

5

RNA para Diagnóstico de Falhas em Turbinas a Gás

5.1.

Introdução

Neste capítulo, a aplicação de RNAs para diagnosticar as falhas no caminho do gás de turbinas a gás foi investigada. As redes neurais criadas receberam os dados gerados pelo modelo termodinâmico da turbina a gás industrial apresentado no Capítulo 4. Os resultados de validação e treinamento das redes neurais foram posteriormente apresentados e examinados.

5.2.

O Modelo de Diagnóstico

Uma única rede neural não é capaz de lidar com problemas tão complexos e de larga escala como o diagnóstico de falhas em turbinas a gás [1]. Desta forma a proposta deste trabalho é usar várias redes neurais para detectar, isolar e quantificar as falhas nos principais componentes do equipamento.

Dada uma turbina a gás industrial com um compressor e uma turbina, serão estudadas um total de 6 redes neurais. Na Figura 1 é apresentado um diagrama onde as redes estão ordenadas de acordo com o fluxo de dados de operação. As RNAs recebem os dados e os classificam, ou quantificam, de acordo com a funcionalidade de cada uma.

A primeira rede neural a ser estudada tem a função de classificar os dados de operação, detectando se o equipamento tem ou não falhas. Para uma turbina degradada, uma segunda rede neural pode ser utilizada. Esta RNA isola as falhas simples de componentes das falhas combinadas.

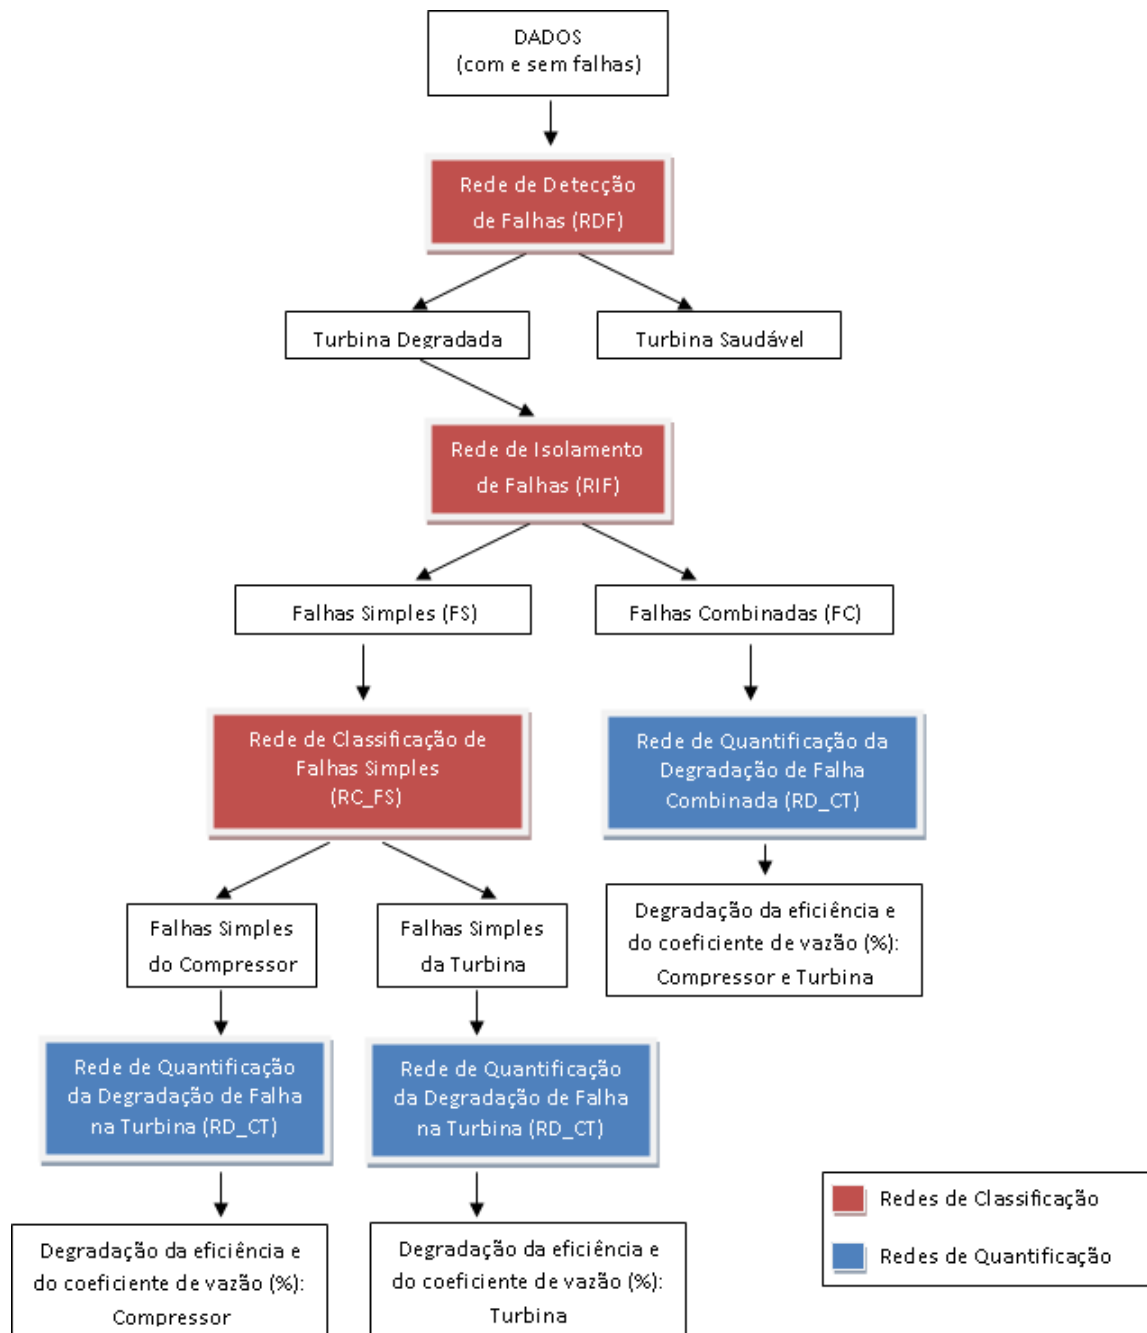


Figura 12 – Diagrama hierarquia das redes neurais estudadas.

Para identificar as falhas simples dos componentes é necessária uma nova rede neural para classificá-las como acúmulo de sujeira no compressor ou como erosão/corrosão da turbina.

No caso de falhas dos componentes, outras redes neurais são utilizadas para quantificar a magnitude da degradação. O mesmo ocorre com as falhas combinadas, uma vez que só existe uma única combinação

de falhas de componentes, não havendo necessidade de uma rede de classificação para este grupo de falhas. Assim, a última rede neural a ser estudada é também uma rede quantitativa.

5.3. O Projeto das Redes Neurais

Uma das mais importantes considerações na construção de uma RNA é como escolher sua configuração para um determinado assunto. A configuração da rede neural é determinada pelo número de camadas escondidas e pelo número de neurônios nessas camadas. Já o número de entradas e saídas da rede depende do tipo de problema em questão. Entretanto, não existe hoje uma solução teórica para otimizar esta configuração [9].

De modo geral, a configuração da rede neural é determinada principalmente pela complexidade do problema. Para o estudo de um novo problema, normalmente o projeto da rede neural começa com um tamanho pequeno e, posteriormente, a mesma vai aumentando, caso os resultados dos testes não forem satisfatórios.

Todas as redes neurais usadas neste estudo são do tipo MLP com algoritmo de retropropagação. A arquitetura de cada rede foi parcialmente determinada pelo tipo de função do diagnóstico (detectar, isolar ou quantificar). Alguns de seus parâmetros, como o número de camadas escondidas e o número de neurônios em cada uma destas camadas, foram variados até que fossem obtidos bons resultados.

O número de parâmetros de entrada escolhido é o mesmo para todas as redes. Sua escolha tem grande impacto no desempenho do diagnóstico. Neste estudo, seis parâmetros foram escolhidos de acordo com o indicado por [9] e [17], apontados como sendo os que melhor correlacionam as falhas à degradação do desempenho da turbina a gás (Tabela 4). Os valores das entradas serão os desvios destes parâmetros em relação aos seus valores no ponto de projeto.

Tabela 4 – Seleção de parâmetros de entrada das RNAs.

Parâmetros de Entrada das RNA	
1	Pressão de saída do compressor
2	Temperatura de saída do compressor
3	Vazão de combustível
4	Pressão de exaustão
5	Temperatura de exaustão
6	Potência útil da turbina

As funções de ativação usadas são a tangente hiperbólica (função sigmóide) para as camadas escondidas e função linear para a camada de saída, usando o método de treinamento de parada antecipada. A vantagem da utilização da parada antecipada é que a mesma provê um método efetivo de evitar o super treinamento e melhora a capacidade de generalização das redes.

O *software* utilizado para projetar as RNAs deste estudo foi o *Matlab* versão 7.1, que além de ser uma ferramenta computacional eficiente, também apresenta um *toolbox* totalmente voltado para redes neurais. Maiores detalhes desta ferramenta podem ser encontrados em [28].

Os conjuntos de dados apresentados a cada rede foram divididos em três grupos: um de treinamento, um de validação e outro de teste. Antes de serem apresentados à rede, os dados passaram por um pré-processamento sendo normalizados no intervalo $[-1,1]$, e posteriormente sendo desnormalizados. Para a normalização e desnormalização dos dados foram utilizadas duas rotinas disponíveis no próprio *Matlab* chamadas de *premnmx* e *postmnmx*, respectivamente.

5.4. Treinamento e Validação das Redes Neurais

5.4.1. Redes Neurais para Classificação de Falhas

A abordagem inicial de diagnóstico proposta é descobrir e isolar as falhas dos componentes antes de executar a quantificação das falhas. O

desempenho desta classificação é avaliado pela porcentagem das classificações efetuadas com sucesso, ou taxa de acerto, e também pelo erro médio quadrático (MSE).

A rede neural que detecta as falhas nos componentes, aqui chamada de RDF (Rede de Detecção de Falhas), é a primeira rede de classificação a ser estudada. Os exemplos de treinamento e validação incluem dados da turbina a gás operando normalmente, sem falhas, e quando a mesma está degradada, ou seja, com falhas. Existem duas classificações para os dados com falhas: falhas simples dos componentes (FS) ou falhas combinadas dos componentes (FC). A entrada desta rede neural são os desvios dos parâmetros escolhidos como apropriados para a finalidade do diagnóstico, como dito na seção 5.3, em relação aos seus valores no ponto de projeto. Esta rede possui um único neurônio em sua saída.

Como ilustrado na Tabela 5, o resultado da saída da RDF consiste em três classes com dois limites: 0,4 e 0,6. A saída é 1 se o valor do neurônio de saída é maior que 0,6, 0 se a saída é menor que 0,4 e, se o valor for entre 0,4 e 0,6, permanece o mesmo. O objetivo de usar esses limites, e não somente um com o valor de 0,5, é destacar o resultado da detecção quando a rede neural não consegue distinguir claramente os padrões de falha.

Tabela 5 – Os limites da RDF.

Faixa de Valores no Neurônio de Saída	Resultado da Rede RDF	Condição de Turbina a Gás
Acima de 0,6 até 1	1	Sem falha
0,4 até 0,6	0,4 até 0,6	Incerta
Abaixo de 0,4 até 0	0	Com falha

A arquitetura da rede neural irá influenciar de modo significativo o desempenho da rede. Mesmo uma única arquitetura pode obter diferentes resultados em dois treinamentos diferentes, porque, em razão de uma

convergência mais rápida, os pesos e *bias* são inicializados com valores aleatórios antes do treinamento.

Em virtude disto, várias arquiteturas de rede foram treinadas e examinadas, variando o número de camadas escondidas e o número de neurônio em cada camada. Além disso, foram feitas 10 inicializações de pesos diferentes. A Tabela 6 apresenta o melhor resultado obtido para a RDF. Utilizando um conjunto total de 5618 dados, esta rede pôde classificar corretamente 100% dos padrões apresentados na validação. No Apêndice A é possível ver o resultado de todas as configurações testadas para esta rede.

Tabela 6 – Melhor resultado do treinamento e da validação da RDF.

Desempenho da RDF	
Arquitetura	6-14-1
MSE de Treinamento	0,00019
Taxa de Acerto no Treinamento (%)	99,83
MSE de Validação	0,00003
Taxa de Acerto na Validação (%)	100,00
Épocas	2329

Após estudar o uso de redes neurais para detecção das falhas, a próxima etapa deste trabalho é discutir o uso de redes neurais para isolar as falhas. A seguir, serão apresentados dois tipos de redes com esta finalidade: a rede neural que isola as falhas simples das falhas combinadas, RIF (Rede de Isolamento de Falhas) e a rede neural que diferencia as falhas dos componentes, RC_FS (Rede de Classificação de Falhas Simples). Como neste estudo só existe uma combinação de falhas, não houve necessidade de criar uma rede neural classificatória para falhas combinadas. De modo similar à RDF, estas redes neurais foram treinadas com diferentes arquiteturas para que um melhor resultado pudesse ser obtido. No Apêndice A, encontra-se um resumo do desempenho para todas estas redes de classificação.

A RIF possui dois neurônios na saída que correspondem a dois tipos de falha de componente no caminho do gás, que são FS e FC. O treinamento e a validação destas redes incluem apenas dados da turbina a gás degradada (4818 dados). O desempenho para esta rede é apresentado na Tabela 12, no Apêndice A. O melhor resultado foi obtido pela arquitetura 6-12-2, entre todas as tentativas, com uma taxa de acerto de 99,96%.

A RC_FS também possui dois neurônios na saída, um para cada componente. Seu treinamento só utilizou dados com falhas simples dos componentes (722 dados). A Tabela 11 do Apêndice A mostra o resultado do treinamento e da validação para todas as arquiteturas testadas. Todas as redes apresentaram 100% de taxa de acerto, mas a rede com arquitetura igual a 6-6-2 foi a que apresentou o menor erro de validação.

Para o modelo de turbina a gás estudado, a Tabela 7 apresenta um resumo do desempenho das três redes de classificação estudadas. Todas apresentaram bons resultados com uma taxa de acerto acima de 99%.

Tabela 7 – Desempenho das RNA de classificação.

RNA	Tipos de Dados	Taxa de Acerto na Validação (%)
RDF	Com falha e sem falha	100,00
RIF	Falhas simples e combinadas	99,96
RC_FS	Falhas do compressor e da turbina	100,00

Em todas as três redes de classificação apresentadas, a que obteve o pior resultado na validação foi a RIF. A razão para este desempenho pode ser explicada pelo fato dos dados utilizados pela rede incluírem todas as condições de falha: falhas simples e falhas combinadas. As falhas combinadas podem ter uma assinatura muito próxima das falhas simples, se a degradação de um dos componentes for muito baixa.

5.4.2. Redes Neurais para Quantificação de Falhas

A segunda etapa deste trabalho apresenta o estudo de redes neurais para quantificar a degradação da turbina a gás devido às falhas nos componentes. Neste estudo, três redes de quantificação foram avaliadas: uma para cada tipo de falha. Cada rede em particular foi projetada com o intuito de tratar uma determinada condição de falha. A rede para quantificar o acúmulo de sujeira no compressor, por exemplo, é treinada e utilizada apenas para esse fim.

As entradas destas redes de classificação são os desvios das medições dos parâmetros escolhidos em relação ao ponto de projeto, enquanto as saídas são o nível de degradação dos componentes em termos da mudança na capacidade de vazão e na eficiência isentrópica. O desempenho das redes é avaliado através do erro médio quadrático (MSE) além de parâmetros estatísticos como média e desvio padrão.

A primeira rede a ser estudada é a rede que quantifica a degradação de desempenho do compressor devido ao acúmulo de sujeira (RDC), com um conjunto de 722 dados. Novamente, redes com diferentes números de camadas escondidas e neurônios foram avaliadas. A Tabela 8 apresenta o melhor resultado obtido no treinamento e validação da RDC.

Neste estudo, o desvio padrão do vetor de erro é calculado para avaliar a distribuição dos erros de previsão, ou seja, a diferença entre os valores desejados e os valores de saída da rede. Grandes valores de desvio padrão do erro significam que a capacidade da rede de estimar corretamente os valores de degradação do componente é baixa. Por outro lado, valores pequenos de desvio padrão indicam um melhor desempenho da rede neural.

A rede que apresentou melhor desempenho foi a de arquitetura 6-8-2, na qual as estimativas do coeficiente de vazão e da eficiência isentrópica tiveram valores pequenos do desvio padrão do erro de

previsão. No Apêndice A podem ser vistos os resultados do desempenho de todas as redes neurais testadas para esta rede, na Tabela 14.

Tabela 8 – Melhor resultado do treinamento e da validação da RDC.

Desempenho da RDC	
Arquitetura	6-8-2
MSE de Treinamento	0,0039
Média - Eficiência Isentrópica - Trein.	0,1976
Média - Coeficiente de Vazão - Trein.	0,0693
Desvio Padrão - Eficiência Isentrópica - Trein.	0,2389
Desvio Padrão - Coeficiente de Vazão - Trein.	0,1005
MSE de Validação	0,0209
Média - Eficiência Isentrópica - Val.	0,1704
Média - Coeficiente de Vazão - Val.	0,0471
Desvio Padrão - Eficiência Isentrópica - Val.	0,1195
Desvio Padrão - Coeficiente de Vazão - Val.	0,0861
Épocas	3387

As redes de quantificação da degradação da turbina (RDT) e da degradação concomitante do compressor e turbina (RD_CT) tiveram tratamento similar à rede RDC, com um conjunto de 722 e 4096 dados, respectivamente. Para a RDT, a arquitetura que obteve o melhor desempenho, isto é, menor desvio padrão do erro de previsão, foi a 6-20-2. A arquitetura 6-16-12-4 foi escolhida para a RD_CT. Também no Apêndice A podem ser vistas as comparações de todas as arquiteturas estudadas para a RDT e RD_CT, na Tabela 15 e na Tabela 16, respectivamente.

Através dos resultados do treinamento das redes pôde-se observar que as mesmas são capazes de reproduzir, de modo satisfatório, o nível de degradação dos componentes devido às falhas.

5.5. Teste das Redes Neurais

De cada conjunto de dados apresentado a uma determinada rede, 15% ficou reservado para teste, ou seja, as redes não usaram esses dados nem em seu treinamento e nem em sua validação. A Tabela 9 apresenta o resultado dos testes nas redes selecionadas com melhor arquitetura.

Tabela 9 – Resultado dos testes para cada tipo de função de RNA estudado.

		RDF	RIF	RC_FS	RDC	RDT	RD_CT
MSE		0,00011	0,00090	0,00001	0,00040	0,00020	0,00300
Taxa de Acerto (%)		100,00	100,00	100,00	--	--	--
Compressor	Média - Eficiência	--	--	--	0,1038	--	0,0254
	Média - Coef. de Vazão	--	--	--	0,0278	--	0,0417
	Des. Padrão - Eficiência	--	--	--	0,0624	--	0,0825
	Des. Padrão - Coef. de Vazão	--	--	--	0,0319	--	0,751
Turbina	Média - Eficiência	--	--	--	--	0,0568	0,0015
	Média - Coef. de Vazão	--	--	--	--	0,0312	0,0043
	Des. Padrão - Eficiência	--	--	--	--	0,0461	0,0902
	Des. Padrão - Coef. de Vazão	--	--	--	--	0,0719	0,0661

Como pode ser observado, todas as redes de classificação obtiveram taxa de acerto de 100%, ou seja, todos os padrões de falha apresentados foram classificados corretamente. No caso das redes de quantificação, foram obtidos baixos valores de desvio padrão, indicando que as redes são capazes de quantificar corretamente a degradação sofrida pelos equipamentos da turbina a gás.

5.6. Discussão dos Resultados

Neste capítulo foram apresentadas diferentes configurações de redes neurais artificiais para serem empregadas no diagnóstico de falhas de turbinas a gás. As redes desenvolvidas utilizaram padrões de falhas gerados a partir de um modelo termodinâmico de uma turbina a gás industrial típica. Estes padrões serviram como fonte de dados para

treinamento e validação de diferentes arquiteturas de redes neurais. A seguir, serão discutidos os resultados oriundos do estudo realizado.

Neste trabalho dois tipos de RNA foram estudados: as redes de classificação e as redes de quantificação. As redes de classificação desempenham papéis importantes numa análise de diagnóstico. Além de distinguir dados da turbina a gás degradada da saudável, elas também são capazes de isolar os tipos de falha de cada componente.

As RNAs utilizadas para classificação tiveram seu desempenho avaliado em função da taxa de acerto, ou seja, razão do número de acertos classificados corretamente pelo número total de padrões apresentados. Como pode ser visto na Figura 13, todas as redes de classificação obtiveram uma taxa de acerto superior a 99%.

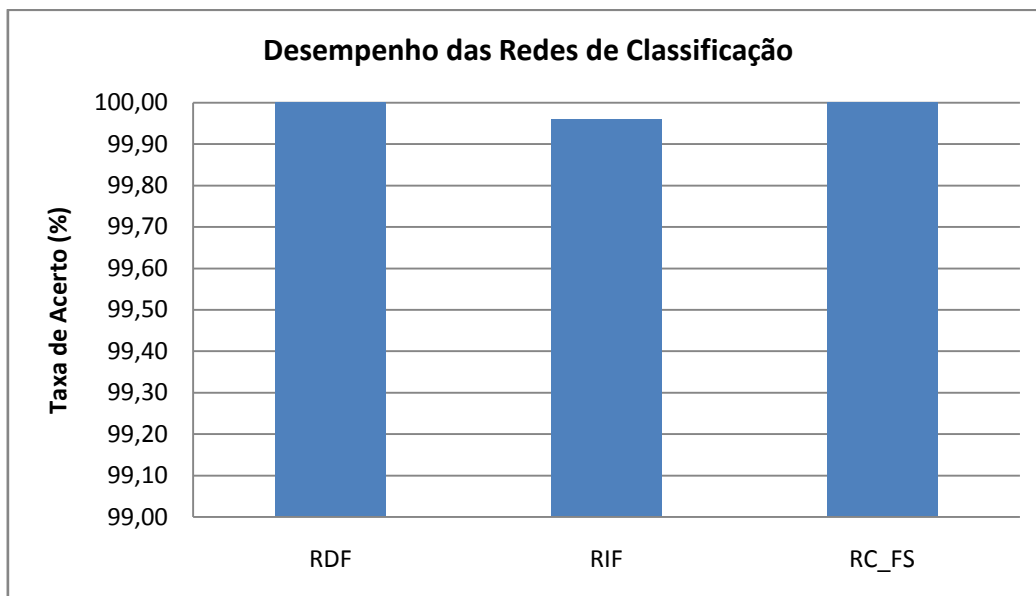


Figura 13 – Desempenho das redes de classificação em função da taxa de acerto.

O resultado inferior da RIF em relação às demais redes é devido à similaridade dos dados de entrada, uma vez que, para falhas combinadas, um dos componentes pode ter um grau de degradação muito baixo em comparação ao segundo componente, fazendo que a rede confunda os dados de falhas combinadas com os dados de falhas simples.

Três redes de quantificação foram apresentadas neste estudo, uma para cada tipo de falha: acúmulo de sujeira no compressor, erosão/corrosão da turbina e a combinação destas duas falhas. As redes estimam a degradação dos componentes através da eficiência isentrópica e do coeficiente de vazão. A previsão do diagnóstico é representada pelo desvio padrão do erro de previsão, calculado com os dados de validação. Baixos valores de desvio padrão indicam que a rede é capaz de prever de forma mais precisa o nível de degradação dos componentes.

A Figura 14 apresenta o desvio padrão do erro de previsão para todas as redes de quantificação estudadas. Pode-se observar que a precisão na quantificação da degradação é melhor para as redes que tratam somente de falhas simples dos componentes do que para a RD_CT, que trata da falha combinada do compressor e da turbina. Este comportamento pode ser explicado pelo fato do desempenho das RNAs dependerem principalmente da complexidade do problema. O número de parâmetros de saída da RD_CT é duas vezes maior que o número de saídas da RDC e da RDT. Assim os resultados da RD_CT podem ser menos precisos do que o esperado.




Figura 14 – Desempenho das redes de quantificação em função do desvio padrão do erro.

A degradação da turbina a gás resulta em mudanças nos parâmetros de desempenho. As assinaturas de diferentes tipos de falhas e vários níveis de severidade são apresentadas na forma de desvios dos parâmetros medidos em relação a um valor de referência, detectáveis através do diagnóstico de falhas do caminho do gás.

Observando estas assinaturas, uma falha específica pode ser detectada e isolada. Porém, as assinaturas para diferentes tipos de falhas podem, às vezes, ser muito similares, e combinadas com os efeitos de ruídos nas leituras de parâmetros, acabam não podendo ser distinguidas pela técnica de diagnóstico em questão.

Assinaturas de falhas similares podem ser encontradas tanto em falhas simples de componentes como em falhas combinadas. Como apresentado na Figura 15 e na Figura 16, a comparação entre uma assinatura de falha da RDC e outra da RD_CT mostram desvios de parâmetros muito parecidos.

As medidas destes desvios têm os mesmos sinais e magnitudes muito similares. Assim, não há como evitar a existência de assinaturas de falhas similares entre vários dados do modelo de falha, e isto pode acabar afetando a qualidade do resultado do diagnóstico. A Tabela 10 traz a legenda dos parâmetros apresentados na Figura 15 e na Figura 16.

Tabela 10 – Lista de símbolos dos parâmetros apresentados nas Figuras 16 e 17.

Símbolos	Parâmetros
P3	Pressão de saída do compressor
T3	Temperatura de saída do compressor
wf	Vazão de combustível
P8	Pressão de exaustão
T8	Temperatura de exaustão
wf	Potência útil da turbina

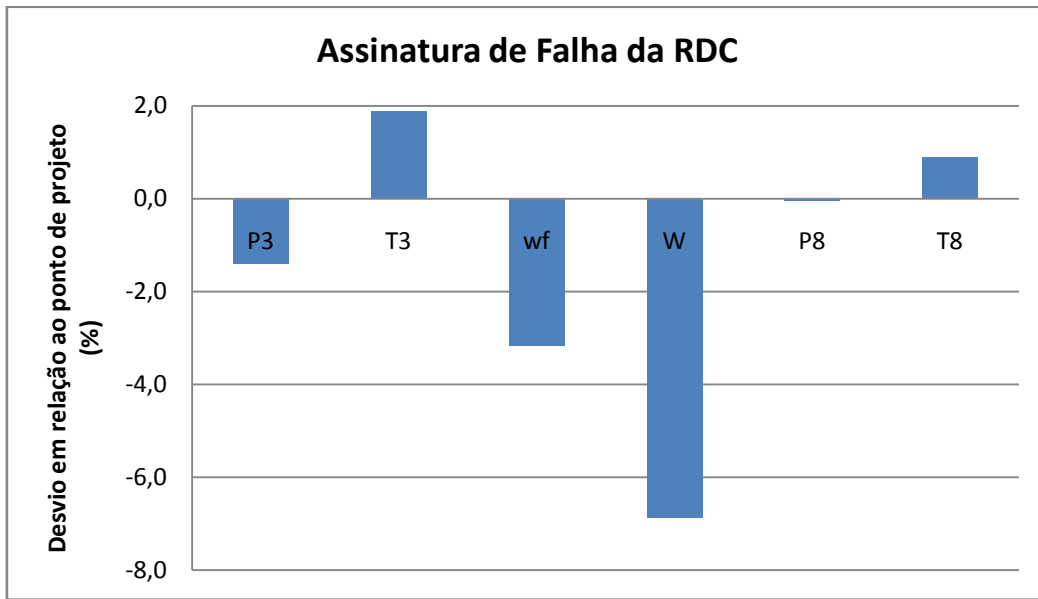


Figura 15 – Assinatura de falha do compressor (2% de queda na eficiência isentrópica e 4% de queda no coeficiente de vazão).




Figura 16 – Assinatura de falha combinada do compressor e da turbina (2% de queda na eficiência isentrópica do compressor, 4% de queda no coeficiente de vazão do compressor, 0,5% de queda na eficiência isentrópica da turbina e 0,5% de queda no coeficiente de vazão da turbina).

Nos testes realizados após o treinamento e validação das redes neurais estudadas, com 15% do conjunto total de dados, ficou ainda mais evidente o bom desempenho das redes neurais estudadas, corroborando os resultados de treinamento e validação.