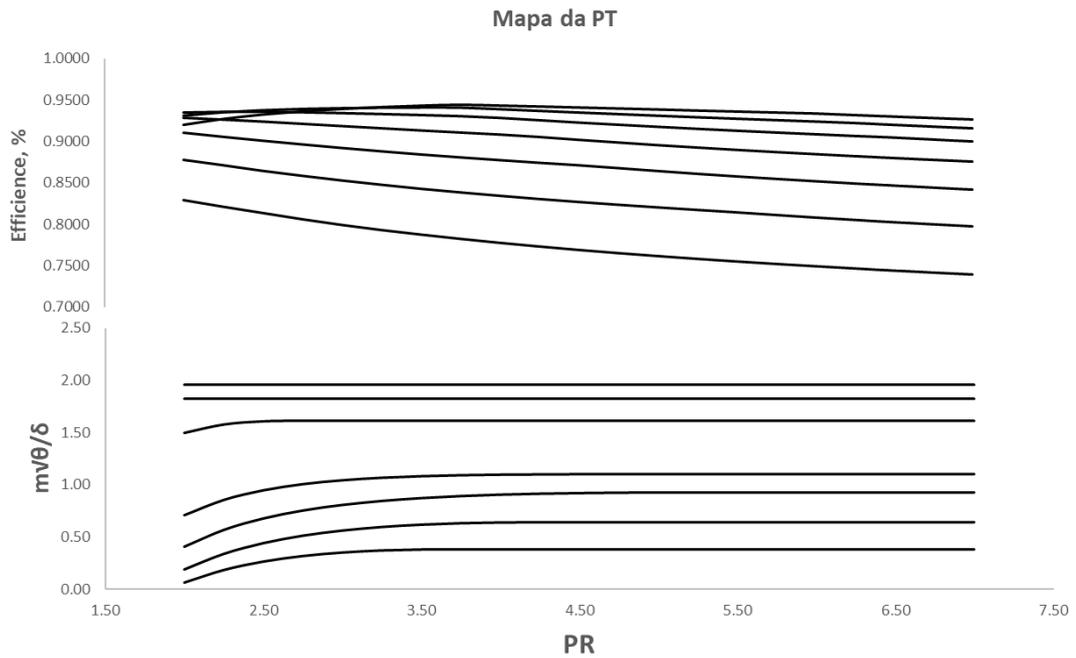


Figura 3.9. Mapa da Turbina livre (Fonte: Autor)

Considera-se que as sangrias feitas no compressor entrem na turbina pelo caminho do gás na parte frontal ou traseira da turbina. Em uma turbina real, esse fluxo entra por todo o comprimento da turbina, através de orifícios de resfriamento localizados nas pás dos primeiros estágios e ao longo da carcaça e do revestimento ou em outras partes do rotor. Para a simulação, essa solução é inadequada, sendo mais apropriado utilizar esse fluxo na entrada e na saída, uma vez que o objetivo é obter os resultados globais de desempenho da turbina, sendo uma modelagem mais simplificada bem aceitável. Outro motivo é que uma modelagem mais próxima da real pode ser muito complexa, o que aumenta significativamente o tempo de simulação.

A vazão mássica de resfriamento no início da expansão (denominada *station one* pelo T-MATS) e na saída são determinadas pelas seguintes equações 3.26 e 3.27.

$$\dot{m}_{cool_{s1}} = \sum \dot{m}_{cool_{in}} \quad (3.26)$$

$$\dot{m}_{cool_{out}} = \sum \dot{m}_{cool} \quad (3.27)$$

Assim, a vazão total no início e no final da expansão podem ser determinadas pelas equações 3.28 e 3.29.

$$\dot{m}_{s1-in} = \dot{m}_{in} + \dot{m}_{cool_{s1}} \quad (3.28)$$

$$\dot{m}_{out} = \dot{m}_{in} + \dot{m}_{cool_{out}} \quad (3.29)$$

A entalpia do fluxo de resfriamento é determinada para os dois pontos pelas equações 3.30 e 3.31

$$dh_{cool_{s1}} = \sum ht_{cool_{in}} * \dot{m}_{cool_{in}} \quad (3.30)$$

$$dh_{cool_{out}} = \sum ht_{cool_{out}} * \dot{m}_{cool_{out}} \quad (3.31)$$

Ao contrário dos parâmetros de saída, a entalpia do fluxo de resfriamento de saída não é a entalpia para todo o fluxo de resfriamento. É considerado apenas a entalpia do fluxo de resfriamento que entra no ponto de saída.

A entalpia no início da expansão (*station one*) pode ser, então, determinada pela equação 3.32, onde  $ht_{in}$  é encontrado através das tabelas termodinâmicas, usando a temperatura total de entrada e a razão combustível/ar.

$$ht_{s1-in} = \frac{ht_{in} * \dot{m}_{in} + dh_{cool_{s1}}}{\dot{m}_{s1-in}} \quad (3.32)$$

Dessa forma, a temperatura total e a entropia no ponto de entrada da turbina são determinadas através das equações polinomiais.

Para o cálculo da potência de saída, primeiramente é calculada a entalpia de saída, como mostra a equação 3.33

$$ht_{out} = \frac{[(ht_{Ideal_{out}} - ht_{s1-in}) * \eta_T + ht_{s1-in}] * \dot{m}_{s1-in} + dh_{cool_{out}}}{\dot{m}_{out}} \quad (3.33)$$

A temperatura total de saída é determinada pelas equações polinomiais, usando o valor calculado da entalpia total de saída.

Dessa forma, a potência da turbina pode ser calculada pela equação 3.34. É importante notar que o bloco leva em consideração apenas o fluxo de resfriamento no ponto de entrada da turbina (*Station One*) e não considera o fluxo de resfriamento no ponto de saída.

$$\dot{W}_{out} = (ht_{s1-in} - ht_{Ideal_{out}}) * \eta_T * \dot{m}_{s1-in} \quad (3.34)$$

Com isso, o torque produzido pelo eixo da turbina é calculado pela razão entre a potência e rotação mecânica, mostrado na equação 3.35.

$$\tau_{out} = \frac{\dot{W}_{out}}{N_{mech}} \quad (3.35)$$

Um resumo dos parâmetros de entrada e de saída da turbina são mostrados na Figura 3.10 e Tabelas 3.6 e 3.7. A Figura 3.10 mostra o bloco da turbina fornecido pelo T-MATS e utilizado no *simulink*. Analisando o bloco, é possível visualizar as entradas e as saídas, as quais são detalhadas nas Tabelas 3.6 e 3.7

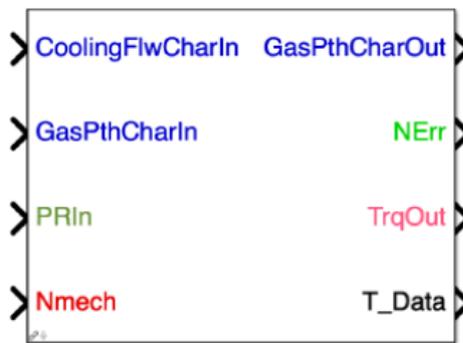


Figura 3.10. Bloco T-MATS para a Turbina (Fonte: T-MATS)

Tabela 3.6. Parâmetros de entrada da turbina

<b><i>Entrada</i></b>	<b><i>Descrição</i></b>
<i>CoolingFlwCharIn</i>	Características do fluido de resfriamento (vetor 5x1)
<i>GasPthCharIn</i>	Características do fluido de entrada (vetor 5x1)
<i>PRMapIn</i>	Razão de pressão do mapa da turbina, posição no mapa. Determina a razão de pressão, eficiência e fluxo do gás
<i>Nmech</i>	Rotação [rpm]

Tabela 3.7. Parâmetros de saída da turbina

<i>Saída</i>	<i>Descrição</i>
<i>GasPthCharOut</i>	Características do fluido de saída (vetor 5x1)
<i>NErr</i>	Erro normalizado
<i>TrqOut</i>	Torque de saída [lbf*ft]. Valor positivo para a turbina
<i>T_Data</i>	Dados de cálculo interno da turbina (vetor 13x1): <ul style="list-style-type: none"> <li>- <i>s_T_Nc</i>: Valor escalar da Rotação corrigida do mapa</li> <li>- <i>s_T_Wc</i>: Valor escalar da Vazão corrigida do mapa</li> <li>- <i>s_T_PR</i>: Valor escalar da Razão de pressão do mapa</li> <li>- <i>s_T_Eff</i>: Valor escalar da Eficiência do mapa</li> <li>- <i>Wcin</i>: Vazão de entrada corrigida [pps]</li> <li>- <i>Wcs1in</i>: Vazão corrigida da station 1 [pps]</li> <li>- <i>Nc</i>: Rotação corrigida [rpm]</li> <li>- <i>NcMap</i>: Rotação corrigida do mapa da turbina</li> <li>- <i>WcMap</i>: Vazão corrigida do mapa</li> <li>- <i>PRMap</i>: Razão de pressão do mapa</li> <li>- <i>EffMap</i>: Eficiência do mapa</li> <li>- <i>Pwrout</i>: Potência de saída [hp]</li> <li>- <i>Test</i>: Dados de cálculo interno da turbina</li> <li>- <i>Nmech</i>: Rotação mecânica do eixo [rpm]</li> </ul>

### 3.3.1.4 Componentes Auxiliares

Para modelar a turbina a gás como uma unidade geradora, é necessário integrar aos componentes principais (compressores, câmara de combustão e turbina) os componentes auxiliares, que combinados formam uma turbina a gás completa. Os componentes auxiliares utilizados e seus respectivos parâmetros de operação são demonstrados a seguir.

#### 3.3.1.4.1 Eixos Mecânicos

Para integrar o modelo da turbina a gás e realizar o acoplamento entre os compressores, e turbinas, é utilizado o bloco de modelagem para o eixo mecânico. Para a turbina em estudo, são utilizados três blocos, que representam as rotações de alta pressão, de baixa pressão e a rotação do gerador elétrico.

Para calcular a aceleração, o bloco utiliza a soma dos torques de entrada e utiliza a seguinte equação 3.36.

$$Ndot = \frac{60 * \sum torque}{2\pi * Shaft\_Inertia\_M} \quad (3.36)$$

Apesar de poder representar o comportamento da turbina em condições transientes, o diagnóstico, realizado nesse trabalho, considera somente condições em regime permanente.

As constantes da equação são usadas para converter as unidades de entrada para a apropriada unidade de saída. Em geral, torque negativo é usado para energia sendo retirada do eixo e torque positivo para energia sendo colocada no eixo.

A Figura 3.11 mostra o bloco do eixo mecânico fornecido pelo T-MATS e utilizado no *simulink*. Analisando o bloco, é possível visualizar as entradas e as saídas, as quais são detalhadas nas Tabelas 3.8 e 3.9

Tabela 3.8. Parâmetros de entrada do eixo

<i>Entrada</i>	<i>Descrição</i>
<i>Torque</i>	Torque de entrada [lbf*ft]
<i>NmechIn</i>	Rotação mecânica [rpm]

Tabela 3.9. Parâmetros de saída do eixo

<i>Saídas</i>	<i>Descrição</i>
<i>NmechOut</i>	Rotação mecânica (igual a rotação mecânica de entrada) [rpm]
<i>Ndot</i>	Aceleração do eixo mecânico [rpm/s]

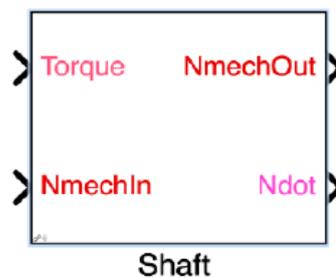


Figura 3.11. Bloco eixo mecânico (Fonte: T-MATS)

### 3.3.1.4.2 Redutor de Velocidades

Para o acoplamento entre a turbina de potência e o gerador elétrico, é necessário um redutor de velocidades para reduzir a rotação do eixo da PT para a rotação de operação do gerador elétrico.

Esse bloco computa a rotação e torque através da equação 3.37.

$$R_M = \frac{N_{mechA}}{N_{mechB}} = \frac{TorqueB}{TorqueA} \quad (3.37)$$

Em que  $R_M$  é a razão de engrenagem e “A” e “B” são os lados do redutor de velocidades, como mostrado na Figura 3.12 Dessa forma, o torque de saída pode ser calculado pela equação 3.38, a seguir.

$$TorqueA = \frac{TorqueB}{Eff_M * R_M} \quad (3.38)$$

Onde  $Eff_M$  é a eficiência da caixa de engrenagem.

A Figura 3.12 mostra o bloco do compressor fornecido pelo T-MATS e utilizado no *simulink*. Analisando o bloco, é possível visualizar as entradas e as saídas, as quais são detalhadas nas Tabelas 3.10 e 3.11

Tabela 3.10. Parâmetros de entrada da caixa de engrenagem

<i>Entrada</i>	<i>Descrição</i>
<i>TorqueB</i>	Torque no lado B [lbf*ft]
<i>NmechA</i>	Rotação mecânica do lado A [rpm]

Tabela 3.11. Parâmetros de saída da caixa de engrenagem

<i>Saída</i>	<i>Descrição</i>
<i>NmechB</i>	Rotação mecânica do lado B [rpm]
<i>TorqueA</i>	Torque do lado A [lbf*ft]

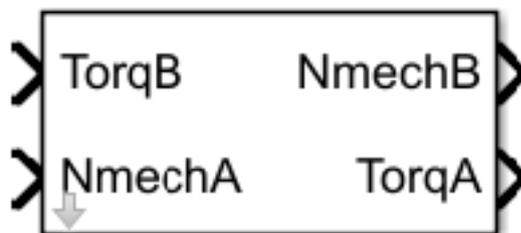


Figura 3.12. Bloco Caixa de engrenagem (Fonte: T-MATS)

### 3.3.1.4.3 Gerador elétrico

Esse bloco é utilizado para converter uma demanda de potência com rotação em torque. Em geral, o bloco é utilizado para simular um gerador elétrico simples.

O bloco utiliza a seguinte Equação 3.39 para computar o torque do gerador elétrico, onde  $\eta_{ge}$  é a eficiência do gerador.

$$Torque = \frac{-PowerDMD}{\eta_{ge} * Nmech} \quad (3.39)$$

A Figura 3.13 mostra o bloco do compressor fornecido pelo T-MATS e utilizado no simulink. Analisando o bloco, é possível visualizar as entradas e as saídas, as quais são detalhadas nas Tabelas 3.12 e 3.13

Tabela 3.12. Parâmetros de entrada do gerador elétrico

<i>Entrada</i>	<i>Descrição</i>
<i>PowerDMD</i>	Demanda de potência [Watt]
<i>Nmech</i>	Rotação mecânica [rpm]

Tabela 3.13. Parâmetros de saída do gerador elétrico

<i>Saida</i>	<i>Descrição</i>
<i>Req_Torq</i>	Torque requerido [lbf*ft]



Figura 3.13. Bloco Gerador elétrico (Fonte: T-MATS)

### 3.3.1.4.4 Solucionador Iterativo

Cada componente da turbina é representado por um modelo individual e é necessário efetuar a integração dos mesmos para que se possa representar o acionador primário como um todo. O objetivo de criar uma forma iterativa de calcular os parâmetros de interesse a partir de variáveis independentes, representadas pelas variáveis de entrada dos modelos individuais da turbina, tais

como fluxo mássico,  $Rline$  e  $Nmech$  para o compressor, vazão de combustível para a câmara de combustão,  $PRIn$  e  $Nmech$  para a turbina.

O processor iterativo repete a sequência de cálculo até que os desvios (erros), definidos em 1%, entre variáveis estimadas sejam minimizados. Neste modelo, utiliza-se o método de Newton-Raphson para determinar qual variável independente deve ser alterada para que ocorra a convergência. Cada vez que uma variável é alterada, uma nova iteração se inicia, com cada componente calculando novamente as suas saídas e atualizando os valores dos erros. Quando os valores dos erros estão abaixo do valor máximo estipulado, é considerado que o sistema convergiu. A Figura 3.14 ilustra o bloco do solucionador iterativo. Analisando o bloco, é possível visualizar as entradas e as saídas, as quais são detalhadas nas Tabelas 3.14 e 3.15

Para o modelo em regime permanente, os erros, que são os valores de saída dos componentes individuais, são as entradas do solucionador e as variáveis independentes, que são as saídas do solucionados, correspondem às entradas dos componentes.

O bloco deve ser utilizado junto com o bloco “do... while” do Simulink. Ambos os blocos devem estar localizados no mesmo local do sistema a ser modelado.

Tabela 3.14. Parâmetros de entrada do Solucionador Iterativo

<i>Entrada</i>	<i>Descrição</i>
<i>Iterações</i>	Número de vezes que o “do... while” deve rodar o sistema
<i>Habilitar</i>	Solver habilitação
$f(x)$	Saídas do sistema a ser solucionado (vetor mx1 contendo todas as saídas do sistema)

Tabela 3.15. Parâmetros de saída do Solucionador Iterativo

<i>Saídas</i>	<i>Descrição</i>
$X$	Entrada para o sistema a ser solucionado (vetor mx1 contendo todas as entradas do sistema). Os valores iniciais são definidos como as condições iniciais
<i>Condição do... while</i>	Entrada para o loop do... while.
$S\_Data$	Dados de cálculo interno: J – Matriz jacobiana calculada JacFailed – Falha na inversão da jacobiana (0 – sem falha, 1 – falha)

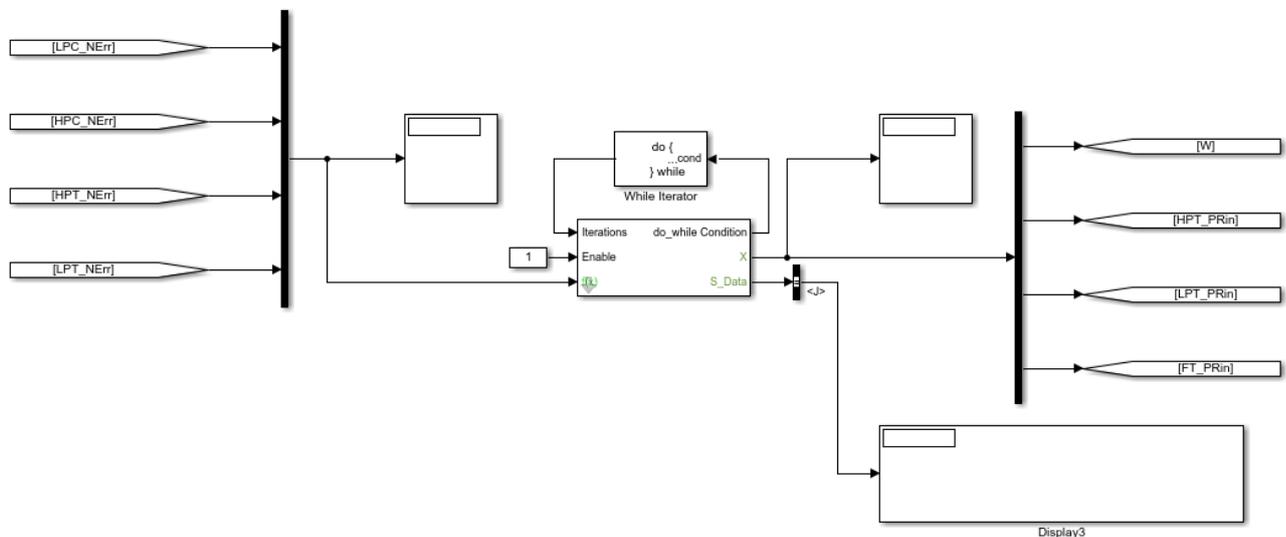


Figura 3.14. Bloco Solucionador Iterativo (Fonte: T-MATS)

### 3.4 Resultados da Simulação

O modelo desenvolvido para a turbina a gás deve apresentar resultados coerentes e satisfatórios, de forma que reproduza fidedignamente o comportamento da turbina a gás real. Somente assim se poderá gerar dados confiáveis para que uma rede neural possa realizar o diagnóstico da turbina. Dessa forma, para validação do modelo construído, utilizando o MATLAB/Simulink/T-MATS, foram comparados os resultados obtidos através do modelo com dados de operação da turbina a gás fornecidos pelo fabricante. Assim, o comportamento da turbina a gás é avaliado através de parâmetros calculados através dos dados gerados pela simulação, tais como a *heat rate*, razão combustível/ar, as razões de pressão dos compressores e a potência elétrica esperada.

Uma vez que o modelo foi escalonado e a simulação realizada, o resultado final trouxe desvios entre os parâmetros reais e os obtidos através do modelo não superiores a 0,24%, podendo-se considerar que o modelo apresentou bons resultados e pode ser utilizado para representar adequadamente o comportamento da turbina SGT-A35(GT62). A Tabela 3.16 mostra a validação do modelo em carga nominal de operação com os principais parâmetros que afetam o desempenho de uma turbina a gás [ANDRADE, 2021].

Tabela 3.16. Validação do Modelo para carga nominal

<b>Carga Nominal e Temperatura ambiente = 15°C</b>			
	<b>Referência</b>	<b>Modelo</b>	<b>erro</b>
<b>Vazão de Ar [kg/s]</b>	95,62	95,62	0,00%
<b>RP LPC [-]</b>	3,430	3,4577	0,80%
<b>RP total [-]</b>	20	20,05	0,24%
<b>FAR [-]</b>	0,01757	0,01758	0,06%
<b>Vazão de Combustível [kg/s]</b>	1,68	1,6810	0,06%
<b>PCI [kJ/kg]*</b>	49111	49111	0,00%
<b>Temp. saída GG [°C]</b>	795	787,41	0,96%
<b>Pressão entrada PT [bar]</b>	3,43	3,41	0,81%
<b>Temp. saída PT [°C]</b>	497	494,072	0,59%
<b>Vazão de exaustão [kg/s]</b>	96,8	97,30	0,509%
<b>Rotação LP [rpm]</b>	5923	5915	0,135%
<b>Rotação HP [rpm]</b>	8784	8778	0,068%
<b>Rotação PT [rpm]</b>	4800	4800	0,00%
<b>Heat Rate [kJ/kWh]</b>	9706	9746,57	0,42%
<b>Potência Elétrica [kW]</b>	30715	30493	0,72%

\*Considerando uma densidade (@15°C e 1atm) de 0,78[kg/m<sup>3</sup>]: 38.306,58[kJ/m<sup>3</sup>]

As Figuras 3.15 e 3.16 mostram os resultados das simulações para diferentes condições. O modelo da turbina foi simulado com diferentes valores de temperatura ambiente, 15°C (condição ISO), 25°C e 35°C, e diferentes condições de carga, 100%, 75% 50% e 25%, e para cada porcentagem de carga, foi feita a variação da temperatura ambiente.

Como visto no capítulo 2, as turbinas a gás apresentam um comportamento de queda de potência gerada com o aumento da temperatura ambiente, enquanto o *Heat Rate* aumenta à medida que a temperatura ambiente aumenta, como mostram as Figuras 3.15 e 3.16. O mesmo comportamento foi apresentado pelo modelo nas condições de carga parcial de 75% e 50% e 25% para as diferentes condições de temperatura ambiente.

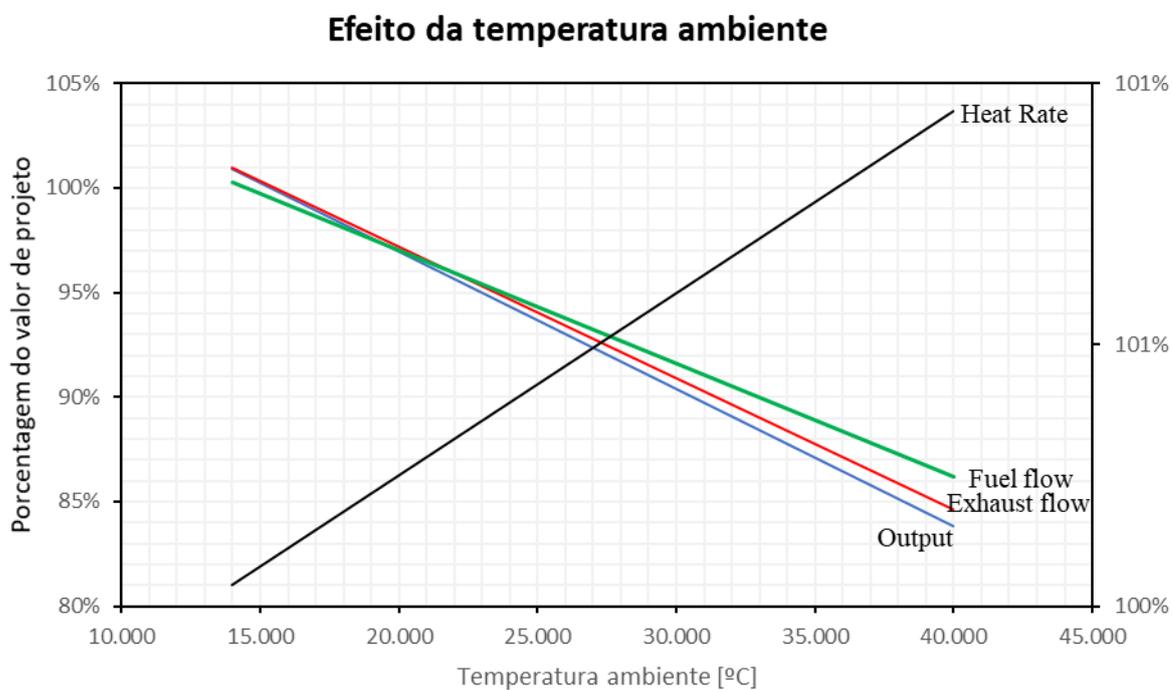


Figura 3.15. Efeito da temperatura ambiente (Fonte: Autor)

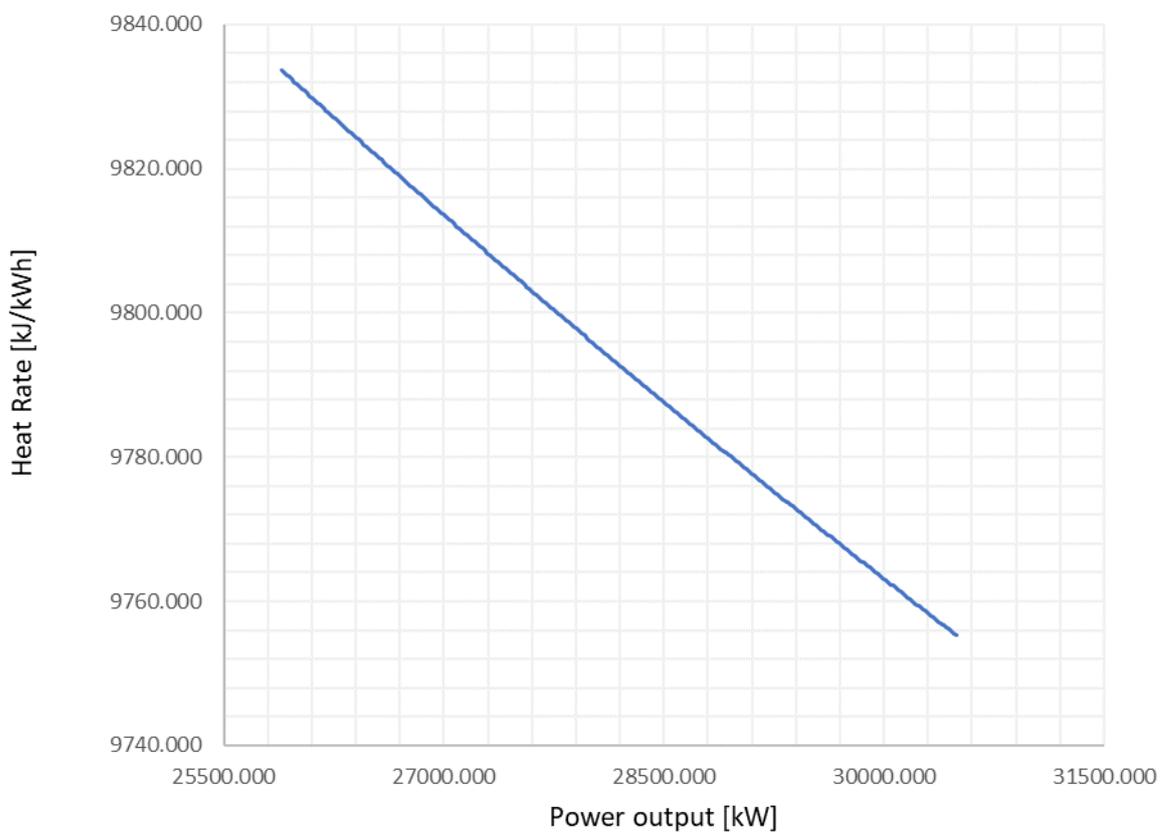


Figura 3.16. Potência Elétrica x Heat Rate (Fonte: Autor)

Como é possível observar na Figura 3.15, a temperatura ambiente é um fator decisivo no desempenho da turbina a gás. O aumento da temperatura ambiente significa diminuição da massa específica do ar, ou seja, o volume de ar aumenta, diminuindo a razão massa/volume. Dessa forma, a vazão mássica que entra no compressor de baixa pressão diminui, o que causa na diminuição da potência produzida, diminuição do consumo de calor e diminuição da vazão de exaustão da turbina a gás. O *Heat Rate* aumenta seu valor devido à proporção de queda dos outros parâmetros

Ainda analisando a Figura 3.15, é possível observar um comportamento coerente para a turbina a gás simulada para diferentes temperaturas ambientes, validando o modelo para estas condições. A Figura 3.16, mostra a relação entre a potência elétrica e o *heat rate* de uma perspectiva diferente, garantindo um comportamento adequado do modelo.

A Figura 3.17 mostra o comportamento da potência elétrica e do *heat rate* da turbina nas diferentes condições de carga simuladas, ou seja, 100%, 75%, 50% e 25%, para as condições ambientes ISO. É de fácil compreensão que à medida que a potência gerada pela turbina diminui, devido a operação em carga parcial, o *Heat Rate* aumenta.

Logo, é possível concluir que o modelo apresentou resultados coerentes. Esses resultados serão utilizados como fonte de dados para treinar e validar redes neurais, responsáveis pela realização do diagnóstico da turbina a gás.

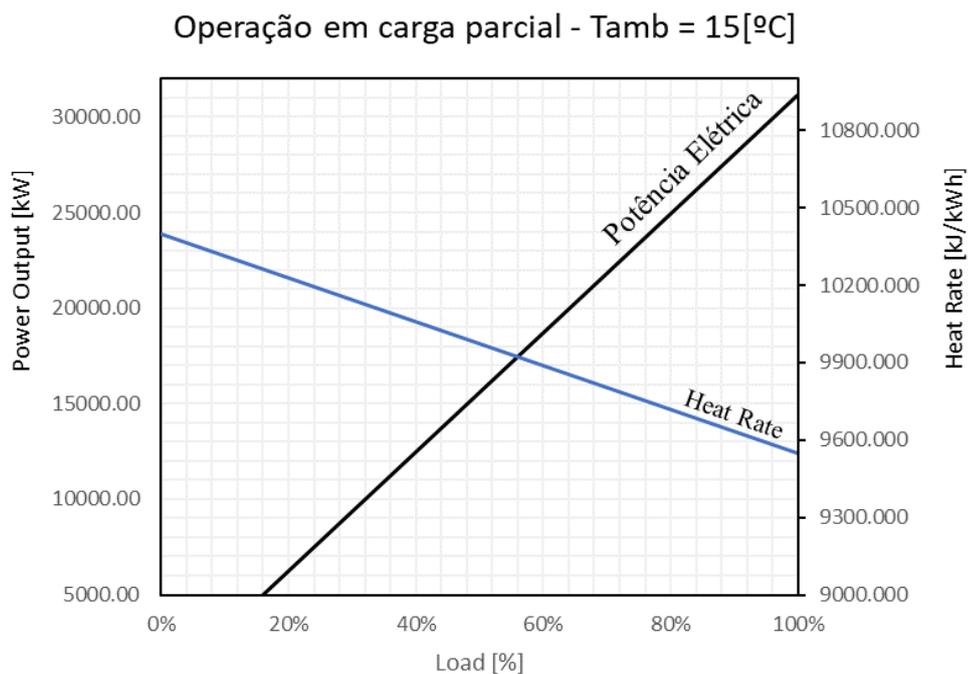


Figura 3.17. Efeito da operação em carga parcial (Fonte: Autor)

# CAPÍTULO 4

## DIAGNÓSTICO TERMODINÂMICO DA TURBINA A GÁS

O presente capítulo descreve a metodologia desenvolvida para o diagnóstico de falhas na turbina a gás SGT-A35(GT62). Como já visto no capítulo anterior, a turbina em questão é composta por dois *spools*, um de alta pressão e outro de baixa pressão, ou seja, o conjunto todo é composto por um compressor de baixa pressão, um compressor de alta pressão, uma câmara de combustão, uma turbina de alta pressão, uma turbina de baixa pressão e uma turbina livre (vide Figura 3.4).

### 4.1 Identificação do problema

O problema de diagnóstico de falhas de desempenho em turbinas a gás pode ser tratado como um problema de identificação e classificação (associação e reconhecimento) das possíveis falhas que ocorrem na máquina.

O diagnóstico de falhas na turbina a gás considerada é realizado através da aplicação de um modelo de rede neural, como descrito no capítulo dois deste trabalho. O modelo de rede neural escolhido foi uma combinação de uma rede neural de regressão e uma de classificação. A rede neural de regressão é um modelo de inteligência computacional usado para resolver problemas de regressão, ou seja, problemas em que a tarefa é prever um valor numérico contínuo com base em um conjunto de entradas. A principal função dessa rede é encontrar uma relação funcional entre as variáveis de entrada e as variáveis de saída. A rede de classificação é um modelo supervisionado em que o algoritmo aprende a classificar novas observações do conjunto de dados rotulado [HORTA, 2015].

### 4.2 Coleta de dados

No presente estudo de caso, os dados foram gerados usando um modelo computacional, conforme explicado no capítulo anterior. Para formar um banco de dados suficientes para alimentar a rede, utilizou-se o modelo computacional da turbina para simular a diversas condições de operacionais, com variação da temperatura ambiente desde 15°C até 40°C e diferentes condições de carga, a qual foi alterada desde 100% até 50% da potência nominal do turbogerador.

Dessa forma, foi possível obter o comportamento da turbina a gás para diferentes temperaturas ambientes e em diferentes condições de carga. O principal motivo para simular a turbina a gás nessas diferentes condições é reproduzir o que acontece na realidade. Durante a operação em uma FPSO, a turbina a gás passa por diversas variações da condição ambiente e diversas variações de carga, uma vez que a turbina a gás trabalha em um sistema ilhado. No entanto, a pressão ambiente não foi alterada, uma vez que essas turbinas são estacionárias nas plataformas e não há mudança de altitude. A umidade relativa do ambiente também não foi alterada para facilitar a simulação.

A variação de carga para uso no diagnóstico foi de 100%, 75% e 50% de carga, uma vez que são as condições mais comuns durante a operação. Essas turbinas operam em um conjunto de quatro (4) turbogeradores alimentando dois barramentos, de forma que sempre há compartilhamento de carga e somente em condições atípicas essas turbinas operam com 25% de carga.

O diagnóstico, neste trabalho, é feito sobre as falhas que afetam o desempenho a turbina a gás, ou seja, que provocam alterações nos parâmetros de operação da máquina, tais como temperatura, pressão e vazão mássica. Como já discutido no capítulo 2, são diversas as falhas que afetam o desempenho da turbina a gás e, para o estudo de caso, este trabalho considerou cinco falhas comuns às turbinas a gás, resumidas na Tabela 4.1, as quais incluem *fouling* no LPC com duas severidades – a severidade 1 afetando em 5% a vazão de ar do compressor e a severidade 2 afetando em 10%; *fouling* no HPC com as mesmas severidades do LPC; e perda de eficiência de 5% da câmara de combustão.

Tabela 4.17. Falhas Simuladas

<i>Falha</i>	<i>Consequência</i>
<i>Perda de eficiência na câmara de combustão</i>	5% da eficiência
<i>Fouling LPC – severidade 1</i>	5% da vazão nominal de ar
<i>Fouling LPC – severidade 2</i>	10% da vazão nominal de ar
<i>Fouling HPC – severidade 1</i>	5% da vazão nominal de ar
<i>Fouling HPC – severidade 2</i>	10% da vazão nominal de ar

Dentre todos os parâmetros obtidos pela simulação em Matlab/simulink, os que foram usados como entrada na rede neural são a temperatura ambiente, temperatura de descarga do compressor de baixa pressão ( $T_2$ ), razão de pressão do compressor de baixa pressão,

temperatura de descarga do compressor de alta pressão ( $T_4$ ), razão de pressão da compressão total, temperatura de exaustão da geradora de gás ( $T_9$ ), vazão de combustível, vazão de exaustão da turbina a gás e potência produzida. Estes parâmetros foram escolhidos por serem os que mais afetam o desempenho da turbina a gás [ANDRADE, 2021], e estão apresentados nos gráficos da Figura 4.1, os quais mostram a variação de cada parâmetro individualmente em função da temperatura ambiente, para a condição de carga nominal da turbina a gás. Vale ressaltar que, para treinamento, validação e teste do modelo de rede neural, os dados coletados e usados compreendem todas as condições simuladas de carga da máquina, ou seja, as simulações em carga nominal, 75%, 50% de carga, mostrados nos apêndices deste trabalho.

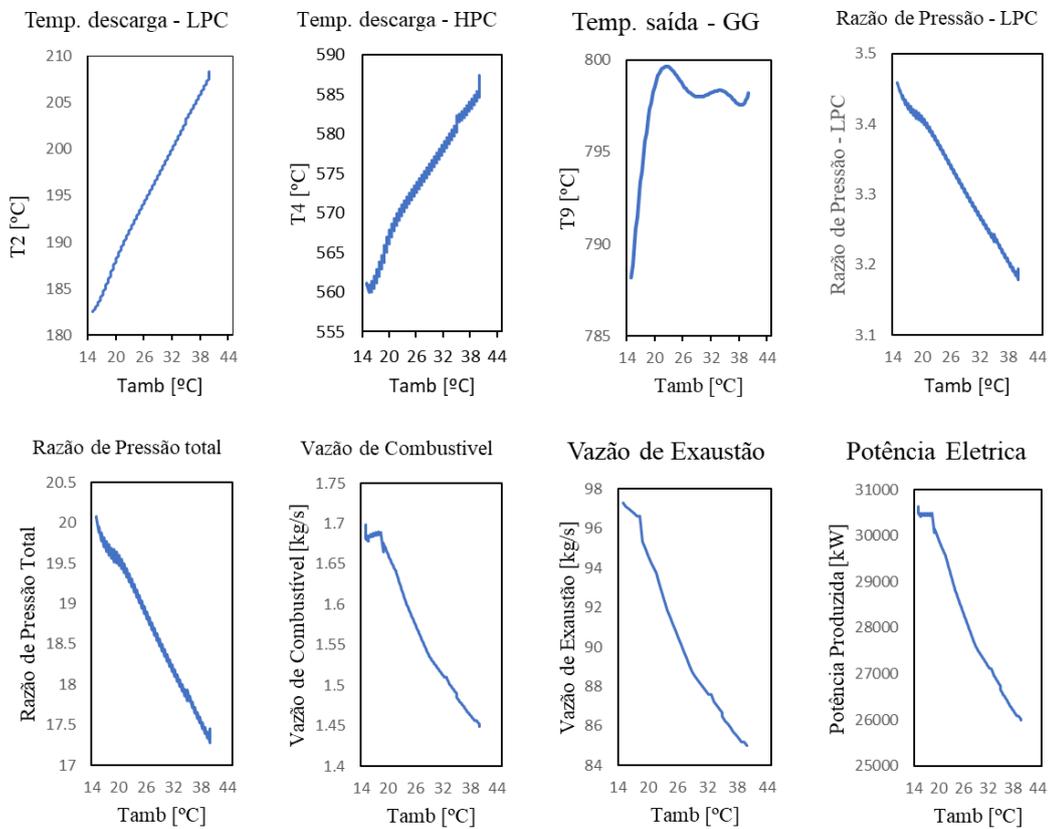


Figura 4.1. Parâmetros de entrada da rede neural em condição nominal (Fonte: Autor)

De forma análoga, os mesmos parâmetros mostrados anteriormente, porém obtidos com a introdução das anomalias listadas anteriormente no modelo da turbina simulada são mostrados nas Figuras 4.2 a 4.6.

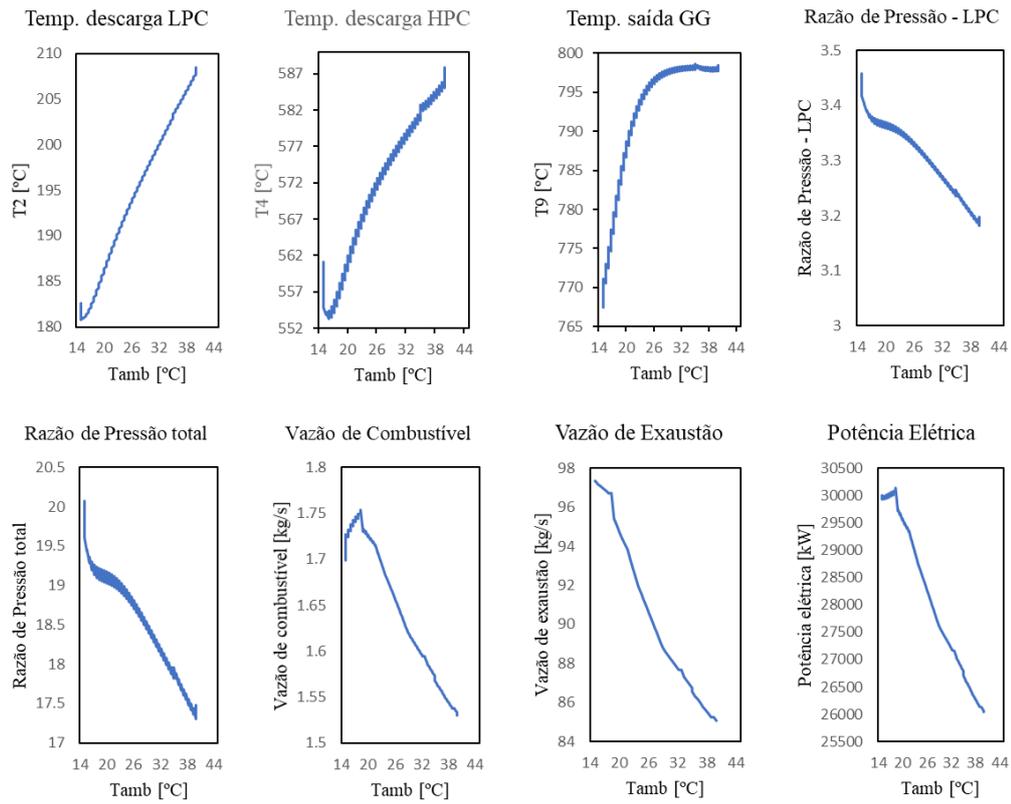


Figura 4.2. Parâmetros de entrada da rede neural em condição de perda da eficiência da câmara de combustão

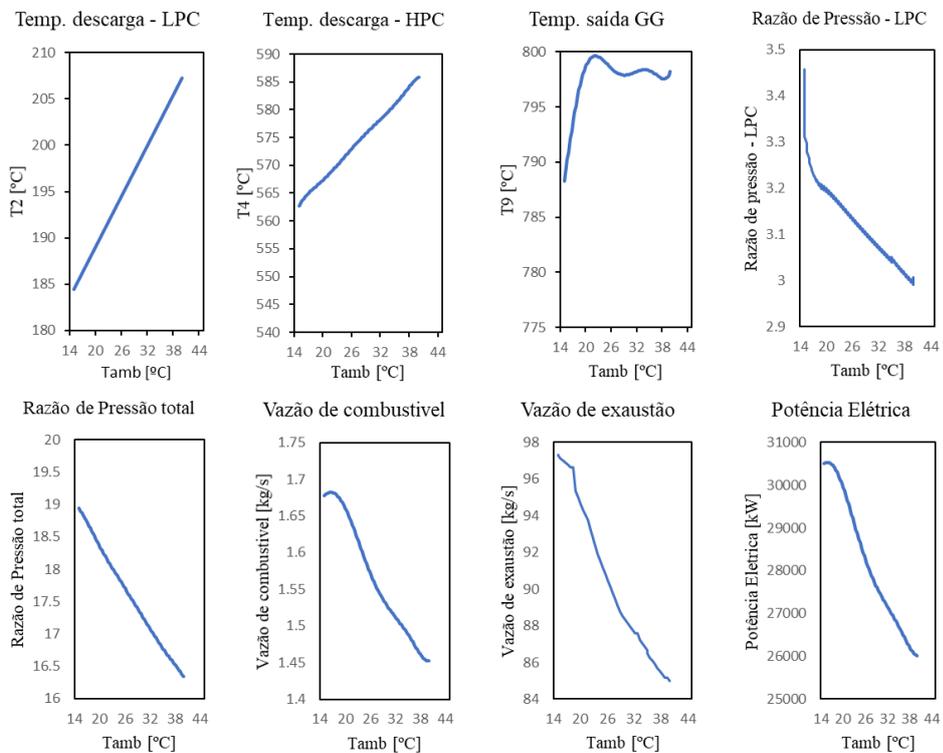


Figura 4.3. Parâmetros de entrada da rede neural em condição de fouling do LPC – severidade 1.

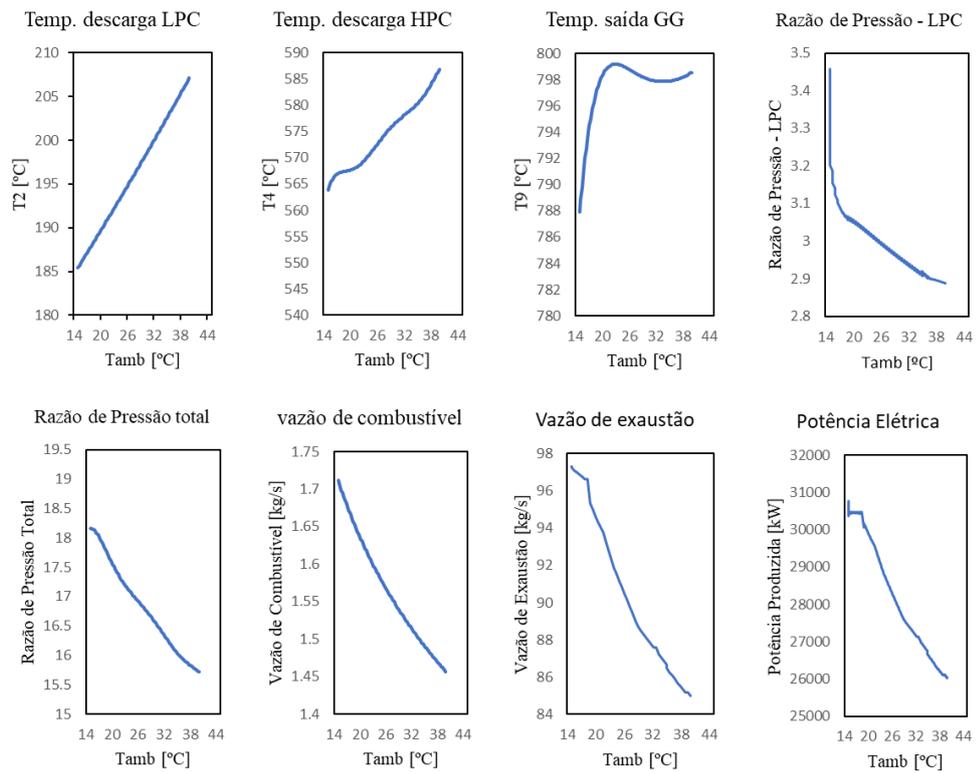


Figura 4.4. Parâmetros de entrada da rede neural em condição fouling do LPC – severidade 2

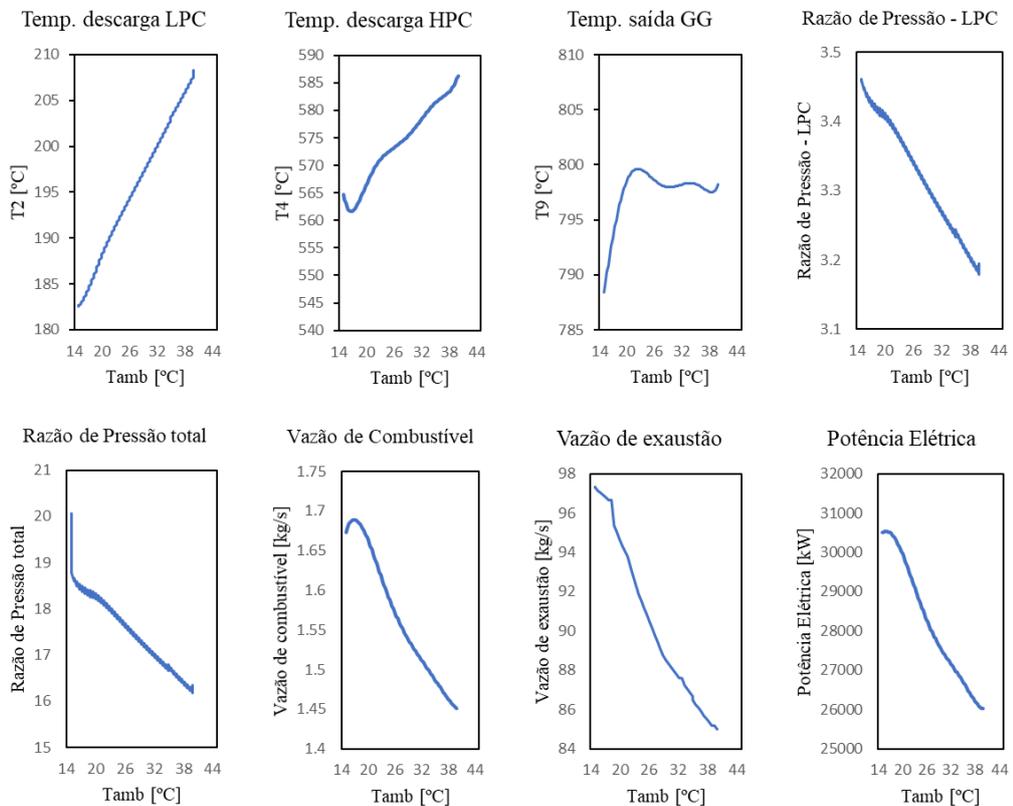


Figura 4.5. Parâmetros de entrada da rede neural em condição fouling do HPC – severidade 1

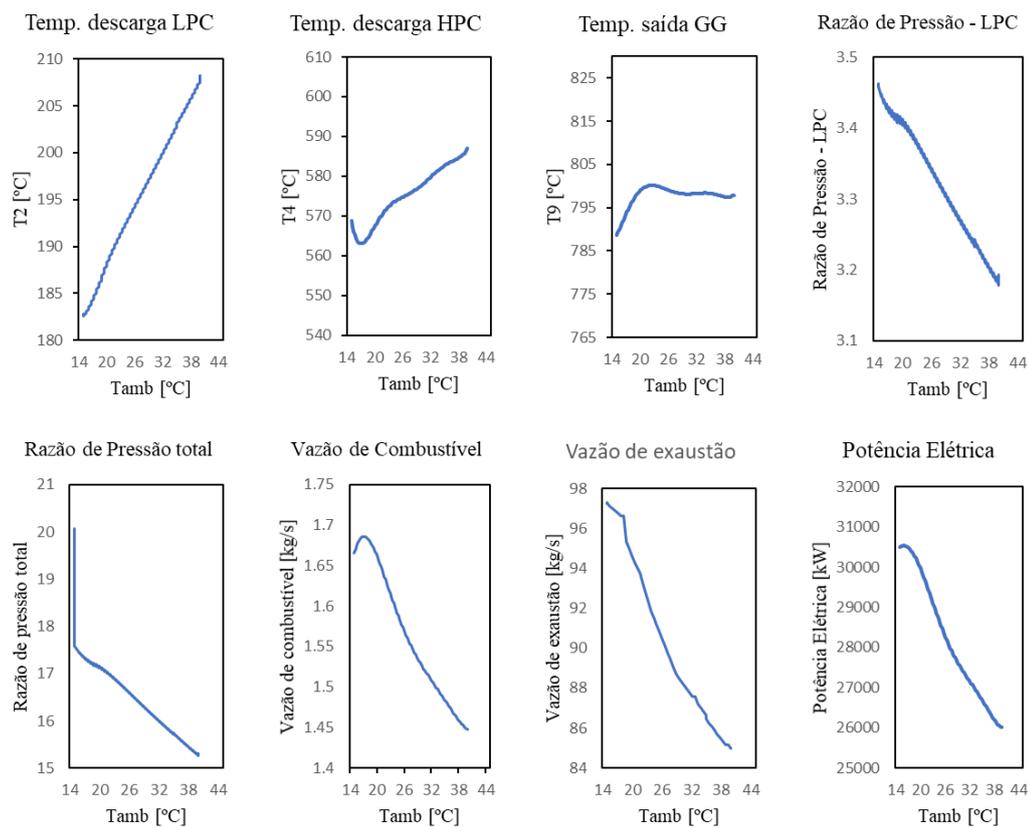


Figura 4.6. Parâmetros de entrada da rede neural em condição do *fouling* HPC – severidade 2

Os parâmetros de saída, escolhidos para avaliar o desempenho do modelo de inteligência computacional, a ser comparado com o modelo da turbina a gás simulado em MATLAB, são a eficiência do compressor de baixa pressão, eficiência do compressor de alta pressão, eficiência da câmara de combustão, eficiência da turbina de alta pressão, eficiência da turbina de baixa pressão, eficiência da PT e o *Heat Rate* [ALBLAWI, 2020]. Uma das formas de validação do modelo da rede neural é através do cálculo da diferença entre os valores da simulação em Matlab com os valores obtidos através da rede neural. Os dados usados para a saída da rede neural, coletados para a condição nominal, são mostrados na Figura 4.7. Vale ressaltar que a Figura 4.7 mostra os dados obtidos através da simulação em MATLAB/Simulink e que serão utilizados para comparação com os dados obtidos pela rede neural.

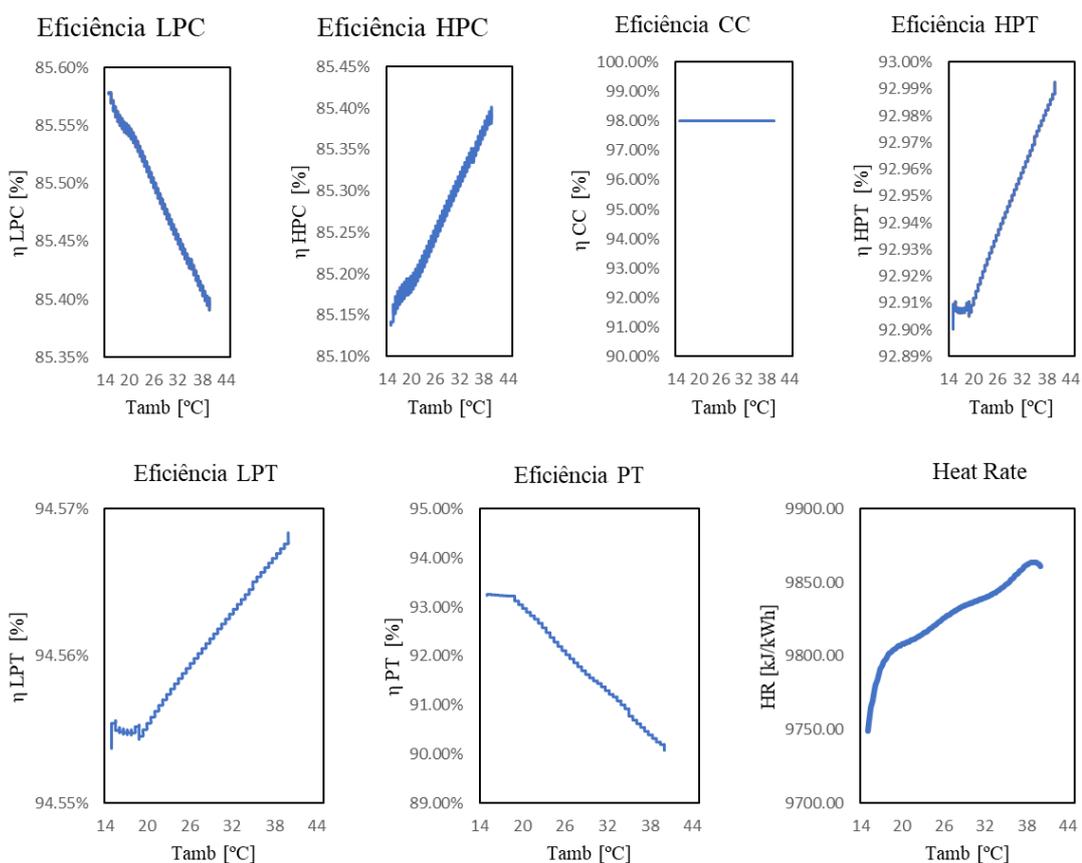


Figura 4.7. Parâmetros de saída em condição nominal

### 4.3 Pré-processamento dos dados

Para alimentar a rede neural é preciso manipular os dados para que estejam no formato adequado quando forem ser utilizados pela rede, como visto no capítulo 2. Ademais, é preciso dividir os dados em conjuntos de treinamento, validação e teste, de forma que a posterior avaliação do modelo possa ser efetuada.

A divisão dos conjuntos de treinamento, validação e teste é uma etapa crucial no treinamento de redes neurais artificiais. Essa divisão permite avaliar o desempenho do modelo em dados não vistos durante o treinamento e ajustar os hiper parâmetros do modelo adequadamente. Existem várias abordagens para realizar essa divisão, sendo as mais comuns o método de divisão fixa e o método de validação cruzada.

No método de divisão fixa, é definido uma porcentagem fixa para cada conjunto, por exemplo, 70% para treinamento, 15% para validação e 15% para teste. Os dados são divididos aleatoriamente, garantindo que a distribuição das classes seja mantida em cada conjunto. O conjunto de treinamento é usado para ajustar os pesos do modelo, o conjunto de validação é

usado para ajustar os hiper parâmetros e monitorar o desempenho durante o treinamento, e o conjunto de teste é usado apenas para avaliar o desempenho final do modelo.

A validação cruzada é uma técnica mais avançada que envolve a criação de múltiplas divisões de treinamento/validação/teste. Uma forma comum é a validação cruzada k-fold, em que os dados são divididos em k subconjuntos (ou folds) de tamanhos aproximadamente iguais. O treinamento é realizado k vezes, cada vez usando k-1 subconjuntos como treinamento e o subconjunto restante como validação. O desempenho é avaliado pela média dos resultados das k iterações. Esse método é útil quando se tem um conjunto de dados limitado, pois permite utilizar todos os dados para treinamento e validação sem comprometer a avaliação do modelo.

Para o modelo deste trabalho, a divisão dos dados é feita através do método da divisão fixa, com a proporção de 70/15/15, sendo a primeira etapa do pré-processamento do conjunto de dados. No entanto, como o modelo elaborado possui duas redes neurais, é preciso preparar os dados para ambas as redes de regressão e classificação. Dessa forma, após dividir os dados em conjuntos de treinamento, validação e teste, é necessário rotular as falhas e realizar a normalização dessa rotulação, criando uma nova variável, para cada conjunto criado, de forma que essa nova variável seja a saída da rede neural de classificação.

A rotulação das falhas é feita de forma binária, ou seja, através de 0 e 1, onde 1 é usado para atestar uma determinada condição de operação e 0 para atestar que determinada condição não está ocorrendo. A tabela 4.2 exemplifica a rotulação das falhas.

Dessa forma, uma nova variável pode ser criada para cada conjunto criado (treinamento, validação e teste), de forma que a rede neural de classificação possa realizar a devida associação e reconhecimento das falhas. Para fins didáticos, essas novas variáveis foram chamadas de *classe\_treinamento*, *classe\_validação* e *classe\_teste* e são definidas nas equações 4.1, 4.2 e 4.3.

$$classe\_treinamento = 2 * (rotulação\ da\ falha) - 1 \quad (4.1)$$

$$classe\_validação = 2 * (rotulação\ da\ falha) - 1 \quad (4.2)$$

$$classe\_teste = 2 * (rotulação\ da\ falha) - 1 \quad (4.3)$$

A Tabela 4.2 mostra os parâmetros de entrada e saída escolhidos para serem utilizados no modelo de rede neural, ou seja, as redes neurais de regressão e classificação, e mostra a rotulação do estado da condição, onde 1 é para atestar que a condição está ocorrendo e 0 para atestar que a condição não está ocorrendo. A Tabela 4.2 é apenas uma amostra de todo o conjunto de dados utilizado e a divisão dos dados para treinamento, validação e teste é feita de forma aleatória para alimentar a rede.

Ainda na Tabela 4.2, é possível visualizar o resultado da modelagem termodinâmica da turbina a gás SGT-A35(GT62). É possível notar que, por exemplo, ao analisar a operação do LPC em condição nominal a 25°C de temperatura ambiente é de 86% e a operação do LPC em uma condição de *fouling*, à mesma temperatura ambiente de 25°C, é de 80%. Isso mostra como a falha afeta o desempenho termodinâmico do compressor e, conseqüentemente, da turbina a gás.

As equações 4.1 a 4.3 normalizam a rotulação das falhas mostradas na Tabela 4.2 em uma nova rotulação entre -1 e 1, de forma a ficar mais adequado para a rede neural, uma vez que a codificação entre -1 e 1 permite a utilização de funções de ativação e algoritmos de otimização que se adequam melhor ao problema de classificação. Além disso, essa normalização ajuda a evitar problemas de saturação das funções de ativação, especialmente em casos em que são utilizadas funções como a tangente hiperbólica (*tansig*), como foi usado nesse trabalho.

Ao terminar a normalização para a rede neural de classificação, é necessário realizar a normalização para a rede de regressão. Para essa rede neural, a normalização é feita pelo método *Z-score*, como mostrado na equação 2.13, ou seja, através da média e desvio padrão do conjunto de treinamento.

Por fim, o escalonador *Min-Max* define os limites mínimos e máximos do conjunto de dados de treinamento, como mostrado na equação 2.14. Dessa forma, após a normalização dos conjuntos de treinamento, validação e teste, é possível seguir para a construção e treinamento das redes neurais, propriamente dito.

Tabela 4.2. Organização dos dados de entrada e saída e rotulação das falhas

Entrada da rede neural									Saída da rede neural						Falhas Rotuladas						
T_amb	T_2	T_4	T_9	LPC_PR	PR_total	m fuel	m exhaust	Wout	$\eta$ LPC	$\eta$ HPC	$\eta$ CC	$\eta$ HPT	$\eta$ LPT	$\eta$ PT	HR	Nominal	Falha na CC	Fouling LPC_1	Fouling LPC_2	Fouling HPC_1	Fouling HPC_2
25	193.41	573.04	798.99	3.36	19.04	1.586	91.17	28554.11	0.86	0.85	0.98	0.93	0.95	0.92	9820.30	1	0	0	0	0	0
25	192.80	571.16	796.23	3.34	18.90	1.67	91.25	28501.66	0.86	0.85	0.93	0.93	0.95	0.92	10356.10	0	1	0	0	0	0
25	193.19	572.63	798.81	3.15	17.86	1.586	91.17	28548.79	0.80	0.85	0.98	0.93	0.95	0.92	9821.39	0	0	1	0	0	0
25	192.96	572.27	798.72	3.01	17.06	1.59	91.17	28546.13	0.77	0.85	0.98	0.93	0.94	0.92	9821.92	0	0	0	1	0	0
25	193.40	572.95	798.98	3.36	17.82	1.59	91.17	28554.64	0.86	0.81	0.98	0.93	0.95	0.92	9820.32	0	0	0	0	1	0
25	193.47	573.90	799.08	3.36	16.71	1.58	91.17	28557.58	0.86	0.77	0.98	0.93	0.95	0.92	9804.73	0	0	0	0	0	1

#### 4.4 Construção do modelo e treinamento

A construção do modelo consiste em duas redes neurais, sendo uma para regressão e outra para classificação. Ambas as redes possuem a arquitetura de propagação direta (FNN), como mostra a Figura 4.8. Em detalhes, ambas as redes neurais possuem as mesmas nove (9) entradas, ambas possuem dez (10) neurônios na camada oculta e, para a rede neural de regressão, sete (7) saídas numéricas e, para a rede neural de classificação, as saídas são as falhas rotuladas, de forma que a resposta para o problema como um todo seja uma tabela contendo os valores das saídas da rede de regressão e os rótulos, entre -1 e 1, das falhas, onde 1 significa que determinada condição ocorreu e -1 significa que a condição não ocorreu, de forma análoga e respeitando a mesma ordem das falhas da tabela 4.2.

Para treinar as redes, é necessário definir as funções de ativação para as camadas ocultas e de saída de cada rede. Para a rede de regressão, as funções de ativação usadas para a camada oculta e para a camada de saída são a *tansig* e a *purelin*, respectivamente. A função *tansig* foi escolhida para a camada oculta da rede de regressão uma vez que é uma função não-linear que permite que a rede neural aprenda relações complexas nos dados. Isso é crucial para capturar padrões não lineares em problemas de regressão, onde as relações entre as variáveis de entrada e a variável de saída podem ser altamente não lineares. Por sua vez, a função *purelin* foi escolhida para a camada de saída uma vez que o problema requer saídas lineares, ou seja, o objetivo é prever um valor contínuo e a saída desejada não precisa ser limitada ou restringida a nenhum intervalo específico.

Para a rede neural de classificação, as funções de ativação usadas para as camadas ocultas e de saída foram ambas *tansig*. Para a camada oculta, o motivo da escolha é o mesmo para a rede de regressão. Já para a camada de saída é desejável realizar a classificação das falhas em uma rotulação nos valores entre -1 e 1 e, como mostra a Figura 2.21, a função *tansig* atua nesse intervalo.

Por fim, antes de realizar o treinamento do modelo, é preciso especificar os hiper parâmetros das redes. Em *Machine Learning*, os hiper parâmetros se referem a parâmetros pré-definidos que não são otimizados durante o treinamento [CHRISTOFIDES et al., 2022]. São diversos os hiper parâmetros que impactam o desempenho do modelo e, para o modelo proposto, os que apresentaram necessidade de alteração, através de tentativa e erro, foram o número de épocas (epochs), a taxa de aprendizado, critério de mínimo erro de treinamento, critério de quantidade máxima de falhas na validação e o tempo máximo para o treinamento.

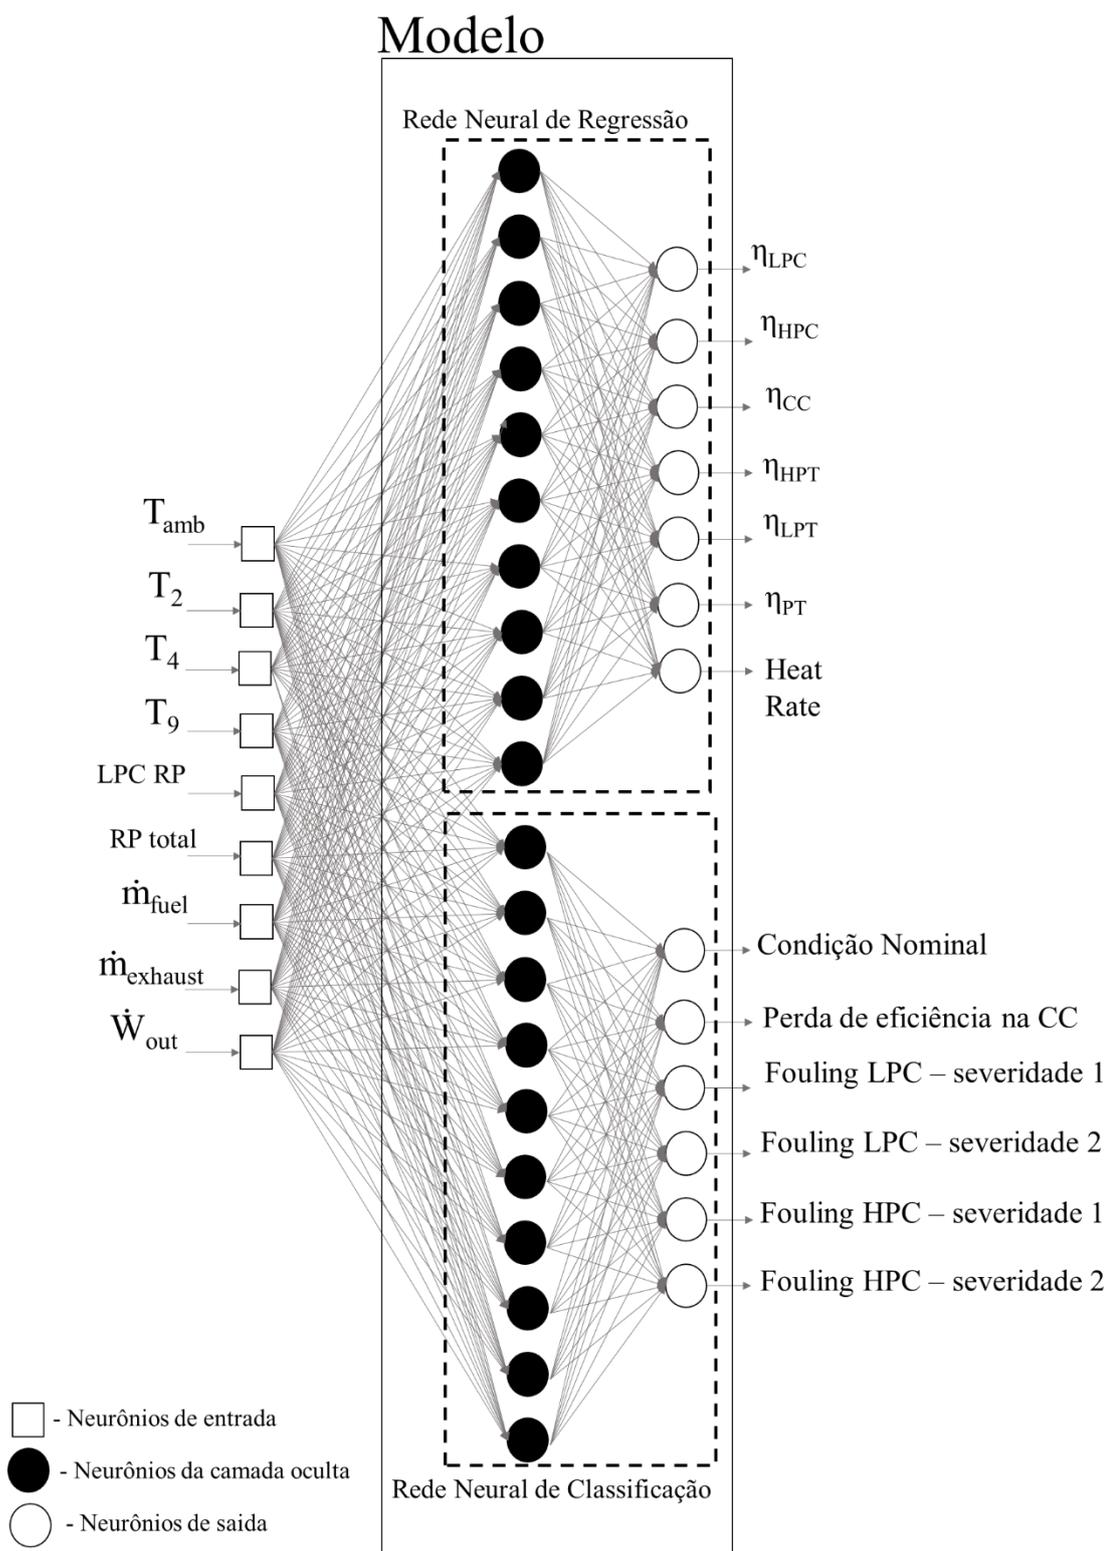


Figura 4.8. Modelo proposto da rede neural para diagnostico (Fonte: Autor)

Outro hiper parâmetro importante definido para o treinamento foi o algoritmo de otimização escolhido. Para ambas as redes, o algoritmo escolhido foi o de *Levenberg-Marquardt* de retropropagação (backpropagation), pois esse algoritmo tem a capacidade de convergir problemas de otimização com alto nível de complexidade, como é o caso do problema em estudo [LIU, 2019].

Após todo o pré-processamento dos dados e construção do modelo, as redes neurais estão prontas para serem treinadas, validadas e testadas. O resultado esperado é que a rede seja capaz de reproduzir o comportamento da turbina a gás em condição nominal (sem falhas) e que seja capaz de reconhecer os valores dos parâmetros de entrada e associar a falha que causa o efeito para que esses parâmetros de entrada tenham esses valores.

#### **4.5 Resultados e Avaliação do modelo de falhas isoladas**

A avaliação do modelo é feita através do conjunto de teste, o qual representa um conjunto de dados ainda não visto pela rede, que após o treinamento e validação, é utilizado para avaliação da rede. Dessa forma, é possível avaliar se a rede aprendeu corretamente com os conjuntos de treinamento e validação. Uma das formas de avaliar a rede é através do cálculo do erro percentual, que consiste no cálculo dos desvios relativos entre os dados gerados pela rede e os dados obtidos através do modelo computacional desenvolvido em MATLAB/Simulink/T-MATS, como mostrado na Equação 4.4.

$$Erro = \frac{Saida\ da\ rede - dados\ simulados}{dados\ simulados} * 100 \quad (4.4)$$

A rede neural de regressão apresentou um erro percentual muito baixo, como é possível ver na Figura 4.9, o que mostra um bom desempenho da rede. O maior erro foi de 0,005% para a eficiência do HPC, seguido de 0,0034% para a eficiência da câmara de combustão e 0,0024% para a eficiência do LPC, mostrando o bom desempenho da rede neural de regressão.

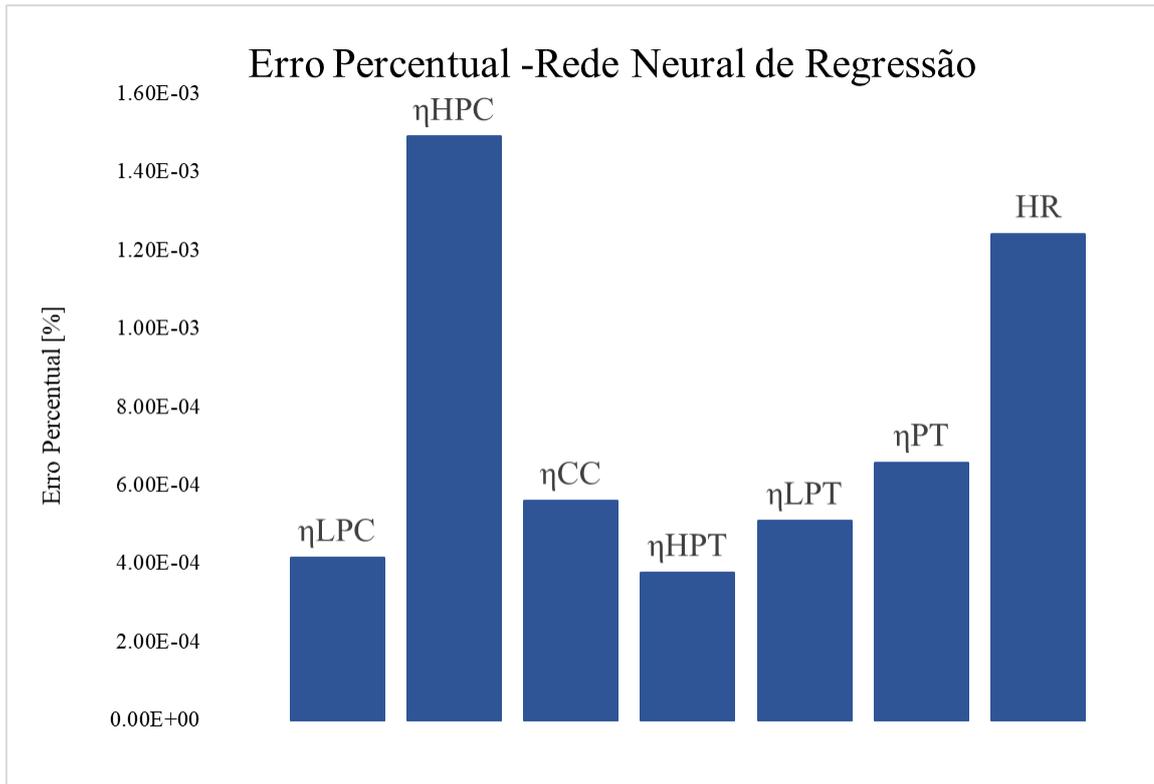


Figura 4.9. Erro Percentual para a rede neural de regressão

Outra forma de avaliar a rede neural é através do cálculo do erro quadrático médio (MSE), já que o problema é uma rede de regressão, como mostra a Equação 4.5 [PASSOS, MISHRA, 2022],

$$MSE = \frac{1}{\text{Numero de dados}} \sum \left( \frac{\text{Saida da rede} - \text{dados simulados}}{\text{dados simulados}} \right)^2 \quad (4.5)$$

Os resultados do cálculo do MSE para a rede neural de regressão são mostrados na Figura 4.10. Os maiores valores do MSE foram para a eficiência do HPC e eficiência do LPC, os quais foram de  $5,39 \cdot 10^{-6}$  e  $2,83 \cdot 10^{-6}$ , respectivamente. O resultado do MSE confirma a avaliação da rede e mostra que a rede é confiável ao operar com um conjunto de dados não vistos anteriormente pela mesma.

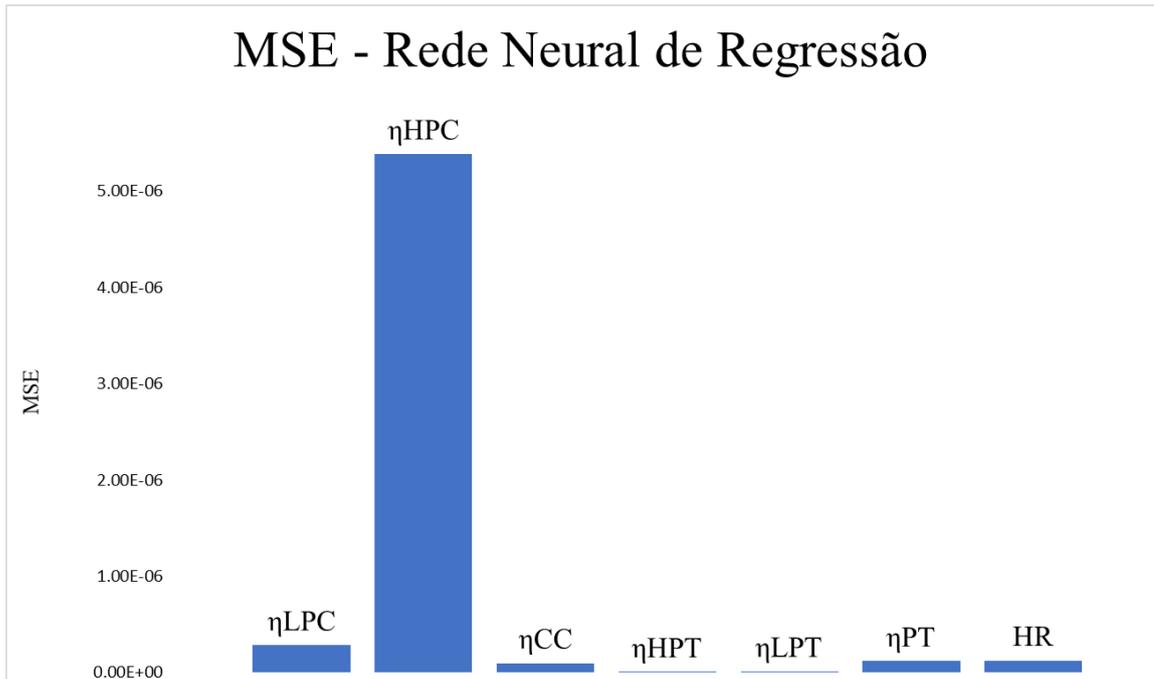


Figura 4.10. MSE para a rede neural de regressão

Para a rede de classificação, os mesmos métodos de avaliação foram utilizados. A rede atingiu 100% de precisão ao classificar as falhas simuladas, resultando em um erro percentual nulo, como mostra a Figura 4.11. Isso mostra como o modelo é capaz de realizar o diagnóstico rápido e eficiente dos diferentes estados da condição da turbina a gás, possibilitando uma atuação mais rápida nas falhas, de forma a manter a turbina a gás sempre operando o mais próximo do ponto de projeto, reduzindo um consumo excessivo de combustível, assim como as emissões de poluentes no meio ambiente.

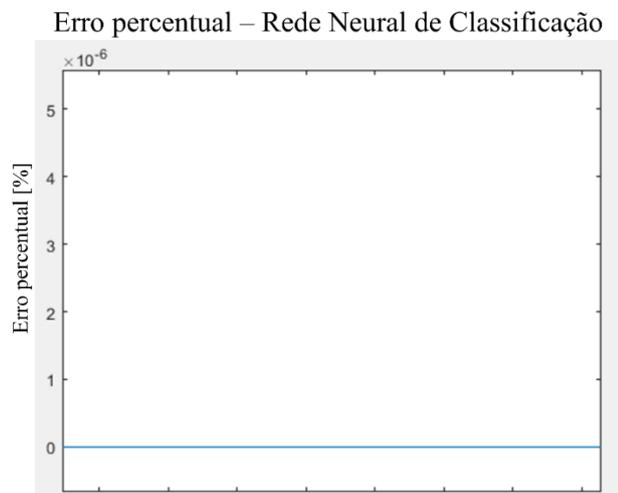


Figura 4.11. Erro percentual nulo para a rede neural de classificação

#### 4.6 Aplicação do modelo para análise de falhas combinadas

O modelo de inteligência computacional também foi avaliado em situações em que a turbina a gás apresenta falhas em dois componentes diferentes de forma simultânea, sendo a metodologia de análise semelhante à apresentada. Foram três situações de falhas simuladas, sendo elas o fouling do LPC ocorrendo junto a uma erosão da PT, perda de eficiência da câmara de combustão ocorrendo junto a uma erosão da LPT e, por fim, *fouling* do HPC com erosão da HPT. Essas situações são resumidas na Tabela 4.3.

Tabela 4.3. Falhas Combinadas simuladas

<i>Falha</i>	<i>Consequência</i>
<i>Fouling LPC + Erosão PT</i>	Perda de 5% da vazão no LPC e na PT
<i>Perda de eficiência da CC + Erosão LPT</i>	Perda de 5% de eficiência da CC e perda de 5% da vazão da LPT
<i>Fouling HPC + Erosão HPT</i>	Perda de 5% da vazão do HPC e da HPT

A construção do modelo para a rede neural de regressão permanece igual, uma vez que as entradas e saídas são as mesmas. Para a rede de classificação, o que irá mudar é o número de saídas da rede, ou seja, a rotulação das falhas, uma vez que o objetivo é que a rede neural seja capaz de identificar os dois problemas que estão ocorrendo ao mesmo tempo. Para facilitar a visualização, a rotulação dos dados é mostrada na Tabela 4.4. De forma similar à Tabela 4.2, a Tabela 4.4 mostra apenas a rotulação das falhas.

Tabela 4.4. Rotulação das falhas combinadas simuladas

<b>Falhas Rotuladas</b>						
<b>Nominal</b>	<b>Falha LPC</b>	<b>Falha HPC</b>	<b>Falha CC</b>	<b>Falha HPT</b>	<b>Falha LPT</b>	<b>Falha PT</b>
1	0	0	0	0	0	0
0	1	0	0	0	0	1
0	0	0	1	0	1	0
0	0	1	0	1	0	0

Dessa forma, a rede neural de classificação apresenta sete saídas combinadas duas a duas, de forma que quando a saída for a falha no LPC simultaneamente com o a falha na PT, tem-se uma saída real. A demonstração da rede utilizada é ilustrada na Figura 4.13.

# Modelo

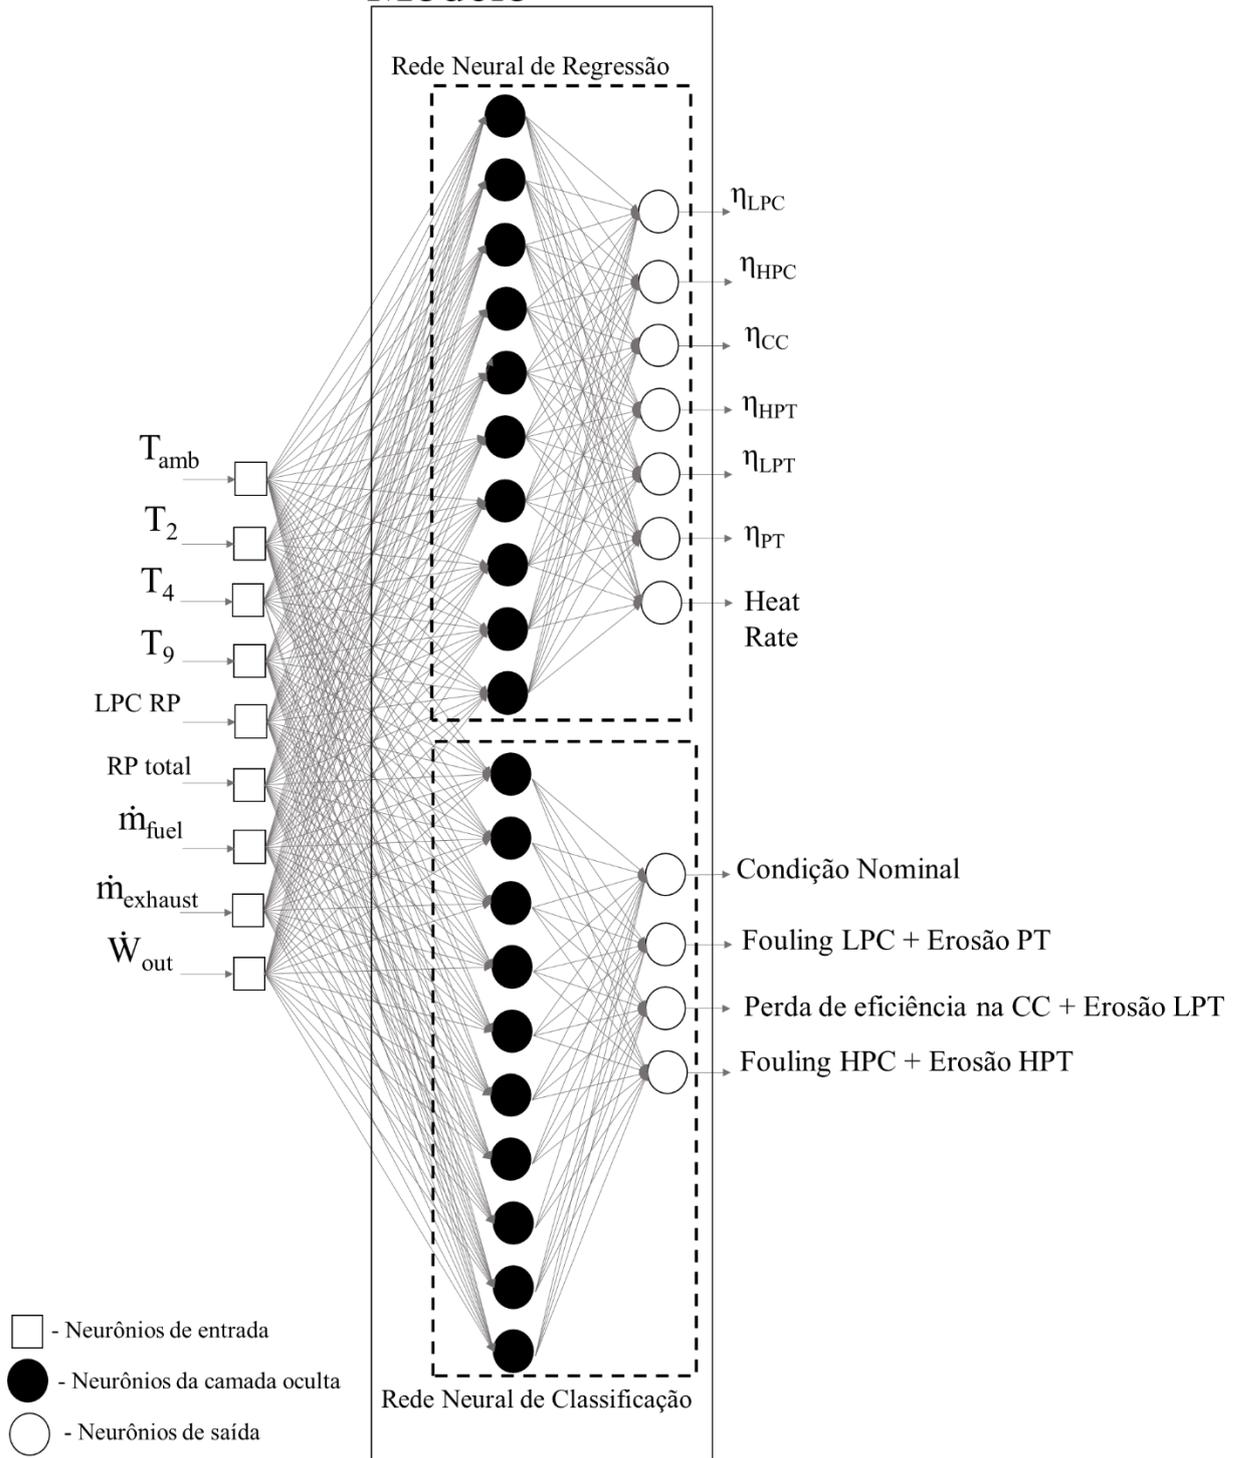


Figura 4.13. Modelo proposto da rede neural para diagnostico de falhas combinadas (Fonte: Autor)

Os hiper parâmetros usados foram os mesmos utilizados para o problema anterior e a rede apresentou bons resultados para o problema em estudo. A avaliação da rede para esse caso também foi efetuada através do cálculo dos erros, os quais estão apresentados nas Figuras 4.14 e 4.15. Analisando o erro percentual e MSE para a rede neural de regressão, é possível perceber que o maior erro ocorre no HPC com MSE de  $5.03 \cdot 10^{-8}$ , o que representa um valor bastante baixo, assim como ocorreu para o caso de falhas isoladas. Em geral, a rede de regressão apresentou erros menores para a situação de falhas combinadas.

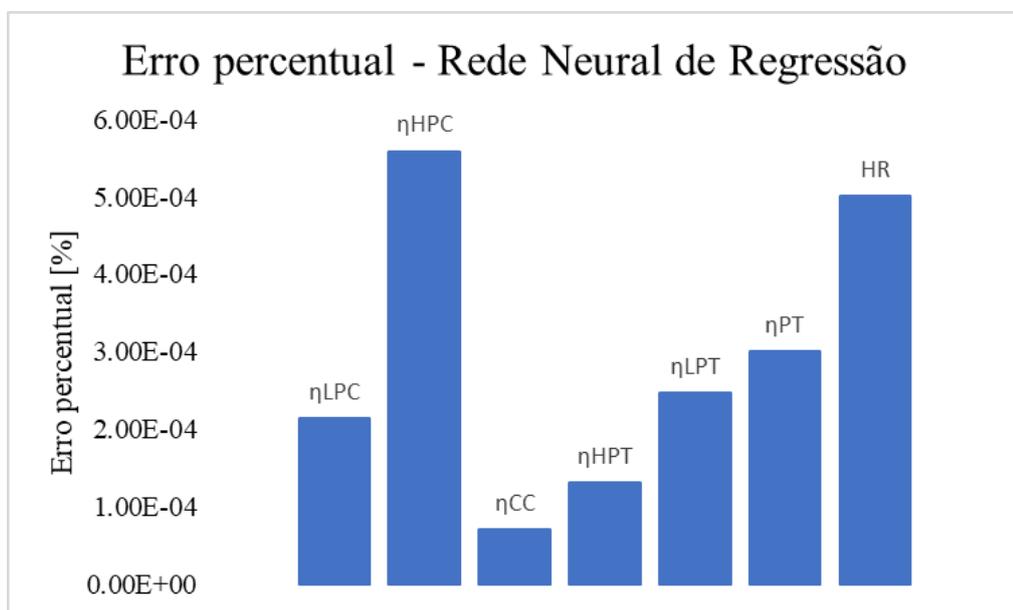


Figura 4.14. Erro percentual para a rede de regressão – Falhas Combinadas

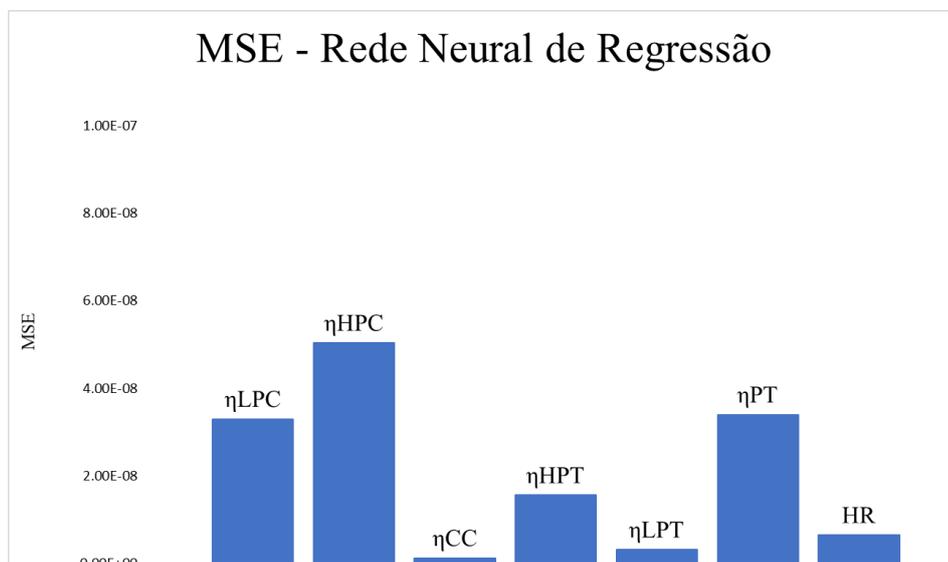


Figura 4.15. MSE rede neural de regressão – Falhas Combinadas

A rede neural de classificação, no entanto, para análise de falhas combinadas apresentou três inconsistências. Em apenas três situações a rede não foi capaz de identificar a condição de falha desejada, resultando em uma resposta inconclusiva. Ao invés de apresentar o resultado entre -1 e 1, nesses três casos a rede apresentou o valor 0, de forma que a identificação da falha nesse caso não foi possível. Esse resultado ocorreu em apenas 3 estados da condição simuladas de um total de 1070 condições, o que mostra um erro de 0.28%, mantendo bom desempenho da rede para a identificação das falhas combinadas.

#### 4.7 Aplicação do diagnóstico termodinâmico

Os custos operacionais para manter uma turbina a gás como a SGT-A35(GT62) é alto e um diagnóstico realizado de forma rápida pode evitar o excessivo consumo energético e as emissões de poluentes ao manter a turbina a gás operando o mais próximo do ponto de projeto.

A Tabela 4.5 mostra o resultado da simulação termodinâmica para a condição ISO e para a condição de falha na câmara de combustão. Tomando como base a condição ISO, a vazão mássica de exaustão da turbina é de 96,8[kg/s], e considerando que a máquina opera 24h por dia, o montante de gases de efeito estufa (*GHG*) liberados em um dia é 8.363,5 toneladas. Considerando o mesmo cenário para a máquina operando um dia completo com uma falha na câmara de combustão, o montante de gases liberados na atmosfera é de 8.410,5 toneladas, uma diferença de 47 toneladas em apenas um dia.

Tabela 4.5. Comparação dos resultados

	ISO	Falha na CC
Tamb [°C]	15	15
Vazão de comb. [kg/s]	1.68	1.73
Exaustão [kg/s]	96.80	97.34
Potência elétrica [kW]	30495.59	29997.94
HR [kJ/kWh]	9746.57	10177.58

O mesmo ocorre para o consumo de combustível. A máquina operando nessa condição de falha pode elevar o consumo de combustível em 4 ton/dia e, ainda, a potência produzida pela turbina a gás é inferior, podendo causar instabilidades na rede.

O custo operacional para manter a turbina a gás operando nessas condições pode ficar muito elevado e, por isso, é importante a realização de um diagnóstico termodinâmico rápido e eficaz, em que se identifique o problema precisamente, para que a atuação seja rápida e evite emissões e consumos excessivos.

# CAPÍTULO 5

## CONCLUSÕES

O presente trabalho pode ser dividido em duas partes principais. A primeira foi a modelagem de uma turbina a gás, com o objetivo de gerar dados para a realização do diagnóstico termodinâmico da turbina. Este diagnóstico é a segunda etapa e principal objetivo deste trabalho.

Na primeira etapa, com auxílio da revisão bibliográfica para turbinas a gás, foi realizado a construção do modelo de uma turbina a gás aeroderivativa, tipo de turbina utilizada para as operações de plataformas de produção do óleo e gás, para a geração de energia elétrica, ou seja, com acoplamento junto ao gerador elétrico. O modelo construído teve base na turbina da Siemens RB211-GT62, turbina a qual possui dois *spools*, sendo um de alta pressão e um de baixa e configuração com turbina de potência.

Com a configuração definida e o modelo construído, o escalonamento dos mapas dos compressores e turbinas puderam ser realizados para atender os parâmetros de operação da turbina RB211-GT62. Com isso, a validação do modelo foi feita e mostrou-se satisfatória. Os erros entre os dados de referência da turbina RB211-GT62 e os dados do modelo não ultrapassaram 1%.

O comportamento da turbina também foi avaliado através do aumento da temperatura ambiente e variação de carga operacional. Com o aumento da temperatura ambiente é observado a diminuição da potência produzida, e uma queda no rendimento térmico, o que é uma condição esperada, uma vez que a massa específica do ar diminui, reduzindo a vazão de ar na entrada do compressor de baixa pressão, conseqüentemente alterando a vazão de ar da máquina como um todo.

A operação da turbina em carga parcial também afeta o rendimento da mesma e é observado que ao operar com cargas mais baixas, como foi simulado, o *heat rate* aumenta. Resultado esperado, uma vez que a turbina operando fora das condições de projeto perde rendimento térmico e o consumo de energia para produzir potência aumenta.

Dessa forma, o modelo pode ser utilizado para representar adequadamente o comportamento da turbina a gás RB211-GT62 para geração de eletricidade, operando em condições de carga nominal e de carga parcial.

Após a modelagem da turbina a gás, um modelo de *machine learning* foi desenvolvido para o diagnóstico termodinâmico do turbogerador. O diagnóstico termodinâmico consiste em detectar falhas que afetam o desempenho da turbina a gás, tais como *fouling*, corrosão e erosão. Para isso, *fouling* nos compressores, perda de eficiência na câmara de combustão e erosão nas turbinas foram simulados e, junto às simulações de comportamento da máquina, ou seja, as simulações em cargas nominal e parcial com a variação da temperatura ambiente, um conjunto de dados significativo pode ser gerado.

O conjunto de dados obtido foi utilizado para alimentar um modelo de *machine learning* para associação e reconhecimento das falhas simuladas. Para isso, duas redes neurais foram elaboradas, uma de regressão e outra de classificação. A rede neural de regressão usada para o problema numérico e a rede neural de classificação para associação das falhas.

Para adequado uso do modelo de inteligência computacional, o pré-processamento do conjunto de dados foi realizado, separando o conjunto de dados em conjuntos de treinamento, validação e teste pelo método da divisão fixa em uma proporção de 70/15/15. A normalização dos dados também foi realizada para que todas as variáveis de entrada estivessem na mesma escala.

Os modelos escolhidos possuem arquitetura de propagação direta e os hiper parâmetros foram escolhidos através de tentativa e erro, a fim de se obter o melhor desempenho da rede. Após treinamento, o modelo foi testado com dados não conhecidos pelas redes. O resultado foi satisfatório e ambos os modelos apresentaram os erros MSE de, no máximo,  $5.5 \cdot 10^{-6}$ , para a rede de regressão. A rede de classificação conseguiu associar e reconhecer todas as falhas simuladas para o problema de falhas isoladas, conforme esperado. Para o problema de falhas combinadas, a rede neural de classificação apresentou três inconsistências, porém que não afetou o desempenho da rede de forma geral, sendo capaz de associar e reconhecer as falhas ocorrendo de forma simultânea, também conforme o esperado.

O trabalho apresentou de forma inovadora um método de diagnóstico termodinâmico em turbinas a gás, que conseguiu, ao mesmo tempo, reproduzir o comportamento de um turbogerador e identificar anomalias em seus componentes principais.

O modelo proposto desempenha de forma rápida e eficiente o diagnóstico de uma turbina a gás, e que, se colocado em prática, é possível reduzir as emissões de gases GHG em até 47ton/dias e evitar um consumo de combustível de até 4ton/dia.

### **5.1 Trabalhos futuros**

O modelo proposto demonstrou bons resultados na identificação e classificação das falhas simuladas e pode ser aprimorado para uma rede neural que atua na previsão das falhas que podem estar prestes a acontecer na turbina a gás.

A rede neural recorrente LSTM pode ser promissora na previsão de falhas em turbinas a gás, uma vez que esse tipo de rede trabalha muito bem com dados temporais e dados sequenciais de processos [LU *et al.*, 2023]. O recurso especial da rede LSTM consiste em que os neurônios das camadas ocultas são manipulados para permitir o processamento de uma sequência temporal mais longa do que redes recorrentes convencionais. Como visto no capítulo 2 deste trabalho, a rede LSTM é caracterizada por três tipos de portas (porta de esquecimento, porta de entrada e camadas de porta de saída) para controlar o estado da célula. Em vez de usar apenas um estado oculto  $ht$  para transmissão, como em uma RNN, o LSTM possui dois estados ocultos,  $ht$  e  $ct$  (geralmente chamados de estado da célula), para transmissão. O modelo de rede neural LSTM aborda significativamente os problemas de desaparecimento e explosão de gradientes que ocorrem no modelo RNN durante o processo de treinamento por meio de unidades de portas [LU *et al.*, 2023].

Através do processamento de dados, um modelo baseado em uma rede neural LSTM pode ser estabelecido para previsão de sequencias temporais de uma turbina a gás. O processo global de modelagem da rede LSTM pode ser dividido em quatro passos, como mostra a Figura 5.1 [LU *et al.*, 2023]:

1. Um modelo é desenvolvido e simulado baseado na operação do sistema.
2. Falhas que ocorrem na turbina são simuladas e os dados armazenados para histórico do comportamento da turbina ao operar com falhas. Os dados simulados são normalizados e separados em conjuntos de treinamento e teste.
3. O modelo de rede neural LSTM é ajustado para minimizar os erros dos conjuntos de treinamento, e o próximo comportamento imediato da turbina a gás é previsto pelo modelo treinado. Se o erro no conjunto de teste é muito grande, é necessário alterar a composição dos pontos de amostra e os parâmetros do modelo antes de treinar o modelo novamente.

4. O modelo de rede neural LSTM, verificado pelo conjunto de teste, é utilizado no teste de previsão. Se o modelo não conseguir prever com precisão o comportamento da turbina a gás, parâmetros são ajustados e o passo 3 é repetido. Por fim, um modelo de previsão de serie temporal de alta qualidade é obtido por meio desse processo.

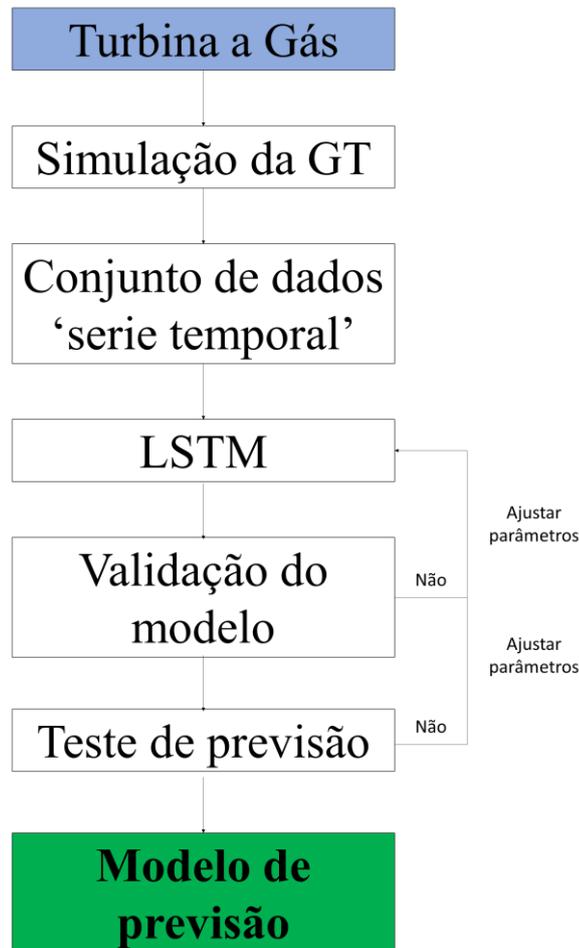


Figura 5.1. Fluxograma para um modelo de previsão de falhas (Fonte: Autor)

## REFERÊNCIAS BIBLIOGRÁFICAS

Carvalho, T. P.; Soares F. A. A. M. N.; Vita, R.; Francisco, R. da P.; Basto, J. P.; Alcalá, S. G. S., “**A systematic literature review of machine learning methods applied to predictive maintenance**”, *Computers & Industrial Engineering*, vol 137, 2019.

Qiu, J.; Wu, Q.; Ding, G.; Xu, Y.; Feng, S., “**A survey of machine learning for big data processing**”, *EURASIP Journal on Advances in Signal Processing*, 67, 2016.

Talaat, M., Gobran, M.H., Wasfi, M., “**A hybrid model of an artificial neural network with thermodynamic model for system diagnosis of electrical power plant gas turbine**”. *Eng. Appl. Artif. Intell.* 68, 222–235, 2018.

Ying, Y.; Li, J., “**An improved performance diagnostic method for industrial gas turbines with consideration of intake and exhaust system**”, *Applied Thermal Engineering*, vol 222, 2022

Bhangu, N. S.; Singh, R.; Pahuja, G. L., “**Availability Performance Analysis of Thermal Power Plants**”, *Journal of The Institution of Engineers (India)*, vol. 100, 2018.

Jagtap, H. P.; Bewoor, A. K.; Kumar, R.; Ahmadi, M. H.; Chen, L., “**Performance analysis and availability optimization to improve maintenance schedule for the turbo-generator subsystem of a thermal power plant using particle swarm optimization**”, *Reliability Engineering and System Safety*, vol. 204, 2020

Shanmugam. K. R.; Kulshreshtha, P., “**Efficiency analysis of coal-based thermal power generation in India during post-reform era**”, *Journal Global Energy Issues*, vol. 23, 2005.

Mathews I.; Mathews E. H.; Van Laar J. H.; Hamer W.; Kleingeld M., “**A simulation-based prediction model for coal-fired power plant condenser maintenance**”, *Applied Thermal Engineering*, vol. 174, 2020

A. M. Y. Rasak, “**Industrial Gas Turbines – Performance and Operability**”, CRC, 2007

Asgari H., “**Modeling, Simulation and Control of Gas Turbines Using Artificial Neural Networks**”, University of Canterbury, 2014

Ghojel J., “**Design-point calculations of industrial gas turbines**”, *Fundamentals of heat engines*, chapter 13, 2020

Brooks F. J., “**GE Gas Turbine Performance Characteristics**”, GE Power Systems, GER3567H, 2015

Chapman J. W., “**Practical Techniques for Modeling Gas Turbine Engine Performance**”, NASA-TM, 2020

Bai M., Liu J., Chai J., Zhao X., Yu D., “**Anomaly Detection of gas turbines based on normal pattern extraction**”, *Applied Thermal Engineering*, vol. 166, 2019

Sallilew W. M., Karim Z. A. A., Baheta A. T., “**Review on gas turbine condition-based diagnosis method**”, *Materials Today: Proceedings*, 2021

Siegelmann H. T., Horne B. G., Giles C. L., “**Computational capabilities of recurrent NARX neural networks**”, *IEEE Trans. Syst. Man Cybernet. Part B (Cybernet.)* 27 (2) (1997) 208–215.

Ibrahim T. K., Rahman M. M., Abdalla A. N., “**Optimum gas turbine configuration for improving the performance of combined cycle power plant**”, *Procedia Engineering*, vol. 15, 2011

Kim, J.H., Song, T.W., Kim, T.S., Ro, S.T., “**Model Development and Simulation of Transient Behavior of Heavy Duty Gas Turbines**”. ASME. *Turbo Expo: Power for Land, Sea, and Air*, vol. 2000

Wilson, D.G., Korakianitis, T., “**The Design of High-Efficiency Turbomachinery Gas Turbines**”, 2nd.ed, MIT Press, 2014

Andrade, A. L. S., “**Análise do comportamento dinâmico de Turbogeneradores a Gás Operando em Sistema Isolado**”, Dissertação de Mestrado, Universidade Federal de Itajubá – UNIFEI, Itajubá/MG, 2021

Saravanamuttoo H. I. H., Rogers G. F. C., Cohen H., *Gas Turbine Theory*, 5<sup>th</sup> edition, Pearson, 2013

Soares, C., *Gas Turbines: A handbook of air, land and sea applications*, Second edition, Elsevier, 2014

Monteiro, U., A., B., V., *Simulação Termodinâmica de Turbinas a Gás para Diagnóstico de Falhas*, Tese de Doutorado, Universidade Federal do Rio de Janeiro – UFRJ, Rio de Janeiro, 2010

OGAJI, S.O.T., SINGH, R., PROBERT, S. D., 2002a, “Multiple-Sensor Fault- Diagnoses for a 2-Shaft Stationary Gas Turbine”, *Applied Energy*, v.71, pp. 321-339.

OGAJI, S.O.T., *et al.*, 2002b, “Parameter Selection for Diagnosing GT Performance Deterioration”, *Applied Energy*, v.73, pp. 25-46.

EFSTRATIOU N., 2008, *Capability Expansion of Non-Linear Gas Path Analysis*. Ph.D. Dissertation, School of Mechanical Engineering, Cranfield University, United Kingdom.

OGAJI, S.O.T., SINGH, R., 2003d, “Advanced Engine Diagnostics Using Neural Networks”, *Applied Soft Computing*, v.3, pp. 259-271.

RESENDE, J.C.F., 1991, *Manutenção Preditiva em Turbomáquinas Utilizando Sistema Especialista na Análise de Vibração*. Tese de M.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.

Kurz,R., *Gas Turbine Performance*, Turbosymposium, 2005

Volponi, A.J. Gas turbine engine health management: Past, present, and future trends. *J. Eng. Gas Turbines Power* 2014, 136, 051201.

Daily, J.; Peterson, J. Predictive maintenance: How big data analysis can improve maintenance. In *Supply Chain Integration Challenges in Commercial Aerospace*; Springer: Berlin/Heidelberg, Germany, 2017; pp. 267–278.

Qiu, J.; Wu, Q.; Ding, G.; Xu, Y.; Feng, S. A survey of machine learning for big data processing. *Eurasip J. Adv. Signal Process.* 2016, 2016, 67.

de Castro-Cros, M.; Velasco, M.; Angulo, C., Machine-Learning-Based Condition Assessment of Gas Turbines – A review, *Energies* 2021, 14, 8468

Kim, P., *MATLAB Deep Learning: With Machine Learning, Neural Networks and Artificial Intelligence*, Apress 2017, 2017944429

Beale, M. H.; Hagan, M. T.; Demuth, H. B., *Neural Network Toolbox™ Getting Started Guide*, MathWorks 2016

Ren Y. M., Alhajeri M. S., Luo J., Chen S., Abdullah F., Wu Z., Christofides P. D., A tutorial review of neural network modelling approaches for model predictive control, *Computers and Chemical Engineering*, vol. 165, 2022

Apaydin H., Feizi H., Sattari M. T., Colak M. S., Shamshirband S., and Chau K.-W., "Comparative analysis of recurrent neural network architectures for reservoir inflow forecasting," *Water*, vol. 12, no. 5, p. 1500, 2020

Shiri F. M., Perumal T., Mustapha N., Mohamed R., A Comprehensive Overview and Comparative Analysis on Deep Learning Models: CNN, RNN, LSTM, GRU, Arxiv, Cornell University, 2023

Minaee S., Azimi E., Abdolrashidi A., "Deep-sentiment: Sentiment analysis using ensemble of cnn and bi-lstm models," arXiv preprint arXiv:1904.04206, 2019

Fang W., Chen Y., Xue Q., "Survey on research of RNNbased spatio-temporal sequence prediction algorithms," *Journal on Big Data*, vol. 3, no. 3, p. 97, 2021.

Prakash, G.; Yuan, X.X.; Hazra, B.; Mizutani, D. Toward a big data-based approach: A review on degradation models for prognosis of critical infrastructure. *J. Nondestruct. Eval. Diagn. Progn. Eng. Syst.* 2021, 4, 021005.

Kurz R, Brun K, Wollie M. Degradation effects on industrial gas turbines. *J Eng Gas Turb Power* 2009;131.

Salman A. D., Fiyadh S. S., Alardhi S. M., Al Omar M., Aljumaily M. M., Al Saadi M. A., Fayaed S. S., Ahmed S. N., Abdalsalm A. H., Jabbar N. M., El-Shafi A., "A comprehensive review on modelling the adsorption process for heavy metal removal from waste water using artificial neural network technique", *Heliyon*, vol. 9, 2023, e15455

M. Khayet, C. Cojocaru, "Artificial neural network model for desalination by sweeping gas membrane distillation", *Desalination* 308 (2013) 102–110.

O.A. Montesinos L´opez, A. Montesinos L´opez, J. Crossa, Fundamentals of artificial neural networks and deep learning, in: O.A. Montesinos L´opez, A. Montesinos L´opez, J. Crossa (Eds.), *Multivariate Statistical Machine Learning Methods for Genomic Prediction*, Springer International Publishing, Cham, 2022, pp. 379–425.

A. Dobay, et al., Potential use of deep learning techniques for postmortem imaging, *Forensic Sci. Med. Pathol.* 16 (4) (2020) 671–679.

Liu Y., “Novel volatility forecasting using deep learning–long short term memory recurrent neural networks”. *Expert Syst, Appl*, 2019;132:99–109.

Passos D, Mishra P., “A tutorial on automatic hyperparameter tuning of deep spectral modelling for regression and classification tasks”, *Chemometrics and Intelligent Laboratory Systems*, 223 (2022), 104520

Kurz R, Brun K, Wollie M. Degradation effects on industrial gas turbines. *J Eng Gas Turb Power* 2009;131.

Kurz R, Brun K. Degradation of gas turbine performance in natural gas service. *J Nat Gas Sci Eng* 2009; 1:95–102.

Kurz R, Simmons HR. Aerodynamic instability and life-limiting effects of inlet and interstage water injection into gas turbines. *J Eng Gas Turb Power* 2006; 128:617.

Liu Z., Karini I. A., Gas Turbine performance prediction via machine learning, *Energy* 192, 2020

Horta G. E., *Aplicação de Máquina de Aprendizado extremo ao Problema de Aprendizado Ativo*, tese de doutorado, UFMG, 2015

Alblawi A., “Fault diagnosis of industrial gas turbine based on thermodynamic model coupled with a multi feedforward artificial neural networks, *Energy Reports*, vol 6, 2020

Tsoutsanis E., Qureshi I., Hesham M., “Performance diagnostics of gas turbines operating under transient conditions based on dynamic engine model and artificial neural networks”, *Engineering Applications of Artificial Intelligence*, 126, 2023

Gülen S. C., “Gas Turbines for Electric Power Generation”, First edition, Cambridge University Press, TJ International Ltd. Padstow Cornwall, 2019

F. Kratzert, D. Klotz, C. Brenner, K. Schulz, and M. Herrnegger, "Rainfall–runoff modelling using Long Short-Term Memory (LSTM) networks," *Hydrology and Earth System Sciences*, vol. 22, no. 11, pp. 6005-6022, 2018.

## APENDICE A. DADOS SIMULADOS

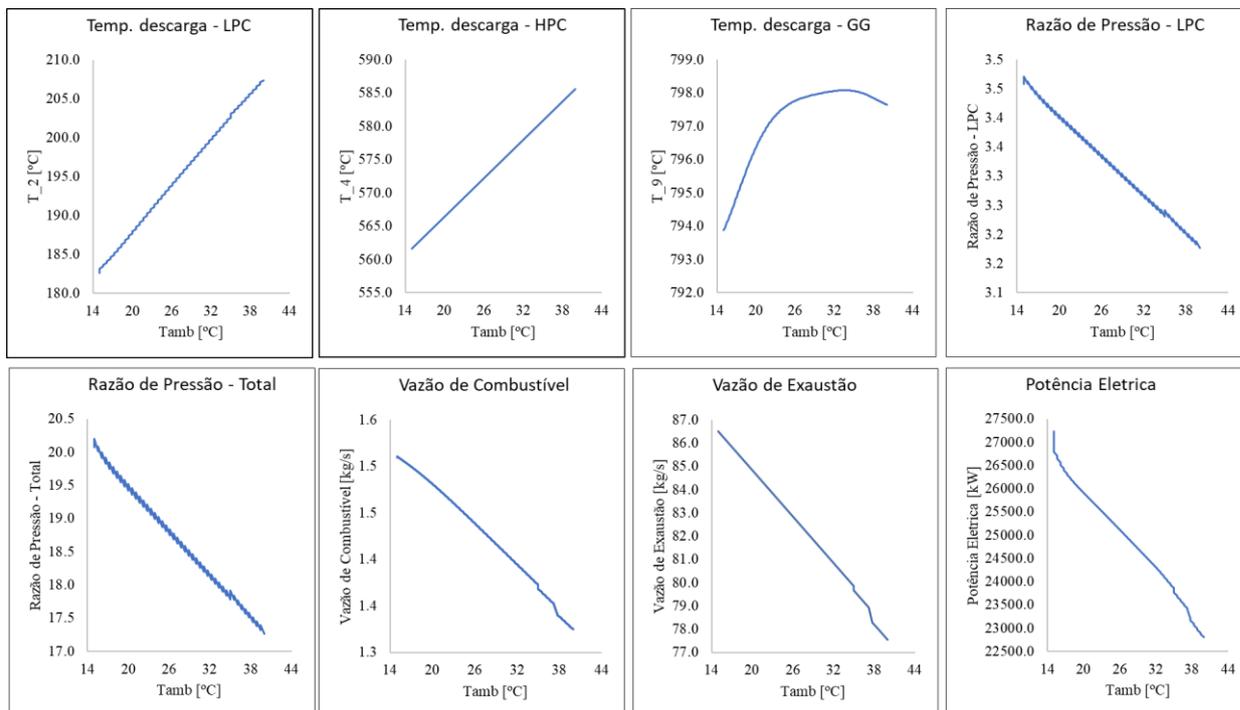


Figura A.1. Parâmetros de entrada da rede neural para a condição nominal e 75% de carga

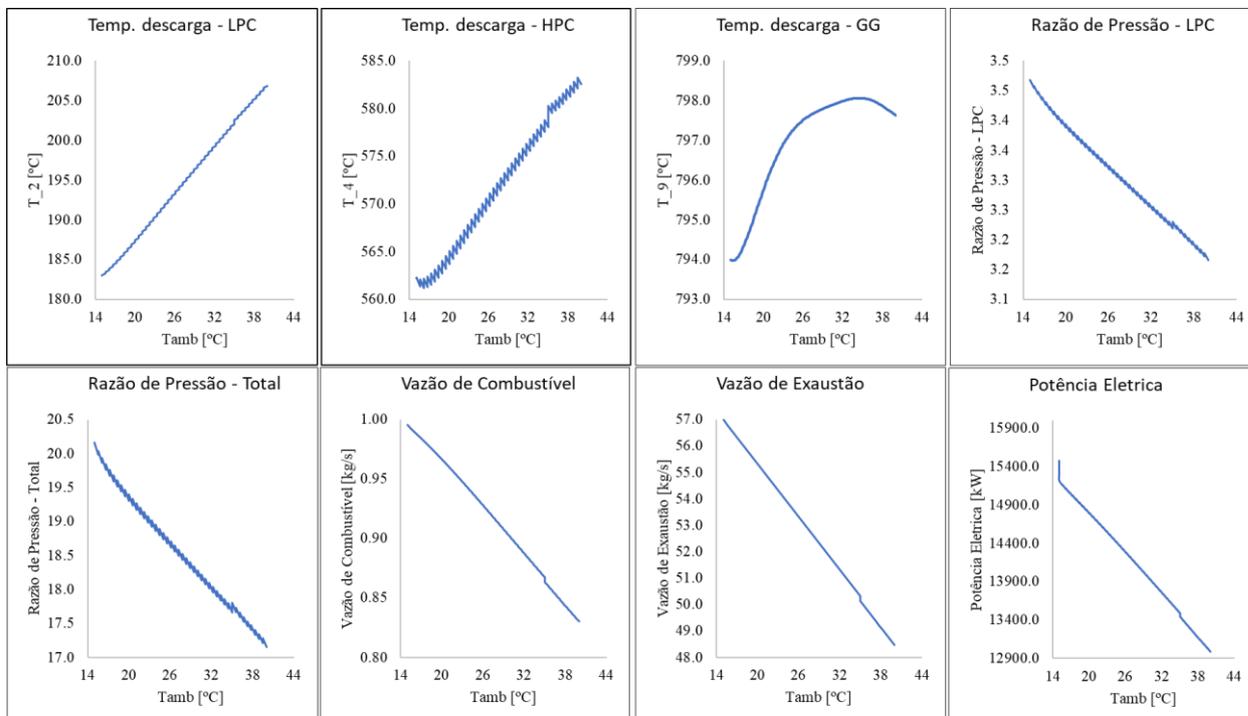


Figura A.2. Parâmetros de entrada da rede neural para a condição nominal e 50% de carga

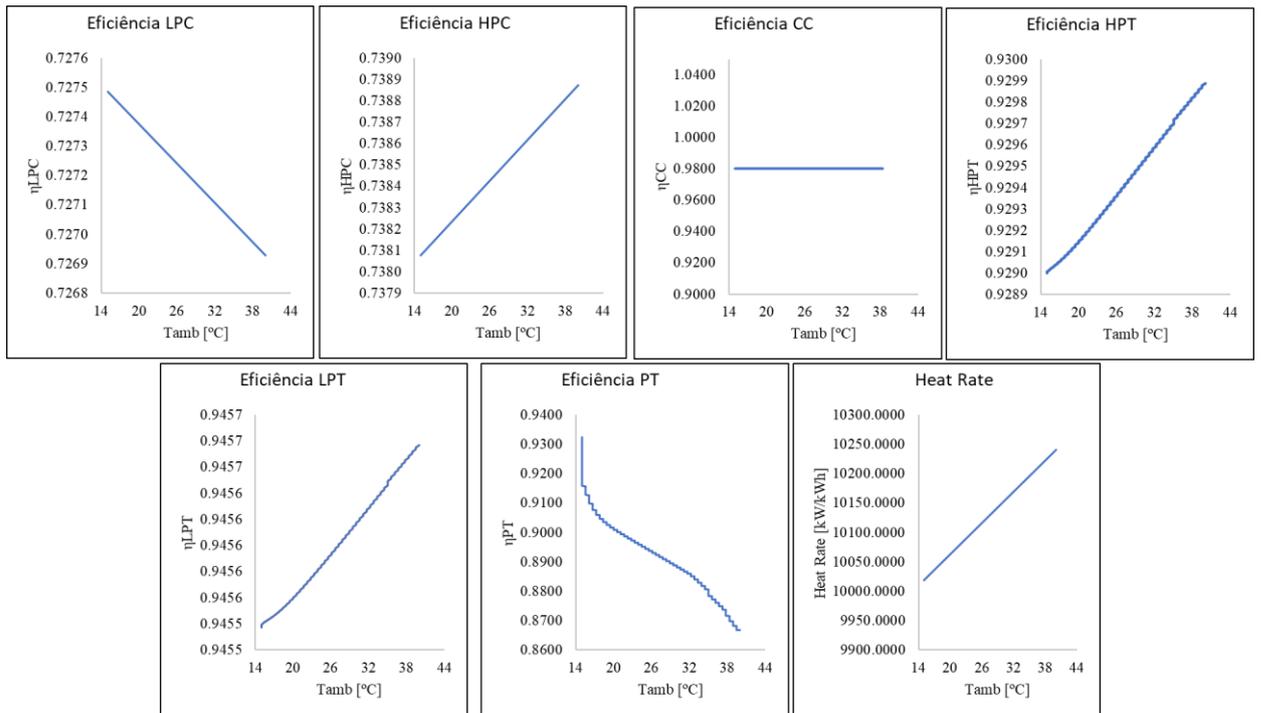


Figura A.3. Parâmetros de saída para a condição nominal e 75% de carga

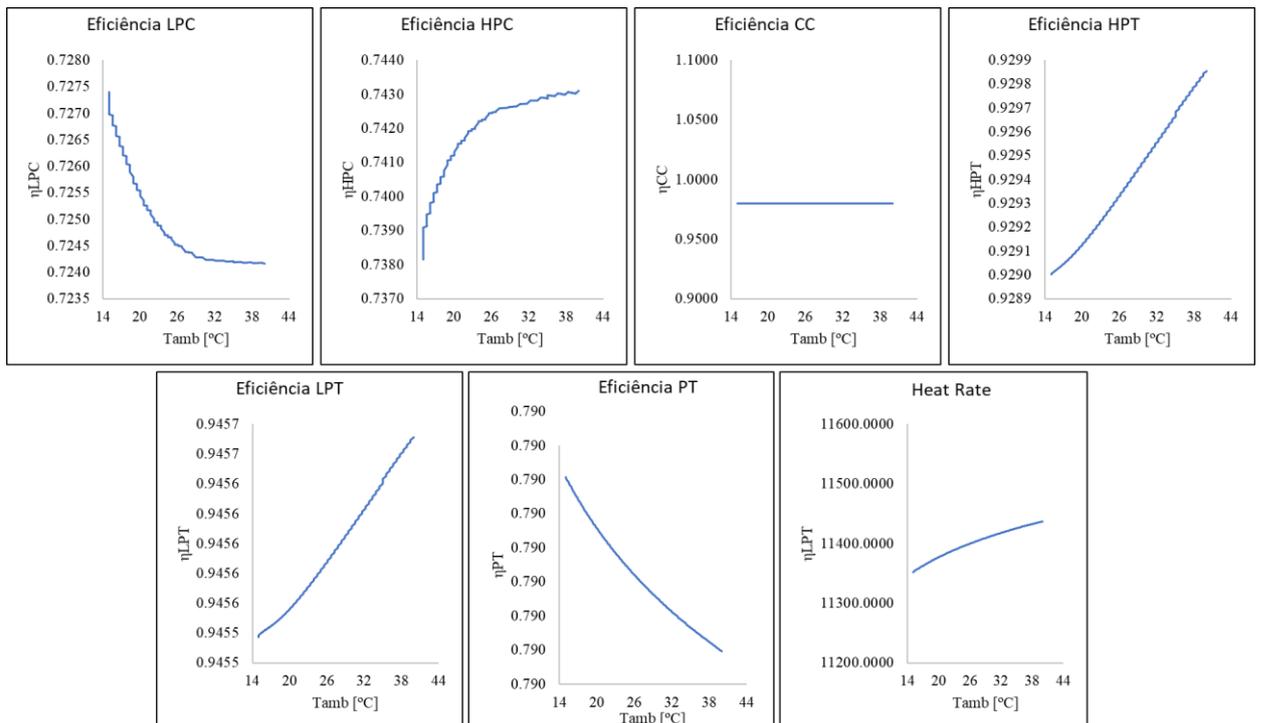


Figura A.4. Parâmetros de saída para a condição nominal e 50% de carga

## APÊNCIE B. REDE NEURAL PARA FALHAS ISOLADAS

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

clc % Limpa tela
clear all % Limpa memória
close all % Fecha todos programas

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%      SCRIPT SEPARA GRUPOS A SEREM UTILIZADOS NA REDE NEURAL
(SeparaGrupos)
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

%      ENTRADA DE DADOS E PRÉ-PROCESSAMENTO
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
MatrizA = dlmread('DadosTratados.csv',';'); % Leitura da Matriz A
(leitura de
% um arquivo .CSV)

NumeroPadroes = size(MatrizA,1); % Número de linhas da Matriz A
(número de
% "padrões")

IndiceAleatorio = randperm(NumeroPadroes); % Criou índices aleatórios
para
% a Matriz A (embaralhou os dados da Matriz A)

AAleatorio = MatrizA(IndiceAleatorio,:); % Matriz A aleatorizada
(dados
% embaralhados)
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%      ESTRATÉGIA DE TREINAMENTO, VALIDAÇÃO E TESTE
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
Setenta = round(NumeroPadroes*0.70); % Variável que estabelece 70% dos
padrões

Quinze = round(NumeroPadroes*0.15); % Variável que estabelece 15% dos
padrões

Treinamento = AAleatorio([1:Setenta],:); % Estabelece os dados a serem
% utilizados para o Treinamento

Validacao = AAleatorio([Setenta + 1 : Setenta + Quinze],:); %
Estabelece os
% dados a serem utilizados para a Validação

Teste = AAleatorio([Setenta + Quinze + 1 : end],:); % Estabelece os
dados a
% serem utilizados para o Teste
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%      CLASSIFICA OS DADOS DE TREINAMENTO, VALIDAÇÃO E TESTE
```

```

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
ClasseTreinamento = 2*Treinamento(:,[17:22]) - 1; % Estabelece a que
classe
% pertence os dados a serem utilizados para o Treinamento(coloca saída
% entre 1 e -1)

ClasseValidacao = 2*Validacao(:,[17:22]) - 1; % Estabelece a que
classe
% pertence os dados a serem utilizados para a Validação (coloca saída
entre
% 1 e -1)

ClasseTeste = 2*Teste(:,[17:22]) - 1; % Estabelece a que classe
% pertence os dados a serem utilizados para a Teste (coloca saída
entre
% 1 e -1)
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%
% DADOS DE TREINAMENTO, VALIDAÇÃO E TESTE
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

Treinamento = Treinamento(:,[1:16]); % Estabelece os dados a serem
% utilizados para o Treinamento

Validacao = Validacao(:,[1:16]); % Estabelece os dados a serem
utilizados
% para a Validação

Teste = Teste(:,[1:16]); % Estabelece os dados a serem utilizados para
% o Teste

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% NORMALIZAÇÃO DOS DADOS E PADRÕES DE TREINAMENTO, VALIDAÇÃO E
TESTE
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

MediaTreinamento = mean(Treinamento); % Cálculo da média dos dados de
% treinamento

DesvioTreinamento = std(Treinamento); % Cálculo do desvio padrão dos
dados de
% treinamento

TreinamentoNormalizado = Treinamento - repmat(MediaTreinamento, ...
size(Treinamento,1),1); % Padrões de Treinamento parcial

TreinamentoNormalizado = TreinamentoNormalizado./repmat ...
(DesvioTreinamento,size(Treinamento,1),1); % Padrões de treinamento

ValidacaoNormalizado = Validacao - repmat(MediaTreinamento, ...
size(Validacao,1),1); % Padrões de Validação parcial

ValidacaoNormalizado = ValidacaoNormalizado./repmat ...
(DesvioTreinamento,size(Validacao,1),1); % Padrões de Validação

```

```

TesteNormalizado = Teste - repmat(MediaTreinamento,size(Teste,1),1);
% Padrões de Teste parcial

TesteNormalizado = TesteNormalizado./repmat(DesvioTreinamento, ...
size(Teste,1),1); % Padrões de Teste

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%     REDE NEURAL DE REGRESSÃO
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

numEntradas      = 9;          % Numero de neuronios de entrada
numEscondidos    = 10;         % Numero de neuronios escondidos
numEscondidos2   = 5;
numSaidas        = 7;          % Numero de neuronios de saida

PR = minmax(TreinamentoNormalizado(:,[1:9]'));
REDE_LINEAR = newff(PR,[numEscondidos,numSaidas],{'tansig'
'purelin'},'trainlm','learngdm','mse');
% PR                                : indica os minimos e maximos do
conjunto de treinamento
% [numEscondidos numSaidas]         : indica a quantidade de neuronios
escondidos e de saida da rede
% {'tansig','purelin'}              : indica que os neuronios das camadas
escondida e de saida terao funcao de ativacao tansig e purelin
% 'trainlm','learngdm'              : indica que o treinamento vai ser
feito com gradiente descendente Levenberg-Marquardt (backpropagation)
% 'mse'                              : indica que o erro a ser utilizado
vai ser MSE (Media dos erros quadraticos)

% Hiperparametros do treinamento (para ajuda, digite 'help traingd')
REDE_LINEAR.trainParam.epochs      = 1000;      % Maximo numero de
iteracoes
REDE_LINEAR.trainParam.lr          = 0.001;     % Taxa de aprendizado
REDE_LINEAR.trainParam.goal        = 0.0;       % Criterio de minimo erro
de treinamento
REDE_LINEAR.trainParam.max_fail    = 6;         % Criterio de quantidade
maxima de falhas na validacao
REDE_LINEAR.trainParam.min_grad    = 0;         % Criterio de gradiente
minimo
REDE_LINEAR.trainParam.show        = 10;       % Iteracoes entre
exibicoes na tela (preenchendo com 'NaN', nao exibe na tela)
REDE_LINEAR.trainParam.time        = inf;       % Tempo maximo (em
segundos) para o treinamento

VV.P = ValidacaoNormalizado(:,[1:9]');%Padrões de validação
VV.T = ValidacaoNormalizado(:,[10:end]');%Saidas validação

REDE_LINEAR_TREINADA = train(REDE_LINEAR,
TreinamentoNormalizado(:,[1:9]'),' , TreinamentoNormalizado(:,[10:end]'),' ,
[], [], VV);

netoutput = sim(REDE_LINEAR_TREINADA,TesteNormalizado(:,[1:9]'));

SaidaSemNormalizacao =
(netoutput.*repmat(DesvioTreinamento(:,[10:end]'),' , 1,

```

```

size(netoutput,2)) + repmat(MediaTreinamento(:, [10:end]), 1,
size(netoutput,2));
TesteTargetSemNormalizacao = Teste(:, [10:end]);

Erro = ((SaidaSemNormalizacao -
TesteTargetSemNormalizacao)./TesteTargetSemNormalizacao)*100; %erro
percentual
%[TesteTargetSemNormalizacao(:,1) SaidaSemNormalizacao(:,1)]

MSE = (((SaidaSemNormalizacao -
TesteTargetSemNormalizacao).^2);

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%% REDE NEURAL DE CLASSIFICAÇÃO
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
numEntradas2 = 9; % Numero de neuronios de entrada
classEscondidos = 10; % Numero de neuronios escondidos
classEscondidos2 = 5;
numSaidas2 = 6; % Numero de neuronios de saida

PR2 = minmax(TreinamentoNormalizado(:, [1:9]));
REDE_CLASSIFICACAO = newff(PR2, [classEscondidos, numSaidas2], {'tansig'
'tansig'}, 'trainlm', 'learngdm', 'mse');
% PR : indica os minimos e maximos do
conjuto de treinamento
% [numEscondidos numSaidas] : indica a quantidade de neuronios
escondidos e de saida da rede
% {'tansig', 'purelin'} : indica que os neuronios das camadas
escondida e de saida terao funcao de ativacao tansig e purelin
% 'trainlm', 'learngdm' : indica que o treinamento vai ser
feito com gradiente descendente Levenberg-Marquardt (backpropagation)
% 'mse' : indica que o erro a ser utilizado
vai ser MSE (Media dos erros quadraticos)

VV2.P = ValidacaoNormalizado(:, [1:9]);
VV2.T = ClasseValidacao';

% Hiperparametros do treinamento (para ajuda, digite 'help traingd')
REDE_CLASSIFICACAO.trainParam.epochs = 1000; % Maximo numero de
iteracoes
REDE_CLASSIFICACAO.trainParam.lr = 0.001; % Taxa de
aprendizado
REDE_CLASSIFICACAO.trainParam.goal = 0.0; % Criterio de
minimo erro de treinamento
REDE_CLASSIFICACAO.trainParam.max_fail = 6; % Criterio de
quantidade maxima de falhas na validacao
REDE_CLASSIFICACAO.trainParam.min_grad = 0; % Criterio de
gradiente minimo
REDE_CLASSIFICACAO.trainParam.show = 10; % Iteracoes entre
exibicoes na tela (preenchendo com 'NaN', nao exhibe na tela)
REDE_CLASSIFICACAO.trainParam.time = inf; % Tempo maximo (em
segundos) para o treinamento

REDE_CLASSIFICACAO_TREINADA = train(REDE_CLASSIFICACAO,
TreinamentoNormalizado(:, [1:9]), ClasseTreinamento, [], [], VV2);
netoutputClassificacao =
sim(REDE_CLASSIFICACAO_TREINADA, TesteNormalizado(:, [1:9]));

```

```
ErroClassificacao = (round(netoutputClassificacao) -  
ClasseTeste')*100;  
MSEClassificacao = (((round(netoutputClassificacao) -  
ClasseTeste')./round(netoutputClassificacao)).^2)/NumeroPadroes;
```

```
Resposta = [SaidaSemNormalizacao' round(netoutputClassificacao)'];  
ConjuntoTeste = [TesteTargetSemNormalizacao' ClasseTeste];
```

## APÊNCIE C. REDE NEURAL PARA FALHAS COMBINADAS

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

clc % Limpa tela
clear all % Limpa memória
close all % Fecha todos programas

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%     SCRIPT SEPARA GRUPOS A SEREM UTILIZADOS NA REDE NEURAL
(SeparaGrupos)
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

%                               ENTRADA DE DADOS E PRÉ-PROCESSAMENTO
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
MatrizA = dlmread('FalhasCombinadas.csv',';'); % Leitura da Matriz A
(leitura de
% um arquivo .CSV)

NumeroPadroes = size(MatrizA,1); % Número de linhas da Matriz A
(número de
% "padrões")

IndiceAleatorio = randperm(NumeroPadroes); % Criou índices aleatórios
para
% a Matriz A (embaralhou os dados da Matriz A)

AAleatorio = MatrizA(IndiceAleatorio,:); % Matriz A aleatorizada
(dados
% embaralhados)
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%                               ESTRATÉGIA DE TREINAMENTO, VALIDAÇÃO E TESTE
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
Setenta = round(NumeroPadroes*0.70); % Variável que estabelece 70% dos
padrões

Quinze = round(NumeroPadroes*0.15); % Variável que estabelece 15% dos
padrões

Treinamento = AAleatorio([1:Setenta],:); % Estabelece os dados a serem
% utilizados para o Treinamento

Validacao = AAleatorio([Setenta + 1 : Setenta + Quinze],:); %
Estabelece os
% dados a serem utilizados para a Validação

Teste = AAleatorio([Setenta + Quinze + 1 : end],:); % Estabelece os
dados a
% serem utilizados para o Teste
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
```

```

%           CLASSIFICA OS DADOS DE TREINAMENTO, VALIDAÇÃO E TESTE
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
ClasseTreinamento = 2*Treinamento(:, [17:23]) - 1; % Estabelece a que
classe
% pertence os dados a serem utilizados para o Treinamento (coloca saída
% entre 1 e -1)

ClasseValidacao = 2*Validacao(:, [17:23]) - 1; % Estabelece a que
classe
% pertence os dados a serem utilizados para a Validação (coloca saída
entre
% 1 e -1)

ClasseTeste = 2*Teste(:, [17:23]) - 1; % Estabelece a que classe
% pertence os dados a serem utilizados para a Teste (coloca saída
entre
% 1 e -1)
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%           DADOS DE TREINAMENTO, VALIDAÇÃO E TESTE
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

Treinamento = Treinamento(:, [1:16]); % Estabelece os dados a serem
% utilizados para o Treinamento

Validacao = Validacao(:, [1:16]); % Estabelece os dados a serem
utilizados
% para a Validação

Teste = Teste(:, [1:16]); % Estabelece os dados a serem utilizados para
% o Teste

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%           NORMALIZAÇÃO DOS DADOS E PADRÕES DE TREINAMENTO, VALIDAÇÃO E
TESTE
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

MediaTreinamento = mean(Treinamento); % Cálculo da média dos dados de
% treinamento

DesvioTreinamento = std(Treinamento); % Cálculo do desvio padrão dos
dados de
% treinamento

TreinamentoNormalizado = Treinamento - repmat(MediaTreinamento, ...
size(Treinamento,1),1); % Padrões de Treinamento parcial

TreinamentoNormalizado = TreinamentoNormalizado./repmat ...
(DesvioTreinamento,size(Treinamento,1),1); % Padrões de treinamento

ValidacaoNormalizado = Validacao - repmat(MediaTreinamento, ...
size(Validacao,1),1); % Padrões de Validação parcial

ValidacaoNormalizado = ValidacaoNormalizado./repmat ...
(DesvioTreinamento,size(Validacao,1),1); % Padrões de Validação

```

```

TesteNormalizado = Teste - repmat(MediaTreinamento,size(Teste,1),1);
% Padrões de Teste parcial

TesteNormalizado = TesteNormalizado./repmat(DesvioTreinamento, ...
size(Teste,1),1); % Padrões de Teste

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%     REDE NEURAL DE REGRESSÃO
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

numEntradas    = 9;          % Numero de neuronios de entrada
numEscondidos  = 10;        % Numero de neuronios escondidos
numEscondidos2 = 5;
numSaidas      = 7;          % Numero de neuronios de saida

PR = minmax(TreinamentoNormalizado(:,[1:9]'));
REDE_LINEAR = newff(PR,[numEscondidos,numSaidas],{'tansig'
'purelin'},'trainlm','learngdm','mse');
% PR                                : indica os minimos e maximos do
conjuto de treinamento
% [numEscondidos numSaidas]         : indica a quantidade de neuronios
escondidos e de saida da rede
% {'tansig','purelin'}              : indica que os neuronios das camadas
escondida e de saida terao funcao de ativacao tansig e purelin
% 'trainlm','learngdm'              : indica que o treinamento vai ser
feito com gradiente descendente Levenberg-Marquardt (backpropagation)
% 'mse'                              : indica que o erro a ser utilizado
vai ser MSE (Media dos erros quadraticos)

% Hiperparametros do treinamento (para ajuda, digite 'help traingd')
REDE_LINEAR.trainParam.epochs    = 1000;      % Maximo numero de
iteracoes
REDE_LINEAR.trainParam.lr        = 0.001;     % Taxa de aprendizado
REDE_LINEAR.trainParam.goal      = 0.0;       % Criterio de minimo erro de
treinamento
REDE_LINEAR.trainParam.max_fail  = 6;         % Criterio de quantidade
maxima de falhas na validacao
REDE_LINEAR.trainParam.min_grad  = 0;         % Criterio de gradiente
minimo
REDE_LINEAR.trainParam.show      = 10;        % Iteracoes entre
exibicoes na tela (preenchendo com 'NaN', nao exhibe na tela)
REDE_LINEAR.trainParam.time      = inf;       % Tempo maximo (em
segundos) para o treinamento

VV.P = ValidacaoNormalizado(:,[1:9]');%Padrões de validação
VV.T = ValidacaoNormalizado(:,[10:end]');%Saidas validação

REDE_LINEAR_TREINADA = train(REDE_LINEAR,
TreinamentoNormalizado(:,[1:9]'),' TreinamentoNormalizado(:,[10:end]'),'
[], [], VV);

netoutput = sim(REDE_LINEAR_TREINADA,TesteNormalizado(:,[1:9]'));

SaidaSemNormalizacao =
(netoutput.*repmat(DesvioTreinamento(:,[10:end]'),' 1,

```

```

size(netoutput,2)) + repmat(MediaTreinamento(:,[10:end]), 1,
size(netoutput,2));
TesteTargetSemNormalizacao = Teste(:,[10:end]);

Erro = ((SaidaSemNormalizacao -
TesteTargetSemNormalizacao)./TesteTargetSemNormalizacao)*100; %erro
percentual
%[TesteTargetSemNormalizacao(:,1) SaidaSemNormalizacao(:,1)]

MSE = (((SaidaSemNormalizacao -
TesteTargetSemNormalizacao).^2);

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%% REDE NEURAL DE CLASSIFICAÇÃO
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
numEntradas2 = 9; % Numero de neuronios de entrada
classEscondidos = 10; % Numero de neuronios escondidos
classEscondidos2 = 5;
numSaidas2 = 7; % Numero de neuronios de saida

PR2 = minmax(TreinamentoNormalizado(:,[1:9]));
REDE_CLASSIFICACAO = newff(PR2,[classEscondidos,numSaidas2],{'tansig'
'tansig'},'trainlm','learngdm','mse');
% PR : indica os minimos e maximos do
conjuto de treinamento
% [numEscondidos numSaidas] : indica a quantidade de neuronios
escondidos e de saida da rede
% {'tansig','purelin'} : indica que os neuronios das camadas
escondida e de saida terao funcao de ativacao tansig e purelin
% 'trainlm','learngdm' : indica que o treinamento vai ser
feito com gradiente descendente Levenberg-Marquardt (backpropagation)
% 'mse' : indica que o erro a ser utilizado
vai ser MSE (Media dos erros quadraticos)

VV2.P = ValidacaoNormalizado(:,[1:9]);
VV2.T = ClasseValidacao';

% Hiperparametros do treinamento (para ajuda, digite 'help traingd')
REDE_CLASSIFICACAO.trainParam.epochs = 1000; % Maximo numero de
iteracoes
REDE_CLASSIFICACAO.trainParam.lr = 0.001; % Taxa de
aprendizado
REDE_CLASSIFICACAO.trainParam.goal = 0.0; % Criterio de minimo
erro de treinamento
REDE_CLASSIFICACAO.trainParam.max_fail = 6; % Criterio de
quantidade maxima de falhas na validacao
REDE_CLASSIFICACAO.trainParam.min_grad = 0.01; % Criterio de
gradiente minimo
REDE_CLASSIFICACAO.trainParam.show = 10; % Iteracoes entre
exibicoes na tela (preenchendo com 'NaN', nao exhibe na tela)
REDE_CLASSIFICACAO.trainParam.time = inf; % Tempo maximo (em
segundos) para o treinamento

REDE_CLASSIFICACAO_TREINADA = train(REDE_CLASSIFICACAO,
TreinamentoNormalizado(:,[1:9]), ClasseTreinamento, [], [], VV2);
netoutputClassificacao =
sim(REDE_CLASSIFICACAO_TREINADA,TesteNormalizado(:,[1:9]));

```

```
ErroClassificacao = (round(netoutputClassificacao) -  
ClasseTeste')*100;  
MSEClassificacao = (((round(netoutputClassificacao) -  
ClasseTeste')./round(netoutputClassificacao)).^2)/NumeroPadroes;
```

```
Resposta = [SaidaSemNormalizacao' round(netoutputClassificacao)'];  
ConjuntoTeste = [TesteTargetSemNormalizacao' ClasseTeste];
```